

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**UM MODELO PARA DESCRIÇÃO E PREVISÃO DA DEMANDA
DOS CONSUMIDORES INDUSTRIAIS
DE ENERGIA ELÉTRICA**

Tese submetida à
Universidade Federal de Santa Catarina
como parte dos requisitos para a
obtenção do grau de Doutor em Engenharia Elétrica

FABIANO FERREIRA ANDRADE

Florianópolis, Junho de 2009.

UM MODELO PARA DESCRIÇÃO E PREVISÃO DA DEMANDA DOS CONSUMIDORES INDUSTRIAIS DE ENERGIA ELÉTRICA

Fabiano Ferreira Andrade

‘Esta Tese foi julgada adequada para obtenção do Título de Doutor em Engenharia Elétrica, Área de Concentração em *Planejamento de Sistemas de Energia Elétrica*, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina’

Prof. C. Celso de Brasil Camargo, D. Eng.
Orientador

Prof. Roberto de Souza Salgado Ph.D.
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica

Banca Examinadora:

Prof. Alexandre P. Alves da Silva, PhD.

Prof. Raimundo C. G. Teive, D. Eng.
Co-Orientador

Dilcemar de Paiva Mendes, Dr. Eng.

Prof. Fernando Seabra, Dr.

Fabiola Sena Vieira, Dra. Eng.

Prof. Rubiara Cavalcante Fernandes, Dr. Eng.

*Dedico este trabalho
à benção divina da união
da minha família
após 27 anos.*

AGRADECIMENTOS

Antes de tudo, agradeço a Deus e à Nossa Sra. da Medalha Milagrosa pela fé e perseverança em cada passo do caminho escolhido.

Aos meus orientadores Celso e Raimundo, pelas doses elevadas de paciência, compreensão e incentivo que dispensaram a mim nesta longa jornada. Talvez eu não me depare mais com outro desafio tão grande pela frente, mas se um dia isso ocorrer, gostaria muito de ter a sorte de encontrar companheiros como vocês.

Aos professores e profissionais cujas participações nas bancas examinadoras contribuíram decisivamente para o desenvolvimento deste trabalho. À Dra. Fabíola, incentivadora desta tese antes mesmo da qualificação e que se tornou uma grande referência ao longo do trabalho. Obrigado ao Prof. Piara, por seus apontamentos precisos e detalhados no texto. O ponto de vista econômico propiciado pelo Prof. Seabra trouxe à luz do conhecimento produtos importantes da tese. Agradeço também ao Dr. Dilcemar por propiciar um melhor entendimento da aplicabilidade desta tese no dia a dia do setor elétrico brasileiro. De forma especial, agradeço a atenção e cuidado dedicados pelo Prof. Alexandre desde a qualificação, passando pela relatoria até as observações na banca final. Seu conhecimento e contribuições engrandeceram sobremaneira o conteúdo deste trabalho.

Às pessoas gentis que se tornaram facilitadoras durante toda execução deste trabalho. Em especial, ao engenheiro José Nazareno da CELESC, à Vera Lúcia da EPAGRI, à Maria Helena do INMET, ao Reinaldo Haas do LEPTEN, à Ana Lúcia e ao Rafael da FIESC, e em especial aos gestores das indústrias catarinenses visitadas durante a pesquisa de campo em abril de 2007.

Ao Laboratório de Planejamento de Sistemas de Energia Elétrica da UFSC e seus integrantes pelo convívio e apoio ao longo dos últimos anos.

À Universidade Federal de Santa Catarina pelo apoio institucional, ao Programa de Pós Graduação em Engenharia Elétrica pelo apoio técnico, ao CNPq e à CAPES pelo apoio financeiro.

A melhor avó do mundo, Edna, cuja despreziosa tabuada semeou meu futuro.

À minha avó Cemília *in memoriam*.

Aos avôs Wolcey e Sebastião, pelos exemplos de garra, sabedoria e hombridade.

Aos meus pais, Catarino e Dona Lili, por acreditarem e me manterem acreditando que tudo isso um dia seria possível.

Aos meus irmãos, Greycinha, Fabrício e Gis, que apesar da distância, foram sempre um porto seguro de apoio, incentivo e carinho.

Aos meus sobrinhos, Rafa, Dudu, Leleo e Luquinha, que deram a percepção exata de quão longa é uma tese.

Aos meus “segundos pais”, Dona Têre e Seu Môa, por estarem sempre juntos nos bons e maus momentos refletindo grandes exemplos de vida.

Finalmente, agradeço à princesa da minha vida, à guerreira das minhas batalhas, à futura mãe da Isa e do Pêpa. Sem você, Nêssa... Esta conquista jamais existiria!

Resumo da Tese apresentada à UFSC como parte dos requisitos necessários para a obtenção do grau de Doutor em Engenharia Elétrica.

UM MODELO PARA DESCRIÇÃO E PREVISÃO DA DEMANDA DOS CONSUMIDORES INDUSTRIAIS DE ENERGIA ELÉTRICA

Fabiano Ferreira Andrade

Junho/2009

Orientador: C. Celso de Brasil Camargo, Dr. Eng.

Área de Concentração: Planejamento de Sistemas de Energia Elétrica.

Palavras-chave: previsão de demanda, mercados competitivos, mineração de dados, econometria, redes neurais artificiais, regularização bayesiana, economia, clima, indústria.

Número de Páginas: 252.

RESUMO: A estreita relação existente entre oferta e demanda é um dos temas centrais do planejamento e da operação dos sistemas de energia elétrica. O desconhecimento sobre o comportamento do consumidor pode ter consequências graves ao equilíbrio entre a oferta e a demanda. A dinâmica de mercados competitivos de energia elétrica envolvendo grandes consumidores industriais exige um alto nível de conhecimento sobre a evolução da demanda. Neste trabalho apresenta-se um novo modelo para descrever e prever a demanda dos consumidores industriais de energia elétrica, de forma desagregada. Por meio de um modelo descritivo da demanda é possível quantificar a influência de fatores econômicos e/ou climáticos característicos de um segmento da indústria. A partir desse conhecimento, o trabalho apresenta um modelo de preditivo, baseado em redes neurais artificiais, para estimar o consumo nos meses seguintes. O diferencial deste trabalho está na aplicação de técnicas de mineração de dados como suporte à integração do modelo econométrico de descrição com o modelo neural de previsão. Para validação da metodologia proposta foram utilizados dados mensais de consumo das indústrias têxtil e metalúrgicas de Santa Catarina, fornecidos pelas Centrais Elétricas de Santa Catarina – CELESC S.A. Os resultados da pesquisa podem contribuir para o planejamento da produção e comercialização da energia elétrica, principalmente em mercados competitivos, gerando maior comprometimento nas relações de comercialização da energia elétrica.

Abstract of Thesis presented to UFSC as a partial fulfillment of the requirements for the degree of Doctor in Electrical Engineering.

A MODEL FOR DESCRIPTION AND FORECAST OF INDUSTRIAL ELECTRICITY DEMAND

Fabiano Ferreira Andrade

Junho/2009

Advisor: C. Celso de Brasil Camargo, Dr. Eng.

Area of Concentration: Electrical Energy Systems Planning.

Keywords: Load forecasting, disaggregated demand, power system planning, neural network applications, bayes procedures, datamining, economics, weather.

Number of Pages: 252.

ABSTRACT: The narrow relationship between demand and supply is of paramount importance for planning and operation of electrical power systems. The lack of knowledge about consumer's behavior may lead to serious problems to the balance between supply and demand. The dynamic of competitive markets related to great industrial consumers needs a high level of knowledge about the market evolution. Then, this work presents a new model to describe and foresee the separated demand of great industrial consumers of electrical energy. It is possible to include the economic and climatic factors, which are characteristics of some industrial sector, by using an appropriated modeling technique. Afterwards, it is developed a predictive model based on neural networks to estimate the demand up to 12 months ahead. The main contribution of this thesis is in the application of data mining procedures as an aid to integrate the econometric model of description with the neural network model of demand forecasting. To validate these models real data were used from CELESC, a south brazilian power utility, referring to textile and metallurgical Industrial sectors. The results of this research have demonstrated that the proposed model is a promising computational tool to improve the understanding of the electrical energy production business.

Sumário

CAPÍTULO 1 APRESENTAÇÃO.....	1
1.1 INTRODUÇÃO	1
1.2 CONTEXTUALIZAÇÃO DO PROBLEMA.....	2
1.3 MOTIVAÇÕES	4
1.4 OBJETIVO GERAL.....	7
1.5 OBJETIVOS ESPECÍFICOS	7
1.6 ORGANIZAÇÃO DO TRABALHO.....	7
CAPÍTULO 2 REVISÃO DA LITERATURA	9
2.1 INTRODUÇÃO	9
2.2 DEMANDA DESAGREGADA.....	11
2.3 DESCRIÇÃO DA DEMANDA	14
2.3.1 Métodos Tradicionais de Descrição da Demanda	14
2.3.2 A Descrição da Demanda Desagregada.....	22
2.3.3 Descrição da Demanda no Contexto do KDD.....	26
2.4 PREVISÃO DA DEMANDA.....	31
2.4.1 Projeção de Demanda X Previsão de Demanda	32
2.4.2 Métodos Tradicionais de Previsão de Demanda.....	37
2.4.3 Previsão da Demanda no Contexto do KDD.....	41
2.5 RESUMO DO CAPÍTULO	49
CAPÍTULO 3 METODOLOGIA	51
3.1 INTRODUÇÃO	51
3.2 MINERAÇÃO DE DADOS	53
3.2.1 As Etapas do Processo de KDD.....	54
3.2.2 Dinâmica do KDD.....	55
3.2.3 Tarefas e Técnicas de KDD.....	56
3.2.4 Etapas para Constituição da Base de Dados.....	57
3.3 MÉTODOS ECONÔMICOS PARA DESCREVER A DEMANDA	59
3.3.1 Etapas da Modelagem Econômic Clássica.....	60
3.3.2 Seleção das Melhores Variáveis	61

3.3.3	<i>Definição do Modelo Estatístico</i>	67
3.3.4	<i>Estimação dos Parâmetros do Modelo</i>	69
3.3.5	<i>Testes de Hipóteses</i>	70
3.3.6	<i>Avaliação de Desempenho do Modelo Econométrico</i>	76
3.4	REDES NEURAIS ARTIFICIAIS PARA PREVER A DEMANDA	78
3.4.1	<i>Redes Neurais Artificiais – Introdução Teórica</i>	79
3.4.2	<i>Previsor Neural da Demanda utilizando Redes MLP</i>	83
3.4.3	<i>Previsor Neural da Demanda utilizando Redes RBF</i>	89
3.5	RESUMO DO CAPÍTULO	92
CAPÍTULO 4 FORMAÇÃO DA BASE DE DADOS		93
4.1	INTRODUÇÃO	93
4.2	O CONSUMO DE ENERGIA ELÉTRICA NAS INDÚSTRIAS DE SANTA CATARINA	95
4.2.1	<i>Pré-processamento da BDP1</i>	96
4.3	LEVANTAMENTO DE VARIÁVEIS ECONÔMICAS DETERMINANTES PARA A INDÚSTRIA CATARINENSE	100
4.3.1	<i>Sondagem sobre a Dinâmica da Indústria Têxtil Catarinense</i>	102
4.3.2	<i>Sondagem sobre a Dinâmica da Indústria Metalúrgica Catarinense</i>	106
4.3.3	<i>Seleção e Pré-Processamento das Variáveis Econômicas para a BDP2</i>	109
4.4	LEVANTAMENTO DE VARIÁVEIS CLIMÁTICAS DE INTERESSE PARA A INDÚSTRIA CATARINENSE	111
4.4.1	<i>Seleção das Variáveis Climáticas para a BDP3</i>	112
4.4.2	<i>Pré-Processamento das Variáveis Climáticas para a BDP3</i>	114
4.4.3	<i>Construção de Indicadores Climáticos Regionais</i>	116
4.5	RESUMO DO CAPÍTULO	122
CAPÍTULO 5 DESCRIÇÃO DA DEMANDA		123
5.1	INTRODUÇÃO	123
5.2	PRÉ-SELEÇÃO DAS MELHORES VARIÁVEIS	124
5.2.1	<i>Transformações Pró-Estacionárias</i>	125
5.2.2	<i>Comportamento Esperado</i>	127
5.2.3	<i>Testes de Estacionariedade</i>	129
5.2.4	<i>Correlações Lineares</i>	131
5.2.5	<i>Regressores Selecionados</i>	136
5.3	APRIMORAMENTO DOS MODELOS ECONÔMICOS	137
5.3.1	<i>Descrição do Consumo de Energia Elétrica –Têxtil</i>	139
5.3.2	<i>Descrição da Tendência do Consumo de Energia Elétrica - Têxtil</i>	142
5.3.3	<i>Descrição do Consumo de Energia Elétrica - Metalúrgico</i>	145
5.3.4	<i>Descrição da Tendência do Consumo de Energia Elétrica- Metalúrgico</i>	147
5.4	RESUMO DO CAPÍTULO	150

CAPÍTULO 6 PREVISÃO DA DEMANDA.....	151
6.1 INTRODUÇÃO	151
6.2 PREVISÃO DO CONSUMO MENSAL DE ENERGIA ELÉTRICA.....	152
6.2.1 Resultados para o Segmento Têxtil	157
6.2.2 Resultados para o Segmento Metalúrgico.....	162
6.3 PREVISÃO DA FAIXA DE CONSUMO DE ENERGIA ELÉTRICA	166
6.3.1 Resultados para o Segmento Têxtil (por faixa)	169
6.3.2 Resultados para o Segmento Metalúrgico (por faixa).....	172
6.4 CONSIDERAÇÕES FINAIS	175
CAPÍTULO 7 CONCLUSÕES	177
ANEXO A – Tabela da Distribuição t de Student.....	183
ANEXO B – Tabelas da Distribuição F.....	185
ANEXO C – Base de Dados Primária 1.....	189
ANEXO D – Base de Dados Primária 2.....	193
ANEXO E – Base de Dados Primária 3.....	209
ANEXO F – Processo de Pré-Seleção e Análise das Variáveis Explicativas.....	229
ANEXO G – Exemplo de Saída do Programa para Descrição da Demanda.....	237
REFERÊNCIAS BIBLIOGRÁFICAS	241

Lista de Tabelas

Tabela 2.1 – Vantagens e Desvantagens da Desagregação da Demanda Industrial.....	12
Tabela 2.2 – Elasticidades Preço e Renda do Consumo Residencial de Eletricidade – Bahia.....	16
Tabela 2.3 – Alguns exemplos de FDS para dias normais e feriados – Espanha.....	19
Tabela 2.4 – Evolução da Participação dos Setores no Consumo de 1984 a 1999 – Hong Kong.....	21
Tabela 2.5 – Características da RNA para Classificação dos Consumidores – Taiwan.....	30
Tabela 2.6 – Comparação dos Cenários Previstos e o Realizado.....	37
Tabela 3.1 – Tarefas para Descoberta de Conhecimento e suas Aplicações.....	56
Tabela 3.2 – Funções e Métodos do Pré-Processamento da Base de Dados.....	58
Tabela 3.3 – Valores Críticos para o Teste de Dickey-Fuller.....	64
Tabela 3.4 – Qualificação para os Coeficientes de Correlação de Pearson.....	66
Tabela 3.5 – Regras Práticas para Interpretação do Índice Condicional.....	74
Tabela 4.1 – Exemplo de Conteúdo da Tabela COMEIND.....	97
Tabela 4.2 – Sessão de KDD para o Pré-Processamento da BDP1.....	97
Tabela 4.3 – Diagnóstico do Comportamento da Demanda do Setor Têxtil.....	103
Tabela 4.4 – Diagnóstico do Comportamento da Demanda do Setor Metalúrgico.....	107
Tabela 4.5 – Variáveis Econômicas Seleccionadas para a BDP2.....	110
Tabela 4.6 – Informações sobre as Estações Climatológicas Seleccionadas.....	113
Tabela 4.7 – Variáveis das Estações Climatológicas que Compõem a BDP3.....	114
Tabela 4.8 – Sessão de KDD para o Pré-Processamento da BDP3.....	115
Tabela 4.9 – Pesos para Determinação dos Indicadores Climáticos Regionais.....	117
Tabela 4.10 – Indicadores Climáticos Compostos.....	120
Tabela 5.1 – Comportamento Esperado para as Variáveis Explicativas.....	127
Tabela 5.2 – Resultado dos Testes de Raiz Unitária.....	130
Tabela 5.3 – Coeficientes de Correlação de Pearson para os Segmentos Têxtil e Metalúrgico.....	132
Tabela 5.4 (a) – Regressores Pré-Seleccionados para a Descrição do Consumo de Energia Elétrica – Têxtil.....	136

Tabela 5.4 (b) – Regressores Pré-Selecionados para a Descrição do Consumo de Energia Elétrica – Metalúrgico.	137
Tabela 5.5 – Evolução do Modelo Descritivo do Consumo de Energia Elétrica – Têxtil.	140
Tabela 5.6 – Interpretação do Modelo Descritivo do Consumo de Energia Elétrica - Têxtil.	141
Tabela 5.7 – Evolução do Modelo Descritivo da Tendência do Consumo de Energia Elétrica – Têxtil.	143
Tabela 5.8 – Interpretação do Modelo Descritivo da Tendência do Consumo de Energia Elétrica - Têxtil.	144
Tabela 5.9 – Evolução do Modelo Descritivo do Consumo de Energia Elétrica – Metalúrgico.	145
Tabela 5.10 – Interpretação do Modelo Descritivo do Consumo de Energia Elétrica - Metalúrgico.	147
Tabela 5.11 – Evolução do Modelo Descritivo da Tendência do Consumo de Energia Elétrica – Metalúrgico.	148
Tabela 5.12 – Interpretação do Modelo Descritivo da Tendência do Consumo de Energia Elétrica - Metalúrgico.	149
Tabela 6.1 – Resumo do Desempenho dos Modelos de Previsão do Consumo de Energia Elétrica - Têxtil.	161
Tabela 6.2 – Resumo do Desempenho dos Modelos de Previsão do Consumo de Energia Elétrica - Metalúrgico.	166

Lista de Figuras

Figura 1.1 – Apresentação Geral do Desenvolvimento da Tese.....	3
Figura 2.1 – Mapa Temático.	11
Figura 2.2 – Relação de Perdas e Ganhos do Ajuste do Nível de Desagregação.	13
Figura 2.3 – Relação Não-linear entre Consumo e a Temperatura Atmosférica Máxima no RJ.....	18
Figura 2.4 – Comportamento Não-Linear da Demanda com a Temperatura na Espanha.	20
Figura 2.5 – Exemplo de Agrupamentos por Perfil de Demanda – Grupo A4 da Celesc S.A.	28
Figura 2.6 – Procedimentos de KDD para a Caracterização dos Consumidores.....	29
Figura 2.7 – Crescimento do PIB X Crescimento da Carga – Diagrama da RNA.....	36
Figura 2.8 – Previsão Trimestral do Consumo de Energia Elétrica – EIA.....	39
Figura 2.9 – Gráfico da modelagem dinâmica para o consumo residencial de energia elétrica.....	39
Figura 2.10 – Arquitetura da RNA para previsão de demanda na Ilha de Lípári, Itália.	44
Figura 2.11 – Resultados da Previsão de Demanda Decomposta.....	44
Figura 2.12 – Variação dos Erros Observados na Previsão com Diferentes Elementos Climáticos.	45
Figura 2.13 – Pré-processamento da Base de Dados - Previsor de Carga On-line.....	46
Figura 2.14 – Previsor de Carga <i>On-line</i> Considerando a Influência das Variáveis Climáticas.	46
Figura 2.15 – Erros da Previsão de Temperatura X MAPE da Previsão da Carga.....	47
Figura 3.1 – Fluxograma das Etapas da Metodologia.	52
Figura 3.2 – Hierarquia entre Dados, Informação e Conhecimento.	53
Figura 3.3 – Etapas do Processo de KDD.	54
Figura 3.4 – Etapas da Modelagem Econométrica Clássica.....	60
Figura 3.5 – Séries Temporais Sintetizadas com a Aplicação de Modelos Estocásticos.	63
Figura 3.6 – Fluxograma do Processo de Construção do Modelo Econométrico.....	68
Figura 3.7 – Modelo Não-linear de um Neurônio.	80
Figura 3.8 – Exemplos de Função de Ativação.....	81
Figura 3.9 - Arquitetura de uma RNA simples.	82
Figura 3.10 – Exemplo de Arquitetura do Modelo Previsor Neural da Demanda – MLP.	84

Figura 3.11 – Fluxograma das Etapas de Construção do Modelo Previsor Neural da Demanda – MLP.	85
Figura 3.12 – Funções de Aproximação de MLPs (a) “ <i>sobretreinada</i> ” e (b) regularizada.	88
Figura 3.13 – O Cálculo da <i>Evidência</i> para Solução do Problema de Occam.	89
Figura 3.14 – Representação do Neurônio de Base Radial.	90
Figura 3.15 – Exemplo de Ajustamento Gráfico dos Parâmetros da RBF.	91
Figura 3.16 – Fluxograma das Etapas de Construção do Modelo Previsor Neural da Demanda – RBF.	92
Figura 4.1 – Etapas para Formação da Base de Dados.	94
Figura 4.2 – Estrutura das planilhas fornecidas pela concessionária com dados de consumo das indústrias. .	96
Figura 4.3 – Estrutura da Tabela SGI com os consumos mensais (kWh) por segmentos da indústria.	100
Figura 4.4 – Evolução do Consumo dos Segmentos Industriais da Pesquisa de Campo.	102
Figura 4.5 – Estações Climatológicas Convencionais das Regiões Sul e Sudeste do Brasil.	112
Figura 4.6 – Anomalias das Temperaturas Equivalentes das Regiões Sul e Sudeste.	118
Figura 4.7 – Anomalias das Temperaturas - Média Móvel de 6 Meses.	119
Figura 4.8 – Variação do Consumo de Energia Elétrica do Segmento Têxtil X Indicador ITMI.	121
Figura 5.1 – Fluxograma de Aplicação do Modelo Descritivo.	124
Figura 5.2 – Exemplos de Transformação Pró-Estacionária.	126
Figura 5.3 – Ajustamento Gráfico do Modelo Descritivo – V12m_CEE-T.	142
Figura 5.4 - Ajustamento Gráfico do Modelo Descritivo – V12m_TCEE-T.	145
Figura 5.5 – Ajustamento Gráfico do Modelo Descritivo – V12m_CEE-M.	147
Figura 5.6 - Ajustamento Gráfico do Modelo Descritivo – V12m_TCEE-M.	150
Figura 6.1 – Particionamento das Séries Históricas para Aplicação nas RNAs.	153
Figura 6.2 – Fluxograma da Construção de RNAs para Previsão do Consumo.	154
Figura 6.3 – Resultados de Previsão com a MLP “ <i>Sobretreinada</i> ”.	155
Figura 6.4 – Arquitetura do Modelo Previsor do Consumo do Segmento Têxtil (T+1).	157
Figura 6.5 – Desempenho do Modelo Previsor do Consumo do Segmento Têxtil (T+1).	158
Figura 6.6 – Arquitetura do Modelo Previsor do Consumo do Segmento Têxtil (T+3).	158
Figura 6.7 – Desempenho do Modelo Previsor do Consumo do Segmento Têxtil (T+3).	159
Figura 6.8 – Arquitetura do Modelo Previsor do Consumo do Segmento Têxtil (T+6).	159
Figura 6.9 – Desempenho do Modelo Previsor do Consumo do Segmento Têxtil (T+6).	160

Figura 6.10 – Arquitetura do Modelo Previsor do Consumo do Segmento Têxtil (T+12).....	160
Figura 6.11 – Desempenho do Modelo Previsor do Consumo do Segmento Têxtil (T+12).	161
Figura 6.12 – Arquitetura do Modelo Previsor do Consumo do Segmento Metalúrgico (T+1).....	162
Figura 6.13 – Desempenho do Modelo Previsor do Consumo do Segmento Metalúrgico (T+1).	163
Figura 6.14 – Arquitetura do Modelo Previsor do Consumo do Segmento Metalúrgico (T+3).....	163
Figura 6.15 – Desempenho do Modelo Previsor do Consumo do Segmento Metalúrgico (T+3).	164
Figura 6.16 – Arquitetura do Modelo Previsor do Consumo do Segmento Metalúrgico (T+6).....	164
Figura 6.17 – Desempenho do Modelo Previsor do Consumo do Segmento Metalúrgico (T+6).	165
Figura 6.18 – Arquitetura do Modelo Previsor do Consumo do Segmento Metalúrgico (T+12).....	165
Figura 6.19 – Desempenho do Modelo Previsor do Consumo do Segmento Metalúrgico (T+12).	166
Figura 6.20 – Fluxograma da Construção de RBFs para Previsão das Faixas de Consumo.	167
Figura 6.21 – Arquitetura do Modelo Previsor da Faixa de Consumo do Segmento Têxtil (T+1).	169
Figura 6.22 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Têxtil (T+1 s/falhas).	169
Figura 6.23 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Têxtil (T+1 c/falhas).	170
Figura 6.24 – Arquitetura do Modelo Previsor da Faixa de Consumo do Segmento Têxtil (T+12).	170
Figura 6.25 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Têxtil (T+12 s/falhas).	171
Figura 6.26 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Têxtil (T+12 c/falhas).	171
Figura 6.27 – Arquitetura do Modelo Previsor da Faixa de Consumo do Segmento Metalúrgico (T+1).	172
Figura 6.28 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Metalúrgico (T+1 s/falhas).	172
Figura 6.29 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Metalúrgico (T+1 c/falhas).	173
Figura 6.30 – Arquitetura do Modelo Previsor da Faixa de Consumo do Segmento Metalúrgico (T+12).	173
Figura 6.31 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Metalúrgico (T+12 s/falhas).	174
Figura 6.32 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Metalúrgico (T+12 c/falhas).	174

Lista de Siglas e Abreviaturas

ABIT	Associação Brasileira da Indústria Têxtil
AC12m	Valor acumulado nos últimos 12 meses (prefixo)
AET	Anomalia Equivalente da Temperatura
AG	Algoritmos Genéticos
AM	Atraso Mensal
AMMC	Atraso Mensal para a Máxima Correlação
ANEEL	Agência Nacional de Energia Elétrica
ANFAVEA	Associação Nacional dos Fabricantes de Veículos Automotores
ARIMA	<i>Autoregressive Integrated Moving Average</i>
ARX	<i>Autoregressive Multiple which Exogenous Variables</i>
AT	Anomalia Climática da Temperatura
BACEN	Banco Central do Brasil
BD	Base de Dados
BDP	Base de Dados Primária
BP	<i>Back-Propagation</i>
CCEE	Câmara de Comercialização de Energia Elétrica
CEE	Consumo de Energia Elétrica
CEE_T	Consumo de Energia Elétrica do segmento Têxtil
CEE_M	Consumo de Energia Elétrica do segmento Metalúrgico
CELESC	Centrais Elétricas de Santa Catarina S.A.
CEMIG	Companhia Energética de Minas Gerais S.A.
CIA	Critério de Informação de Akaike
CIS	Critério de Informação de Schwarz
CNAE	Código Nacional de Atividades Econômicas
CNI	Confederação Nacional da Indústria

COMEIND	Consumo de Energia Elétrica das Indústrias (tabela)
CPFL	Companhia Piratininga de Força e Luz
CRM	<i>Customer Relationship Management</i>
CTEEP	Companhia de Transmissão de Energia Elétrica Paulista
CVM	Comissão de Valores Mobiliários
DF	Teste de presença de raiz unitária de Dickey-Fuller
DFA	Teste de presença de raiz unitária de Dickey-Fuller Aumentado
DNAEE	Departamento Nacional de Águas de Energia Elétrica
EDP	Eletricidade de Portugal
EIA	<i>Energy Information Administration</i>
EPAGRI	Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina
EPE	Empresa de Pesquisa Energética
ESCOS	Empresas de Serviço de Conservação de Energia
FDS	Fator do Dia da Semana
FGV	Fundação Getúlio Vargas
FIESC	Federação das Indústrias do Estado de Santa Catarina
FMI	Fundo Monetário Internacional
FUNCEX	Fundação Centro de Estudos do Comércio Exterior
GN	Gás Natural
GWh	Gigawatt-hora
IA	Inteligência Artificial
IAEA	<i>International Atomic Energy Agency</i>
IBS	Instituto Brasileiro de Siderurgia
IBGE	Instituto Brasileiro de Geografia e Estatística
IC	Índice Condicional para multicolineariedade
ICMS	Imposto sobre Circulação de Mercadorias e Serviços
IEA	<i>International Energy Agency</i>
INCC	Índice Nacional do Custo da Construção Civil
INMET	Instituto Nacional de Meteorologia
IPEA	Instituto de Pesquisa Econômica Aplicada
ITMI	Intensidade Térmica das Mínimas
IVS	Índice de Variação dentro da Semana

KDD	<i>Knowledge Discovery in Databases</i>
KW	Kilowatt
LSTR	<i>Logistic Smooth Transition Regression</i>
LTLF	<i>Long-term Load Forecasting</i>
MAED	<i>Model for Analysis of Energy and Electricity Demand</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MAX_APE	<i>Maximum Absolute Percentual Error</i>
MIA	<i>Mean Index Adequacy</i>
MIPE	Modelo Integrado de Planejamento Energético
MLP	<i>Multi-layer Perceptron</i>
MME	Ministério das Minas e Energia
MM6	Média Móvel de 6 meses
MSE	<i>Mean Square Error</i>
MTLF	<i>Medium-term Load Forecasting</i>
MW	Megawatt
NNCI	Número de Neurônios na Camada Intermediária
OECD	<i>Organisation for Economic Co-operation and Development</i>
ONS	Operador Nacional do Sistema Elétrico
PCA	Perfil de Carga Anual
P&D	Pesquisa e Desenvolvimento
PIB	Produto Interno Bruto
PP	Teste de presença de raiz unitária de Phillips-Perron
RBF	<i>Radial-Basis Functions</i>
RNA	Rede Neural Artificial
SEB	Setor Elétrico Brasileiro
SECEX	Secretaria de Comércio Exterior
SGI	Segmentos da Indústria (tabela)
SIN	Sistema Interligado Nacional
SOM	<i>Self-organizing Map</i>
STLF	<i>Short-term Load Forecasting</i>
TCEE	Tendência de Consumo de Energia Elétrica
TCEE_T	Tendência de Consumo de Energia Elétrica do segmento Têxtil

TCEE_M	Tendência de Consumo de Energia Elétrica do segmento Metalúrgico
TI	Tecnologia da Informação
USP	Universidade de São Paulo
UFSC	Universidade Federal de Santa Catarina
VAR	<i>Vector Auto-Regressive</i>
VSTLF	<i>Very Short-term Load Forecasting</i>
V12m	Varição em relação ao mesmo período do ano anterior (prefixo)

CAPÍTULO 1

Apresentação

1.1 INTRODUÇÃO

Ao longo de mais de um século, aprendemos que a importância da produção de energia elétrica, em grande escala, para a vida das pessoas, empresas e demais instituições é indiscutível. Atualmente, o desenvolvimento pleno das atividades da sociedade está cada vez mais associado à disponibilidade de oferta de energia elétrica. A dependência extrema da sociedade moderna em relação ao suprimento de energia elétrica já foi amplamente demonstrada por ocasião de blecautes ou de crises no abastecimento, como recentemente na Califórnia, iniciada em junho de 2000, ou o racionamento de energia elétrica imposto aos brasileiros durante o ano de 2001 (CAMARGO e TEIVE, 2006).

Em todo o mundo, existe uma cadeia produtiva, organizada basicamente em sistemas de geração, transmissão, distribuição e comercialização de energia elétrica, cuja atuação vai desde o aproveitamento de outras fontes de energia até o fornecimento da energia elétrica ao consumidor final, segundo uma forma de contratação estabelecida. Diferentemente de uma cadeia de produtos tradicionais, o “produto” energia elétrica ainda não pode ser armazenado em grande escala. Não havendo um “estoque regulador” direto para a eletricidade, a geração de energia elétrica deve estar sempre em sintonia com a demanda.

A estreita relação existente entre oferta e demanda é um dos temas centrais do planejamento e da operação dos sistemas de energia elétrica. No curtíssimo prazo, o desconhecimento sobre o comportamento da demanda pode ter consequências graves à continuidade do fornecimento de energia elétrica à população. No longo prazo, as consequências do desequilíbrio entre a oferta e a demanda podem levar a crises de abastecimento, com impactos significativos à economia e ao desenvolvimento do país. Nesse sentido, o acompanhamento do cenário econômico no Brasil e no mundo, e das políticas para o setor energético são essenciais para a compreensão do comportamento da demanda.

Atualmente, a indústria brasileira é responsável por cerca de 45% do consumo total de energia elétrica. Além de ser a maior classe consumidora, o setor industrial é cada vez mais um “termômetro” das atividades econômicas no Brasil. Por outro lado, a dinâmica do seu consumo de energia elétrica é bem mais complexa e caracterizada pela maior volatilidade. A mesma demanda industrial, que apresenta taxas de crescimento bem acima da média da economia brasileira em períodos de expansão econômica, é capaz de, em épocas de crise, como em janeiro de 2009, recuar quase 15% na comparação anual. O comportamento da demanda dos consumidores industriais de energia elétrica é ainda mais determinante no ambiente de contratação livre, onde os mesmos representam a grande maioria dos compradores.

Neste trabalho apresenta-se um novo modelo para descrever e prever a demanda dos consumidores industriais de energia elétrica, de forma desagregada. Por meio da descrição da demanda é possível quantificar a influência de fatores econômicos e/ou climáticos característicos de um segmento da indústria. A partir desse conhecimento, o trabalho apresenta um modelo de previsão, baseado em redes neurais artificiais, para o consumo nos meses seguintes. O diferencial deste trabalho está na aplicação de técnicas de mineração de dados como suporte à integração do modelo econométrico descritivo com o modelo de redes neurais preditivo.

1.2 CONTEXTUALIZAÇÃO DO PROBLEMA

Os estudos sobre o comportamento da demanda encontram aplicação em diversas áreas do setor elétrico, com objetivo de resolver problemas de naturezas distintas. Nos centros de operação de carga, por exemplo, o conhecimento da variação da demanda alguns minutos à frente ou para a semana seguinte é de grande importância. Nesse caso, a ocorrência de grandes eventos, a sazonalidade do calendário e de clima podem ser fatores determinantes. No outro extremo do horizonte de análise, o planejamento da expansão do sistema elétrico procura estabelecer cenários socioeconômicos para os próximos anos ou décadas que serão determinantes para a evolução da demanda e, por consequência, do crescimento da geração, transmissão e distribuição de energia elétrica.

O foco deste trabalho está na previsão de demanda no médio prazo. Considera-se aqui, que o conhecimento sobre a evolução do consumo das indústrias, nos próximos meses até um ano à frente, contribui para o planejamento da produção e comercialização da energia elétrica, principal-

mente em mercados competitivos. Além disso, a descrição da demanda em relação aos fatores que a influenciam, como o clima e a economia, abre caminho para aplicação de estratégias comerciais customizadas. O maior conhecimento sobre a dinâmica de cada segmento industrial pode gerar um maior comprometimento na relação de comercialização da energia elétrica.

Nos últimos anos, uma área denominada Descoberta de Conhecimento em Base de Dados (KDD - *Knowledge Discovery in Databases*) vem despertando grande interesse junto à comunidade científica. Originária de outras áreas: estatística, inteligência artificial, reconhecimento de padrões, gerenciamento de dados, entre outras, pode-se afirmar que a metodologia de KDD orientou o desenvolvimento deste trabalho. A Figura 1.1 apresenta, de forma resumida, todo o desenvolvimento da tese, partindo da importância dada ao problema da demanda, passando pela segmentação da indústria, até a obtenção dos modelos descritivo e preditivo para o consumo de energia elétrica.

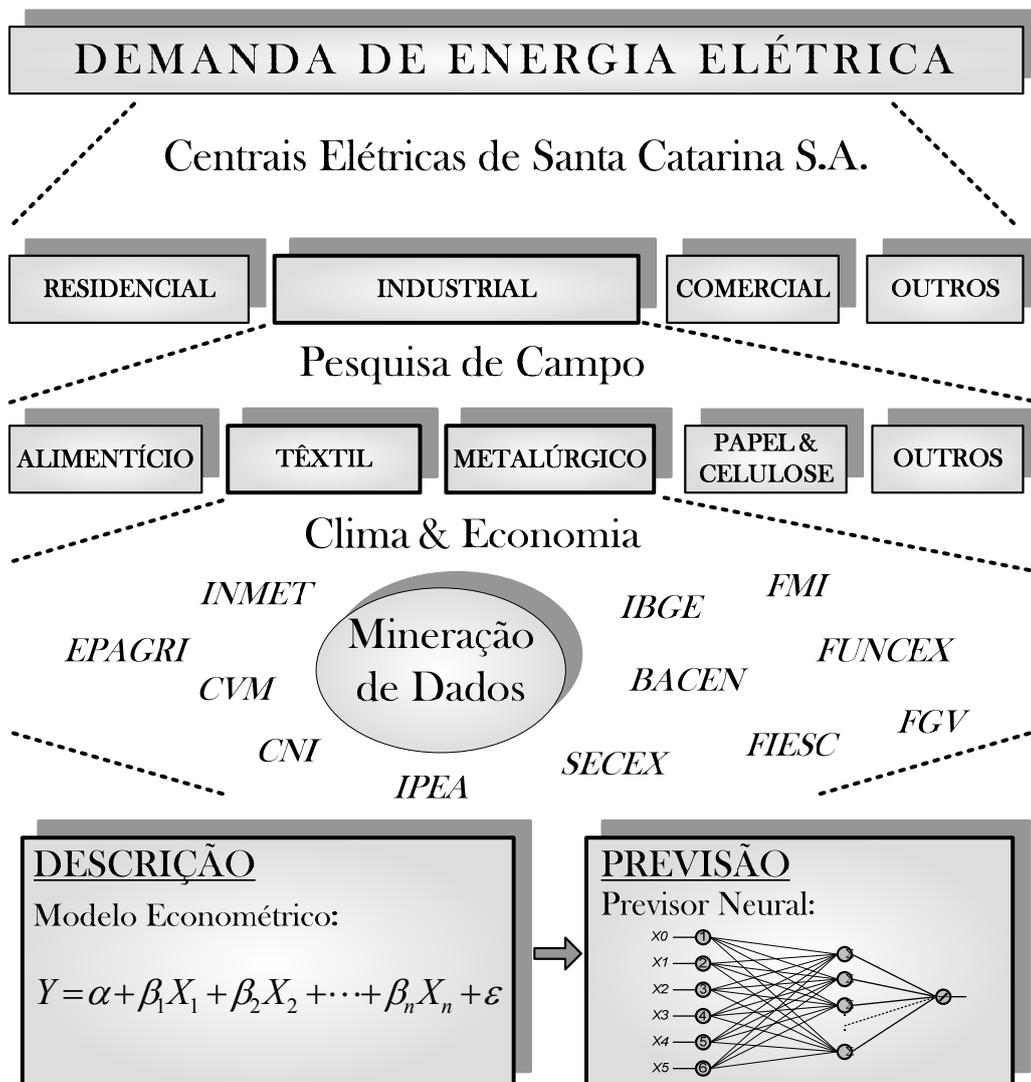


Figura 1.1 – Apresentação Geral do Desenvolvimento da Tese.

Fonte: Elaborado pelo Autor.

Após a definição do objeto de estudo da tese, ou seja, a demanda desagregada dos consumidores industriais de energia elétrica, contamos com o apoio do departamento comercial das Centrais Elétricas de Santa Catarina – CELESC S.A., que forneceu as séries históricas mensais de consumo da classe industrial de Santa Catarina de 1996 a 2006. A partir desta inestimável colaboração, foram iniciados os trabalhos de mineração de dados e de pesquisa de campo com os gestores das principais indústrias do Estado.

Para subsidiar os modelos de descrição e previsão da demanda, foi necessário formar uma grande base de dados sobre a economia e o clima, que poderiam afetar alguns segmentos industriais. Novamente, a pesquisa contou com o apoio de diversas instituições, em especial das instituições ligadas ao monitoramento do clima, como o Instituto Nacional de Meteorologia – INMET e a Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina – EPAGRI. Os indicadores econômicos utilizados na pesquisa são de domínio público e foram reunidos a partir de consultas às principais instituições de acompanhamento da economia brasileira e mundial, como a Fundação Getúlio Vargas, o Instituto Brasileiro de Geografia e Estatística, o Fundo Monetário Internacional, entre outros.

Com um volume suficiente de dados de qualidade foram estabelecidas as condições necessárias para o desenvolvimento de modelos econométricos, característicos de cada segmento industrial analisado. O conhecimento das variáveis de maior impacto na evolução do consumo de energia elétrica, mostrou-se fundamental para a construção de modelos previsores de qualidade baseados em redes neurais artificiais. A aplicação de técnicas de inteligência artificial, comum na previsão de curto prazo, apresentou resultados significativos para previsão da demanda no médio prazo. Em alguns casos, o erro médio de previsão foi inferior a 3% para um horizonte de 12 meses à frente, mesmo se tratando de uma classe de consumo mais volátil e abordada de forma desagregada.

1.3 MOTIVAÇÕES

Os problemas do setor elétrico relacionados à descoberta de conhecimento sobre a demanda são tão diversos e complexos quanto às soluções a eles propostas. A variação da demanda dos consumidores industriais no médio prazo, em função de variáveis econômicas e climáticas próprias de cada segmento, foi escolhida como a base deste trabalho pelos seguintes motivos:

- i. A expectativa de que os fatores que influenciam atividades econômicas específicas possam explicar melhor o comportamento da demanda em relação àqueles que afetam a indústria como um todo;
- ii. Poder contribuir ao conjunto de técnicas e aplicações para a previsão de demanda com uma nova abordagem via mineração de dados, econometria e redes neurais;
- iii. A maior participação da classe industrial no consumo total de energia elétrica;

- iv. Busca de novos conhecimentos sobre a influência do clima nas atividades econômicas industriais, em especial da indústria têxtil;
- v. Boa disponibilidade de dados confiáveis sobre o consumo de energia elétrica e atividades econômicas dos consumidores industriais;
- vi. A forte influência exercida pela indústria na dinâmica de evolução do mercado de energia elétrica no ambiente de contratação livre;
- vii. A possibilidade de transformar o conhecimento sobre o comportamento da demanda de segmentos específicos da indústria em vantagens estratégicas, capazes de facilitar as ações de marketing num ambiente competitivo;
- viii. Poder contribuir com os mecanismos de redução dos níveis de incerteza associadas à atividade de comercialização de energia elétrica com clientes industriais.

As motivações para o desenvolvimento de uma pesquisa de doutorado podem estar sujeitas a ajustes de percurso. No entanto, ao longo deste trabalho, nenhuma crise, regra ou legislação reduziu a sua aplicabilidade, ao contrário, o mercado de consumidores livres, por exemplo, continua sendo a área com maior potencial de aproveitamento deste novo modelo de descrição e previsão da demanda. Entretanto, as oportunidades oferecidas aos agentes já não são as mesmas de 2002, início da formação do mercado, e as expectativas já não são tão otimistas como em 2006, quando o crescimento anual do mercado ainda estava na casa de dois dígitos.

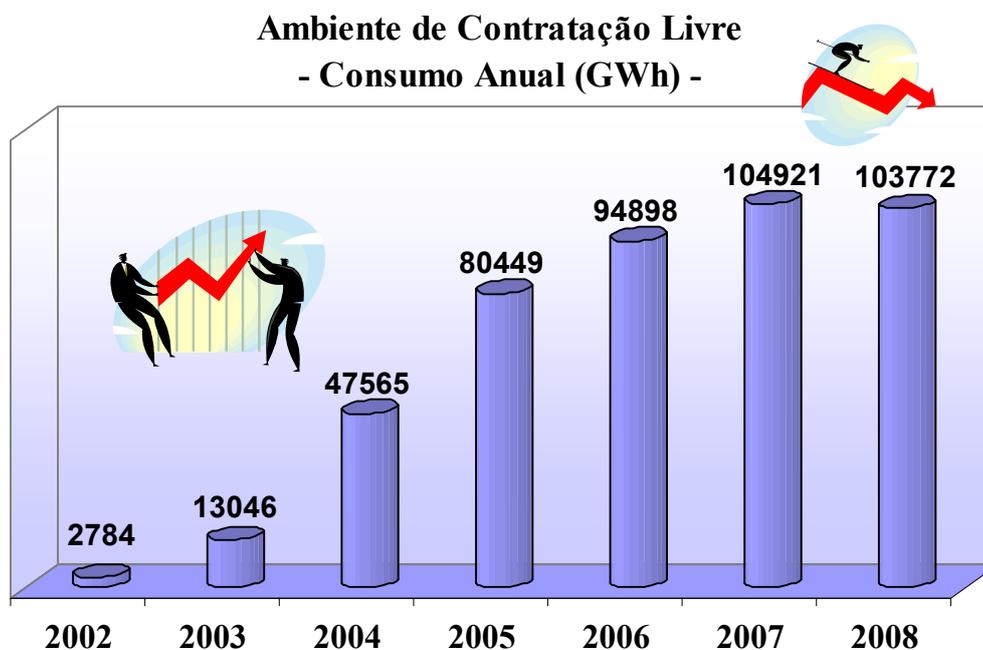


Figura 1.2 – Evolução do Consumo Anual de Energia Elétrica no Ambiente de Contratação Livre.

Fonte: Elaborado pelo Autor a partir de EPE, 2009.

Pode-se observar na Figura 1.2 a rápida expansão do consumo de energia elétrica no ambiente de contratação livre de 2002 até 2006/2007, atingindo $\frac{1}{4}$ do fornecimento total de energia elétrica no mercado brasileiro. Porém, a taxa de crescimento mais comportada de 2006 para 2007 e a retração do mercado em 2008, agravada ainda mais pela crise financeira internacional, cujos efeitos foram sentidos no quarto trimestre de 2008, reforçam o papel do planejamento estratégico da comercialização com foco no comportamento da demanda.

No documento de defesa de qualificação desta tese, de outubro de 2006, procurou-se caracterizar alguns fatores responsáveis pelo surgimento e crescimento deste competitivo mercado de eletricidade. De certa forma, tais fatores ainda são válidos:

- ➔ O ambiente regulatório – tem possibilitado que um número cada vez maior de potenciais consumidores livres deixe o mercado cativo;
- ➔ A existência de um consenso entre os potenciais consumidores de que o ambiente de contratação livre pode lhes trazer vantagens competitivas;
- ➔ A ação das empresas comercializadoras para a conquista da maior e melhor fatia possível deste novo mercado consumidor.

À época, já era possível traçar um panorama para os anos seguintes: *“Muito provavelmente, nos próximos anos, a parcela do consumo livre em relação ao consumo total, experimentará uma acomodação. A absorção de novos grupos consumidores para o mercado livre será limitada por questões técnicas e não só de regulamentação. Existe uma tendência global de equilíbrio entre o mercado livre e o mercado de consumidores cativos. A disputa pelos grandes consumidores ocorrerá mais no âmbito da contratação livre, com a disputa de preços, serviços e vantagens relacionadas à energia elétrica oferecidas por cada empresa.”*(ANDRADE, 2006).

O comportamento do mercado livre nos últimos 3 anos pode ser entendido como reflexo da própria saturação do mercado, das dificuldades de ordem regulatória, e ainda, como se pôde constatar, do retorno de alguns clientes à condição de cativos, no mercado regulado de energia elétrica.

A aplicação do modelo proposto nesta tese para descrição e previsão da demanda de consumidores industriais de energia elétrica é especialmente útil para lidar com a incerteza dos mercados em momentos de grande turbulência. Atualmente, a mesma indústria brasileira que repercutiu negativamente os efeitos da crise financeira internacional encoraja novas estratégias de atuação por parte das empresas comercializadoras que disponham de maior conhecimento sobre o comportamento da demanda.

Uma das principais motivações deste trabalho advém da necessidade das empresas do setor elétrico, em especial as comercializadoras, de conhecer o comportamento da demanda de seus clientes. Um bom planejamento das ações para competição no mercado livre pode e deve ser acompanhado de modelos para descoberta de conhecimento sobre o comportamento da demanda dos consumidores industriais de energia elétrica.

1.4 OBJETIVO GERAL

O objetivo geral deste trabalho é desenvolver e aplicar uma metodologia para descobrir conhecimento novo e útil sobre a demanda por energia elétrica, característica de cada segmento industrial, por meio de técnicas de mineração de dados aplicadas ao conjunto das variáveis socioeconômicas e climáticas que mais a influenciam.

1.5 OBJETIVOS ESPECÍFICOS

- Descrever e analisar os trabalhos relacionados ao estudo da demanda por energia elétrica, mais próximos à realidade do Setor Elétrico Brasileiro, e que, de alguma forma, contribuam para o adequado desenvolvimento deste trabalho;
- Aplicar as técnicas de mineração de dados para a construção das bases de dados sobre energia, economia e clima;
- Considerar o comportamento da demanda da indústria de forma desagregada, conforme as atividades econômicas de cada segmento analisado;
- Construir, no âmbito da metodologia, as condições para realização de duas tarefas de mineração de dados, a descrição e a previsão da demanda dos consumidores industriais;
- Obter modelos econométricos sobre a demanda dos segmentos industriais, capazes de descrever a influência das variáveis econômicas e climáticas;
- E finalmente, alcançar níveis significativos de acurácia na previsão no médio prazo para o consumo de energia elétrica de cada segmento.

1.6 ORGANIZAÇÃO DO TRABALHO

A elaboração desta tese foi estruturada considerando sete capítulos. Neste primeiro, foi apresentado o contexto dos problemas relacionados à demanda dos consumidores industriais de energia elétrica, as motivações e os objetivos para busca de conhecimento sobre seu comportamento frente às variáveis que o influenciam.

No Capítulo 2, *Revisão da Literatura*, são apresentados e analisados diversos trabalhos de áreas que contribuem para elucidação do comportamento da demanda. Métodos econométricos, técnicas de inteligência artificial e mineração de dados, são as principais metodologias apresentadas. No entanto, são enfatizados os trabalhos com maior nível de desagregação da carga, que consideram variáveis econômicas e/ou climáticas, ou que utilizam técnicas de mineração de dados, para descrição ou previsão da demanda industrial.

O Capítulo 3, *Metodologia*, apresenta o embasamento teórico relacionado às técnicas de mineração de dados, à construção de modelos econométricos e ao uso de redes neurais artificiais

para a previsão da demanda. Ao longo do texto, aspectos teóricos e conceituais são apresentados de modo a subsidiar a elaboração da metodologia proposta. Nesse capítulo, discorre-se sobre a importância das tarefas de KDD para a construção das bases de dados sobre energia, economia e clima, sobre os cuidados na utilização da econometria para descrever a demanda, e as etapas para construção dos modelos neurais de previsão da demanda dos consumidores industriais de energia elétrica.

O Capítulo 4, *Formação da Base de Dados*, descreve o processo de formação das bases de dados primárias, relacionadas ao consumo de energia elétrica da indústria de Santa Catarina, e às variáveis econômicas e climáticas, no período compreendido entre janeiro de 1996 e dezembro de 2006. Esse capítulo destaca os procedimentos para realização da etapa de pré-processamento das séries históricas como condição básica para o desenvolvimento dos modelos descritor e predictor da demanda.

O Capítulo 5, *Descrição da Demanda*, apresenta as etapas para o desenvolvimento e aplicação do modelo de descrição da demanda dos consumidores industriais de energia elétrica. A partir das bases de dados sobre a economia e o clima, são construídos os modelos de descrição com as variáveis de maior correlação com a demanda. Tais modelos ainda são aprimorados com a estimação dos parâmetros de regressão múltipla, passando pelos testes de hipóteses e de avaliação do desempenho. Nesse capítulo são consideradas as séries históricas de consumo e de tendência de consumo de energia elétrica.

O Capítulo 6, *Previsão da Demanda*, descreve as etapas para a construção dos modelos de previsão da demanda dos consumidores industriais de energia elétrica. Apesar de ser a última etapa desta pesquisa, o modelo preditivo baseia-se na pesquisa de campo, na formação da base de dados, na aplicação de modelos econométricos, e no uso de técnicas de inteligência artificial para a previsão da demanda no médio prazo. Nesse capítulo, destaca-se a qualidade alcançada na previsão do consumo e da faixa de consumo, em diferentes horizontes de tempo e segmentos industriais.

Finalmente, o Capítulo 7, *Conclusões*, estabelece algumas ponderações sobre os resultados alcançados nesta pesquisa à luz dos objetivos para ela pretendidos. Apresentam-se ainda, alguns aspectos relacionados à aplicabilidade da metodologia, bem como suas limitações, além de sugestões para trabalhos futuros.

CAPÍTULO 2

Revisão da Literatura

2.1 INTRODUÇÃO

Neste capítulo são analisados diversos trabalhos de áreas que contribuem para a elucidação do comportamento da demanda por energia elétrica em função das variáveis que mais a influenciam. Desde os primeiros trabalhos, que utilizam métodos econométricos, até as mais recentes pesquisas envolvendo inteligência artificial e mineração de dados, apresentam-se os caminhos, percorridos ao longo da pesquisa, para a descoberta de conhecimento novo e útil sobre a demanda de energia elétrica.

Os pilares da metodologia proposta nesta tese são a aplicação das melhores técnicas para previsão e descrição da demanda de energia elétrica, em diferentes segmentos industriais, considerando variáveis econômicas e climáticas que regem seu comportamento.

Das duas tarefas de KDD citadas, ressalta-se que a previsão e a descrição, apesar de suas semelhanças, são diferentes, tanto na concepção quanto nos seus objetivos (FAYYAD, 1996){1}. Um modelo preditivo visa a maior acurácia possível para os apontamentos futuros, ainda que as variáveis envolvidas na modelagem possam não estar claramente correlacionadas. Já a meta de um modelo descritivo para a demanda é a de esclarecer os níveis de correlação entre as variáveis que realmente podem influenciar no seu comportamento.

A revisão da literatura envolveu diversas áreas de estudo que de alguma forma contribuíram para que este trabalho alcançasse seus objetivos. A Seção 2.2 apresenta e justifica o estudo da demanda de forma mais desagregada, relacionando suas vantagens e desvantagens. A Seção 2.3 relaciona e analisa algumas aplicações de descrição da demanda, cujas abordagens apresentam similaridade com o modelo descritivo proposto neste trabalho. Da mesma forma, a Seção 2.4 apresenta algumas contribuições relevantes ao problema da previsão de demanda, que tiveram influência do desenvolvimento do presente modelo preditivo. Finalmente, a Seção 2.5 apresenta um resumo do capítulo.

Os estudos sobre o comportamento da demanda, por encontrar aplicabilidade em diferentes áreas do setor elétrico e sofrer a influência de diversos fatores, são altamente caracterizados pela multidisciplinariedade. Para delimitar o escopo deste trabalho e posicioná-lo em relação às referências bibliográficas consultadas, foi elaborado um Mapa Temático. Na Figura 2.1 pode-se observar oito temas principais diretamente relacionados a esta tese, os círculos verdes mais próximos ao centro da figura, com seus respectivos índices¹ sequenciais, que identificam a ordem em que ocorrem as citações ao longo deste capítulo. Os demais temas, círculos alaranjados, estão indiretamente associados a este trabalho e também apresentam seus índices sequenciais. A grande maioria das referências consultadas está associada a pelo menos um dos oito temas principais. Considerando todas as referências consultadas, o Mapa Temático foi dividido em quatro áreas: Técnicas de Solução, Variáveis de Influência, Tipo de Consumo, Horizonte de Estudo. Também foram relacionadas outras abordagens, círculos azuis, que contribuíram marginalmente à tese; elas tratam das outras fontes de energia ou destacam os mercados competitivos de energia elétrica. Os índices sequenciais presentes no mapa e não pertencentes a nenhum dos temas específicos, também foram de grande relevância na revisão da literatura, porém, eles referem-se a questões de temática mais ampla, como conceitos, análises, ou críticas sobre a descrição e/ou previsão da demanda.

¹ Os índices sequenciais foram grafados entre chaves após cada citação de referência bibliográfica no texto.

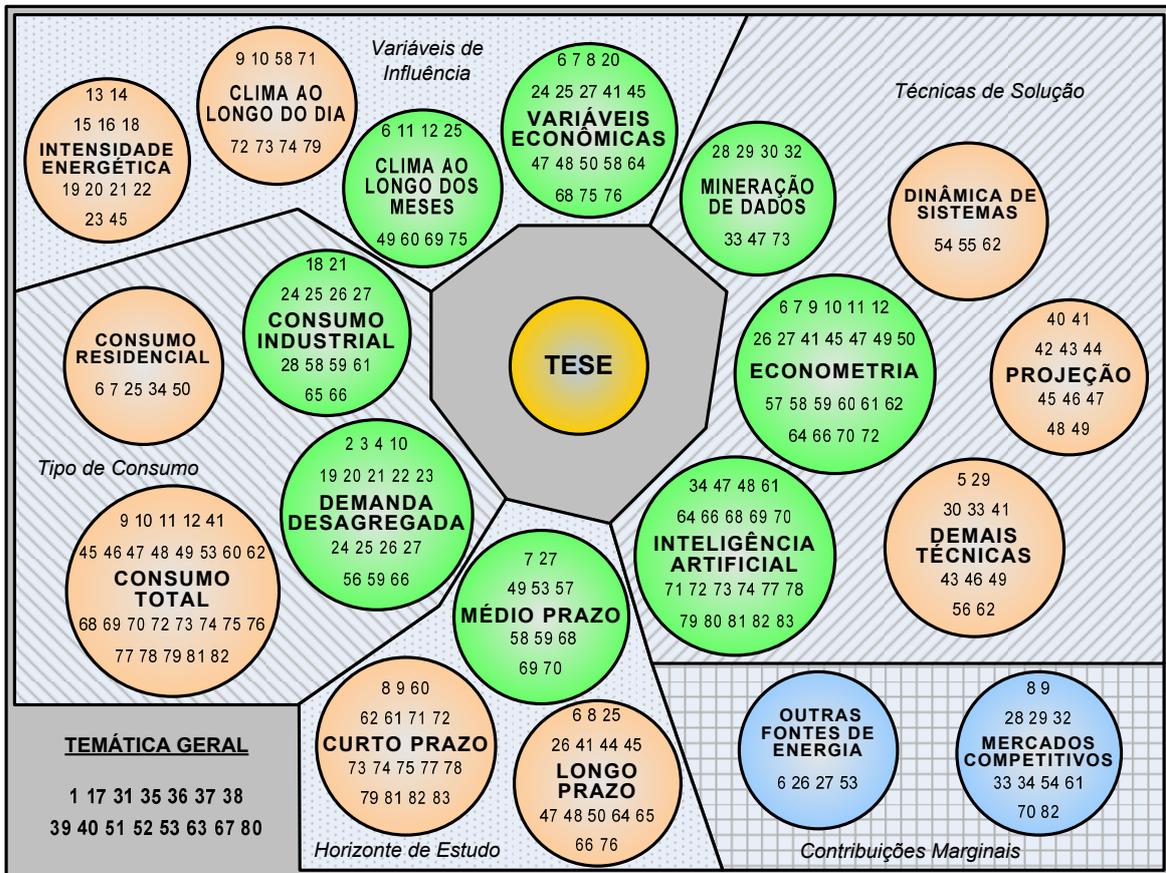


Figura 2.1 – Mapa Temático.

Fonte: Elaborado pelo Autor.

2.2 DEMANDA DESAGREGADA

O nível de desagregação apresenta-se como um fator determinante para os objetivos da previsão de demanda. A maioria dos estudos de previsão para o médio ou longo prazos considera a demanda de energia elétrica com baixos níveis de desagregação. Quando se considera o consumo de energia elétrica de todo sistema interligado nacional, por exemplo, não ocorre nenhuma desagregação. Nesse caso, os estudos de previsão estão mais associados ao processo de planejamento mais amplo dentro do setor elétrico. Quando as divisões estruturais e regulatórias são observadas, os modelos de previsão normalmente desagregam o consumo segundo as classes comercial, residencial, industrial, poder público e as demais classes. Para atender aos objetivos deste trabalho, considerou-se ainda um nível adicional de desagregação para a classe de consumidores industriais: a separação por segmentos da indústria.

Durante o processo de revisão da literatura pôde-se verificar que existem poucos trabalhos relacionados à desagregação da demanda para o setor industrial, com vistas à previsão ou descrição da demanda, embora o processo de projeção de demanda da indústria segundo as atividades econômicas já seja de conhecimento público há mais tempo. Um dos trabalhos pioneiros na questão da

segmentação industrial para efeito de previsão (CHANG e CHERN, 1981){2} justificava este procedimento afirmando enfaticamente que “diferentes indústrias têm diferentes processos de produção, que são influenciados por diferentes parâmetros externos e, portanto, apresentam diferentes padrões de consumo”. A desagregação da demanda industrial, com uma análise setorial, possibilita conhecer melhor as características próprias de cada segmento e os graus de influência das variáveis externas sobre os mesmos. Assim, tanto os “nós” quanto os “ramos” dessa complexa rede do comportamento dos consumidores industriais, ficam mais evidentes.

Existem várias maneiras de se realizar a desagregação da demanda. Entre elas, destacam-se: (1) por classe social: residencial, comercial, industrial e outros, (2) pela intensidade energética²: eletrointensivos e os demais, (3) pelo consumo: grandes consumidores e os demais, (4) por atividades econômicas: agricultura, transportes, comércio, construção civil, energético, etc., (5) por segmentos industriais: têxtil, metalúrgico, cerâmico, alimentar, etc.

A desagregação a um nível de detalhamento muito grande também não é uma garantia de modelos mais precisos para estudo da demanda. Deve-se compreender, porém, que os objetivos de um estudo sobre a demanda, juntamente com os meios disponíveis para sua consecução, são determinantes para a escolha do nível de desagregação. Mc CAFFEIRTY e BEATTIE (1991){3} relacionam algumas vantagens e desvantagens do estudo da demanda industrial de forma desagregada:

Tabela 2.1 – Vantagens e Desvantagens da Desagregação da Demanda Industrial.

Desagregação da Demanda Industrial	
Vantagens	Desvantagens
- Maior aproveitamento das informações disponíveis	- A própria definição do nível adequado de desagregação a ser utilizado
- Componentes de maior frequência não são omitidas	- A disponibilidade de muitos dados
- A variação dos dados de entrada é mais dinâmica	- Maior esforço para modelagem
- Permite desenvolver modelos mais especializados	

Fonte: Adaptado de Mc CAFFEIRTY e BEATTIE, 1991.

Assim como as empresas do setor de energia elétrica, as grandes empresas do comércio atacadista apresentam contribuições interessantes ao problema da previsão de demanda. A distribuição espacial dos mais variados tipos de produtos, a dinâmica da elasticidade da demanda, o grau de sazonalidade e de aceitação de cada produto, são alguns fatores que naturalmente diferenciam este mercado do mercado de energia elétrica. Ainda assim, as soluções propostas para a previsão de demanda de produtos trazem contribuições interessantes para definição de um modelo de previsão de demanda de energia elétrica. Segundo ZOTTERI et al. (2005){4} a previsão é um processo mais complexo do que a simples escolha do melhor algoritmo a ser implementado. Os autores dedicam especial atenção ao problema do ajuste correto do nível de agregação/desagregação dos dados, o

² indicador energético que se refere à relação entre o consumo final de energia de uma determinada área socioeconômica e o seu produto interno bruto.

que pode resultar na melhoria do modelo. Tal escolha depende basicamente do entendimento do processo de geração da demanda. Após analisarem diversos trabalhos de previsão de demanda, das duas principais vertentes em termos hierárquicos, *Top-Down*³ e *Bottom-Up*⁴, pôde-se estabelecer uma análise custo-benefício bastante útil para escolha do nível de desagregação adequado:

- ➔ Previsões de demanda, mais precisas, dependem do conhecimento dos fatores que regem seu comportamento, que por sua vez, podem ser mais característicos de cada segmento da indústria;
- ➔ A necessidade de estimar tais fatores, entretanto, traz o custo da habilidade em se capturar as diferenças entre os segmentos da indústria, ao mesmo tempo em que proporciona uma previsão mais acurada dos diferentes segmentos (Figura 2.2);
- ➔ A escolha de uma posição adequada para esta relação depende de dois fatores:
 - A disponibilidade de informações relevantes sobre a demanda e seus fatores;
 - O grau desejado de distinção no comportamento da demanda entre os segmentos industriais analisados.

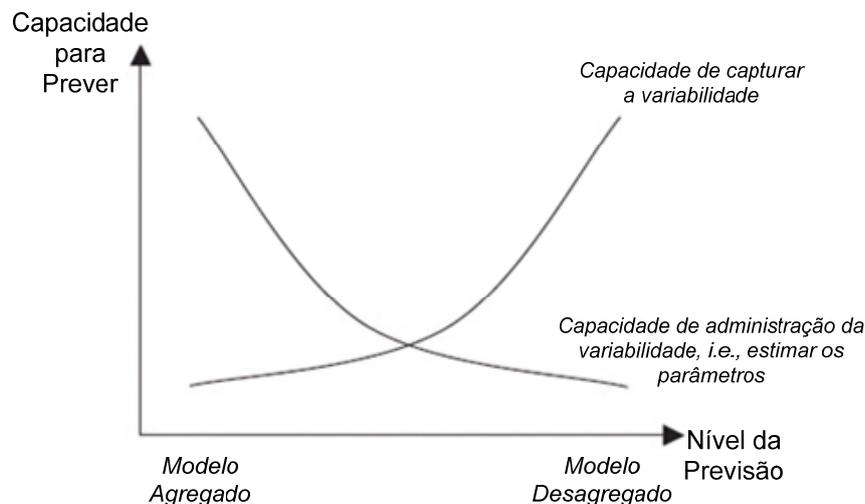


Figura 2.2 – Relação de Perdas e Ganhos do Ajuste do Nível de Desagregação.

Fonte: ZOTTERI et al.,2005.

Como pôde ser observada na literatura, a definição do nível ideal de desagregação dos dados da demanda industrial não é uma tarefa trivial. A análise dos aspectos positivos e negativos desta opção torna-se um fator ainda mais instigante para o desenvolvimento desta pesquisa.

³ Técnica de previsão que prevê o total do consumo agregado e posteriormente realiza o rateio das respectivas parcelas de consumo, com base em suas proporções históricas. (Adaptado de WANKE, 2008) {5}

⁴ Técnica de previsão que prevê separadamente o consumo de cada uma das parcelas, conforme a profundidade da desagregação, que posteriormente são somadas para obtenção de uma previsão agregada do consumo.

2.3 DESCRIÇÃO DA DEMANDA

Podemos afirmar que um modelo de descrição da demanda é mais “responsável”, se comparado ao modelo preditivo, à medida que exige um nível de significância elevado para a definição das variáveis que realmente podem influenciar o comportamento da demanda. Por outro lado, um modelo de previsão é avaliado em função de sua capacidade em acertar o futuro com os valores hoje previstos. Nesse caso, pode não haver necessariamente um compromisso de estabelecer uma modelagem com variáveis explicativas correlacionadas. Entretanto, os sistemas baseados nas técnicas de KDD podem contemplar ambas as características para o estudo da demanda.

Um modelo para descoberta de conhecimento sobre o comportamento da demanda encontra, na tarefa da descrição, uma medida do grau de relacionamento entre as variáveis explicativas e a variável dependente. Ou seja, pode-se medir o quanto as variáveis climáticas, as variáveis socioeconômicas e/ou as alterações na intensidade energética conseguem explicar do comportamento da demanda.

Na revisão da literatura, referente à descrição da demanda, pode-se observar a preocupação dos autores com o melhor ajuste possível de seus equacionamentos ao mundo real do consumidor de energia elétrica. A crescente liberalização dos mercados de eletricidade, que, na maioria dos países, acentuou a busca pelo melhor entendimento possível das reações dos consumidores: aos preços, às condições climáticas, às horas do dia, aos dias da semana, às estações do ano, entre outras externalidades.

A continuação desta seção apresenta vários trabalhos em diferentes perspectivas sobre o problema da descrição da demanda. A Seção 2.3.1 relaciona os trabalhos mais tradicionais que fazem uso de métodos econométricos ou séries temporais. A Seção 2.3.2 apresenta alguns trabalhos que utilizaram um nível maior de desagregação para o estudo da demanda. Ao final, a Seção 2.3.3 dedica-se a aplicações de KDD que auxiliam na tarefa de descrição da demanda, como classificação de consumidores e clusterização de perfis de consumo.

2.3.1 Métodos Tradicionais de Descrição da Demanda

Embora o foco dos autores não seja o consumo industrial, DERGIADES e TSOULFIDIS (2008){6} apresentam um dos trabalhos mais completos de descrição de demanda, com dados anuais da economia, do clima e do consumo residencial de energia elétrica nos Estados Unidos, entre 1965 e 2006. Para estimar as correlações, foi utilizado o recente modelo econométrico de cointegração, *ARDL – Autoregressive Distributed Lag* – Autorregressivo com Defasagens Distribuídas, com as variáveis especificadas, na Equação 2.1, já considerando seus respectivos logaritmos.

$$CE_t = a_0 + a_1Y_t + a_2PE_t + a_3CH_t + a_4PO_t + a_5S_t + \varepsilon_t \quad (2.1)$$

Em que,

- t período de tempo.
- CE consumo de energia residencial per capita.
- Y renda da população per capita.
- PE preço médio real da energia elétrica para os consumidores residências.
- CH índice anual dos graus Celsius de desvio da temperatura para a média diária.
- PO preço médio do óleo utilizado para aquecimento das residências.
- S nível de ocupação das residências per capita.
- a_0, \dots, a_5 coeficientes do modelo de regressão.
- ε termo de erro estocástico.

Os resultados obtidos na correlação de longo prazo confirmaram as expectativas da teoria econômica. O preço da energia elétrica apresentou elasticidade negativa e próxima à unidade. As demais variáveis correlacionaram-se positivamente para o nível de ocupação das residências, que obteve alta significância com o maior coeficiente. Na Equação 2.2, o melhor modelo econométrico obtido pelos autores, aparecem duas variáveis com termos defasados em dois anos: o próprio consumo de energia residencial per capita e o preço da energia concorrente (óleo). Nos testes de causalidade, na direção do consumo de energia elétrica, foram identificados o desvio das temperaturas e o preço do óleo.

$$CE_t = 1,175CE_{t-2} + 0,273Y_t - 1,065PE_t + 0,726CH_t + 0,199PO_{t-2} + 1,543S_t + \varepsilon_t \quad (2.2)$$

Estudos como este, potencializam a eficácia das políticas do setor elétrico ao estabelecer importantes relações teóricas entre as variáveis explicativas e o comportamento da demanda.

O trabalho apresentado por GARCEZ e GHIRARDI (2003)⁷ considera o mercado de consumidores residenciais de energia elétrica na Bahia, com a aplicação de diferentes modelos econométricos. Partindo do pressuposto que a trajetória do consumo residencial de energia elétrica correlaciona-se numa certa direção com as variáveis explicativas escolhidas, os autores averiguaram a trajetória das séries mensais das mesmas, a saber: tarifa média real da eletricidade, rendimento real familiar e o índice de preço real dos eletrodomésticos. Inicialmente, foi realizada uma etapa de pré-processamento e validação dos dados disponíveis para evitar a obtenção de resultados enganosos. A análise da estabilidade das séries foi realizada com a aplicação dos testes de Dickey-Fuller Aumentado (*ADF*)⁵ para detecção da presença de raiz unitária⁶, revelando que as três variáveis econômicas eram não-estacionárias⁷. Os autores realizaram o teste de Engle & Granger⁸ e verifica-

⁵ Testa a hipótese da estacionariedade da série por meio da estimação do modelo de mínimos quadrados ordinários.

⁶ Uma série possui raiz unitária quando, após a aplicação de uma diferença, o resultado apresentar-se estacionário, ou seja, a o efeito de tendência é predominante na série e não a correlação.

⁷ Uma série temporal é estacionária se sua média e sua variância são constantes ao longo do tempo e se a covariância entre dois valores da série depende apenas da distância no tempo que separa os dois valores.

⁸ Testa a existência de cointegração por meio de uma regressão estática sem defasagens, com ou sem tendência, e do cálculo do respectivo resíduo da série.

ram que apesar da não estacionariedade, as variáveis apresentavam cointegração⁹ de primeira ordem, eliminando o problema da regressão espúria¹⁰ do modelo linear clássico.

A Tabela 2.2 apresenta os valores de elasticidade-preço e elasticidade-renda estimados pelos autores segundo os seguintes modelos de regressão: (1) regressão linear clássica, (2) regressão linear clássica com uso de variável dummy¹¹ em função do início do racionamento de energia elétrica em junho de 2001 que quebrou a estrutura da série de consumo, (3) ajustamento parcial, (4) autorregressivo vetorial – VAR, (5) cointegração de Johansen.

Tabela 2.2 – Elasticidades Preço e Renda do Consumo Residencial de Eletricidade – Bahia.

Modelos de Regressão	Elasticidade-preço	Elasticidade-Renda
Regressão Linear Clássica	-0,072	0,755
Regressão Linear c/ dummy	-0,047	0,390
Ajustamento Parcial	-0,039	0,155
VAR	-0,044	0,126
Cointegração de Johansen	-0,073	0,394

Fonte: GARCEZ e GHIRARDI, 2003.

Apesar da sinalização adequada das elasticidades e a confirmação de que a renda dos consumidores residenciais tem um impacto maior na curva de demanda em relação ao preço da energia elétrica, preocupa o fato da dispersão dos valores encontrados para estes parâmetros por cada técnica, embora em todas elas se obtivesse um bom nível de significância. Nenhum modelo é apontado como melhor ou pior que os demais e as faixas de valores possíveis acabam se tornando o resultado a ser aproveitado.

Considerando os objetivos da presente pesquisa, torna-se mais relevante compreender a elasticidade do comportamento dos consumidores num ambiente de mercado competitivo para a energia elétrica. A partir da experiência pós-liberalização do *Electricity Pool of England and Wales* – EPEW, KIRSCHEN, et al. (2000){8} analisam como a exposição dos consumidores à volatilidade dos preços induz ao ajuste de suas curvas de demanda. Os clientes desse tipo de mercado sujeitam-se a preços diferentes de hora em hora ao longo do dia, resultado do preço *spot* de mercado para cada ponto da curva de preço diária. Fez-se uma distinção entre os efeitos de curto e de longo prazo na reação dos consumidores em função da variação nos preços:

- ➔ Longo Prazo: O preço médio do mercado afeta o nível geral da demanda dos clientes. Diferenças significativas de preço entre o dia e a noite ou entre a semana e o final de semana, por exemplo, poderiam encorajar a instalação de geradores térmicos mais econômicos

⁹ A cointegração implica que duas variáveis compartilhem tendências estocásticas semelhantes e, de fato, como a diferença entre ambas é estacionária, elas nunca divergem muito uma da outra (HILL et al., 2003).

¹⁰ Uma regressão é considerada espúria quando seus resultados são aparentemente significativos a partir de dados não relacionados, principalmente quando se faz análise de regressão com séries não estacionárias.

¹¹ Dummy é uma variável discreta, assume valores de 0 ou 1, utilizada pelos economistas para validar as variáveis quantitativas apenas quando determinadas condições estejam presentes no intervalo de análise do modelo.

cos para uso nos horários de pico. O custo-benefício destas opções de gerenciamento pelo lado da demanda deve ser analisado no longo-prazo.

- ➔ Curto Prazo: O preço da energia para cada período do dia seguinte cria as condições para que os consumidores modifiquem suas curvas de demanda diárias com maior ou menor rapidez e intensidade.

Além do preço da energia elétrica, a modulação da carga ao longo do dia e até dos meses é um fator muito importante para descrição da demanda. Considerando o maior mercado independente de energia elétrica do mundo, o PJM¹², SISWORAHardjo, et. al (2006){9} apresentaram um modelo de regressão não linear para determinar a demanda horária em função da temperatura ao longo do dia. Entretanto, após aplicar a transformada rápida de Fourier, e identificar no espectro as sazonalidades principais (24h, semanal, e semestral), os autores modelaram duas regressões distintas: uma para os finais de semana e outra para os dias de semana. Além disso, as séries temporais eram separadas conforme as quatro estações do ano. Esses cuidados possibilitaram a obtenção de ótimos resultados, em testes de previsão, com erros percentuais absolutos entre 1,8% e 3,3% para as 24h do dia seguinte.

A tarefa de descrição da demanda por eletricidade pode ser realizada também pela análise de variações climáticas ao longo do dia. Segundo SILVA (2002){10} o mercado de energia elétrica é particularmente sensível uma vez que há uma estreita relação entre consumo e temperatura ambiente. O autor demonstrou a existência de uma correlação não linear entre as duas variáveis, a partir dos dados diários, para ao mês de março de 2002, referentes ao consumo de energia elétrica e a temperatura máxima atmosférica na cidade do Rio de Janeiro. Os dados de sábado e domingo foram excluídos da amostra em função do grau de influência diferenciado da temperatura sobre o consumo de energia elétrica nesses dias. Mesmo com um conjunto de dados reduzido, a estatística da regressão foi muito satisfatória, com um coeficiente de determinação múltipla¹³ de 0,7802, conforme a dispersão dos pontos bem próximos à curva no gráfico seguinte.

¹² Mercado livre de energia elétrica que abrange 13 estados norte-americanos com uma capacidade instalada de 163,5 GW, mais 56 mil milhas em linhas de transmissão, para atender uma população de 51 milhões de pessoas.

¹³ Representa a proporção da variação em °C que é explicada pelo conjunto das variáveis explicativas selecionadas.

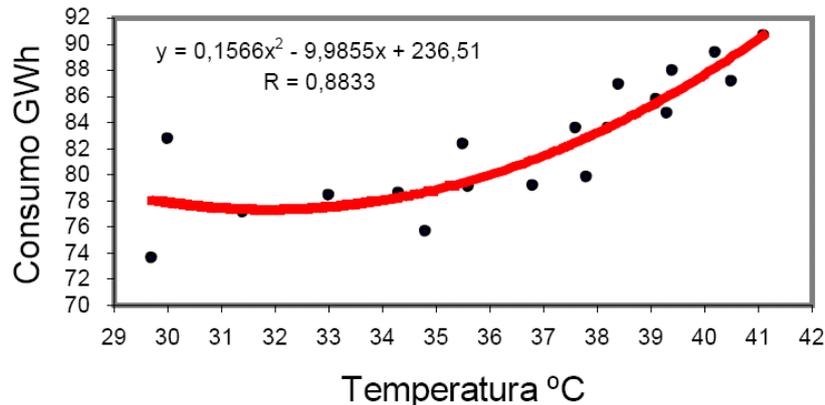


Figura 2.3 – Relação Não-linear entre Consumo e a Temperatura Atmosférica Máxima no RJ.

Fonte: SILVA, 2002.

Apesar da especificidade do exemplo acima para cidade do Rio de Janeiro num mês de março sob a ação de uma forte onda de calor, o comprometimento da demanda com as altas temperaturas ficou bem evidente. No intervalo de 29° até 35° predomina uma zona de insensibilidade com uma correlação praticamente nula, evoluindo posteriormente para uma correlação fortemente positiva. Por outro lado, por meio deste estudo não foi possível atestar o grau de influência das baixas temperaturas no consumo de eletricidade.

Uma análise aprofundada sobre o problema da não-linearidade da resposta da demanda às variações da temperatura foi realizada por MORAL-CARCEDO e VICÉNS-OTERO (2005){11}, para diferentes regiões da Espanha com dados diários de 1995 a 2003. Para a descoberta da correlação entre a demanda e a temperatura, os autores reconhecem a necessidade de um estudo mais desagregado, geográfica e setorialmente (residencial, comercial e industrial), o que não acontece em virtude da agregação dos dados disponíveis. Inicialmente, dois problemas básicos foram solucionados pelos autores: o efeito de calendário e a não-homogeneidade climática territorial.

A curva de demanda diária tem seu comportamento dependente do grau de atividade da população ao longo da semana e nas datas especiais de feriados. Pode-se estabelecer no modelo econométrico uma variável, FDS (fator do dia da semana), para refletir o efeito do calendário sobre a curva de demanda diária. Definiu-se a quarta-feira como o dia com a maior demanda provável da semana (FDS = 1,00) Para o cálculo nos demais dias consideram as seguintes variáveis:

- $D_{d,s}$ – demanda no dia d da semana s ;
- Qua_s – demanda na quarta-feira¹⁴ da mesma semana s ;
- $IVS_{d,s} = D_{d,s} / Qua_s$ – índice de variação dentro da semana s para o dia d ;

Desde que os efeitos de sazonalidade, de temperatura e de condições econômicas tenham uma variação suave, o efeito de calendário pode ser capturado pelo IVS. Por um processo de re-

¹⁴ Se a quarta-feira ocorrer em data de feriado o modelo utiliza a demanda média dos dias úteis anterior e posterior.

gressão, em que cada dia da semana e feriados podem ser representados por variáveis dummy, pôde-se agrupar os dias da semana com IVS mais similares dentro da amostra. O conhecimento do FDS dos dias no período de estudo e sua inclusão no modelo de regressão permitiram a análise da influência da temperatura na demanda para todo o conjunto de dados, livre da influência do calendário. A Tabela 2.3 apresenta alguns valores encontrados pelos autores para o efeito do dia da semana nos agrupamentos mais similares.

Tabela 2.3 – Alguns exemplos de FDS para dias normais e feriados – Espanha.

Tipo de Dia	Segunda	Terça	Quarta	Quinta	Sexta	Sábado	Domingo
Dias Normais	0,97	1,00	1,00	1,00	0,99	0,88	0,78
1º de janeiro				0,67			
1º de maio		0,72		0,76		0,79	0,72
12 de outubro	0,76		0,82			0,83	0,76
25 de dezembro				0,66			
31 de dezembro			0,75			0,71	

Fonte: Adaptado de MORAL-CARCEDO e VICÉNS-OTERO, 2005.

Como os consumidores estão distribuídos espacialmente, em diferentes localidades na Espanha, sob condições climáticas próprias, não seria conveniente supor que a relação temperatura-demanda seja estimada uniformemente. Assim, as seguintes medidas foram tomadas:

- i. Determinação de zonas geoclimáticas homogêneas. Com base na temperatura média diária registrada por 47 estações meteorológicas, os autores identificaram, através do processo de clusterização, 7 zonas geoclimáticas homogêneas;
- ii. Foi escolhida uma estação meteorológica mais central nas zonas geoclimáticas para representar a temperatura de influência na demanda daqueles consumidores;
- iii. Cálculo de um indicador para a temperatura de influência na demanda de eletricidade, considerando todo o país. Os autores utilizaram a população de cada zona como peso na média ponderada da temperatura nas sete zonas.

O cruzamento dos dados sobre a componente não residual da demanda de energia elétrica e a temperatura média diária para o período de cinco anos, apresentado na Figura 2.4, demonstra a existência de um comportamento não-linear entre as duas grandezas. A região de inflexão tem especial importância. Pois, mais precisamente no entorno da temperatura de limiar, a direção da elasticidade da demanda se inverte.

Para a descoberta da correlação entre a demanda e a temperatura os autores implementaram o modelo de regressão *LSTR* (*logistic smooth transition regression*) que possibilita representar adequadamente a mudança do comportamento da demanda com a temperatura.

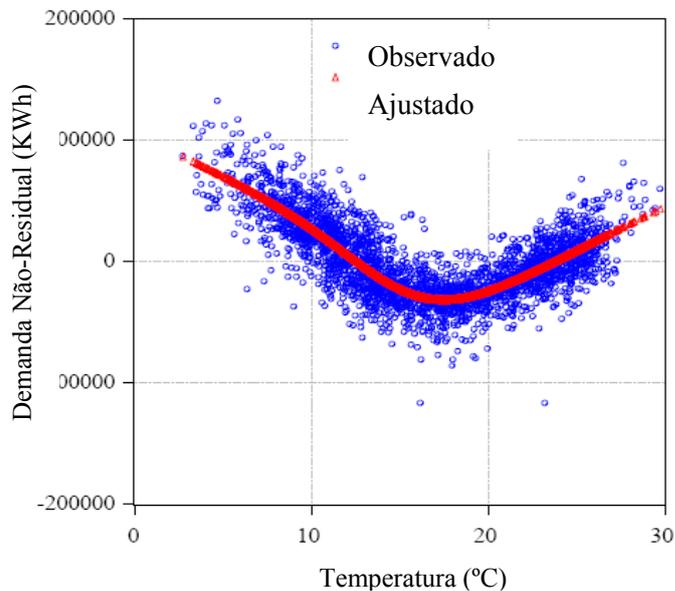


Figura 2.4 – Comportamento Não-Linear da Demanda com a Temperatura na Espanha.

Fonte: MORAL-CARCEDO e VICÉNS-OTERO, 2005.

BESSEC e FOUQUAU (2008){12} descreveram a não-linearidade entre a temperatura e o consumo de energia elétrica, considerando duas décadas de informações de 15 países do continente europeu. Seguindo uma metodologia similar à utilizada no caso espanhol, os autores conseguiram identificar relações bem distintas, entre a temperatura média e o consumo, para os países da região norte, onde o aquecimento das residências é o fator significativo, em comparação com aqueles da região sul do continente, que sofrem o efeito tanto do calor quanto do frio. Devido à abrangência do estudo, os autores reafirmam o papel determinante da temperatura como fator de sensibilidade do consumo de energia elétrica, especialmente nas regiões de maior amplitude térmica.

Como o mercado de energia elétrica é composto por um mix de consumidores, com padrões distintos de elasticidade ou capacidade de adequação da produção, o conhecimento mais próximo da dinâmica de comportamento dos clientes torna-se cada vez mais relevante no dia a dia das empresas comercializadoras de energia elétrica. Quando o objetivo é descrever a demanda por eletricidade no longo prazo, para um país, região ou até mesmo para uma carteira de clientes, as mudanças estruturais no consumo podem ser consideradas. Na maioria das vezes, este processo é bem lento e necessita de um distanciamento de vários anos para que as análises sejam mais robustas, e capazes de captar a transformação estrutural do consumo de eletricidade. CHOW (2001){13} apresenta uma análise dos fatores que transformaram completamente o consumo de eletricidade de Hong Kong de 1984 até 1999. A rápida integração de Hong Kong na economia chinesa após a política de abertura adotada por Pequim a partir de 1979, elevou a participação do PIB do setor terciário de 67,5% em 1980 para 85,2% em 1997. Os segmentos bancário, transporte e comércio foram os responsáveis pelo avanço da economia preterindo os setores primário (menos de 1%), secundário (14,7%) e de manufaturados (6,5%). Além da migração de várias indústrias para a Chi-

na e do elevado crescimento do segmento de transportes do país, ocorreram políticas de expansão da ocupação populacional e um aumento no número de domicílios por habitante. Como reflexo dessas mudanças estruturais, pode-se observar na Tabela 2.4 as mudanças significativas na participação dos setores residencial, comercial e industrial no consumo de eletricidade num intervalo de apenas 15 anos. Em valor absolutos, por exemplo, o consumo anual da indústria reduziu de 0,91 GWh em 1984 para 0,68 GWh em 1999.

Tabela 2.4 – Evolução da Participação dos Setores no Consumo de 1984 a 1999 – Hong Kong.

Anos	Residencial (%)	Comercial (%)	Industrial (%)
1984	20	46	34
1988	21	46	33
1992	23	51	26
1996	26	57	18
1999	25	61	14

Fonte: Adaptado de CHOW, 2001.

Mudanças estruturais muito rápidas estão mais sujeitas a acontecer nos países ou mercados menores em função da complexidade e da inércia próprias das políticas de planejamento de longo prazo. Hong Kong é uma ilha bem localizada que experimentou em duas décadas um crescimento médio real de 6% do PIB ao ano e de 4% per capita.

Das variáveis econômicas consideradas no processo de compreensão da demanda por eletricidade, o crescimento da economia é provavelmente a mais estudada. O papel da eletricidade na sociedade moderna possibilita medir o desenvolvimento de um país ou região. Uma questão complexa sobre a causalidade da relação energia elétrica versus PIB (EE-PIB) vem sendo estudada em diversos países pela aplicação de métodos econométricos com resultados quase sempre conflitantes. Um estudo realizado por GHALI e EL-SAKKA (2004){14}, com dados da economia canadense de 1961 a 1997, refuta com veemência a hipótese clássica de neutralidade da relação EE-PIB e demonstra a causalidade bidirecional existente nesse período. Ou seja, tanto o crescimento da economia induz ao aumento do consumo de energia elétrica quanto é induzido por ele, embora as intensidades possam ser diferentes. PAUL e BHATTACHARYA (2004){15} demonstram por meio da técnica de cointegração de Engle-Granger que existe uma causalidade bidirecional na relação EE-PIB entre 1950 e 1996 na Índia, além de ressaltar que estudos semelhantes sobre a economia indiana revelam quase sempre resultados conflitantes.

A priori, a existência da relação EE-PIB, sua intensidade e direção podem ser atribuídas às características do estágio de crescimento econômico dos países em determinados períodos de análise. Ainda assim, a complexidade do tema requer muito cuidado antes que se estabeleçam expectativas claras sobre o papel da energia elétrica no desenvolvimento da economia, e vice-versa. (CHONTANAWAT, et al, 2006){16}.

O uso da econometria com o objetivo de explicar o comportamento da demanda exige conhecimento profundo dos planejadores para que se obtenham resultados confiáveis e significativos. A mera replicação de equações com uso de séries históricas não tem grande importância como conhecimento científico. ZARNIKAU (2003){17} analisa diversas modelagens para equações de demanda e alerta sobre o cuidado que se deve ter quanto às interpretações de correlações entre as variáveis, expectativas de demanda, e outras conclusões, após verificar em testes a baixa qualidade alcançada por vários modelos econométricos para descrição e/ou previsão.

Os métodos tradicionais para descrição da demanda e os problemas por eles aqui abordados desafiam os planejadores do mercado de energia elétrica à complexa tarefa de compreensão do comportamento do consumidor à luz da dinâmica de seus fatores de influência, sejam eles oriundos da economia, do clima ou da intensidade energética.

2.3.2 A Descrição da Demanda Desagregada

Essa seção apresenta um resumo de alguns trabalhos que, por meio da desagregação, procuram compreender melhor o comportamento da demanda de energia elétrica. Serão apresentadas análises sobre a evolução da intensidade energética em alguns países, devido às mudanças estruturais da economia, ou em função de variáveis climáticas ou socioeconômicas.

Segundo ANG (1995){18}, o principal objetivo dos estudos mais desagregados é estimar o impacto de mudanças estruturais da cadeia produtiva na demanda por energia. Utilizando dados sobre o consumo de energia e a produção industrial de Singapura entre 1982 e 1990, o autor analisou a variação do consumo e da intensidade energética para diferentes níveis de agregação de 28 segmentos. O primeiro nível separava os segmentos em dois grupos conforme a intensidade energética; o segundo nível era composto por três grupos intensivos: metálicos, não metálicos e a química, e dois grupos não intensivos: construção civil e os demais segmentos. Assim, sucessivamente, até que cada segmento formasse um grupo no quinto nível. Os resultados para os diferentes níveis de desagregação mostraram que, no geral, os segmentos mais intensivos têm conseguido uma maior eficiência energética de 1984 até 1990, enquanto os demais apresentam uma tendência de crescimento leve da intensidade energética no período.

Com o objetivo de contribuir ao debate sobre a evolução da eficiência energética nos Estados Unidos, e demonstrar a necessidade de desagregação dos setores da economia para a realização dos estudos, MURTISHAW e SCHIPPER (2001){19} analisam a relação $\frac{E}{PIB}$ segundo três fatores: atividade econômica, aspectos estruturais da economia e a intensidade energética de cada setor. Após o estudo com 11 setores da economia americana de 1988 a 1998, os autores constataram que a eficiência energética dos setores passou a ter menor influência que as mudanças estruturais nos últimos anos, em relação à melhoria da intensidade energética. A consolidação da internet e das tecnologias da informação foram as grandes responsáveis pelo crescimento do valor agregado dos

produtos no segmento de manufaturados, em função da diminuição da demanda por serviços mais intensivos. Os autores destacam ainda dois fatos interessantes: o pioneirismo da proposta de desagregação dos segmentos da economia americana para análise da eficiência energética, e a “enorme” dificuldade para obtenção de dados sobre o setor energético daquele país.

STEENHOF (2006){20} estudou o comportamento da demanda de energia elétrica para 37 segmentos industriais da China. Foi considerada a mesma decomposição de fatores do trabalho anterior, mais a variação no preço dos combustíveis. A participação da eletricidade na matriz energética do setor industrial chinês tem crescido em ritmo acelerado, passando de 24,3% em 1980 para 43,6% em 2002. No mesmo período, nota-se uma redução da intensidade energética nos segmentos industriais, devido em parte às políticas de estado para o setor de energia, mas que ainda mantém o país com um “gigantesco” potencial para melhoria da eficiência energética. A abertura da economia, que impulsionou fortemente a atividade econômica do país e elevou os preços dos combustíveis fósseis, afetou sobremaneira a demanda chinesa por eletricidade nos últimos 20 anos. Apesar dos resultados do processo de decomposição apresentarem características próprias para cada segmento industrial analisado, de 1988 a 1998, pode-se observar o seguinte panorama para evolução do consumo de energia elétrica da indústria chinesa como um todo:

- i. O rápido crescimento da atividade econômica foi o maior responsável pelo crescimento da demanda por energia elétrica no setor industrial do país;
- ii. O crescimento foi acompanhado de perto pelas mudanças estruturais da economia, do ganho de eficiência da cadeia produtiva, e em menor grau da variação do preço dos combustíveis fósseis;
- iii. Para o atual estágio de industrialização da economia chinesa, a melhoria da eficiência energética tem um papel mais importante no comportamento da demanda por eletricidade no setor do que as mudanças estruturais.

Pode-se notar um contraste na caracterização da relação existente entre a demanda e a intensidade energética, na comparação das indústrias norte-americanas e chinesa nos últimos anos. Os efeitos, estrutural da economia e da redução da intensidade energética, assumem ordens de relevância invertidas para o entendimento da evolução da demanda nos dois países.

Segundo MIKETA e MULDER (2005){21}, essas diferenças ocorrem entre países e entre segmentos industriais. A razão disso estaria no processo de evolução tecnológica e de agregação de valor aos produtos. Com o objetivo de analisar o grau de independência entre os segmentos industriais de diferentes países, em relação ao nível de eficiência energética e os fatores mais importantes relacionados, os autores analisaram 10 setores da economia em 56 países, sendo 32 menos industrializados e 24 industrializados, no período de 1971 a 1995. Os seguintes aspectos ajudam a entender melhor a intensidade energética no âmbito da descrição da demanda desagregada:

- i. A intensidade energética dos países em desenvolvimento tem sido reduzida mais rapidamente do que nos países industrializados, que por sua vez apresentam os melhores níveis de efficientização energética;
- ii. A eficiência energética de um segmento industrial está bem mais relacionada com a eficiência energética do país do que com a eficiência energética média do segmento industrial no mundo;
- iii. O comportamento da demanda não deve ser analisado desconsiderando-se o processo de difusão das tecnologias e de conhecimento dentro dos segmentos industriais dos países.

O potencial para efficientização energética para o setor industrial no Brasil foi analisado por RAFAEL (2004){22} considerando as características próprias do uso final da energia elétrica de cada segmento da indústria. O objetivo do trabalho era “a inserção dos valores associados com a preservação e a racionalização na utilização dos recursos naturais para a produção de serviços energéticos necessários ao desenvolvimento industrial e social”. Apesar do foco principal do autor, a questão da sustentabilidade do uso da energia elétrica, seu trabalho revela como a segmentação do setor industrial pode ser benéfica para a qualidade do estudo.

O Ministério de Ciência e Tecnologia da Espanha patrocinou uma pesquisa a fim de determinar quais os “setores chaves” no consumo de energia final naquele país (ALCÁNTARA e PADILLA, 2003){23}. A partir do modelo matemático de Insumo-Produto desenvolvido por Leontief¹⁵, os autores puderam estabelecer as elasticidades de consumo, desagregado nos 18 setores da economia selecionados, bem como seu impacto entre os setores. Como resultado, foi possível estabelecer quais setores são mais importantes para induzir o consumo dos demais (elasticidade-própria) e quais são mais induzidos ao consumo, quando a economia como um todo se movimenta (elasticidade-distribuída). Os resultados obtidos podem auxiliar na definição da política energética a ser adotada para cada setor da economia.

Com foco nas políticas governamentais do setor energético e seus efeitos nas mudanças climáticas, AGNOLUCCI (2009){24} descreveu a demanda de vários setores industriais da Alemanha e Reino Unido no período de 1978 à 2004. Além de justificar a importância da abordagem da demanda de forma desagregada, o autor identifica a diversidade na elasticidade-preço nos diferentes segmentos da indústria. O nível de atividade econômica também influencia positivamente o consumo de energia elétrica, em níveis característicos de cada segmento analisado. O autor conclui o trabalho sugerindo adoção de uma política tributária mais austera para redução do consumo de energia elétrica no setor industrial, dada sua considerável elasticidade-preço.

Um modelo de descrição da demanda e dos preços da eletricidade nos setores residencial e industrial dos Estados Unidos foi apresentado por KAMERSCHEN e PORTER (2004){25}, com

¹⁵ Ganador do Prêmio Nobel de Economia em 1973 em reconhecimento ao seu modelo que estabelece as relações existentes entre bens diferentes e setores diferentes da cadeia produtiva.

base em dados climáticos e socioeconômicos anuais entre 1973 e 1998. Para descrever o comportamento das variáveis dependentes foi proposto um sistema de equações simultâneas com a mesma forma para os dois setores¹⁶:

$$\begin{cases} \ln Q = \alpha_1 + \alpha_2 \cdot \ln PE + \alpha_3 \cdot \ln PIB + \alpha_4 \cdot \ln GN + \alpha_5 \cdot \ln DTA + \alpha_6 \cdot \ln DTB + \varepsilon \\ \ln PE = \beta_1 + \beta_2 \cdot \ln Q + \beta_3 \cdot \ln MO + \beta_4 \cdot \ln CC + \beta_5 \cdot \ln TJ + \varepsilon \end{cases} \quad (2.3)$$

Em que,

Q Demanda de energia elétrica média do setor dividida pelos consumidores;

PE Preço marginal da energia elétrica para o setor, deflacionado pelo PIB;

GN Preço real do gás natural;

DTA Dias de temperatura alta no ano – acima de um limiar pré-definido;

DTB Dias de temperatura baixa no ano – abaixo de um limiar pré-definido;

MO Custo da mão de obra para o ano;

CC Custo de uma cesta de combustíveis no ano;

TJ Taxa de juros média no ano;

α_i e β_i Coeficientes das equações simultâneas, representam a medida da correlação;

ε Componente residual das equações.

Os resultados obtidos pelos autores apresentaram altos níveis de determinação múltipla tanto para a equação de demanda quanto para a equação do preço. A maior contribuição do trabalho foi a constatação do menor grau de elasticidade dos consumidores industriais frente às variações de temperatura ou de preço da energia elétrica, em comparação com os consumidores residenciais. Além disso, os anos mais frios apresentaram maior influência sobre a demanda das residências que os anos mais quentes. Este fato pode ser observado nas equações ajustadas para cada setor por meio da modelagem.

➤ Sistema de Equações para o Setor Residencial:

$$\begin{cases} \ln Q = 8,10 - 0,94 \cdot \ln PE + 0,65 \cdot \ln PIB + 0,34 \cdot \ln GN - 0,04 \cdot \ln DTA + 0,14 \cdot \ln DTB + \varepsilon \\ \ln PE = 1,92 - 0,22 \cdot \ln Q + 1,29 \cdot \ln MO + 0,33 \cdot \ln CC - 0,30 \cdot \ln TJ + \varepsilon \end{cases} \quad (2.4)$$

➤ Sistema de Equações para o Setor Industrial:

$$\begin{cases} \ln Q = 12,5 - 0,35 \cdot \ln PE + 0,24 \cdot \ln PIB + 0,01 \cdot \ln GN - 0,06 \cdot \ln DTA - 0,03 \cdot \ln DTB + \varepsilon \\ \ln PE = -4,70 - 0,03 \cdot \ln Q + 1,71 \cdot \ln MO + 0,75 \cdot \ln CC - 0,09 \cdot \ln TJ + \varepsilon \end{cases} \quad (2.5)$$

Na indústria de gás natural, a descrição do consumo para o setor industrial também é um importante pré-requisito para as decisões do planejamento e da operação dos sistemas. ÚBEDA e BERZOSA (2007) {26} apresentam um novo modelo de decomposição para descrever e prever o

¹⁶ Apenas a demanda e o preço da eletricidade utilizados no modelo são característicos de cada setor.

consumo de gás natural da Enagas/Espanha, para até três anos à frente. O diferencial da proposta está na capacidade do modelo de decomposição (tendência e sazonalidades ao longo dos anos, das semanas e do dia) em descrever o perfil de consumo dos 22 segmentos da indústria analisados.

Uma estimativa da relação preço-demanda para o gás natural no Estado de Santa Catarina, considerando as características próprias dos segmentos industriais de 2001 a 2002, foi realizada por ANDRADE, et al. (2004a){27}. No estudo de caso sobre a demanda do segmento cerâmico, por exemplo, foi estabelecida a seguinte equação de regressão múltipla:

$$VOL = 0,79 - 0,65 \cdot PGN + 0,15 \cdot DMM - 0,02 \cdot IGPM + 0,002 \cdot INCC + 0,001 \cdot TCE \quad (2.6)$$

Em que,

VOL volume de GN consumido no mês pelo segmento cerâmico;

PGN preço médio mensal do GN para o segmento cerâmico;

DMM dólar médio mensal;

IGPM índice geral de preços da Fundação Getúlio Vargas;

INCC índice nacional do custo da construção civil;

TCE toneladas de cerâmica exportada.

Conforme a Equação 2.6, os aumentos de preço do gás e da taxa de inflação provocam uma diminuição no consumo de GN do setor cerâmico. Por outro lado, a apreciação do dólar, o aquecimento do mercado interno e o acréscimo nas exportações favorecem o consumo de GN pela indústria cerâmica. Do ponto de vista da teoria econômica, as afirmações acima fazem sentido, porém a qualidade do ajuste na regressão, com vistas à previsão, deixou a desejar. O autor obteve um coeficiente de determinação múltipla da ordem de 56%. Apesar do conjunto limitado de dados para um estudo desta magnitude, o trabalho incentiva a inclusão de variáveis próprias de cada segmento da indústria para o processo de descrição da demanda, seja por gás natural ou por energia elétrica.

2.3.3 Descrição da Demanda no Contexto do KDD

Algumas técnicas de KDD são implementadas com sucesso em tarefas que auxiliam no processo de descrição da demanda. As tarefas de clusterização e classificação de consumidores têm sido utilizadas no setor elétrico para subsidiar as mais diversas ações de planejamento das empresas, principalmente nas áreas de comercialização e marketing. Nessa seção serão apresentadas algumas abordagens com técnicas de KDD, que ajudam a compreender melhor o comportamento da demanda por energia elétrica.

PITT e KIRSCHEN (1999){28} defendem o processo de descrição da demanda como base para a estrutura tarifária no mercado britânico. Entretanto, os autores ressaltam as dificuldades inerentes aos bancos de dados das empresas distribuidoras de energia elétrica: grande dimensão, dados inconsistentes ou ruidosos, dados incompletos ou inexistentes e a esparsidade. Somam-se a

esses fatos, a complexidade, a não-linearidade e as interações mútuas da relação entre a curva de demanda e os fatores como clima, horário do dia, período do ano e as características de cada consumidor. Neste sentido, os autores consideraram a mineração de dados (*data mining*) a técnica mais adequada para extrair conhecimento útil em relação aos perfis dos consumidores.

Um algoritmo otimizado para mineração dos dados disponíveis foi testado para o seguinte conjunto de dados: (a) 500 consumidores industriais com medição de meia em meia hora (outubro de 1994 a abril de 1995); (b) dados horários da temperatura, velocidade do vento, umidade do ar; (c) fator de carga, tarifa e atividade econômica dos consumidores. Foram realizados diferentes tipos de agrupamento dos consumidores, conforme as variáveis consideradas e o nível de representatividade desejado, formando diferentes árvores de decisão. Os resultados demonstraram que os seguintes fatores são preponderantes na classificação dos perfis de demanda, por ordem de importância: o dia (da semana ou de final de semana), o fator de carga, atividade econômica e o tipo de tarifa.

A privatização do setor de distribuição de energia elétrica no reino Unido, em meados da década de 90, mudou radicalmente a relação comercial entre as empresas e seus clientes, antes cativos, que se tornaram livres. Em abril de 1994 o limite mínimo de demanda para enquadramento no mercado livre foi reduzido de 1 MW para 100 kW. Segundo BIRCH, et al. (1996){29} este ambiente regulatório fez surgir uma grande variedade de tarifas nas empresas comercializadoras de eletricidade devido à competitividade. Porém, o rápido crescimento do mercado causou problemas relevantes no processo de contratação entre as partes. Havia muitas informações inválidas, cobranças incorretas, e dados pouco confiáveis sobre os perfis de demanda, etc. Para subsidiar os estudos tarifários para este tipo de mercado, os autores defendiam a aplicação de tarifas que considerassem o perfil da demanda como fator altamente relacionado aos custos para seu atendimento. Como um primeiro passo, para o reconhecimento dos diferentes perfis de demanda dos consumidores, os autores propõem a clusterização e a classificação das curvas de carga diárias em duas categorias, dia de semana e final de semana, utilizando lógica *fuzzy*. Obtiveram acerto de 96,7% para os dias de verão e de 81,13% no dias de inverno.

Com o propósito de verificar quais os perfis de demanda representativos para uma amostra dos grandes consumidores de energia elétrica das Centrais Elétricas de Santa Catarina – CELESC S.A., ANDRADE (2003){30} implementou uma técnica de clusterização híbrida¹⁷. Para identificar e agrupar 442 consumidores, a partir do cálculo do desvio padrão para diferença dos perfis de demanda dos consumidores. Estes níveis de similaridade, calculados dois a dois, definiram uma matriz de similaridade, base do processo de aglutinação dos perfis semelhantes que formam as topologias apresentadas na Figura 2.5.

A necessidade de aprimoramento da estrutura tarifária do setor elétrico brasileiro por meio da implantação de novos agrupamentos tarifários, em função dos perfis de demanda dos consumi-

¹⁷ Parte hierárquica, com aglutinação livre dos consumidores calculados na matriz de similaridade; e não hierárquica que promove os cortes na árvore de similaridade reduzindo o número de grupos.

dores, é defendida por ANDRADE, et al. (2004b){31}. Além de mais justa, em relação aos custos impostos ao sistema, esta solução poderia melhorar a compreensão do comportamento do consumidor, com a conseqüente exploração da sua heterogeneidade por parte das empresas do setor.

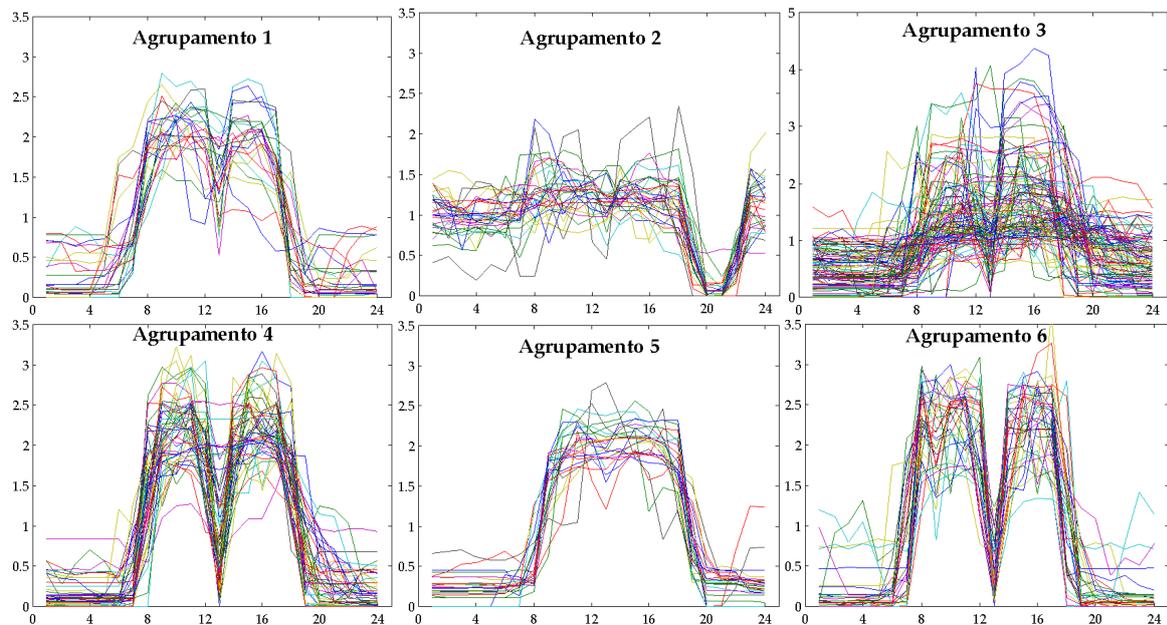


Figura 2.5 – Exemplo de Agrupamentos por Perfil de Demanda – Grupo A4 da Celesc S.A.

Fonte: Adaptado de ANDRADE, 2003.

A desregulamentação parcial do mercado de energia elétrica no Japão, a partir de março de 2000, induziu as empresas à formação de estratégias de marketing para a conquista de novos clientes, ou simplesmente, para a manutenção da carteira de suprimento. Nesse contexto, o conhecimento do comportamento dos consumidores tornou-se peça chave na competição entre as comercializadoras. KITAYAMA, et al. (2002){32} defendem a implantação do *Customer Relationship Management - CRM*, característico das grandes empresas do varejo de produtos, no mercado de energia elétrica. Os autores apresentam um modelo de estratégias de marketing para definição do perfil dos consumidores, baseado em técnicas de mineração de dados, focado em duas variáveis: a demanda e o fator de carga. Os clientes com maior demanda e maior fator de carga, por exemplo, deveriam ser atendidos pessoalmente com produtos e serviços adicionais, além da concessão de descontos diferenciados por serem os mais rentáveis para a empresa.

O processo de caracterização da carga dos consumidores deve considerar, além da técnica de clusterização, todo o processo de manipulação dos dados disponíveis. Segundo FIGUEIREDO, et al. (2005){33} o ambiente competitivo dos mercados aumentou significativamente o montante de dados armazenados sobre seus participantes, e as ferramentas aptas para extrair conhecimento útil desses bancos de dados podem ser um grande diferencial para as empresas comercializadoras. Os autores realizaram a caracterização da carga de 165 consumidores de média tensão da EDP –

Eletricidade de Portugal, por meio da aplicação dos procedimentos de KDD. A Figura 2.6 apresenta o diagrama geral do trabalho. Pode-se observar os cuidados com a seleção dos dados e com o pré-processamento, para eliminação de inconsistências antes da formação do conjunto de perfis de carga que serão utilizados nos processos de clusterização e classificação.

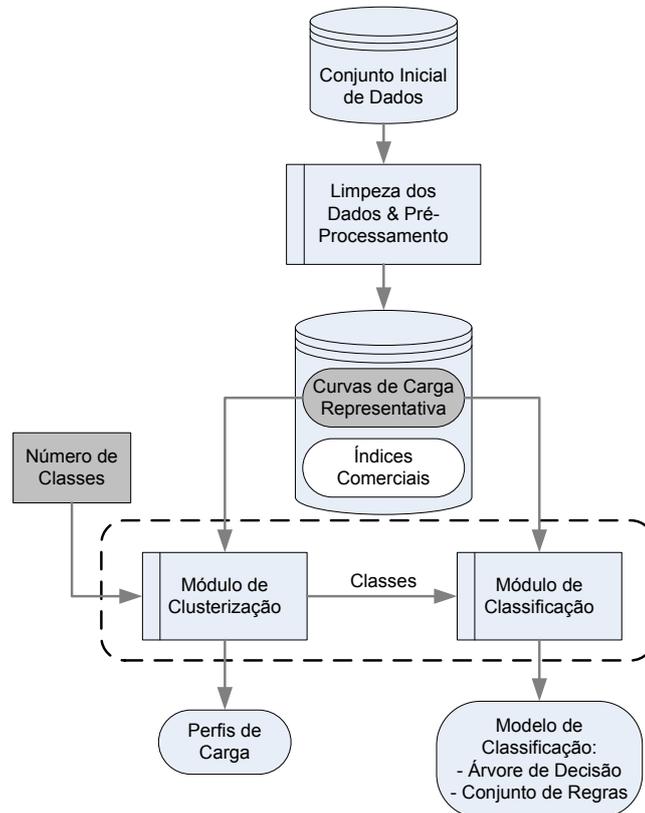


Figura 2.6 – Procedimentos de KDD para a Caracterização dos Consumidores.

Fonte: FIGUEIREDO et al., 2005.

Após a formação dos grupos de consumidores, o módulo de classificação tem o objetivo de estabelecer regras para que novos clientes sejam agrupados corretamente. Para isso consideram-se como variáveis de entrada do algoritmo de classificação C5.0 os indicadores comerciais como contrato e atividade econômica e alguns parâmetros sobre a forma das curvas de carga: (1) fator de carga; (2) fator noturno – demanda média das 23h as 7h em relação à demanda equivalente do dia; (3) fator almoço – demanda média das 12h as 15h em relação à demanda equivalente do dia. A saída desse algoritmo revelou, para os dias de semana, um conjunto de 13 regras para a definição do grupo de cada novo perfil apresentado com um acerto de 81%, enquanto que para os finais de semana 15 regras e 74% de acerto.

A tendência de liberalização dos mercados de energia elétrica e o aumento da competitividade fizeram crescer ainda mais a disputa por novos produtos, tarifas, e estratégias de marketing, inclusive para os consumidores de baixa tensão. A instalação de medidores de demanda eletrônicos para os consumidores residenciais ainda é tema de discussão no aspecto técnico-econômico em

vários países. Uma forma inteligente de contornar em parte este problema é a aplicação de técnicas de classificação dos perfis de carga dos consumidores por meio de dados já conhecidos pelas empresas distribuidoras de energia elétrica. CHANG e LU (2003){34} implementaram a clusterização e a classificação de um conjunto de 300 curvas de carga de consumidores de baixa tensão (220V) da TPC – *Taiwan Power Company*. A definição dos grupos típicos foi realizada por meio da técnica *Fuzzy k-means*. Já a classificação de cada perfil no grupo mais adequado foi conseguida com a modelagem de uma rede neural artificial (RNA) com as características da Tabela 2.5.

Tabela 2.5 – Características da RNA para Classificação dos Consumidores – Taiwan.

Parâmetros	Descrição
Entradas	Dois neurônios para as séries de consumo mensal e a variação do consumo mensal durante um ano normalizada pelo consumo em janeiro
Aprendizado	Algoritmo de retropropagação dos erros
Função de Ativação	Log-sigmoidal.
Camada Intermediária	Composta de 22 neurônios, após uma série de testes
Saídas	N neurônios, conforme o número de grupos do processo de clusterização, que indicam o grau de pertinência do perfil testado em relação ao grupo correspondente

Fonte: Adaptado de CHANG e LU, 2003.

A ideia dos autores, sobre a existência de uma correlação entre as curvas de carga diárias e o consumo ao longo do ano, foi bem sucedida para as amostras testadas. A menor taxa de acerto do processo de classificação foi de 92,2% quando 6 grupos foram considerados e de 97,0% quando 5 grupos foram considerados. Esse procedimento abriria caminho para novas estruturas tarifárias neste nicho de mercado, ainda muito incipiente no setor elétrico.

2.4 PREVISÃO DA DEMANDA

A relevância dos modelos de previsão de demanda tem sido enaltecida consideravelmente em diferentes aplicações, dentro do cenário energético mundial nos últimos anos. A necessidade das empresas do setor elétrico em antecipar os eventos futuros, para se posicionar corretamente no presente, tornou-se vital para gestão de seus negócios num ambiente cada vez mais competitivo. Previsões precisas permitem otimizar a produção, os custos de geração, transmissão e distribuição, as trocas de energia entre as companhias, provendo maior segurança, confiabilidade e economia na operação do sistema (OLIVEIRA e WAZLAWICK, 2004){35}. Para o atual estágio regulatório do setor elétrico brasileiro, as técnicas de previsão tornam-se úteis, não só para as empresas geradoras, transmissoras, distribuidores e grandes consumidores, mas também para os novos entes: ONS, CCEE, EPE, comercializadoras, autoprodutores e produtores independentes. Conforme KHOTANZAD et al. (2002){36}, as previsões podem ser consideradas em diversas decisões operacionais das empresas. Entre elas destacam-se: otimização da capacidade de geração e dos estoques de combustíveis, definição das melhores opções para os contratos de compra e venda de energia elétrica para um mercado de preços sensíveis. Além disso, se vista pelo lado da demanda, a acurácia da previsão proporciona melhores índices de qualidade e continuidade dos serviços.

O ponto de partida de um sistema de previsão de demanda é a consideração dos fatores que provavelmente são os responsáveis pelo comportamento da mesma no horizonte de estudo. Neste sentido, os principais fatores que podem contribuir são (CAVALLARO, 2005){37}:

- ➔ Efeitos de Calendário: diferentes demandas no inverno e verão, início e fim do período escolar no ano, a curva de carga diária, ciclos semanais com carga diferenciada nos finais de semana, datas festivas como Natal, Reveillon, e etc;
- ➔ Efeitos Econômicos: períodos de recessão ou expansão, novos centros industriais, variação nos preços da energia elétrica, gerenciamento pelo lado da demanda, etc;
- ➔ Efeitos Meteorológicos: temperaturas médias e máximas, níveis de umidade do ar, cobertura de nuvens, tempestades, neve, entre outros;
- ➔ Eventos Randômicos: importantes transmissões de TV, eventos esportivos, entrada e saída de operação de grandes indústrias eletrointensivas, etc.

Segundo BAO (2002){38}, existem na literatura dois tipos básicos de previsão de demanda. Se o objetivo do modelo for estudar os futuros padrões de demanda em uma região específica, estado ou país, trata-se de uma previsão espacial. Nesse caso, as características peculiares de cada região, como clima e/ou economia, podem ser incorporadas para a melhoria dos resultados. Já a previsão temporal implica a definição de uma base de tempo adequada aos objetivos pretendidos, podendo ser de minutos, horas, dias, meses ou anos. Os objetivos citados não são excludentes. De

certa forma, a metodologia da presente tese contempla em parte a questão espacial, ao considerar os efeitos do clima de diversas regiões do país sobre o consumo do segmento têxtil, e a questão temporal do processo de previsão, ao permitir estimativas sobre o consumo de energia elétrica dos segmentos industriais para os meses seguintes.

Pode-se considerar a existência de quatro horizontes de tempo típicos de previsão: (Mc CAFFEIRTY e BEATTIE, 1991) e (CAVALLARO, 2005){39}:

- *VSTLF – very-short-term load forecasting*: a previsão de curtíssimo prazo. Considera um período de tempo de alguns minutos à frente, e aplica-se nos procedimentos mais detalhados da área de operação das empresas;
- *STLF – short-term load forecasting*: a previsão de curto prazo. Objetiva um período de tempo de algumas horas até uma semana a diante, e aplica-se nos procedimentos operacionais de alocação da geração e atendimento aos picos de demanda;
- *MTLF – medium-term load forecasting*: a previsão de médio prazo. Pode considerar desde algumas semanas até um ano como período de tempo à frente. Aplica-se em estudos tarifários, no planejamento da produção e/ou comercialização, intercâmbios de energia, e na formação dos estoques de combustíveis para geração;
- *LTLF – long-term load forecasting*: a previsão de longo prazo. Considera de alguns anos até uma ou duas décadas como horizonte de tempo à frente. Aplica-se ao planejamento estratégico das empresas do setor, ajudando a dimensionar os negócios no futuro (usinas, subestações, redes de transmissão e distribuição) de forma a minimizar os custos e maximizar os benefícios.

A metodologia para a previsão de demanda de energia elétrica, proposta neste trabalho para um horizonte de médio prazo, considera diversos efeitos que podem contribuir para as mudanças no comportamento dos consumidores dos setores industriais. A grande contribuição do trabalho está na aplicação de modernas técnicas de previsão que consideram as variáveis econômicas e climáticas, próprias da dinâmica de cada segmento industrial. Na continuação desta seção discorre-se sobre alguns trabalhos de previsão de demanda utilizando métodos tradicionais (estatística, séries temporais, econometria, modelos dinâmicos, etc.), outros mais recentes baseados em tarefas de descoberta de conhecimento em base de dados (redes neurais artificiais, lógica fuzzy, algoritmos genéticos e *data mining*). As referências ao longo de cada subseção foram ordenadas conforme os respectivos horizontes de estudo, do longo até o curto prazo.

2.4.1 Projeção de Demanda X Previsão de Demanda

Antes de proceder à análise dos trabalhos de previsão de demanda para o setor elétrico, surge a necessidade de estabelecer uma distinção mais clara para a sutil diferença das palavras

projeção e previsão no âmbito do planejamento energético. Do ponto de vista etimológico, a projeção pode ser entendida como “lanço, ação de estender, prolongamento, lançar para diante”. Já a previsão refere-se às ações de “ver antes, perceber, descobrir” (HOUAISS, 2006){40}. Essa distinção concatena-se ao fato das metodologias de projeção, geralmente aplicadas no planejamento do setor elétrico, basearem-se no prolongamento das ações e reações do passado para cenários futuros pré-estabelecidos. Estes, estabelecidos conforme as taxas de crescimento econômico e/ou demográfico, nível de investimentos, custos de capital, intensidade energética, e etc. As soluções destes problemas, geralmente, utilizam métodos econométricos ou da dinâmica de sistemas para estimação das relações de causa e efeito entre os parâmetros relacionados ao comportamento da demanda. Em ambos os casos, a projeção é realizada segundo determinados cenários de referência estimados por especialista do setor.

Já a aplicação de técnicas direcionadas ao descobrimento de conhecimento novo, útil e dinâmico sobre o comportamento da demanda de energia deve ser entendida como uma previsão. Este conhecimento pode ser alcançado por meio da análise de séries históricas sobre o consumo de energia elétrica e daquelas variáveis que mais poderiam influenciá-la. Conforme os horizontes de estudo, podem ser observadas as sazonalidades, não-linearidades, novos fatores de influência na demanda, além da adaptabilidade para diferentes situações de aplicação do modelo. Finalmente, com uso de métodos tradicionais ou mais recentes, objetiva-se encontrar a maneira mais adequada de efetuar a análise dos dados e gerar resultados precisos para a previsão.

Embora um dos objetivos deste trabalho seja a previsão de demanda, algumas premissas básicas para a projeção do mercado de energia elétrica ajudam a compreender a complexidade das relações entre os fatores que ditam seu comportamento. O Plano Decenal de Expansão de Energia Elétrica para o período 2006-2015 publicado pela Secretaria de Planejamento e Desenvolvimento Estratégico do Ministério de Minas e Energia, cita como referência para a projeção no mercado brasileiro os seguintes elementos (EPE, 2006){41}:

- i. O crescimento populacional, pelo seu impacto direto no consumo das residências, do setor comercial, serviços públicos, iluminação pública e, indiretamente, no setor industrial;
- ii. A evolução da economia, pelo seu impacto geral sobre a renda e sobre o consumo de energia elétrica nas diversas classes;
- iii. A perspectiva de expansão e diversificação da produção dos setores industriais com maior participação no consumo de energia elétrica;
- iv. A evolução da autoprodução de energia elétrica para uso próprio da indústria em virtude de seu impacto sobre a parcela da demanda a ser atendida pelo sistema elétrico;
- v. A evolução da conservação de energia e o gerenciamento pelo lado da demanda, pelo seu potencial de deslocamento de consumo.

Enquanto as metodologias de previsão de demanda primam pela descoberta das relações intrínsecas entre os elementos citados, para serem bem sucedidas, o projetista constrói cuidadosamente cenários macroeconômicos de população, de domicílios, dos grandes consumidores industriais de energia elétrica, da autoprodução e da conservação de energia, determinando as correspondentes trajetórias plausíveis. Considerando-se três cenários de crescimento econômico: baixo, alto e de referência, os autores apresentam a evolução do consumo estimado de energia elétrica no Brasil em três períodos distintos. A taxa média de crescimento projetada para o mercado de energia elétrica brasileiro oscilava entre 4,0% e 6,1% ao ano dependendo do período de tempo. Tal diferença percentual, aparentemente pequena, tem um impacto significativo no planejamento de longo prazo para o setor. Outra informação importante do estudo é a tendência de maior crescimento no consumo do setor comercial em relação ao setor industrial. Com toda a dificuldade para a consecução dos cenários considerados, a complexidade para a realização de um trabalho desta grandeza merece toda consideração, pois contribui muito para o entendimento do mercado de energia elétrica.

Segundo BRANCO et al. (2003){42}, a metodologia tradicional, mais utilizada pelas empresas de energia elétrica para projeção, seria baseada na Portaria 760 do antigo DNAEE de 1976. Considerando a tendência histórica para aplicação de métodos econométricos, particularmente na projeção das indústrias, desagrega-se o consumo em dois segmentos: grandes indústrias e consumidores industriais tradicionais. O consumo é projetado conforme as perspectivas de evolução do PIB secundário, considerando uma elasticidade unitária para a relação consumo-PIB. Além disso, podem ser considerados os incentivos governamentais a determinados segmentos individuais. Para projetar os seis primeiros anos aplica-se uma pesquisa direta aos grandes consumidores e nos anos seguinte somente correlaciona-se a demanda ao PIB do setor. É notável a limitação deste tipo de metodologia. As margens para erro (entrevistas, intenções de investimento, programas de governo, etc.) tornam bastante incerta a qualidade do modelo. A consideração de que o comportamento futuro das variáveis possa ser projetado diretamente da análise dos dados passados é um tanto pretensiosa, face à dinâmica do mercado de energia elétrica nos dias de hoje. A utilização de equipamentos cada vez mais eficientes energeticamente e o aumento da consciência da conservação de energia por parte dos consumidores finais, por exemplo, são alguns dos processos que têm modificado o comportamento da demanda em diversos países.

Um dos modelos de projeção de demanda mais respeitados foi o desenvolvido pela IAEA (*International Atomic Energy Agency*). O MAED – *Model for Analysis of Energy and Electricity Demand* é baseado na dinâmica de sistemas e depende da estipulação de cenários para a macroeconomia no horizonte de estudo (IAEA, 2006){43}. Em HAINOUN et al. (2006){44} pode-se atestar a qualidade da aplicação deste modelo para a projeção de longo prazo da demanda de energia elétrica na Síria. Além dos dois cenários tradicionais de alto e baixo crescimento econômico, os autores apresentam um terceiro cenário, de alto crescimento, mas com maior incremento da eficiência

energética. As conclusões do trabalho, sobre o efeito positivo da eficiência energética para todos os setores de consumo e para a economia do país, são bem interessantes.

Também considerando o longo prazo como horizonte, DA-PENG e DONG-HAI (2008){45} apresentaram um estudo com a “previsão” do consumo de energia até 2015, para a terceira economia do mundo, que há vários anos cresce em ritmo acelerado. Entretanto, o crescimento do consumo de energia na China tem sido caracterizado por uma forte redução da intensidade energética, nas últimas duas décadas. A metodologia de projeção, apresentada pelos autores, utiliza modelos de regressão temporal para estimar as variáveis de maior impacto no consumo de energia: crescimento do PIB da indústria, a taxa de urbanização e os índices de preços dos energéticos. Uma vez estimadas essas variáveis, seria possível então, estabelecer o efeito no consumo de energia elétrica. O modelo econométrico, além de apresentar um elevado nível de ajustamento na estimação, ainda considera os efeitos da redução da intensidade energética daquele país.

TOLMASQUIM, et al. (2000){46} propõem um modelo paramétrico para a projeção de demanda no longo prazo para a realidade brasileira. O MIPE – Modelo Integrado de Planejamento Energético projeta a demanda para cada segmento de consumo e de oferta de energia, em cenários bastante diversificados. Nessa abordagem os autores consideram os detalhes do processo de produção industrial como: energia útil por forma de destinação, participação de cada fonte energética, os rendimentos de conversão, a participação de cada tecnologia na cadeia produtiva, a participação de cada segmento na composição dos produtos, entre outros. O nível de desagregação considerado pelo modelo é bastante alto, o que exige um elevado custo para se captar todas as peculiaridades dos processos por traz da formação da demanda.

A “previsão” decenal de carga foi pesquisada por FURNAS Centrais Elétricas S.A., no âmbito dos programas de P&D da ANEEL, e suscitou a publicação de dois trabalhos. MAIA, et. al (2007){47} apresentam um sistema de projeção do mercado de energia elétrica baseado nas técnicas de mineração de dados e nos cenários econômicos para: PIB, salário mínimo, preço da energia elétrica, população, número de consumidores e consumo de energia elétrica. Os pesquisadores compararam os resultados com dois métodos: redes neurais artificiais e regressão linear. Com resultados muito semelhantes para estimação, foi ressaltada a importância da quantidade e qualidade das informações e recursos disponíveis para o sucesso das projeções de longo prazo. De forma complementar, OKAMOTO, et. al (2007){48} apresentam um modelo de “previsão” decenal de carga utilizando técnicas de inteligência artificial, mais especificamente, redes neurais e lógica fuzzy. O modelo proposto obteve melhores resultados na comparação com o modelo estatístico clássico de regressão dinâmica. Além de considerar as perspectivas macroeconômicas, para construção dos cenários futuros e as séries históricas disponíveis, os autores mapeavam, por meio das RNAs, qual o efeito esperado para a variação do consumo em relação às variações do PIB e da população. Enquanto isso, a discretização *fuzzy* das variáveis de entrada e saída da rede facilitam a representação de conceitos qualitativos, como “alto” e “baixo”, sobre as taxas de crescimento en-

volvidas. A Figura 2.7 apresenta um diagrama da RNA implementada e um gráfico das taxas de crescimento do PIB e da taxa de crescimento da carga no Sistema Interligado Nacional (SIN). Pode-se notar que a relação entre elas não é tão direta, mesmo no horizonte de longo prazo.

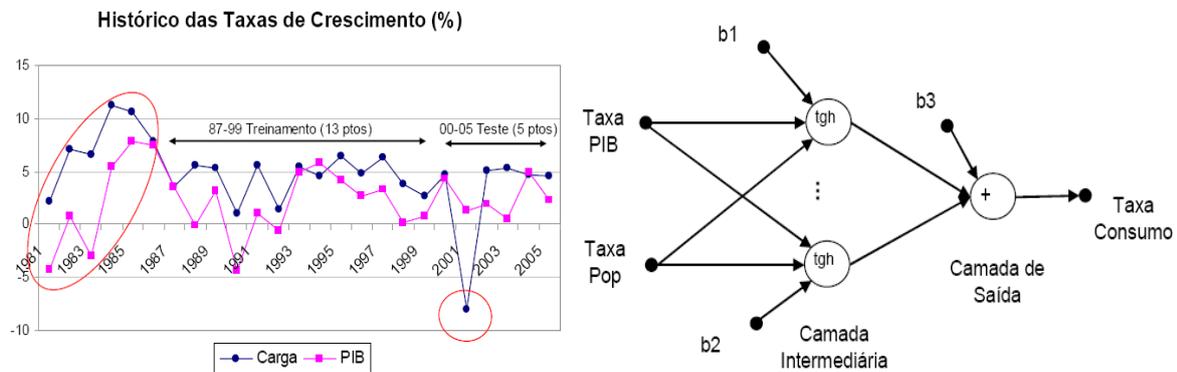


Figura 2.7 – Crescimento do PIB X Crescimento da Carga – Diagrama da RNA.

Fonte: OKAMOTO, et. al, 2007.

Apesar de todos os avanços científicos, a previsão de carga ainda é um desafio considerável. Segundo PINTO, et. al (2005){49}, é necessário possuir uma ampla gama de variáveis, a partir de cenários socioeconômicos e de aspectos climatológicos, capazes de refletir as modificações no comportamento do consumidor ao longo dos anos. Porém, eventos inesperados, como o racionamento de energia elétrica brasileiro em 2001, podem produzir uma mudança completa na carga e nos padrões de consumo, transformando as informações históricas em dados obsoletos. A solução apresentada pelos autores é um modelo de projeção da demanda no médio prazo, baseado nas previsões de variáveis econômicas e climáticas que a influenciam. Apesar do pequeno histórico das séries utilizadas, de 2000 a 2005, as simulações apresentaram erros baixos na projeção do consumo. Destacam-se algumas características do trabalho:

- ➔ Apesar da proposta não sugerir o uso de métodos estatísticos, citados como meros replicadores do passado, os autores utilizam rotinas para identificação de relações causa-feito no modelo de previsão do clima ao longo dos meses (temperatura);
- ➔ Houve um descolamento entre a produção industrial do Estado de São Paulo e a carga da distribuidora ELEKTRO após 2001;
- ➔ O PIB do ano anterior, variável base da modelagem, apresentou boa correlação com consumo de energia elétrica para o ano seguinte;
- ➔ Para o clima, a exemplo de outras citações, os meses de novembro a janeiro (verão) apresentam a maior dificuldade para o modelo de “previsão”.

2.4.2 Métodos Tradicionais de Previsão de Demanda

O Instituto de Pesquisa Econômica Aplicada – IPEA, fundação pública vinculada ao Ministério do Planejamento e Orçamento, que auxilia na elaboração e acompanhamento da política econômica no Brasil, publicou um “texto para discussão” sobre a previsão do comportamento da demanda futura. Nele, ANDRADE e LOBÃO (1997)^{50} propõem a previsão para o consumo residencial de energia elétrica no longo-prazo a partir da estimativa da elasticidade-renda e da elasticidade-preço da demanda residencial no Brasil, com dados anuais de 1970 a 1995. Foram consideradas como variáveis explicativas do consumo residencial de energia elétrica no período t (C_t), a tarifa média residencial (P_t), a renda familiar (Y_t) e o preço médio real dos eletrodomésticos (PE_t). Após a implementação de um modelo autoregressivo vetorial (VAR¹⁸) obteve-se a seguinte relação:

$$C_t = -0,05084 \cdot P_t + 0,2132 \cdot Y_t - 0,1864 \cdot PE_t \quad (2.7)$$

As elasticidades, determinadas pela técnica de regressão, corresponderam aos sinais esperados pela teoria econômica. Uma vez estimadas as elasticidades, realiza-se a projeção para o período 1997-2005, que depende da expectativa sobre a política tarifária para o setor no futuro. O primeiro cenário baseou-se na manutenção do valor real das tarifas, enquanto o segundo, refletia uma tendência de valorização real das tarifas.

Após 1997 ocorreu certa recuperação de valor real das tarifas praticadas, porém seria impossível imaginar a conservação de energia advinda do grave racionamento de energia elétrica de 2001. A Tabela 2.6 revela o quão difícil é a tarefa de previsão no longo prazo, após a comparação com o consumo efetivamente realizado. O cenário 2, o mais esperado à época, previu um consumo para o terceiro ano à frente 3,85 % aquém do ocorrido, e de 4,50% além do consumo anual previsto para 2005. Além de errar muito na previsão, para mais e para menos num curto espaço de tempo, a série prevista pelos autores para o consumo de energia elétrica anual apontava um crescimento médio anual da ordem de 1,5%, que após o advento do racionamento foi na direção oposta: retração média anual de -0,3%.

Tabela 2.6 – Comparação dos Cenários Previstos e o Realizado.

Anos	Realizado	Cenário 1		Cenário 2	
	Consumo (TWh)	Consumo (TWh)	Erro (%)	Consumo (TWh)	Erro (%)
2000	83,6	83,2	-0,47	80,0	-3,85
2005	82,3	93,3	+13,37	86,0	+4,50
Período	Cresc. (%a.a.)	Cresc. (%a.a.)	Diferença	Cresc. (%a.a.)	Diferença
00-05	-0,3	+2,3	-2,6%	+1,5%	-1,8%

Fonte: Elaborado pelo autor a partir de ANDRADE e LOBÃO, 1997 e EPE, 2006.

¹⁸ É um modelo de equações simultâneas cuja principal vantagem é mensurar o impacto que variáveis endógenas defasadas têm sobre as variáveis contemporâneas (ENDERS, 1995)^{63}.

Esses erros de previsão no consumo de energia revelam-se comuns em vários estudos de diversos países, independentemente das metodologias implementadas. Algumas situações especiais, como o racionamento de energia elétrica ocorrido no Brasil em 2001, não são consideradas nos modelos de previsão da demanda, e quando ocorrem impactam negativamente em todo o setor elétrico. Com exceção da Região Sul, naquele período, ocorreu uma redução do consumo per capita e da demanda total por eletricidade considerável no país. Apesar da melhora “forçada” da intensidade energética, as empresas do setor tiveram que se adequar a um mercado consumidor equivalente aquele de quatro anos antes do racionamento (BARDELIN, 2004){51}.

Segundo um estudo realizado com dados de vários países integrantes da *IEA – International Energy Agency*, desconsiderando-se situações especiais como o racionamento, na maioria das vezes os planejadores erraram por sobre estimação, o que em tese não comprometeria o atendimento a demanda. Os principais fatores de erro detectados por (LINDEROTH, 2002){52}, foram:

- Erros nas expectativas de crescimento, em especial do setor industrial;
- Grandes diferenças de elasticidade-renda e elasticidade-preço entre os países.

Também pode-se atestar que os erros de previsão dentro de cada um dos setores não eram correlacionados ao longo dos anos do estudo (1980, 1990 e 1995), fato que poderia representar uma falha sistêmica da modelagem. Independente do país analisado, sempre havia um período com erros consideráveis de previsão.

A *EIA – Energy Information Administration* é a agência oficial de estatísticas sobre o setor de energia dos Estados Unidos. De forma independente, ela presta informações de interesse público para satisfazer as exigências do governo, da indústria e demais entidades interessadas. SANDERS et. al (2008){53} apresentam uma avaliação global das previsões de médio prazo (trimestral) publicadas pela EIA, para diversos energéticos, incluindo a eletricidade. De todos os mercados analisados, a previsão para o consumo de energia elétrica apresentou os melhores resultados. A Figura 2.8 apresenta as taxas de crescimento da demanda trimestrais ocorridas e previstas, bem como os erros percentuais da previsão em cada trimestre. Pode-se notar o reflexo negativo para a qualidade das previsões do consumo de energia elétrica devido ao comportamento inesperado da economia americana entre 2000 e 2002. A crise financeira das empresas de tecnologia em 2000 comprometeu o consumo deixando-o bem abaixo do esperado e, da mesma forma, a rápida recuperação da economia no ano seguinte elevou-o a patamares acima do esperado.

Com vistas à previsão de demanda no médio prazo, SCHUCH (2000){54} apresentou uma nova metodologia para o planejamento do consumo de energia elétrica em ambiente competitivo. Por meio da técnica de análise e modelagem dinâmica de sistemas, o trabalho consiste na suposição de que os fatores estratégicos e comportamentais dos agentes de mercado, fonte de grande incerteza, devem ser incluídos na modelagem das estimativas de demanda de empresas distribuidoras/comercializadoras de energia elétrica.

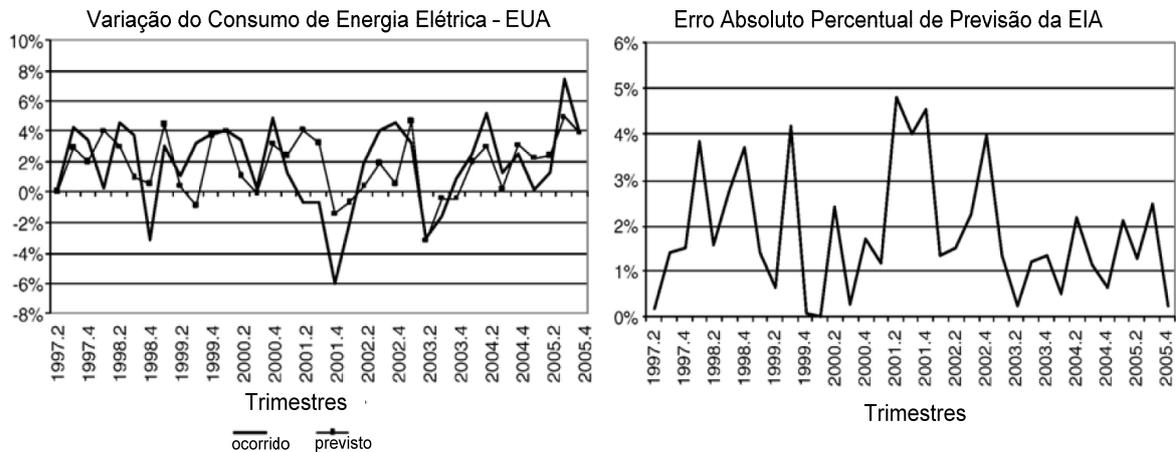


Figura 2.8 – Previsão Trimestral do Consumo de Energia Elétrica – EIA.

Fonte: SANDERS et. al, 2008.

Por meio da modelagem dinâmica de sistemas, a metodologia para a previsão de demanda no médio prazo proposta por BRANCO et al. (2003){55} tem por objetivo corrigir a simples projeção do comportamento das variáveis no passado para o futuro. Segundo os autores, algumas decisões que ocorrem em um determinado instante, poderão ter consequências só depois de algum tempo. Como exemplo, os autores citam o atraso da reação do consumidor aos reajustes das tarifas de energia elétrica, que pode ser modelada dinamicamente. A Figura 2.9 apresenta um diagrama das relações envolvendo o consumo residencial de energia elétrica. Tais relações podem ter seus aspectos sociais, comportamentais, não lineares, entre outros representados matematicamente com a aplicação da modelagem dinâmica de sistemas.

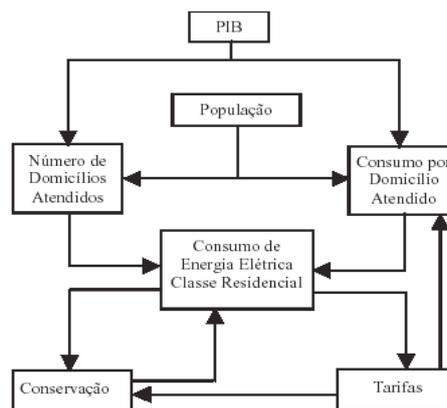


Figura 2.9 – Gráfico da modelagem dinâmica para o consumo residencial de energia elétrica.

Fonte: BRANCO et al., 2003.

A abordagem *Top-Down/Bottom-Up* para previsão da demanda no médio prazo do setor elétrico venezuelano foi apresentada por DORTOLINA e NADIRA (2005){56}. Nela, primeiro se estabelece uma previsão da demanda total por energia (*Top-Down*) considerando as tendências históricas do PIB, do número de consumidores, do consumo per capita e da população. Em seguida

a demanda total é segmentada para cada grupo tarifário (residencial, comercial, industrial e outros) observando a história de participação no consumo total de cada um (*Bottom-Up*). Esse tipo de abordagem aproxima-se muito do problema de projeção, quando se prioriza apenas o estudo da relação existente entre demanda e suas variáveis explicativas, sem avaliar o potencial de predição das mesmas.

Outro tipo de previsão de carga, bastante utilizada, baseia-se no modelo econométrico ARIMA – *Autoregressive Integrated Moving Average*. DAMRONGKULKAMJORN e CHURUEANG (2005){57} aplicam esse modelo de regressão para a série histórica de consumo, decomposta em duas componentes: de tendência e de sazonalidade da demanda. Para realizar a previsão mensal do consumo total de energia elétrica da Tailândia, os autores utilizaram dados de janeiro de 1991 até dezembro de 2003, com o intuito de ajustar o modelo, e obtiveram a previsão de carga para os 12 meses de 2004, com um MAPE¹⁹ bem baixo (1,6%).

Para os modelos autorregressivos, a informação suficiente para estimar o futuro da demanda encontra-se apenas na própria série de consumo registrada. Se ocorrerem mudanças importantes na economia, no clima, ou na intensidade energética, a qualidade dos resultados deverá diminuir, mesmo com uso de técnicas de decomposição apresentadas.

Uma proposta, mais específica para a previsão do consumo industrial de energia elétrica no médio prazo, foi apresentada por SOUZA et al. (2005){58} para o Estado de Santa Catarina. Os autores consideraram os meses de agosto de 1993 a dezembro de 2003 para as seguintes variáveis socioeconômicas: horas trabalhadas na produção, utilização da capacidade instalada, salário líquido real, vendas reais, consumo residencial de energia elétrica, arrecadação de ICMS, produção industrial e o número de dias úteis na indústria. Após simular seis modelos de regressão, um integrado autorregressivo de média móvel (ARIMA), e um de suavização exponencial (Holt-Winters), os autores propuseram um modelo final, cujo resultado era uma média das contribuições de cada modelo em separado. Essa tentativa de autocorreção apresentou resultados mais precisos em relação àqueles obtidos pelo modelo em uso na empresa distribuidora. Porém, apenas para a região amostral do consumo os resultados da estimação melhoraram. O MAPE obtido na proposta em comparação com o programa de previsão existente na concessionária foi de 1,80% e 5,31%, respectivamente. Enquanto, para o consumo não amostrado, o MAPE foi de 4,69% e 3,29%, na mesma comparação. Pode-se concluir então, que as variáveis explicativas do consumo industrial de energia elétrica explicaram com sucesso o seu comportamento, mas não estavam devidamente modeladas para prever os próximos meses de consumo. Como previsor, o modelo tradicional da distribuidora ainda é preferível em relação ao proposto no estudo.

Entendendo que a desagregação proporcionaria um benefício maior que o custo de sua elaboração, Mc CAFFEIRTY e BEATTIE (1991){59} apresentaram um modelo de previsão de médio prazo para 18 setores industriais da Irlanda do Norte. Para prever a demanda nos meses à frente, os

¹⁹ Erro absoluto médio em percentual, do inglês *Mean Absolute Percentage Error*.

autores utilizaram o modelo integrado autorregressivo da média móvel (ARIMA). Para um conjunto de dados de 108 meses, a desagregação melhorou a *MAPE* do processo de previsão da indústria de 5,33% para 4,60% com um bom nível de significância, mesmo sem a consideração de variáveis externas características de cada setor.

O impacto de variáveis climáticas no consumo de energia elétrica também é bastante utilizado na previsão da demanda quando o horizonte é de curto prazo. A técnica de autorregressão múltipla com variáveis exógenas (ARX) foi apresentada por CHEN et al. (2005){60}, para prever a curva de demanda nos dias da semana seguinte. O diferencial conseguido pelos autores foi estabelecer quatro tipos de condições climáticas: normal – condizente com a estação, anormal – dia frio no verão ou quente no inverno, extremo – muito quente ou muito frio e de transição – início e final das estações. Este tipo de segmentação permitiu uma regressão mais especializada, produzindo resultados mais precisos naqueles dias com clima fora do padrão normal. Os resultados obtidos provaram que a relação entre a temperatura e o consumo é não linear, não segue um padrão bem comportado, e por isso se justificaria considerar tipos distintos de clima na modelagem.

A aplicação de modelos de previsão de curto prazo pode ser útil até para as empresas de serviço de conservação de energia (ESCOS). CRISTOFARO, et. al (2003){61} demonstram como os consumidores industriais podem economizar no planejamento e operação de suas instalações, e como as ESCOS podem oferecer novos serviços. Com previsões mais precisas, baseadas em modelos econométricos autorregressivos e em RNAs, os ganhos viriam da gestão inteligente da contratação da demanda. Pode-se antecipar a contratação de forma inteligente, quando observadas as variações de preço da energia elétrica, conforme os postos horários, e a previsão da carga.

DOUGLAS, et. al (1998){62} realizam a previsão dos picos de demanda de energia elétrica, da *Oklahoma Gas and Electric Company – Califórnia/USA*, com base nas séries históricas de consumo e nas previsões de temperaturas médias e máximas para região. A partir da estimação baseada na estatística *bayesiana*, um algoritmo recursivo usado em conjunto com um modelo linear dinâmico, os autores representam o comportamento da demanda em diferentes horizontes de tempo (curto, médio e longo prazos). Os resultados obtidos alertam sobre a perda de precisão nas estimativas de demanda em virtude da baixa qualidade da previsão do clima, principalmente no verão.

2.4.3 Previsão da Demanda no Contexto do KDD

Uma das primeiras aplicações de redes neurais artificiais para a previsão de demanda no setor elétrico foi apresentada no início da década de 90. LIU et al. (1991){64} compararam o desempenho de um modelo de previsão baseado em RNAs com outro, mais tradicional, baseado na econometria para previsão de longo prazo em Singapura. Os autores treinaram uma rede *MLP* (*Multi-Layer Perceptron*), de três camadas com dados sobre o consumo anual de energia elétrica. Treinada de 1960 a 1984 para aplicação no período subsequente de 1985 a 1990, com dados de entrada sobre: consumo anual, PIB, preço real da energia elétrica, e a evolução da população. O

desempenho da rede, no período de treinamento, foi superior ao do modelo econométrico, que por sua vez, teve maior precisão para a previsão nos anos de simulação. Apesar disso, os autores recomendaram mais estudos para aprimorar a aplicação das RNAs na previsão de demanda.

FARAHAT (2004){65} implementou um sistema de inferência nebulosa, para complementar as informações obtidas por uma RNA, no problema de previsão. O objetivo do autor era estabelecer uma previsão de longo prazo para a demanda industrial de energia elétrica no Egito, considerando apenas a série histórica de consumo. Na formulação apresentada, enquanto a RNA faz a previsão da série de consumo para os anos seguintes, o sistema de inferência nebuloso fica responsável por estabelecer o mínimo e o máximo consumo, com base na variação da carga no ano corrente e nos anos anteriores. As regras do sistema de inferência não foram obtidas automaticamente, e sim definidas por um especialista da área de previsão.

Uma solução, baseada na aplicação de redes neurais, para a previsão de demanda no longo prazo foi proposta por AZADEH e SOHRABKHANI (2006){66}. Observando o comportamento não linear da demanda industrial no Iran, entre 1979 e 2003, com especial atenção àquela formada pelas indústrias eletrointensivas, os autores propõem uma MLP para previsão setorial da carga para um ano à frente, com as seguintes características:

- 5 neurônios na camada de entrada: preço da energia, n. de consumidores, preço dos combustíveis fósseis, intensidade energética, valor adicionado (PIB) – variáveis por setor;
- 2 camadas intermediárias, com 3 e 2 neurônios;
- 1 neurônio na camada de saída, o consumo do setor para o ano seguinte;
- Treinamento com dados de 1979 até 1999, e testes com dados de 2000 à 2003.

Os resultados obtidos pelos autores com uso da RNA foram comparados com aqueles obtidos por um modelo econométrico de regressão, com uma boa vantagem para o primeiro.

A aplicação de técnicas de inteligência artificial com o objetivo de realizar a previsão de demanda no longo prazo tem conquistado um espaço crescente no setor elétrico de vários países. GHODS e KALANTAR (2008){67} apresentam uma análise de vários métodos de previsão para este horizonte de previsão, a saber: redes neurais, algoritmos genéticos, lógica *fuzzy*, e até os modelos estatísticos ou baseados nas econometria. A constatação do autor pode ser assim resumida:

- Os métodos tradicionais, como regressão e séries temporais, são utilizados em muitos países em virtude de seus resultados serem considerados mais confiáveis;
- As redes neurais podem resolver problemas não-lineares, e devido ao comportamento não linear da demanda, em várias aplicações, ela vem ganhando espaço;
- O uso de algoritmos genéticos faz mais sentido, na modelagem da previsão de longo prazo, quando existe um conjunto muito grande de variáveis ou caminhos possíveis.

Atualmente, boa parte das empresas distribuidoras de energia elétrica no país realiza pesquisas na área de previsão de carga com uso de redes neurais. A Companhia Energética de Brasília – CEB desenvolveu um programa, Previsor de Mercado de Energia Elétrica (PMEE), adequado à realidade do setor elétrico brasileiro e às necessidades da empresa. O modelo considera os dados de consumo de energia elétrica de cada grupo consumidor, os indicadores econômicos estaduais e nacionais, que têm uma boa correlação com a demanda. Além da aplicação de técnicas de inteligência artificial para obtenção da previsão no médio prazo, o modelo considera ainda:

- i. O percentual de perdas para determinados períodos nos anos de previsão;
- ii. Os eventos agendados que normalmente modificam a curva de carga;
- iii. Inclusão, edição ou remoção das classes consumidoras envolvidas no processo.

O resultado final da aplicação revelou os índices de crescimento do consumo para os anos analisados, o mercado de referência/superior/inferior, a demanda por regiões e as prováveis tarifas de fornecimento da energia elétrica (FARIA et al., 2005){68}.

A maioria das pesquisas de aplicação das RNAs na previsão de demanda tem como objetivo entender o problema de curto ou curtíssimo prazo levando em consideração aspectos climáticos. Entretanto, CAVALLARO (2005){69} propõe um modelo de previsão de demanda de energia elétrica no médio prazo para a ilha italiana de Lipari, cujas peculiaridades tornaram o problema bem interessante. Além de ser uma região isolada do sistema elétrico interligado do país, sua demanda depende das estações do ano (fator turismo) e das condições climáticas (fator temperatura). Para aumentar a eficiência da geração de energia elétrica (geradores a diesel) e diminuir o risco de desabastecimento no mês de dezembro, por escolha do autor, foi implementada uma RNA conforme a Figura 2.10. A RNA com três camadas tinha as seguintes características:

- ➔ 8 unidades de entrada: (1) tipo de dia da semana D , (2) horário do dia h , (3) demanda de energia no período h para o mês de março, (4) temperatura média no horário h para o mês de março, (5) demanda de energia no período h para o mês de agosto, (6) temperatura média no horário h para o mês de agosto, (7) demanda de energia no período h para o mês de outubro, (8) temperatura média no horário h para o mês de outubro;
- ➔ 17 neurônios na camada intermediária: determinados por meio de tentativa e erro;
- ➔ 1 unidade de saída: demanda de energia elétrica prevista para o mês de dezembro para o período do dia de maior temperatura.

Os meses de março e outubro refletem o início e o fim da alta temporada de turismo, respectivamente, e normalmente contém os picos de demanda anual. Já o mês de agosto reflete o consumo no meio da temporada. A estimação da demanda a partir de dados dos três meses, considera-

dos chaves pelo autor, obteve resultados bem animadores (MSE^{20} em torno de 2%). Finalmente, o autor atesta que as RNAs são mesmo apropriadas para analisar variáveis com presença forte de não linearidade e incertezas.

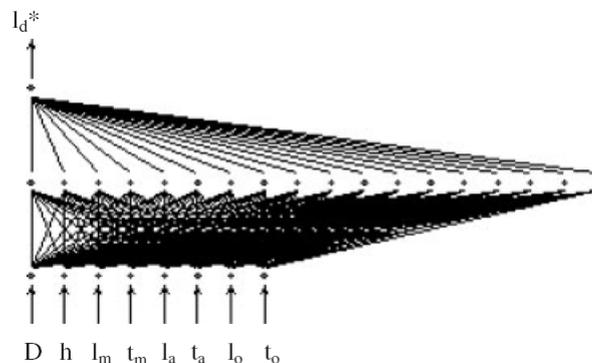


Figura 2.10 – Arquitetura da RNA para previsão de demanda na Ilha de Lipari, Itália.

Fonte: CAVALLARO, 2005.

Um dos trabalhos mais interessantes sobre a previsão de demanda no médio prazo foi apresentado por GONZÁLES-ROMERA et. al (2006){70}. Para prever o consumo de energia elétrica do mês seguinte na península espanhola, os autores apresentam uma nova proposta: prever separadamente a tendência do consumo e a sazonalidade, com duas redes neurais específicas. As variáveis de entrada da RNA eram valores de consumo cada um dos 12 meses anteriores. A justificativa para não considerar os fatores climáticos, foram os erros de previsão, relatados na literatura, em função da dificuldade de previsão do clima. O consumo previsto, resultado da soma das saídas das redes, apresentou um MAPE de 1,89%, inferior ao modelo similar com apenas uma MLP (2,69%) e ao modelo tradicional de previsão de séries temporais – ARIMA (3,8%), considerando o mesmo conjunto de dados. A Figura 2.11 apresenta os resultados obtidos pelo modelo com dados de janeiro de 1975 até dezembro de 2002: treinamento (276 meses) e validação (60 meses).

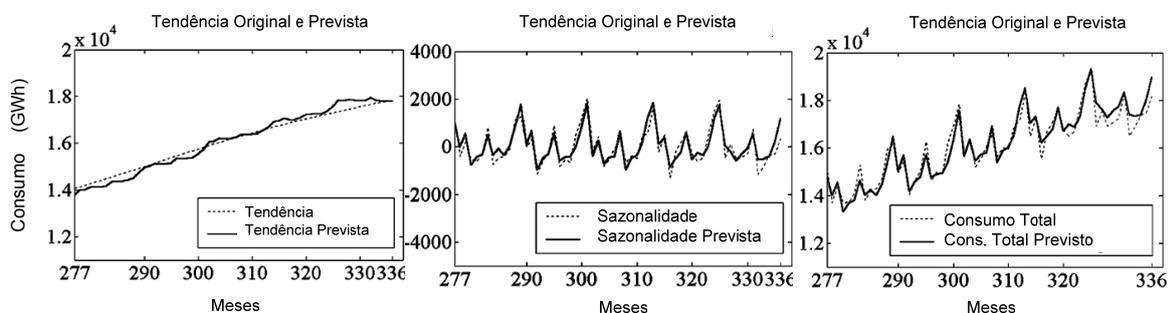


Figura 2.11 – Resultados da Previsão de Demanda Decomposta.

Fonte: Adaptado de GONZÁLES-ROMERA et. al, 2006.

²⁰ Erro médio quadrático – Mean Square Error

Alguns autores realizam a previsão de demanda tomando como base em uma característica típica que poderá se repetir no futuro, com algum nível de incerteza. MANDAL et al. (2005){71} determinam curvas similares de demanda para a energia elétrica, com base nas séries históricas, e procedem a previsão somando um vetor de distorções simulado via RNA. Os fatores temperatura máxima, temperatura mínima, dia da semana e a demanda média dos últimos 3 dias similares de cada ano são as entradas da rede. Este estudo demonstrou, com bons resultados, a versatilidade da aplicação das RNAs em conjunto com outras técnicas de previsão para o curto prazo.

ANDRADE et al. (2003){72} realizaram um estudo para determinar a influência de elementos climatológicos na demanda diária de energia elétrica da região metropolitana de Belo Horizonte. A partir de um modelo de redes neurais, os pesquisadores verificaram as melhorias na precisão com inclusão ou não dos elementos climáticos: pressão atmosférica, temperatura, radiação solar e umidade relativa. Pode-se observar na Figura 2.12 a redução do desvio padrão médio dos erros quando são consideradas pelo menos uma das variáveis climáticas na camada de entrada da RNA. Destaque para a melhoria da precisão (12,41%) com o uso da pressão atmosférica. Segundo os autores, a princípio, mudanças meteorológicas mais significativas afetam essa variável antes da temperatura.

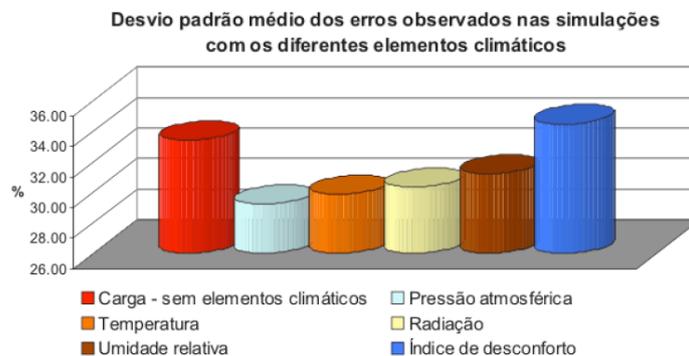


Figura 2.12 – Variação dos Erros Observados na Previsão com Diferentes Elementos Climáticos.

Fonte: ANDRADE et al., 2003.

Ainda com foco na previsão de curto prazo, SILVA et al. (2003){73} apresentaram um sistema de previsão de carga *on-line* que considera os efeitos de variáveis climáticas e de eventos capazes de modificar a trajetória da curva de carga diária. O sistema realiza previsões, de forma autônoma, para a carga própria global da Companhia Energética de Minas Gerais – CEMIG, suas regionais, e barramentos de carga selecionados, e para um horizonte de 96h à frente, com intervalo de integração de 15 minutos. A etapa de pré-processamento dos dados é considerada fundamental para a robustez do modelo de previsão. A Figura 2.13 apresenta três destes processos, que antecedem a implementação das redes neurais.

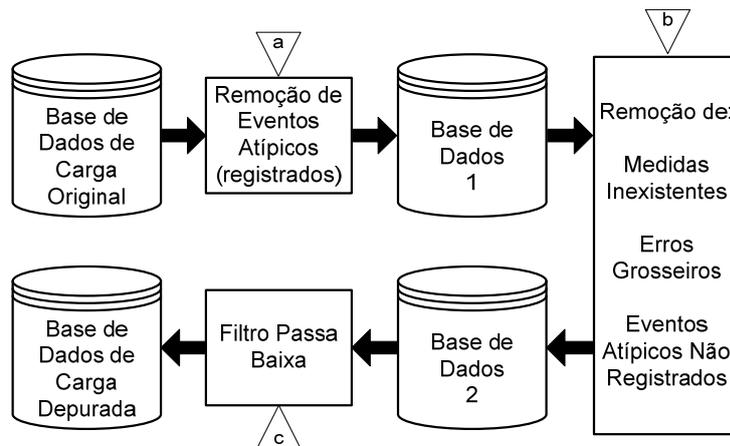


Figura 2.13 – Pré-processamento da Base de Dados - Preditor de Carga On-line.

Fonte: SILVA et al., 2003.

A filosofia para a previsão de carga, adotada pelos autores, é: se a previsão meteorológica indicar variações significativas de temperatura, umidade, etc., o programa realiza uma busca no histórico, identificando situações semelhantes, para a correção da previsão de carga típica. A Figura 2.14 ilustra as etapas deste processo. Também, na previsão para os dias atípicos (feriados), faz-se a busca de dias semelhantes no histórico para corrigir a previsão de carga típica.

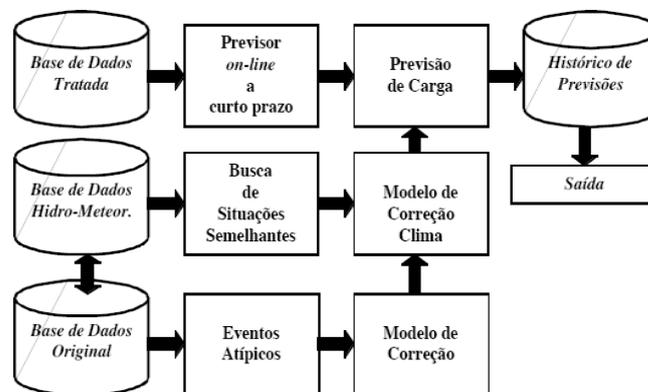


Figura 2.14 – Preditor de Carga On-line Considerando a Influência das Variáveis Climáticas.

Fonte: SILVA et al., 2003.

Em alguns casos a previsão de demanda pode ser pré-requisito básico para despacho da geração e alocação das fontes de energia disponíveis. Há alguns anos a cooperativa de energia elétrica *Western Farmers* de Oklahoma/EUA utiliza um sistema de previsão de curto prazo, desenvolvido pelo *Energy Systems Research Center of the University of Texas*. METHAPRAYOON, et. al (2007){74} apresentam na Figura 2.15 os resultados de previsão da carga obtidos para uma hora a frente e para o dia seguinte, com a aplicação de redes neurais para a previsão do clima (temperatura). Apesar de boa acurácia nos resultados, com MAPE de 1,09% e 2,82% para uma hora e para um dia à frente respectivamente, os autores alertam para influência que os erros de previsão da temperatura têm no resultado final de previsão da carga.

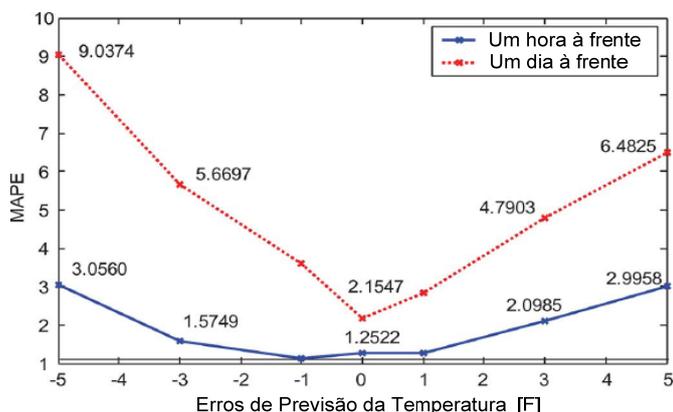


Figura 2.15 – Erros da Previsão de Temperatura X MAPE da Previsão da Carga.

Fonte: METHAPRAYOON, et. al, 2007.

Uma tendência que pode ser observada nas diversas obras estudadas é a especificação dos modelos de previsão. Seja em função das variáveis climáticas, econômicas, sociais ou regionais envolvidas, seja pela adequação às características peculiares de cada tipo de consumidor – residencial, comercial, industrial, eletrointensivos, cativos e não cativos. Um modelo de previsão de curto prazo baseado em RNAs e algoritmos genéticos (AG) capaz de adaptar-se às diferentes características de mercado e clima, das regiões do Estado de Santa Catarina, foi apresentado em OLIVEIRA (2004) {75}. Em um dos trabalhos publicados pelo autor para exemplificar sua tese, ele propõe para cada uma das seis subestações escolhidas, um “previsor neural especializado”, capaz de aprender acerca do comportamento da carga local e de se autoajustar à dinâmica do mercado de energia elétrica. Ou seja, para as diferentes estações climáticas do ano, com ajustes evolutivos de curto, médio e longo prazos dados pelo algoritmo genético. Os resultados obtidos pelo modelo especializado na rede de distribuição das Centrais Elétricas de Santa Catarina – CELESC, por mercado ou por estação climática, foram bem superiores ao modelo de RNA tradicional (OLIVEIRA e WAZLAWICK, 2004) {76}.

Como alternativa ao modelo básico de previsão de carga, baseado no MLP, CARPINTEIRO et al. (2004) {77} apresentaram um modelo neural hierárquico, por meio de uma extensão dos mapas auto-organizáveis de Kohonen (SOM²¹ – *self-organizing map*) para a previsão de curto prazo. As características da curva de carga de cada dia da semana são identificadas com maior facilidade com a ativação de cada uma das sete áreas de saída do mapeamento. Assim, o modelo apresentado pelos autores conseguiu reduzir o MAPE de 5,92%, do modelo tradicional, para 2,03%, considerando um dia de feriado durante a semana.

O Núcleo de Inteligência Computacional Aplicada da Pontifícia Universidade Católica do Rio de Janeiro implementou com sucesso um modelo de previsão de curtíssimo prazo da demanda

²¹ RNA não supervisionada que projeta um conjunto de dados n-dimensional em um espaço de dimensões reduzidas, geralmente, uni ou bidimensional. A similaridade dos conjuntos apresentados na camada de entrada é representada pela proximidade no mapa de saída.

de energia elétrica para a CEMIG – Centrais Elétricas de Minas Gerais (LEITE et al., 2000){78}. O sistema de inferência nebulosa proposto era especializado para cada dia da semana e tinha seis variáveis de entrada, relativas à demanda do sistema para os seis últimos períodos de 10 minutos. Utilizando funções de pertinência os autores encontraram 4740 regras para prever o nível de carregamento nos 10 minutos seguintes, com um *MAPE* sempre inferior a 1,22%.

GUIRELLI et al. (2005){79} apresentam um trabalho de inteligência artificial para a tarefa de previsão de carga, aplicada ao sistema de transmissão da CTEEP - Companhia de Transmissão de Energia Elétrica Paulista. Os modelos de previsão são ajustados conforme os padrões de curva de carga (perfis) para cada dia da semana. Além da previsão da curva de carga para o dia seguinte, solucionada com a aplicação de RNAs, os autores propõem um sistema de inferência nebulosa para a previsão de curtíssimo prazo (15 min a 1 hora). Com nove dados de entrada, referentes à demanda nas últimas duas horas, e uma saída, referente à demanda prevista 15 minutos à frente, o sistema apresentou um *MAPE* abaixo de 1,2% para todos os dias da semana. Quanto à possibilidade de melhoria na previsão com a inclusão da temperatura ambiente como dado de entrada, os autores verificaram que para este caso específico pouca ou nenhuma melhoria ocorreu.

Um dos trabalhos pioneiros de aplicação de lógica *fuzzy* para acelerar o processo de aprendizagem das redes neurais artificiais na previsão de demanda foi apresentado por WANG e WANG (1993){80}. Nesta abordagem o ajuste dos pesos da RNA é feito de maneira otimizada para cada conjunto de dados a ela apresentado durante o período de treinamento. Tanto o erro quanto a variação do erro encontrado pela RNA, em relação ao valor esperado de cada interação, são fuzzificados na entrada do controlador (configurado com as funções de pertinência) para a determinação das regras que maximizam uma função objetivo, associada ao melhor ajuste dos pesos da rede. Além de ser mais precisa para o objetivo de previsão da demanda, o previsor *neuro-fuzzy* obteve uma taxa de convergência 100 vezes maior em relação ao tradicional algoritmo *back-propagation*.

A aplicação de um modelo previsor *neuro-fuzzy* com objetivo de aprimorar a previsão da curva de demanda para o dia seguinte, foi realizada com êxito por LOPES et al. (2003){81} para uma concessionária de energia elétrica brasileira. A formulação proposta pelos autores reduziu em torno de 35 vezes o número de ciclos de treinamento da rede e o tempo de processamento. Além disso, a aplicação do modelo de previsão *neuro-fuzzy* se mostrou muito precisa, com um *MAPE* de 0,97% e um erro máximo de 2,98% para o conjunto de dados de teste.

Uma proposta para a previsão da demanda de energia elétrica em um ambiente competitivo, realizada por KHOTANZAD et al. (2002){82}, destaca-se pela agregação das três principais técnicas de inteligência artificial. Trata-se de um modelo de previsão de curto prazo para a demanda de energia elétrica em um ambiente de mercado competitivo, onde podem ocorrer variações bruscas de preço ao longo do dia, e por consequência, alterar a curva de carga esperada dependendo do grau de reação dos consumidores. Parte-se de um modelo RNA padrão com um conjunto de treinamento com dados dos 3 últimos anos. Corrige-se a saída da RNA por meio de um sistema de

inferência nebuloso, que incorpora os efeitos da reação dos consumidores aos parâmetros: carga, temperatura, variação de preço e de carga em relação ao dia anterior. A definição das regras e das funções de pertinência mais adequadas foi obtida com a aplicação da técnica de algoritmos genéticos. Essa técnica avaliou, de forma evolutiva, as diversas combinações possíveis para as funções de pertinência, sem a necessidade de um especialista em previsão. Os resultados obtidos pelos autores, além da inovação proposta, reduziram em média 18% o valor do MAPE na comparação com o desempenho do previsor com redes neurais tradicionais em três diferentes casos (MAPE = 2,64).

Segundo SILVA et. al (2008){83}, uma questão muito importante para o desenvolvimento de modelos neurais de previsão, a representação do conjunto de variáveis de entrada, não tem sido considerada com o devido cuidado. Os autores propõem um novo procedimento, que considera a relevância das variáveis independentes, para seleção automática das variáveis de entrada das redes neurais. A proposta obteve uma qualidade na previsão muito boa, compatível com outras modelagens customizadas. A grande vantagem dessa abordagem está na facilidade de processamento das variáveis exógenas e da demanda, que servem de entrada para uma rede neural artificial, com regularização bayesiana, para previsão no curto prazo.

2.5 RESUMO DO CAPÍTULO

As referências da literatura apresentadas neste capítulo demonstram a complexidade dos problemas relacionados ao estudo da demanda por energia elétrica. Desde o objetivo pretendido para a descoberta de conhecimento, passando pelas técnicas de mineração de dados, até a escolha das variáveis que influenciam no comportamento da demanda, foram relacionadas diversas metodologias. Para facilitar a análise das referências bibliográficas utilizadas neste trabalho, caracterizado pela multidisciplinariedade, foi elaborado um Mapa Temático com todas as citações do Capítulo 2, agrupadas segundo as áreas analisadas na literatura.

Inicialmente, foram estabelecidas algumas definições e objetivos para as técnicas de projeção, previsão e descrição da demanda, com diferentes níveis de desagregação. Foram apresentados exemplos de projeção de demanda tradicionais do setor elétrico brasileiro e alguns trabalhos de previsão de demanda baseados em métodos econométricos. O Capítulo 2 também apresentou como os aspectos econômicos, climáticos, de calendário e de intensidade energética, relacionados à variação da carga dos consumidores, são abordados em diversas obras.

A revisão da literatura, no entanto, procurou enfatizar os trabalhos com maior nível de desagregação da carga, que utilizavam técnicas de mineração de dados, para descrição ou previsão da demanda industrial. Pode-se observar ao longo do texto, como a utilização de variáveis econômicas e climáticas é importante, tanto para a modelagem econométrica quanto para construção de modelos neurais de previsão da demanda. Ao final desta revisão pode-se estabelecer um caminho viável para elaboração da proposta metodológica de previsão no médio prazo, pautado pela integração de modelos lineares e não lineares e pela consideração de variáveis econômicas e climáticas.

CAPÍTULO 2 – Revisão da Literatura

CAPÍTULO 3

Metodologia

3.1 INTRODUÇÃO

O estudo do comportamento da demanda, conforme apresentado no capítulo anterior, pode ser bastante complexo em função dos objetivos pretendidos e das variáveis de influência consideradas, referentes à economia ou ao clima. Esses parâmetros variam conforme o ponto de vista dos especialistas ou o foco das áreas de planejamento nas empresas do setor elétrico. O caminho escolhido por esta metodologia apresenta-se de forma bastante particular. Com objetivo de contribuir para os estudos do comportamento do consumidor de energia elétrica industrial, algumas áreas do conhecimento foram examinadas: *KDD*, mineração de dados, economia, meteorologia, estatística, processos estocásticos, econometria, redes neurais, entre outras. A Figura 3.1 apresenta o fluxograma da metodologia proposta com uma síntese do conteúdo de cada etapa.

Ainda que se tenha considerado como universo da pesquisa apenas o Estado de Santa Catarina, o estudo sobre o consumo de energia elétrica das indústrias dependeu de um conjunto relati-

vamente grande de dados. Foram pesquisados vários indicadores mensais sobre economia, clima, e consumo de energia elétrica individual dos clientes, perfazendo séries históricas com mais de 10 anos amostrados. Assim, para garantir a qualidade dos resultados da pesquisa, com uso de dados em grande monta, optou-se por incluir técnicas de descoberta de conhecimento e mineração de dados na metodologia. A Seção 3.2 introduz o processo de descoberta de conhecimento em bases de dados e apresenta as etapas do KDD utilizadas na *Formação da Base de Dados* do Capítulo 4.

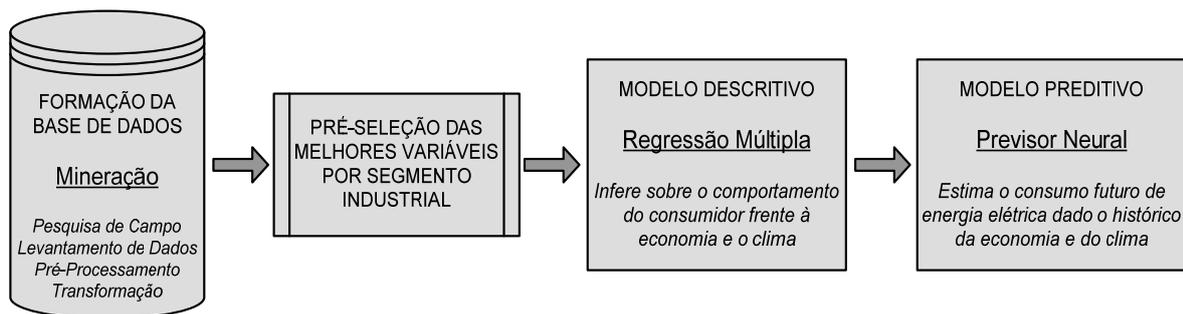


Figura 3.1 – Fluxograma das Etapas da Metodologia.

Fonte: Elaborado pelo autor.

Diante da diversidade dos aspectos que podem ser considerados num estudo sobre o comportamento do consumidor de energia elétrica, surgiu a necessidade de delimitação dos objetivos do modelo de descoberta de conhecimento e dos meios que possibilitem sua consecução. Para atender ao objetivo geral apresentado no Capítulo 1: “Descobrir conhecimento novo e útil sobre o consumo de energia elétrica de segmentos industriais de Santa Catarina com base nas variáveis econômicas e climáticas que mais o influenciam”, foram realizadas importantes escolhas quanto às técnicas e parâmetros analisados na literatura.

Entre as indagações a respeito do comportamento da demanda, duas delas instigaram o desenvolvimento das tarefas de KDD presentes nesta metodologia:

- Com que intensidade, uma variável econômica ou climática pode estar correlacionada com o consumo de energia elétrica de um segmento da indústria?
- Conforme o histórico de consumo, que volume pode-se esperar que seja consumido pelo segmento para o(s) mês(es) seguinte(s)?

A influência de uma determinada variável, seja econômica ou climática, sobre o consumo pode ser entendida, estatisticamente, pelo grau de correlação entre elas num processo de regressão. Para responder a primeira questão, a Seção 3.3 da metodologia apresenta um modelo de descrição da demanda, baseado na econometria, capaz de inferir sobre as correlações entre o consumo e as variáveis econômicas/climáticas, com qualidade e precisão.

Já a expectativa de consumo para os períodos seguintes pode ser estimada por meio de modelos de previsão de demanda. Pode-se comprovar com os resultados obtidos ao final deste

trabalho que apesar do maior nível de desagregação dos dados de consumo, em nível de segmentos industriais, não houve uma redução da acurácia tanto da previsão quando da descrição do consumo. A metodologia para a tarefa de previsão de demanda é apresentada na Seção 3.4. O modelo previsor estabelece redes neurais artificiais típicas de cada segmento e horizonte.

Um dos aspectos mais importantes que caracterizam esta metodologia é a interligação entre um modelo descritivo (que explora muitas variáveis até descrever o comportamento dos consumidores com uso de ferramentas estatísticas clássicas) e o modelo preditivo (que utiliza apenas as variáveis indicadas pela descrição nas camadas de entrada das redes neurais). **O resultado final é uma metodologia de previsão de demanda mais precisa e fundamentada na compreensão das relações lineares²² existentes entre a economia, o clima e a ação de consumir energia elétrica.**

3.2 MINERAÇÃO DE DADOS

Os constantes avanços na área da Tecnologia da Informação (TI) têm viabilizado o armazenamento de grandes e múltiplas bases de dados. A disseminação de novas bases para fins comerciais, científicos ou administrativos, deve-se a tecnologias como a Internet, sistemas gerenciadores, dispositivos de armazenamento cada vez mais eficientes, e a redução constante dos custos. Segundo FAYYAD et al. (1996), “nossa habilidade para analisar e entender uma grande quantidade de dados está muito abaixo da nossa capacidade de obter e guardar estes dados”.

Nos últimos anos, a área de Descoberta de Conhecimento em Base de Dados (KDD - *Knowledge Discovery in Databases*) vem despertando grande interesse junto à comunidade científica e industrial. Tal área, às vezes é confundida com a expressão Mineração de Dados (*Data Mining*), mais popular, que na realidade é uma das etapas do KDD (GOLDSCHMIDT e PASSOS, 2005). A Figura 3.2 ilustra, na forma de uma pirâmide, os estágios da transformação de um grande conjunto de dados em conhecimento útil num contexto meramente ilustrativo.

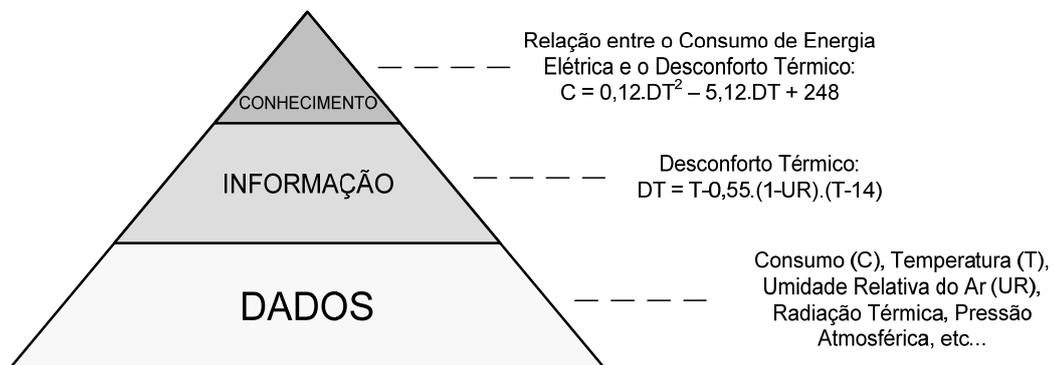


Figura 3.2 – Hierarquia entre Dados, Informação e Conhecimento.

Fonte: Elaborado pelo Autor a partir de GOLDSCHMIDT e PASSOS, 2005.

²² Apesar do modelo preditivo fazer uso da não linearidade, que eventualmente exista nas relações entre as variáveis explicativas e o consumo de energia (treinamento e simulação das RNAs), a etapa inicial desta metodologia realiza a seleção das melhores variáveis com base no modelo econométrico, que é essencialmente linear.

Historicamente, a descoberta de conhecimento em bases de dados origina-se de diversas outras áreas: estatística, inteligência artificial, reconhecimento de padrões, gerenciamento de bancos de dados.

O termo KDD foi formalizado em 1989 em referência ao amplo conceito de procurar conhecimento a partir de bases de dados. Segundo FAYYAD et al. (1996), “KDD é um processo não trivial, para identificação de padrões, válidos²³, novos e potencialmente úteis²⁴, e compreensíveis em bases de dados”. Um padrão compreensível deve ser interpretado como um conhecimento, representado segundo normas sintáticas de linguagem formal, que seja interpretado pelo homem.

3.2.1 As Etapas do Processo de KDD

A descoberta de conhecimento em bases de dados compreende algumas etapas para ascensão dos dados na hierarquia anteriormente apresentada. A Figura 3.3 ilustra um diagrama geral dos passos que constituem um processo de KDD.

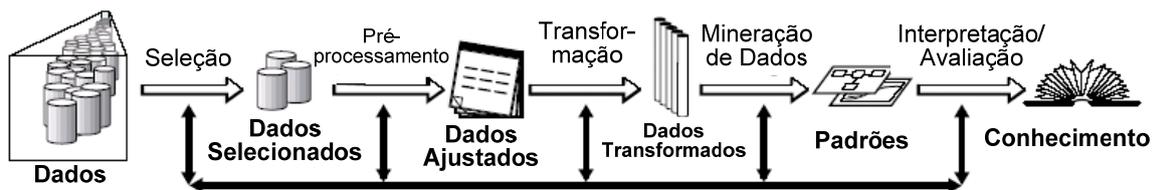


Figura 3.3 – Etapas do Processo de KDD.

Fonte: Traduzido de FAYYAD et al., 1996.

- Seleção de Dados: representa a identificação de quais informações, no conjunto disponível, devem ser utilizadas no restante do processo de KDD.
- Pré-processamento: o objetivo desta etapa é assegurar a qualidade dos dados selecionados, tornando-os ajustados ao processo de KDD.
- Transformação: esta etapa facilita a implementação dos algoritmos de mineração de dados por meio da normalização dos dados ajustados.
- Mineração de Dados: é a principal etapa do processo de KDD, responsável pela busca efetiva por conhecimento a partir dos dados transformados. Nessa fase, são definidos as técnicas e os algoritmos a serem utilizados na tarefa em questão (GOLDSCHMITD e PASSOS, 2005).
- Interpretação e/ou Avaliação: também conhecida como pós-processamento, nesta etapa os padrões extraídos podem ser simplificados, avaliados ou simplesmente documentados para o usuário final (MELANDA, 2004).

²³ Um padrão válido indica que o conhecimento deve ser verdadeiro e adequado ao contexto da aplicação de KDD.

²⁴ Um padrão útil é aquele que pode proporcionar benefícios ao contexto da aplicação de KDD.

GOLDSCHMIDT e PASSOS (2005) ressaltam que o processo de KDD é ao mesmo tempo interativo e iterativo. Existe a necessidade de atuação do homem como responsável pelo controle do processo, por meio da interpretação e análise dos fatos observados. Por outro lado, existe a possibilidade de repetições integrais ou parciais do processo de KDD na busca de resultados satisfatórios, por meio de refinamentos sucessivos de técnicas e de algoritmos.

3.2.2 Dinâmica do KDD

A busca de conhecimento por meio da mineração de dados, apresentada, é a parte mais complexa do processo de KDD. Isto se deve à dificuldade de percepção, interpretação e conjugação adequada de inúmeros fatos que surgem durante o processo. Segundo GOLDSCHMIDT e PASSOS (2005), são recorrentes as questões sobre como executar um processo para descoberta de conhecimento de algo que não se sabe exatamente o que seja.

O foco das metodologias para a realização do KDD está no pré-estabelecimento de conjuntos ordenados de regras e tarefas a serem seguidas a fim de realizar processos que produzam resultados satisfatórios, e não no desenvolvimento de melhores ferramentas computacionais.

Segundo FAYYAD, et al. (1996), o maior esforço do projeto de KDD está na tarefa de elaboração do problema. Os objetivos, expectativas e metas para os modelos de conhecimento gerados demandam mais tempo que a otimização dos algoritmos para solução dos problemas. O desenvolvimento desta metodologia e sua aplicação também não fugiram à regra.

Dessa forma, apresentam-se a seguir, importantes conceitos para a documentação e o planejamento das tarefas de descrição e previsão do consumo de energia elétrica. Todos eles foram considerados ao longo do desenvolvimento da pesquisa.

Levantamento Inicial: compreende um exame preliminar da base de dados para obtenção de informações sobre a natureza e o propósito dos dados a serem analisados:

- Inventário das bases de dados disponíveis;
- Esboçar uma lista das necessidades e expectativas dos usuários (planejadores) e o tipo de conhecimento que pode satisfazer suas expectativas;
- Avaliar a qualidade dos dados disponíveis para o propósito do KDD;
- Verificar se os dados estão disponíveis em quantidade suficiente para o processo de KDD, pois bases pequenas ou pouco representativas podem inviabilizá-lo;
- Identificar e documentar todo o conhecimento prévio existente e disponível acerca do domínio da aplicação.

Definição dos Objetivos: conforme a tarefa de KDD estipulam-se alguns requisitos quanto ao modelo de conhecimento a ser produzido. Esta etapa requer uma forte interação entre o analista de KDD e os especialistas do domínio da aplicação:

- O analista de KDD deve ser capaz de identificar as expectativas existentes no domínio da aplicação (revisão da literatura) e associá-las a tarefas de mineração de dados capazes de atender tais expectativas;
- A identificação do tipo de tarefa de mineração de dados é fundamental nesta metodologia, pois constitui o núcleo do processo de KDD;

Planejamento das Atividades: Para cada objetivo traçado de descoberta de conhecimento sobre a demanda, referentes às indagações da Seção 3.1, pode-se documentar uma sessão de KDD, por meio de um formulário padrão com os seguintes tópicos:

- Identificação da aplicação, objetivo e tarefa específica;
- Plano de Ação: Relaciona quais métodos ou técnicas serão implementados desde o pré-processamento até a mineração dos dados, incluindo a ordem de aplicação;
- Execução do Plano de Ação: compreende a execução ordenada dos métodos que compõe o plano. A cada ciclo, pode-se executar, total ou parcialmente, o plano na busca dos melhores resultados. A documentação, por meio das sessões de KDD, torna-se essencial ao analista, para que se tenha o mínimo controle sobre o processo.
- Avaliação dos Resultados: apesar de ser realizada ao final do processamento de cada método, a avaliação de resultados torna-se mais efetiva após a execução dos métodos de mineração de dados. Nesta etapa é possível confrontar as características do modelo de conhecimento gerado com as expectativas sobre o mesmo.

3.2.3 Tarefas e Técnicas de KDD

Uma tarefa de KDD equivale a uma operação da etapa de mineração de dados. As mais comuns estão listadas na Tabela 3.1, com os respectivos exemplos de aplicação.

Tabela 3.1 – Tarefas para Descoberta de Conhecimento e suas Aplicações.

Tarefa de KDD	Exemplos de Aplicação
Classificação	Permite associar a cada registro de um banco de dados, um único rótulo ou classe. Uma comercializadora de energia elétrica pode realizar planos de atendimento diferenciados, conforme a segmentação dos perfis de crédito ou de montante contratual de seus clientes.
Clusterização	Possibilita a identificação automática dos registros de uma base de dados na forma de agrupamentos com características similares.
Descoberta de Associações	Incremento nas vendas de um determinado segmento comercial a partir do conhecimento das associações freqüentes entre os produtos consumidos pelos clientes.
Descoberta de Sequências	Permite a descoberta de associações em diferentes transações ao longo do tempo. Essa identificação dos padrões de consumo auxilia na elaboração de estratégias de vendas que acompanhe as sazonalidades.

Detecção de Desvios	Detecção de fraudes em cartões de crédito, planos de saúde, arrecadação. Identificação de furtos de energia elétrica.
Previsão de Séries Temporais	Solução de problemas relacionados ao planejamento e a tomada de decisões, reduzindo o nível de incerteza e os riscos do negócio.
Regressão	Busca de funções, lineares ou não, que mapeiem ajustadamente os registros de um banco de dados. Pode-se pré-estabelecer a variação na carga num determinado período em função da variação da temperatura.
Sumarização	Identificar as características dos consumidores de energia elétrica de determinado segmento industrial em relação à elasticidade-preço.

Fonte: Elaborado pelo Autor a partir de GOLDSCHMIDT e PASSOS, 2005.

A expressão “técnica de KDD” se refere a qualquer teoria que possa fundamentar a implementação de um método de KDD. Existem diversos tipos de técnicas e de algoritmos para a mineração de dados: redes neurais artificiais, lógica fuzzy, algoritmos genéticos, estatística, econometria, algoritmos específicos para tarefa de descoberta de regras de associação como o Apriori, entre outros (GOLDSCHMIDT e PASSOS, 2005).

Na seção seguinte, são apresentados os procedimentos para seleção, pré-processamento e transformação dos dados. A aplicação desta etapa da metodologia é de grande importância para o sucesso do trabalho e está documentada no Capítulo 4, referente à formação da base de dados. Quanto às tarefas e técnicas de KDD, a metodologia proposta contempla duas etapas de mineração de dados: a regressão como forma de descrever estatisticamente o consumo de energia elétrica da indústria (Seção 3.3), e a previsão de séries temporais acerca do consumo de energia elétrica com a aplicação de técnicas de inteligência artificial (Seção 3.4).

3.2.4 Etapas para Constituição da Base de Dados

PESQUISA DE CAMPO

O ponto de partida para obtenção de dados para a pesquisa foi estimar quais variáveis poderiam colaborar com o processo de KDD, sobre o consumo de energia elétrica de alguns segmentos da indústria catarinense. Apesar de existir muitos exemplos na literatura, optou-se pela realização de uma pesquisa de campo com os gestores das indústrias como forma de qualificar a escolha das variáveis relacionadas ao consumo de energia elétrica. Foram realizadas algumas entrevistas, nas empresas e/ou sindicatos representativos das quatro atividades industriais de maior consumo de energia elétrica em Santa Catarina, que por questão de sigilo não puderam ter seus nomes citados neste documento.

LEVANTAMENTO DE DADOS

O processo de levantamento de dados proposto nesta metodologia foi uma das etapas mais árduas de todo o trabalho. Mesmo assim, a obtenção das mais de 40 séries históricas sobre econo-

mia e clima, primou-se pela confiabilidade das fontes disponíveis no Brasil e no exterior. As principais instituições que forneceram os dados à pesquisa estão listadas no Capítulo 4.

PRÉ-PROCESSAMENTO DA BASE DE DADOS

Segundo GOLDSCHIDT e PASSOS (2005), a etapa de pré-processamento compreende as funções relacionadas à captação, à organização, ao tratamento e à preparação dos dados para etapa de mineração de dados. Nesta etapa, pode-se realizar desde a correção de dados errados até a formatação para os algoritmos a serem utilizados. A Tabela 3.2 descreve as funções e os métodos do pré-processamento que foram utilizados para formação das bases de dados sobre energia, economia e clima.

Tabela 3.2 – Funções e Métodos do Pré-Processamento da Base de Dados

Função: Seleção de Dados	
Objetivo: identificação de quais informações (registros ou atributos) das bases de dados existentes, devem ser efetivamente consideradas durante o processo de KDD.	
Etapa	Método
Redução de Dados Horizontal	Seleção dos registros de interesse para a pesquisa e verificação da unicidade dos mesmos para cada série histórica.
Redução de Dados Vertical	De forma análoga à Análise de Componentes Principais (HAYKIN, 2001), realiza-se uma seleção das melhores variáveis, econômicas e climáticas de cada segmento industrial, para os modelos descritivo e preditivo.
Função: Limpeza dos Dados	
Objetivo: eliminação dos dados da base que estejam incompletos (informação ausente ou pouco detalhada), ruidosos (valores divergentes ou <i>outliers</i>), ou inconsistentes (discrepância semântica) por meio: da verificação da consistência das informações, da correção de possíveis erros com o preenchimento ou a eliminação de valores desconhecidos e redundantes, e da eliminação de valores não pertencentes ao domínio.	
Etapa	Método
Limpeza de Informações Ausentes	Preenchimento com Medidas Estatísticas. A média ou a moda das séries de dados podem substituir os valores ausentes.
Limpeza de Inconsistências	Exclusão de Casos: pode-se verificar e substituir informações inconsistentes por medidas estatísticas.
Limpeza de Dados Fora do Domínio	Um caso particular da Exclusão de Casos onde se faz necessário o conhecimento prévio do domínio de cada atributo.
Função: Normalização ou Transformação dos Dados	
Objetivo: ajustar a escala dos valores de cada atributo de forma que eles sejam padronizados.	
Etapa	Método
Definição do Método mais Adequado ao Algoritmo de Mineração de Dados	(1) Norma Euclidiana: considera a diferença de cada registro para a média e o desvio padrão da amostra; (2) Normalização Linear: todos os registros variam linearmente entre 0 (mínimo) e 1 (máximo); (3) Normalizar pelo valor médio da série; (4) Normalizar pelo valor máximo da série;

Função: Construção de Atributos	
Objetivo: gerar novos atributos a partir dos atributos existentes que, além de reduzir o conjunto de dados, incorporam informações de relacionamentos de dados ao problema.	
Etapa	Método
Geração de Informação	Inclusão na base de dados da relação lógica desejada entre os atributos existentes.
Função: Partição do Conjunto de Dados – (Válida para o Modelo Preditivo)	
Objetivo: Segundo GOLDSCHMIDT e PASSOS (2005), a avaliação de um modelo de conhecimento requer que os dados utilizados na construção do modelo não sejam os mesmos utilizados na avaliação deste. Assim, pelo menos dois conjuntos de testes devem ser utilizados na etapa de previsão da demanda.	
Etapa	Método
Particionamento	Partição da base de dados em dois conjuntos de séries históricas: de 1997 a 2004 para treinamento e de 2005 a 2006 para os testes de aplicação da rede neural.

Fonte: Elaborado pelo Autor.

3.3 MÉTODOS ECONÔMETRICOS PARA DESCREVER A DEMANDA

O processo de descrição da demanda proposto, compreende a aplicação de um conjunto de técnicas e ferramentas estatísticas capazes de inferir sobre o verdadeiro comportamento dos consumidores de energia elétrica dos segmentos industriais em estudo. Nessa fase da metodologia pode-se estimar a importância que cada variável econômica ou climática tem sobre as variações no consumo de energia elétrica de cada segmento. Ao final desta etapa, pode ser repassado para o modelo predictor neural da demanda, o conhecimento sobre as variáveis que apresentam níveis mais significativos de relacionamento com o consumo de energia elétrica.

Uma das mais completas definições sobre a econometria, verificada em TINTNER (1968), apresenta e justifica sua utilização nesta metodologia: “*A econometria é a aplicação da estatística matemática aos dados econômicos para dar apoio empírico aos modelos formulados pela economia matemática e obter resultados numéricos, que por sua vez, refletem certa perspectiva em relação ao papel da economia*”. Da mesma forma, o modelo econômico-matemático proposto na tese foi embasado na revisão da literatura e nas pesquisas de campo com indústrias. Por meio da aplicação da modelagem estatística foram obtidos resultados numéricos, que refletem o papel da economia e do clima sobre o comportamento do consumo de energia elétrica dos segmentos industriais para os anos observados.

Esta seção apresenta as principais técnicas da modelagem econométrica que foram utilizadas no desenvolvimento e aplicação do modelo descritivo da demanda. Toda a sequência de procedimentos, observada nesta seção, pode ser verificada nos resultados numéricos apresentados no Capítulo 5, além de servir como um roteiro para outras aplicações de regressão múltipla.

3.3.1 Etapas da Modelagem Econométrica Clássica

A Figura 3.4 apresenta um diagrama com as etapas características de uma modelagem econométrica clássica, que por sua vez, é muito próximo ao proposto neste trabalho. Resumidamente, a modelagem econométrica deve contemplar cada uma das etapas, da seguinte forma:

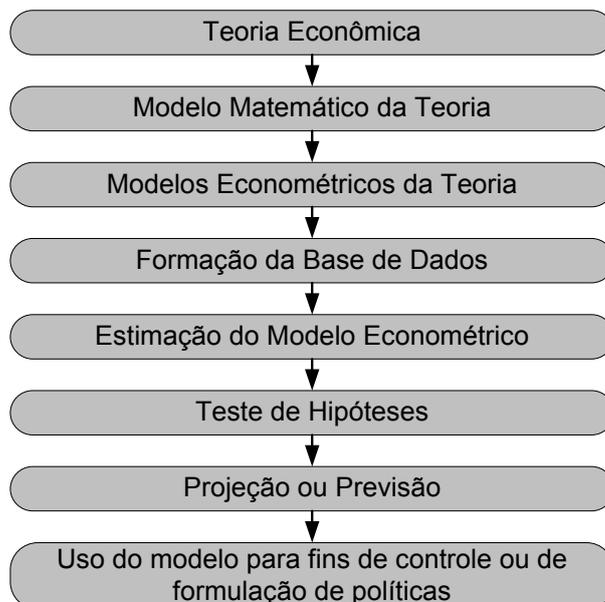


Figura 3.4 – Etapas da Modelagem Econométrica Clássica.

Fonte: GUJARATI, 2006.

- ➔ Teoria Econômica: a revisão da literatura, em conjunto com as pesquisas de campo, permitiram o estabelecimento de algumas relações no âmbito da teoria econômica: por exemplo, que o crescimento do produto interno bruto aumentaria o consumo de energia elétrica, pois o mesmo seria acompanhado de maior consumo das famílias, das indústrias e do governo.
- ➔ Modelo Matemático da Teoria: estabelece qual o tipo de relação matemática existe entre as variáveis. São diretamente/inversamente proporcionais? Variam linearmente ou existe alguma relação exponencial/polinomial entre elas? No caso exemplificado anteriormente, espera-se que o PIB tenha relação linear positiva com o consumo de energia elétrica, ou vice-versa. No desenvolvimento deste trabalho foram admitidas que todas as variáveis econômicas e climáticas teriam, individualmente, relações lineares com o consumo de energia elétrica dos segmentos. Cada uma com seu respectivo nível de correlação esperada, positiva ou negativa.
- ➔ Modelos Econométricos da Teoria: nesta etapa pode-se definir a forma de representação de todas as variáveis explicativas capazes de ajudar na estimação da variável dependente

(consumo). Para esta aplicação foi adotado o modelo de regressão linear clássico para mais de uma variável explicativa, ou simplesmente, Modelo de Regressão Múltipla.

- ➔ Formação da Base de Dados: etapa essencial para a defesa dos resultados obtidos, seja no contexto da discussão das teorias econômicas, ou para simples contribuição ao tema de pesquisa. A qualidade dos dados obtidos está diretamente relacionada à qualidade e confiabilidade dos resultados alcançados. Para atender a essas e outras necessidades este trabalho apresenta a etapa de mineração de dados integrada ao processo de formação da base de dados no Capítulo 4.
- ➔ Estimação do Modelo Econométrico: com o uso das séries históricas das variáveis explicativas e dependentes podem ser estimadas as relações entre as variáveis e o grau de ajustamento do modelo matemático aos dados observados. Ou seja, pode-se aferir o nível e a qualidade da estimação do modelo econométrico e de seus estimadores (variáveis exógenas utilizadas como regressores). Quase sempre a estimação é realizada paralelamente ao Teste de Hipóteses que auxilia na otimização do modelo econométrico, tornando-se um processo iterativo e trabalhoso de aprimoramento desse tipo de aplicação.
- ➔ Teste de Hipóteses: a partir do primeiro modelo econométrico desenvolvido podem ser realizados diversos testes relacionados, por exemplo: à significância do modelo de regressão e dos coeficientes da mesma, às relações de causalidade ou precedência temporal entre as variáveis, à contribuição marginal de cada regressor na qualidade da estimação final, entre outros.
- ➔ Projeção ou Previsão: De posse de um bom modelo econométrico, o passo seguinte seria a elaboração de relatórios com a previsão do comportamento da variável dependente a partir do conhecimento das variáveis explicativas. Porém, na metodologia utilizada neste trabalho, a função de prever o consumo é EXCLUSIVA do modelo neural de previsão do consumo de energia elétrica.
- ➔ Uso do modelo para fins de controle ou formulação de políticas: representa uma prática comum nas instituições econômicas dos governos. Porém, a aplicação da econometria para compreensão do comportamento do consumo de energia elétrica das indústrias poderia subsidiar a tomada de decisões, no âmbito do planejamento estratégico, dos agentes do setor mais próximos ao dia a dia dos grandes consumidores industriais.

3.3.2 Seleção das Melhores Variáveis

O processo de seleção das melhores variáveis tem o objetivo de complementar a etapa de formação da base de dados, tornando-a mais reduzida ao priorizar as séries históricas mais representativas para o comportamento da demanda. Com a aplicação de alguns testes estatísticos pode-se

descartar aquelas variáveis que pouco ou nada poderiam contribuir para a descrição da demanda dos segmentos industriais. Para participar do modelo matemático de descrição da demanda, as séries históricas das variáveis candidatas passam por três testes:

- i. Teste de Raiz Unitária: para verificar a estacionariedade das séries históricas;
- ii. Correlação Linear de Pearson: para medir o nível de correlação existente entre as variáveis explicativas (econômicas e climáticas) e a variável dependente (consumo de energia elétrica) ao longo dos anos considerados;
- iii. Cálculo do atraso mensal que maximiza a correlação (AMMC) linear entre as variáveis explicativas e a variável dependente.

TESTES DE RAIZ UNITÁRIA

A regressão linear múltipla, definida como modelo econométrico para a presente aplicação, está descrita na Seção 3.3.3. Entretanto, uma das condições necessárias para sua consecução, a estacionariedade da série histórica, estabelece um dos pré-requisitos mais importantes do processo de seleção das variáveis da metodologia.

Segundo GUJARATI (2006), a análise de regressão baseada em séries temporais pressupõe implicitamente que as séries temporais subjacentes são estacionárias²⁵. Como, na prática, a maior parte das séries econômicas é não-estacionária, foram realizadas transformações nas séries históricas originais, ainda no processo de formação das bases de dados, a fim de torná-las mais adequadas à metodologia. Por exemplo, a série histórica de crescimento do PIB que originalmente é não-estacionária, por apresentar uma tendência clara de crescimento ao longo dos anos, pode ser modificada para ser razão do PIB do mês (m) do ano atual (a) pelo PIB do mesmo mês m do ano anterior (a-1) e então tornar-se estacionária. Como esta e outras transformações, apresentadas no Capítulo 4, não garantem a estacionariedade da nova série histórica, deve-se aplicar testes de verificação da existência de raiz unitária.

Para apresentar os testes de raiz unitária utilizados nesta metodologia é importante introduzir alguns conceitos relacionados aos processos estocásticos²⁶. Uma série temporal econômica (Y_t) pode ser resultado de um processo estocástico estacionário, se para todos os valores de t:

$$\text{(média constante)} \quad E(Y_t) = \mu \quad (3.1)$$

$$\text{(variância constante)} \quad \text{var}(Y_t) = \sigma^2 \quad (3.2)$$

$$\text{(covariância depende de s, e não de t)} \quad \text{cov}(Y_t, Y_{t+s}) = \text{cov}(Y_t, Y_{t-s}) \quad (3.3)$$

²⁵ Se uma série temporal é estacionária, sua média, variância e autocovariância (em diferentes defasagens) permanecem as mesmas ao longo do tempo, ou seja, não importa qual seja o ponto em que as medimos.

²⁶ Um processo aleatório ou estocástico é um conjunto de variáveis aleatórias ordenadas no tempo (GUJARATI, 2006)

Com o uso de modelos para representar os processos estocásticos pode-se estimar a veracidade das relações acima. Para ilustrar a teoria, os modelos básicos para geração das séries históricas aleatórias, a saber: estacionário, passeio aleatório, passeio aleatório com constante, e passeio aleatório com constante e tendência, foram sinteticamente construídos nos gráficos da Figura 3.5.

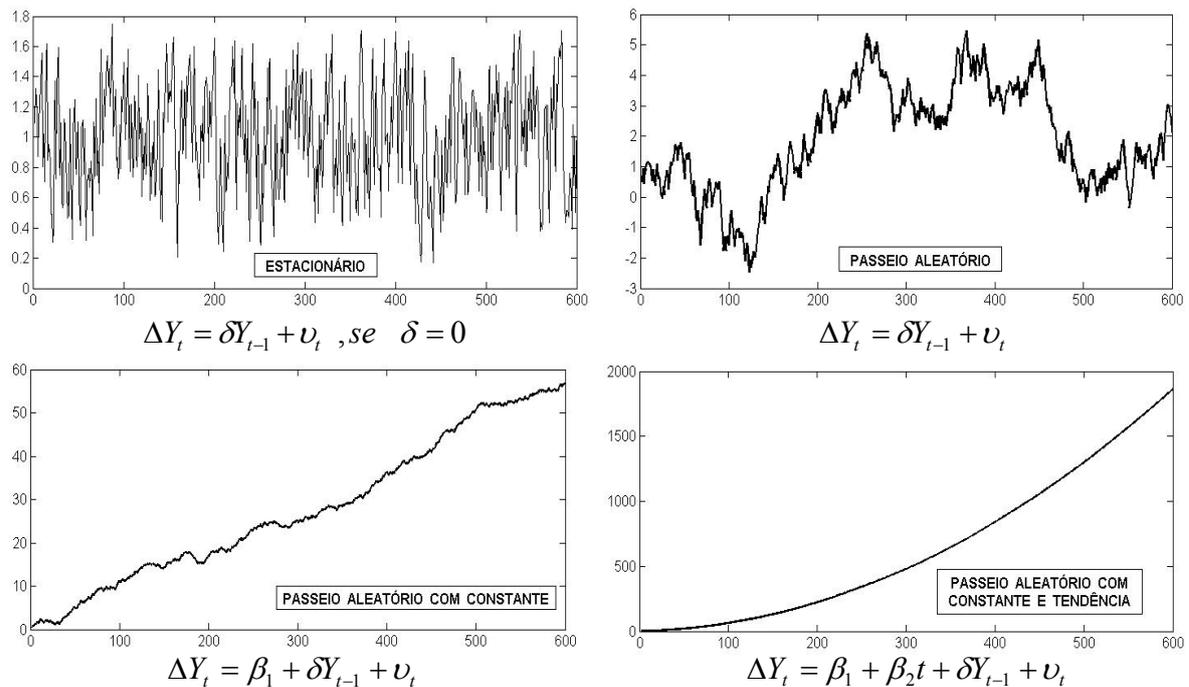


Figura 3.5 – Séries Temporais Sintetizadas com a Aplicação de Modelos Estocásticos.

Fonte: Elaborada pelo autor.

A representação matemática dos modelos da Figura 3.5 utiliza os seguintes elementos: ΔY_t – variação da série temporal a cada novo período t , β_1 – coeficiente linear, β_2 – fator de correlação temporal, δ – coeficiente angular, v_t – termo de erro ou resíduo, que apresenta média zero e variância constante, e não é autocorrelacionado.

A partir da equação do passeio aleatório, pode-se pensar que a simples estimação do coeficiente angular da relação (δ) determinará se Y_t é estacionária. Porém, o teste de significância *t de Student* para verificar se δ é estatisticamente diferente de zero não pode ser aplicado, pois o coeficiente de Y_{t-1} não segue uma distribuição *t*, nem mesmo em grandes amostras. Dickey e Fuller mostraram que, sob a hipótese nula de que $\delta=0$, o valor *t* estimado do coeficiente de Y_{t-1} segue a estatística τ (*tau*) (GUJARATI, 2006). Os autores calcularam esses valores críticos com base em simulações de Monte Carlo. A estatística ou teste de *tau* é conhecido como teste de Dickey-Fuller (DF) em homenagem aos seus descobridores.

A aplicação do teste DF é específica para cada processo estocástico considerado como modelo para a série histórica analisada. Os valores críticos do teste de *tau* usado para verificar a hipó-

tese nula de que $\delta=0$ diferem se a série histórica for considerada um passeio aleatório simples ou com constante e/ou com tendência. O resultado de teste DF considera a série histórica estacionária se o valor t para o δ estimado no modelo estocástico for inferior ao valor crítico para o nível de significância estatística desejado. A Tabela 3.3 apresenta alguns valores críticos para o teste de Dickey-Fuller conforme o modelo especificado e nível de significância.

Tabela 3.3 – Valores Críticos para o Teste de Dickey-Fuller

Modelo	1%	5%	10%
$\Delta Y_t = \delta Y_{t-1} + v_t$	-2,56	-1,94	-1,62
$\Delta Y_t = \beta_1 + \delta Y_{t-1} + v_t$	-3,43	-2,86	-2,57
$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + v_t$	-3,96	-3,41	-3,13

Fonte: HILL et al., 2003.

A pressuposição de que o termo de erro v_t seria não-correlacionado é necessária para a realização do teste DF como fora apresentado. Porém, os mesmos autores desenvolveram o *teste de Dickey-Fuller aumentado* (DFA) para verificar a presença de raiz unitária no caso de v_t ser auto-correlacionado. O novo teste envolve o “aumento” das equações precedentes pelo acréscimo dos valores defasados da variável dependente ΔY_t . Para o modelo com constante e tendência o teste DFA consistiria na estimação da seguinte regressão:

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \sum_{i=1}^m \alpha_i \Delta Y_{t-i} + v_t \quad (3.4)$$

Em que,

m é o número de termos de diferenças defasados a ser incluído

α_i são os coeficientes angulares dos iésimos termos defasados

v_t é o termo de erro ou resíduo, ou também chamado de ruído branco puro²⁷

Obs. 1: Os valores críticos para o teste DFA são os mesmo do teste original, pois ambos seguem a mesma distribuição estatística assintótica.

Obs. 2: o número de termos defasados (m) é determinado empiricamente, mas sempre com o objetivo de que m seja suficiente para que o termo de erro não apresente autocorrelação.

Adicionalmente, esta metodologia utiliza o teste de Phillips-Perron (PP) na etapa de verificação da presença de raiz unitária nas séries históricas das bases de dados. Para desenvolver esse teste os autores usaram de métodos não-paramétricos²⁸ para levar em conta a correlação serial nos termos de erro sem somar termos de diferenças defasadas (que ocorre no teste DFA). Por apresen-

²⁷ Tipo especial de processo estocástico (ou série temporal) puramente aleatório, o qual apresenta média zero, variância constante e serial não-correlacionado.

²⁸ Fazem a correção para a estatística-t do coeficiente de regressão (δ) considerando a correlação serial.

tar resultados mais significativos à medida que aumenta o número de termos defasados da série histórica analisada, o teste PP facilita a verificação da estacionariedade quando os termos de erro correlacionam-se devido à sazonalidade do fenômeno econômico ou climático gerador.

Com a aplicação dos testes de DF, DFA e PP puderam ser descartadas quase todas as variáveis da base de dados que, estatisticamente, eram não-estacionárias para os anos analisados. A partir desta seleção foram identificadas e classificadas as variáveis com maior possibilidade de “explicar” o comportamento do consumo de energia elétrica dos segmentos industriais.

CORRELAÇÃO LINEAR DE PEARSON

De modo a dar continuidade ao processo de seleção das melhores variáveis para o modelo econométrico de descrição da demanda, cada uma das variáveis explicativas foi correlacionada individualmente com a variável dependente. Um método usualmente utilizado para medir a correlação entre duas variáveis é o *Coefficiente de Correlação Linear de Pearson*, também conhecido como Coeficiente de Correlação do Momento Produto. Este foi o primeiro método de correlação, estudado por Francis Galton e seu aluno Karl Pearson, em 1897 (LIRA, 2005). Este coeficiente de correlação também é utilizado na análise de componentes principais, análise fatorial, análise de confiabilidade, entre outras.

Para efetuar seu cálculo, considerando:

- X uma variável explicativa com n períodos amostrados (x_1, x_2, \dots, x_n) , cuja média dos valores da série histórica seja dado por \bar{x} , e
- Y uma variável dependente com n períodos amostrados (y_1, y_2, \dots, y_n) cuja média dos valores da série histórica seja dado por \bar{y} , o coeficiente de correlação linear de Pearson pode ser calculado pela Equação 3.5:

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3.5)$$

A suposição básica para a utilização deste coeficiente em estudos amostrais é de que o relacionamento entre as duas variáveis seja linear, e assim estar adequado para medir o relacionamento linear. A segunda hipótese é de que as variáveis envolvidas sejam aleatórias e que sejam medidas no mínimo em escala intervalar.

Na prática, o coeficiente (ρ) é interpretado como um indicador que descreve a interdependência entre as variáveis X e Y, com a forma $\hat{Y} = \alpha + \beta\hat{X}$, em que α e β são constantes. A tarefa de qualificar os valores obtidos para o coeficiente de correlação apresenta diferentes resultados na literatura. Apenas como um guia geral, as correlações entre as variáveis econômicas e climáticas da base de dados nesta metodologia foram avaliadas conforme a Tabela 3.4:

Tabela 3.4 – Qualificação para os Coeficientes de Correlação de Pearson

Valor de ρ	Qualificação
$0,00 < \rho < 0,20$	A correlação linear é praticamente inexistente
$0,20 \leq \rho < 0,40$	Existe uma correlação linear muito fraca
$0,40 \leq \rho < 0,70$	Existe uma correlação linear de fraca a moderada
$0,70 \leq \rho < 0,90$	Existe uma correlação linear forte
$0,90 \leq \rho < 1,00$	Existe uma correlação linear muito forte
$ \rho = 1,00$	Existe uma correlação linear perfeita

Fonte: DRAPER e SMITH, 1981.

Adicionalmente, dependendo do tamanho da amostra, um valor de ρ pode não ter significância estatística. Assim, para descartar uma variável explicativa em virtude do baixo nível de correlacionamento com a variável dependente realiza-se um teste de hipóteses utilizando a distribuição *t de Student* com 99% de nível de confiança.

No Capítulo 5 pode-se verificar como resultado dos testes de correlação linear para as 40 variáveis explicativas, em relação às séries históricas de consumo de energia elétrica, ajuda a selecionar as melhores variáveis para aplicação da metodologia.

ATRASO MENSAL PARA MÁXIMA CORRELAÇÃO

Para completar o processo de seleção das melhores variáveis foram realizadas outras correlações lineares, incluindo defasamentos mensais entres as séries históricas X e Y. A consideração de 0 a 12 meses como defasagem entre os valores das variáveis explicativas e a variável dependente possibilita identificar com quantos meses de atraso tem-se o maior impacto na variação do consumo de energia elétrica devido à variação de cada variável explicativa. O efeito do indicador de confiança da indústria, por exemplo, no consumo de energia elétrica do segmento metalúrgico é verificado com maior intensidade três meses depois de sua variação. Assim, o atraso mensal para a máxima correlação (AMMC) desta relação é igual a 3.

Além de verificar quais defasagens apresentam melhor nível de correlação, os resultados obtidos para os 12 atrasos revelam a sensibilidade das séries históricas explicativas na relação “causa-efeito²⁹” com a variável dependente. Pode-se notar no Capítulo 5 como algumas séries econômicas apresentam boa correlação com o consumo de energia elétrica apenas para poucas defasagens, enquanto que outras, menos sensíveis, apresentam baixa variação do valor de ρ ao longo das defasagens consideradas.

²⁹ A existência de altos níveis de correlacionamento não garante a existência de causalidade entre as variáveis.

3.3.3 Definição do Modelo Estatístico

Segundo GUJARATI (2006), a definição do modelo estatístico ocorre quando o economista modifica a função matemática determinística entre as variáveis explicativas e a variável dependente. No caso da relação entre PIB e consumo de energia elétrica, por exemplo, pressupõe-se que há uma relação exata entre elas como a apresentada na Equação 3.6.

$$Y = f(X) \Rightarrow Y = \beta_1 + \beta_2 X \quad (3.6)$$

Mas como as relações entre variáveis econômicas e climáticas são, em geral, inexatas, para solucionar o problema e respeitar as propriedades probabilísticas do comportamento dessas variáveis, adotam-se modelos estatísticos ou econométricos considerando as mesmas variáveis aleatórias e inseridas em processos estocásticos. Para isso, adiciona-se um distúrbio ou termo de erro, que tem propriedades probabilísticas conhecidas, na equação anterior:

$$Y = \beta_1 + \beta_2 X + \nu \quad (3.7)$$

O modelo estatístico adotado nesta metodologia como modelo de descrição do consumo de energia elétrica da indústria está fundamentado em duas condições:

- A existência de significativas relações lineares entre as principais variáveis explicativas e a variável dependente (identificadas no cálculo do coeficiente de correlação de Pearson);
- A possibilidade de determinação do comportamento do consumo em função da variação mútua dos valores assumidos pelas variáveis econômicas e/ou climáticas selecionadas.

Para atender a segunda condição do modelo estatístico, foi proposta a realização de uma Análise de Regressão Múltipla para descrever o comportamento do consumo para cada segmento industrial. Para efeito de simplificação, considerando-se que, após o processo de seleção de variáveis, tenhamos duas variáveis explicativas para relacionar com a variável dependente (Y), a equação de regressão múltipla pode ser representada por:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \nu_i \quad (3.8)$$

Em que,

Y é a variável dependente ou *regressando*.

X₂ e X₃ são as duas variáveis explicativas ou *regressores*.

β₁ é o intercepto ou coeficiente linear, representa o efeito médio sobre Y de todas as variáveis excluídas do modelo ou quando X₂ e X₃ são igualados a zero.

β₂ e β₃ são os coeficientes parciais da regressão múltipla. β₂ mede a variação no valor médio de Y por unidade de variação em X₂ com o valor de X₃ constante. É o efeito “direto” ou “líquido” da variação de uma unidade de X₂ sobre a variação da variável dependente.

ν é o termo de erro estocástico.

i corresponde a iésima observação das séries históricas.

O marco de referência do modelo de regressão linear clássico (teórico) apresenta importantes condicionantes para a aplicação da análise de regressão múltipla. Entre as principais, pode-se destacar:

- Supõe-se que o modelo de regressão múltipla utilizado é linear nos parâmetros, que os valores dos regressores são fixados em amostras repetidas e que há suficiente variabilidade nos valores dos regressores;
- Ausência de relação linear entre os regressores (colineariedade ou multicolineariedade), para que nenhum deles possa ser expresso como combinação linear exata dos demais regressores. Porém, na prática, quando coletamos dados para análises empíricas, provavelmente, existirá algum nível de correlação entre os regressores. A solução, nesse caso, passa pela configuração de modelos de regressão com menor presença de colineariedade;
- Ausência de tendências de especificação, ou seja, espera-se que o modelo esteja corretamente especificado (linear, log-linear, quadrático, etc). Coaduna-se com a primeira condicionante;
- Demais testes estatísticos: o termo de erro estocástico tem valor médio zero, variância constante e não apresenta correlação serial – estatisticamente equivalente a $v_i \sim N(0, \sigma^2)$; a covariância entre v_i e os regressores X_i é nula.

Além de atender as condicionantes acima, o modelo descritivo proposto nesta metodologia foi aprimorado com a aplicação de alguns testes de hipóteses apresentados na Seção 3.3.5. A Figura 3.6 apresenta um fluxograma do processo de construção do modelo econométrico. As próximas seções descrevem em detalhes cada uma das etapas de desenvolvimento do modelo.

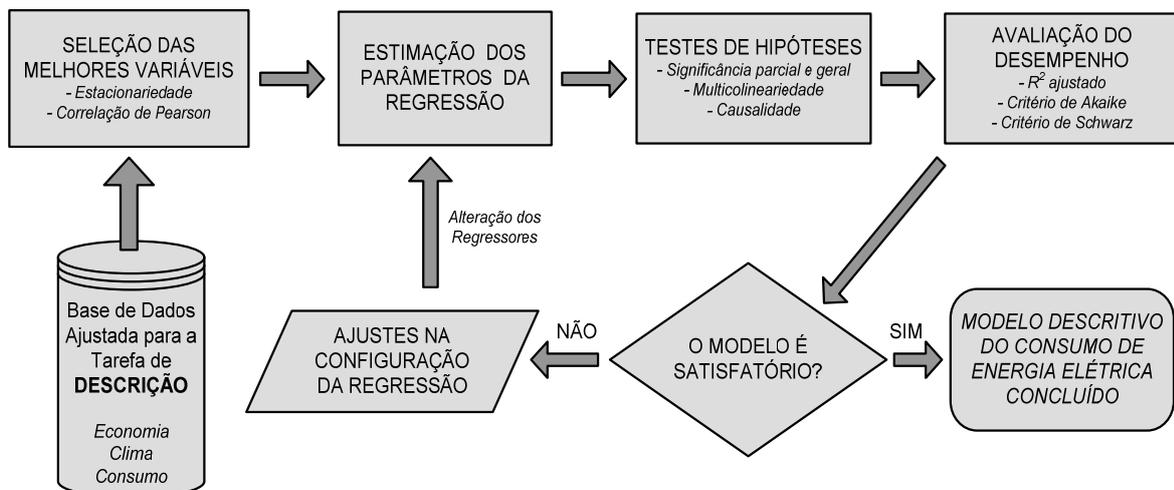


Figura 3.6 – Fluxograma do Processo de Construção do Modelo Econométrico.

Fonte: Elaborado pelo autor.

hiperplano da regressão amostral se ajusta aos dados. Ou seja, R^2 mede a proporção ou percentual da variação total de Y que é explicada pelo modelo de regressão. Seu cálculo é dado pela equação:

$$R^2 = \frac{\beta' X' Y - n \bar{Y}^2}{Y' Y - n \bar{Y}^2} \quad (3.13)$$

A construção deste indicador considera todas as diferenças entre os valores verdadeiros e estimados da variável dependente ao longo da amostra. O valor do coeficiente de determinação situa-se entre 0 e 1. Do cálculo à interpretação, pode-se afirmar que o modelo econométrico “expliou” entre 0% e 100% da variação de Y . Entretanto, segundo GUJARATI (2006), a literatura adverte para que não se busque a maximização de R^2 a todo custo no desenvolvimento de um modelo de regressão. Para se obter estimativas confiáveis dos coeficientes de regressão é mais importante a realização de inferências estatísticas sobre os mesmos. Constata-se no âmbito da economia, a obtenção de elevados valores de R^2 para modelos estatísticos com regressores pouco significativos ou de duvidosa relação sistêmica com a variável dependente.

3.3.5 Testes de Hipóteses

No contexto desta metodologia, os testes de hipóteses são responsáveis pelo processo de inferência estatística sobre o modelo econométrico proposto. Os resultados obtidos nesta fase, mesmo que de forma iterativa, permitem refinar a qualidade e elevar a significância do modelo descritivo do consumo de energia elétrica das indústrias. A partir de um modelo de regressão múltipla com todas as variáveis explicativas inicialmente selecionadas, procede-se à realização dos seguintes testes de hipóteses:

- ➔ Teste da Significância dos Coeficientes Parciais
- ➔ Teste da Significância Geral do Modelo
- ➔ Avaliação da Contribuição Marginal do Regressor
- ➔ Testes de Multicolineariedade
- ➔ Testes de Causalidade

TESTE DA SIGNIFICÂNCIA DOS COEFICIENTES PARCIAIS

Considerando verdadeira a premissa $v_i \sim N(0, \sigma^2)$, mencionada na Seção 3.3.3, podemos adotar o teste t para testar uma hipótese sobre qualquer um dos coeficientes parciais da regressão, de forma individual. No caso da regressão com apenas duas variáveis explicativas X_2 e X_3 , para testar a hipótese nula de X_2 não exercer influência sobre Y quando X_3 permanece constante³¹, postula-se que:

³¹ Condição que limita a ação individual do teste de significância sobre o regressor.

$$H_0 : \beta_2 = 0 \quad e \quad H_1 : \beta_2 \neq 0 \quad (3.14)$$

Em que,

H_0 é a hipótese nula

H_1 é a hipótese alternativa

β_2 é o verdadeiro coeficiente linear parcial do regressor X_2

Para podermos rejeitar a hipótese nula e não descartar a variável X_2 do modelo econométrico, o valor da estatística t calculada para β_2 deve ser superior ao valor crítico³² de t ao nível de significância selecionado. O cálculo do valor de t , neste caso, pode ser efetuado pelas equações:

$$t = \frac{\hat{\beta}_2 - \beta_2}{ep(\beta_2)} \quad (3.15)$$

$$ep(\beta_2) = \frac{\sigma}{\sqrt{\sum_{i=1}^n (X_{2i} - \bar{X}_2)^2}} \quad (3.16)$$

Em que,

$\hat{\beta}_2$ é o coeficiente linear parcial estimado pelo modelo regressor

ep é o erro padrão da amostra

σ é o desvio padrão da amostra do regressor X_2 .

As equações 3.14 a 3.16 podem ser estendidas para a realização dos testes de significância dos demais coeficientes lineares parciais do modelo descritivo (GUJARATI, 2006).

TESTE DA SIGNIFICÂNCIA GERAL DO MODELO

O teste de significância geral da regressão múltipla verifica a hipótese nula de que β_2, β_3, \dots , e β_k sejam simultaneamente iguais a zero. Entretanto, devido à aplicabilidade individual do cálculo de t , o mesmo não pode ser aplicado com as mesmas amostras dos k regressores para testar a significância geral do modelo.

Para solucionar este problema, pode-se recorrer à técnica da análise de variância para reescrever os termos da regressão e aplicar o *teste de Fischer*, ou simplesmente, *teste F*. A Equação 3.17 relaciona, em letras minúsculas, os desvios das amostras de X e de Y para seus valores médios com os resíduos e coeficientes parciais estimados pela regressão.

³² Valores tabelados da distribuição *t de Student* (vide Anexo A) e que também são disponibilizados em vários softwares de Estatística ou planilhas eletrônicas. O cálculo do t -crítico considera também os graus de liberdade, dados pela diferença entre o tamanho da amostra n e o número de variáveis da regressão múltipla, incluindo a variável dependente.

$$\begin{array}{ccc} \sum y_i^2 = \hat{\beta}_2 \sum y_i x_{2i} + \hat{\beta}_3 \sum y_i x_{3i} + \dots + \hat{\beta}_k \sum y_i x_{ki} + \sum \hat{v}_i^2 & & (3.17) \\ \longleftarrow \quad \longleftarrow & & \\ STQ = & SQE & + SQR \end{array}$$

Em que,

STQ é a soma total dos quadrados, tem n-1 graus de liberdade.

SQE é a soma dos quadrados explicados pela regressão, tem n-k graus de liberdade.

SQR é a soma dos quadrados dos resíduos, tem k-1 graus de liberdade (correspondentes ao número de regressores considerados).

Pode-se demonstrar que para a hipótese nula $\beta_2 = \beta_3 = \dots = \beta_k = 0$ e sob a premissa da normalidade de v_i , a variável F se distribui com k-1 e n-k graus de liberdade, respectivos numerador e denominador da estatística F, conforme a equação:

$$F = \frac{SQE / (k - 1)}{SQR / (n - k)} \quad (3.18)$$

Para que o modelo descritivo do consumo de energia elétrica seja considerado significativo, com a avaliação positiva da contribuição simultânea de todos os regressores, o valor de F deve ser superior ao valor F-crítico³³ conforme o nível de significância desejado.

O teste de hipóteses apresentado equivale-se a um teste da hipótese nula de que o coeficiente de determinação múltipla (R^2) seja igual a zero. Demonstra-se que: quando $R^2=0 \Leftrightarrow F=0$, pois nenhuma parcela da variação de Y foi explicada pelos regressores; ou quando $R^2=1 \Leftrightarrow F=\infty$, de forma que variação de Y foi explicada pelos regressores. Desta relação pode-se escrever a Equação 3.19, que facilita a implementação computacional deste teste de significância.

$$F = \frac{R^2 / (k - 1)}{(1 - R^2) / (n - k)} \quad (3.19)$$

AVALIAÇÃO DA CONTRIBUIÇÃO MARGINAL DO REGRESSOR

Segundo GUJARATI (2006), na prática, a questão da contribuição marginal ou incremental do regressor no modelo é uma das mais importantes. Na maioria das pesquisas empíricas, o pesquisador pode não estar totalmente convencido que valha a pena acrescentar uma variável X sabendo que outras várias já estão presentes no modelo. Por outro lado, não se quer excluir variáveis que aumentem substancialmente a SQE. Com a técnica de análise de variância pode-se inferir se uma nova variável X reduz significativamente a SQR da regressão.

³³ F-crítico são os valores tabelados da distribuição F (vide anexo B) e que também são disponibilizados em vários softwares de Estatística ou planilhas eletrônicas.

Para a avaliação da contribuição marginal do novo regressor realiza-se um teste F comparando a qualidade do modelo em explicar Y, antes e depois da adição do novo X. A partir de 3.19 demonstra-se que o valor de F para testar a hipótese da contribuição marginal é dado por:

$$F = \frac{(R_{depois}^2 - R_{antes}^2) / (\text{número de novos regressores})}{(1 - R_{depois}^2) / (n - \text{número de parâmetros depois})} \quad (3.20)$$

De maneira similar aos testes de hipótese apresentados, para que uma nova variável explicativa apresente contribuição marginal significativa ao modelo descritivo de consumo de energia elétrica, o valor de F deve ser superior ao valor F-crítico conforme o nível de significância desejado.

TESTES DE MULTICOLINEARIEDADE

A ausência de multicolineariedade foi apresentada anteriormente como uma das premissas do modelo clássico de regressão múltipla. Na prática, é impossível estabelecer um modelo de regressão múltipla com algumas variáveis econômicas sem que exista alguma correlação linear entre elas. A função deste teste na metodologia é evitar que o modelo descritivo do consumo de energia elétrica apresente um nível de multicolineariedade exagerado. A detecção da sua presença nos modelos não é um processo determinístico. Porém, para isso, existem algumas regras práticas:

- R^2 alto com coeficientes parciais pouco significativos;
- Altos níveis de correlação entre pares de regressores (correlação cruzada);
- Cálculo do índice condicional (IC) com os autovalores da matriz de regressores.

As duas primeiras regras são autoexplicativas e puderam ser implementadas computacionalmente sem maiores esforços. Já a terceira regra necessita de maiores detalhes para sua aplicação. Para participar do cálculo do IC do modelo de regressão múltipla, as variáveis explicativas devem estar previamente padronizadas³⁴. Efetua-se o cálculo dos autovalores da matriz dos regressores ($X' \times X$), já padronizados. Quanto maior for um dado autovalor da matriz, maior é o nível de correlação linear dos regressores das respectivas linha e coluna em que ele se encontra. De forma empírica, determinou-se um número condicional k, cuja raiz quadrada resulta em IC, que permite qualificar a presença da multicolineariedade no modelo. Para avaliar os resultados da Equação 3.21 utilizam-se as regras práticas da Tabela 3.5.

$$IC = \sqrt{\frac{\text{máximo autovalor}}{\text{mínimo autovalor}}} = \sqrt{k} \quad (3.21)$$

³⁴ Nesta transformação cada valor em X é substituído pela diferença entre o valor amostrado X_{ik} e o valor médio \bar{X}_k dividida pelo desvio padrão do regressor σ_k .

Tabela 3.5 – Regras Práticas para Interpretação do Índice Condicional

Intervalos	Diagnóstico
IC < 10	Baixa Multicolineariedade
10 ≤ IC ≤ 30	Multicolineariedade de Fraca a Moderada
IC > 30	Multicolineariedade Grave

Fonte: GUJARATI, 2006.

Segundo GUJARATI (2006), alguns autores acreditam que o índice condicional é o melhor meio disponível de diagnosticar a multicolineariedade, embora tal opinião não seja geral. Esta sofisticada regra prática, também de fácil programação, apresentou resultados consistentes na fase de aplicação da metodologia.

TESTES DE CAUSALIDADE

Embora a análise de regressão trate da dependência de uma variável em relação a outras, isso não implica necessariamente numa relação de causa-efeito entre elas numa dada direção. Porém, quando as variáveis envolvem séries temporais pode-se fazer alguma inferência nesse sentido. Como afirma KOOP (2000), “... o tempo não corre para trás. Isto é, se o fato A aconteceu antes do fato B, então é *possível* que A cause B. Contudo, não é possível que B cause A”. Essa abordagem, aparentemente óbvia, que não garante um fator de relação causal entre as variáveis, leva à compreensão do termo precedência temporal. Termo este, preferido por muitos autores à causalidade.

O teste de causalidade de Granger baseia-se na afirmativa de Koop. Ele pressupõe que a informação relevante para estabelecer a relação entre duas variáveis A e B está contida unicamente nos dados da série temporal das mesmas. Assim, a solução do teste de causalidade bilateral, dá-se pela estimação do seguinte par de regressões:

$$A_t = \sum_{i=1}^m \alpha_i B_{t-i} + \sum_{j=1}^m \beta_j A_{t-j} + v_{1t} \quad (3.22)$$

$$B_t = \sum_{i=1}^m \lambda_i B_{t-i} + \sum_{j=1}^m \delta_j A_{t-j} + v_{2t} \quad (3.23)$$

Uma vez que o futuro não pode prever o passado, se a variável B Granger-causa³⁵ a variável A, então variações em B deveriam preceder variações em A. Portanto, em uma regressão (Equação 3.22) de A contra outras variáveis (incluindo seus valores passados), se incluirmos “m” valores passados ou defasados de B e eles melhoram significativamente a previsão de A, então podemos dizer que B causa A. O mesmo raciocínio vale para testar se A causa B, usando a Equação 3.23.

A solução do teste de causalidade de Granger segue os passos abaixo:

³⁵ Forma usual de afirmar que B causa A, segundo o teste de Granger.

- Cálculo da regressão restrita de A: regressão de A contra todos os termos defasados de A sem a inclusão dos termos defasados de B. A partir dela, calcular o coeficiente de determinação múltipla (R_R^2) .
- Cálculo da regressão irrestrita de A: regressão de A contra todos os termos defasados de A e com todos os termos defasados de B. A partir dela, calcular o coeficiente de determinação múltipla (R_{IR}^2) .
- Cálculo de F: para testar a hipótese nula $H_0: \Sigma \alpha_i = 0$, equivalente a dizer que os termos de B defasados não cabem na regressão, ou ainda, que eles não contribuem significativamente para prever A, aplica-se o teste F de forma análoga à Equação 3.20:

$$F = \frac{(R_{IR}^2 - R_R^2)/(m)}{(1 - R_{IR}^2)/(n - k_{IR})} \quad (3.24)$$

Em que,

n é o número de períodos das séries históricas

k_{IR} é o número de parâmetros da estimados na regressão sem restrições

- Resultado: Se o valor de F calculado em 3.24 for superior ao F-crítico no nível de significância desejado, rejeita-se a hipótese nula, pois os termos defasados de B cabem na regressão. Portanto, estima-se que a variação de B causa a variação de A.
- Causalidade bidirecional: adicionalmente, pode-se encontrar uma relação de causalidade bidirecional quando os testes estimarem que A causa B e que B causa A.

Na prática, o número de termos defasados que devem ser incluídos no teste de causalidade de Granger não é uma questão trivial. Por se tratar de um modelo de defasagens distribuídas, pode-se recorrer ao critério de informação de Schwarz³⁶ para determinar o melhor valor de m .

Para o aprimoramento do modelo de descrição aqui proposto, é verificada a presença de causalidade em duas etapas: (i) testando se as variáveis econômicas e climáticas, individualmente, apresentam alguma relação de precedência temporal com o consumo de energia elétrica; (ii) testando se variação de alguma dessas variáveis explicativas precede temporalmente a variação em outra explicativa. Em suma, deseja-se que no modelo descritivo final, as variáveis explicativas apresentem alguma relação de causalidade com o consumo e pequena ou nenhuma relação de causalidade entre si.

³⁶ Parte-se do modelo de regressão com várias defasagens e vai-se gradativamente reduzindo o número de defasagens até se encontre o valor de m que minimiza CIS, onde: $\ln CIS = \ln \left(\frac{\sum u_i^2}{n} \right) + \frac{\ln(n) \cdot k_{IR}}{n}$ (GUJARATI, 2006).

3.3.6 Avaliação de Desempenho do Modelo Econométrico

A construção do modelo econométrico que inspire confiança requer uma série de cuidados, como se pôde constatar nas seções anteriores. Não basta apenas reunir um grupo de variáveis que apresentem boa correlação com o consumo e estimar seus coeficientes parciais. Na maioria das pesquisas, incluindo esta, o modelo econométrico final foi obtido após várias iterações. Ou seja, parte-se de uma configuração inicial para a regressão múltipla, realizam-se todos os testes de hipóteses, avalia-se a qualidade do modelo em curso, e, se preciso, ajusta-se novamente a regressão. A Figura 3.6 ilustra as etapas para construção do modelo econométrico proposto.

Para a etapa de avaliação do modelo, no escopo desta metodologia, são examinados os principais critérios utilizados para escolher entre modelos concorrentes e/ou compará-los para fins de previsão. Antes, faz-se uma importante distinção entre previsão dentro da amostra e previsão fora da amostra. O primeiro caso de previsão está contemplado nesta metodologia, sendo que, sua precisão revela o quão ajustados estão os dados da amostra ao modelo econométrico escolhido. Enquanto que no segundo caso, o foco está em determinar como um modelo ajustado prevê os valores futuros do regressando, conhecidos os valores dos regressores.

Devido à forma com que foi elaborada a metodologia da tese (Figura 3.1), a previsão para fora da região amostral não será analisada pelo modelo regressor construído com técnicas de econometria. Esta função será exercida pelo modelo predictor neural, que por sua vez, será subsidiado pelo conhecimento gerado com o modelo de descrição do consumo de energia elétrica.

CÁLCULO DO R^2 AJUSTADO

Uma das medidas da qualidade do ajustamento de um modelo de regressão é o R^2 , variando entre 0 e 1. Conforme justificado em (GUJARATI, 2006), sua utilização na avaliação de desempenho do modelo econométrico tem importantes ressalvas: (i) R^2 mede a qualidade do ajustamento dentro da amostra e, por isso, não consegue garantir que o modelo faça uma boa previsão para fora da amostra; (ii) o acréscimo de uma nova variável explicativa, mesmo que pouco significativa, no modelo não reduz o valor de R^2 , deixando a “tentação” de maximizar R^2 enchendo o modelo de regressores.

O R^2 ajustado permite penalizar a qualidade do modelo devido ao acréscimo de regressores. Formulado por Henry Theil, e denotado por \bar{R}^2 , ele pode ser calculado por 3.25. Diferentemente do coeficiente original, \bar{R}^2 só aumenta se o valor absoluto de t para a variável adicionada for maior que 1, nos teste de significância.

$$\bar{R}^2 = 1 - (1 - R^2) \frac{n-1}{n-k} \quad (3.25)$$

Em que,

k é o número de variáveis do modelo (regressando + regressores).

CRITÉRIO DE INFORMAÇÃO DE AKAIKE (CIA)

Seguindo a mesma lógica de penalização do cálculo de \bar{R}^2 , o critério de informação de Akaike impõe uma pena maior para o acréscimo de regressores. A vantagem de se usar o CIA na avaliação do modelo é que ele serve para o cálculo de desempenho tanto dentro quanto fora da região amostral. Seu valor pode ser obtido pela equação abaixo:

$$\ln CIA = \ln\left(\frac{\sum u_i^2}{n}\right) + \left(\frac{2k}{n}\right) \quad (3.26)$$

CRITÉRIO DE INFORMAÇÃO DE SCHWARZ

Ainda na mesma lógica, outro indicador comumente utilizado na literatura é o critério de informação de Schwarz. Seu valor pode ser obtido pela equação abaixo:

$$\ln CIS = \ln\left(\frac{\sum u_i^2}{n}\right) + \frac{\ln(n) \cdot k}{n} \quad (3.27)$$

Se um regressor que não possui capacidade para explicar o regressando, sua adição ao modelo fará aumentar o valor de CIA e CIS. Comparando-se as equações 3.26 e 3.27, verifica-se que o custo marginal da adição dos regressores é geralmente maior no CIS que no CIA³⁷. Para a avaliação do modelo, prefere-se mais o critério de Schwarz quando se trabalha com grandes amostras. Já para os casos em que a amostragem é pequena, a sinalização de Akaike é mais precisa (ENDERS, 2004). O objetivo ideal para avaliar e aprimorar o modelo desta metodologia é encontrar uma solução de consenso entre os dois critérios de informação.

CÁLCULO DO MAPE DA PREVISÃO NA REGIÃO AMOSTRAL

O *Mean Average Prediction Error* (MAPE) é um indicador puramente descritivo que não tem propriedades teóricas fortes. Porém, como R^2 , ele é calculado na maioria das publicações como forma de avaliar a qualidade da previsão. Portanto, podemos medir o desempenho do modelo de regressão múltipla pela precisão que ele tem em “prever” dentro da região amostral, fruto da estimação pelo método dos mínimos quadrados. Seu cálculo é obtido pela equação:

$$MAPE = \frac{\sum_{i=1}^n \left(\frac{Y_i - \hat{Y}_i}{Y_i}\right)^2}{n} \quad (3.28)$$

Em que,

n é o tamanho da amostra

Y é o vetor com os valores verdadeiros do regressando

\hat{Y} é o vetor com os valores estimados do regressando

³⁷ $\ln(n) > 2$ para toda série histórica com 8 ou mais períodos.

Com o cálculo e a avaliação da regressão múltipla fecha-se o ciclo para elaboração do modelo descritivo da demanda de energia elétrica dos segmentos industriais de pesquisa. Com a aplicação das técnicas estatísticas apresentadas nesta seção foram alcançados importantes objetivos propostos pela pesquisa. Várias respostas sobre a relação existente entre a economia, o clima e o consumo de energia elétrica, que inclusive subsidiaram o desenvolvimento do modelo preditivo, foram respondidas no Capítulo 5, com a implementação do modelo econométrico proposto.

3.4 REDES NEURAIS ARTIFICIAIS PARA PREVER A DEMANDA

A última etapa da metodologia proposta apresenta o desenvolvimento do Modelo Previsor Neural da Demanda. Como apresentado na Figura 3.1, o objetivo do modelo preditivo é estimar o consumo futuro de energia elétrica dos segmentos industriais, a partir do histórico das variáveis econômicas, climáticas e do próprio consumo de energia elétrica disponíveis.

No capítulo anterior pôde-se observar que muitos trabalhos, com técnicas de KDD ou de econometria, só consideram o histórico da demanda para realizar suas previsões. Alguns autores justificam essa opção, por considerar que a influência das variáveis exógenas já estaria contida no histórico da variação da demanda, ou porque tais variáveis seriam medidas com elevado grau de incerteza (BORLEA et. al 2005). A presente metodologia, além de discordar desse ponto de vista, considera fundamental a utilização de variáveis econômicas e/ou climáticas, para previsão no médio prazo da demanda industrial desagregada.

Com a aplicação do modelo descritor da demanda, apresentado na seção anterior, tornou-se desnecessário considerar todas as variáveis econômicas e climáticas para modelagem das redes neurais. Apenas as variáveis dos modelos econométricos de cada segmento são utilizadas na construção dos respectivos modelos previsores. Seria totalmente inviável configurar as redes neurais, testando mais de 40 possíveis variáveis de entrada, embora pudessem ser utilizadas outras técnicas para redução do conjunto de variáveis candidatas, como a análise de componentes principais.

Uma característica do modelo previsor proposto, que o distingue dos demais, é que a variável objeto da previsão não é o consumo de energia elétrica no mês, e sim a variação do consumo no mês em comparação com o mesmo período do ano anterior. Essa simples mudança na forma de observar a demanda, detalhada nos próximos capítulos, possibilita uma análise do consumo de forma contínua, ou seja, sem considerar os efeitos da sazonalidade ao longo do ano³⁸. Dessa forma, o modelo previsor neural pôde ser elaborado com uma única rede neural artificial (RNA) para prever qualquer mês ao longo das séries históricas. Caso contrário, poderia ser necessário elaborar RNAs exclusivas para certos meses do ano. BORLEA et. al, (2005) apresenta um modelo de redes

³⁸ No Capítulo 4, pode-se perceber os efeitos da sazonalidade nos perfis anuais da carga típicos de cada segmento, principalmente nos meses de férias nas indústrias.

neurais para previsão do consumo nos 12 meses à frente, com informações recorrentes, ou seja, a previsão de um dado mês serve de entrada para a previsão do mês seguinte.

A Seção 3.4.1 apresenta uma introdução teórica sobre as redes neurais artificiais, em que o objetivo principal é ambientar o leitor sobre alguns conceitos básicos dessa técnica, de modo a compreender o processo de aprimoramento dos modelos de previsão de cada segmento. As seções seguintes apresentam as etapas de construção dos dois modelos previsores neurais utilizados na metodologia: na Seção 3.4.2 – predictor neural baseado nas redes *MLP* (*Multi-Layer Perceptron*), na Seção 3.4.3 – predictor neural baseado nas redes *RBF* (*Radial-Basis Functions*).

3.4.1 Redes Neurais Artificiais – Introdução Teórica

As redes neurais artificiais são modelos matemáticos inspirados nos princípios de funcionamento dos neurônios biológicos e na estrutura do cérebro (GOLDSCHMIDT e PASSOS, 2005). Esses modelos têm capacidade de adquirir, armazenar e utilizar conhecimento experimental e buscam simular computacionalmente habilidades humanas como aprendizado, generalização, associação e abstração. Segundo HAYKIN (2001), uma rede neural, vista como uma máquina adaptativa, é um processador maciça-paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural de armazenar conhecimento experimental torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

- i. O conhecimento é adquirido pela rede a partir de seu ambiente por meio de um processo de aprendizagem;
- ii. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

O uso de redes neurais artificiais oferece algumas propriedades e capacidades úteis em relação à tarefa de previsão de demanda, (GOLDSCHMIDT e PASSOS, 2005) e HAYKIN (2001):

- **Aprendizado por Experiência** – As RNAs tentam aprender padrões diretamente a partir dos dados por meio de repetidas apresentações dos dados à rede que busca abstrair modelos de conhecimento de forma automática. Tal processo é denominado aprendizado e é implementado por um algoritmo de aprendizado.
- **Não-linearidade** – Um neurônio artificial pode ser linear ou não-linear, e uma rede constituída por conexões de neurônios não-lineares é também não-linear.
- **Mapeamento de Entrada-Saída** – Envolve a modificação dos pesos sinápticos de uma rede neural pela aplicação de um conjunto de amostras de treinamento, com sinais de entrada e respostas desejadas. Assim, as RNAs não dependem de um modelo matemático que relacione a entrada do processo com a saída.

- Adaptabilidade – As redes neurais têm uma capacidade inata de adaptar seus pesos sinápticos a modificações do meio ambiente. Além disso, quando está operando em um ambiente não-estacionário, uma rede pode ser projetada para modificá-los em tempo real.
- Generalização – As RNAs são capazes de generalizar seu conhecimento a partir de exemplos anteriores. Tal característica permite que as RNAs lidem com ruídos e distorções nos dados, respondendo corretamente a novos padrões.
- Abstração – Representa a capacidade das RNAs em identificar a essência de um conjunto de dados de entrada, percebendo quais as características relevantes em um conjunto de entradas.

MODELO DE UM NEURÔNIO

Um neurônio é uma unidade de processamento de informação fundamental para operação de uma RNA. A Figura 3.7 apresenta um modelo não-linear de um neurônio, com três elementos básicos:

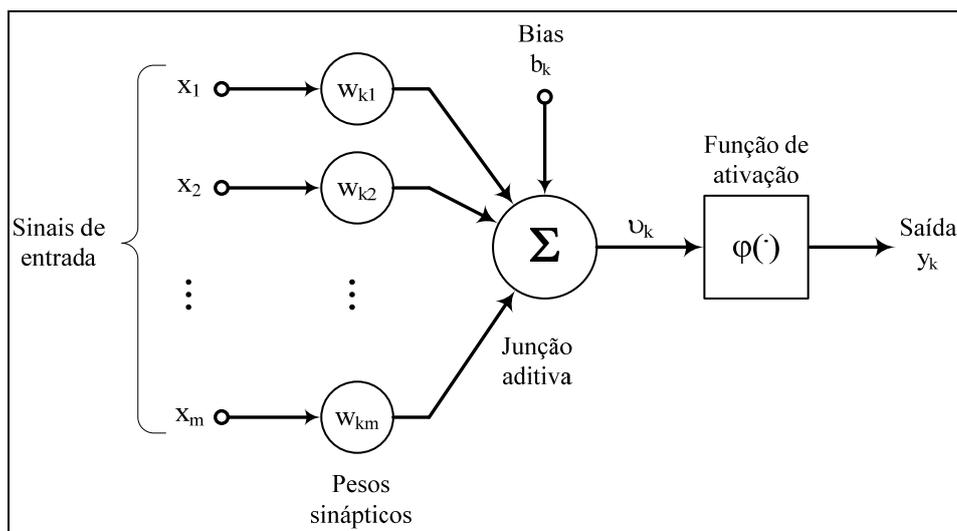


Figura 3.7 – Modelo Não-linear de um Neurônio.

Fonte: HAYKIN, 2001.

- i. Um conjunto de sinapses, cada uma caracterizada por um peso. Um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} ;
- ii. Um somador para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio. As operações descritas aqui constituem um “combinador linear”;
- iii. Uma função de ativação para restringir a amplitude da saída de um neurônio. Tipicamente, o intervalo normalizado da amplitude da saída de um neurônio é escrito como o intervalo unitário fechado $[0, 1]$ ou $[-1, 1]$.

O modelo neuronal inclui também um *bias* aplicado externamente, representado por b_k , cujo efeito é aumentar ou diminuir a entrada líquida da função de ativação. Em termos matemáticos, podemos descrever um neurônio k escrevendo o seguinte par de equações (HAYKIN, 2001):

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (3.29)$$

$$y_k = \varphi(u_k + b_k) \quad \text{ou} \quad y_k = \varphi(v_k) \quad (3.30)$$

Em que,

- | | |
|----------------------------------|---|
| $x_1, x_2, \dots, x_m,$ | são os m sinais de entrada do neurônio; |
| $w_{k1}, w_{k2}, \dots, w_{km},$ | são os pesos sinápticos do neurônio k ; |
| u_k | é a saída do “combinador linear” para os sinais de entrada; |
| v_k | é o potencial de ativação do neurônio; |
| $\varphi(\cdot)$ | é a função de ativação; |
| y_k | é o sinal de saída do neurônio. |

A função de ativação define a saída de um neurônio em termos do seu potencial de ativação v . Dos tipos básicos de funções de ativação, a Figura 3.8 apresenta aquelas que foram utilizadas no desenvolvimento dos modelos de previsão da demanda, com as respectivas nomenclaturas utilizadas pelo programa *Matlab* (MATLAB, 2006).

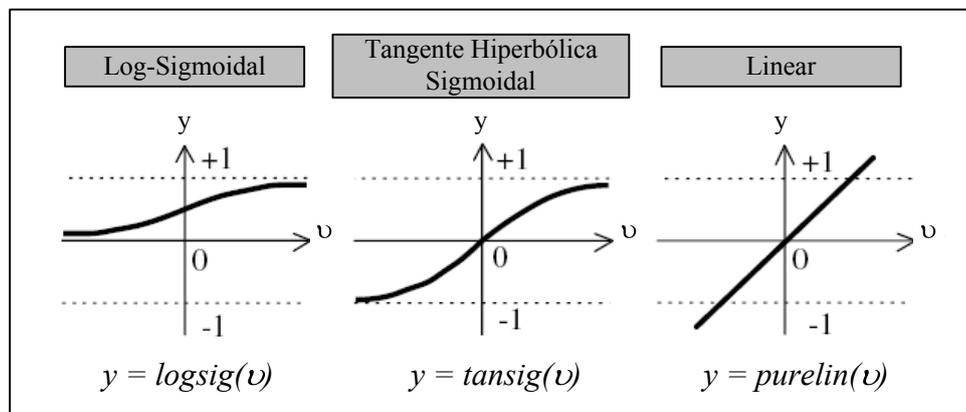


Figura 3.8 – Exemplos de Função de Ativação.

Fonte: MATLAB, 2006.

REPRESENTAÇÃO DE UMA RNA

Uma RNA, de forma simplificada, possui um sistema de neurônios e conexões semelhante ao sistema biológico. Numa RNA os neurônios são organizados em camadas, com conexões entre elas. A Figura 3.9 ilustra graficamente a arquitetura de uma RNA simples, em que os círculos representam os neurônios e as linhas representam os pesos das conexões. A camada interna, na qual também ocorre o processamento interno da rede, é tradicionalmente denominada de camada escondida.

dida. Segundo HAYKIN (2001), a função dos neurônios ocultos é intervir entre a entrada externa e a saída da rede de uma maneira útil³⁹. Uma RNA pode ter mais de uma camada escondida de acordo com a complexidade do problema. Para fins computacionais os neurônios são rotulados com uma numeração sequencial de cima para baixo, da esquerda para a direita.

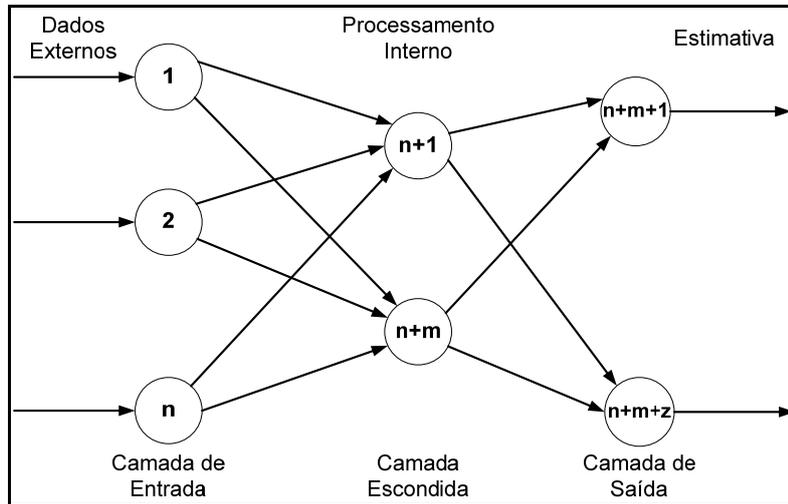


Figura 3.9 - Arquitetura de uma RNA simples.

Fonte: GOLDSCHMIDT e PASSOS, 2005.

Os nós de fonte da camada de entrada da rede fornecem os respectivos elementos do padrão de ativação (vetor de entrada), que constituem os sinais de entrada aplicados aos neurônios (nós computacionais) na segunda camada (i.e., a primeira camada oculta). Os sinais de saída da segunda camada são utilizados como entrada para a terceira camada, e assim por diante para o resto da rede. O conjunto de sinais de saída dos neurônios da última camada da rede constitui a resposta global da rede para o padrão de ativação fornecido pelos nós de fonte da camada de entrada (HAYKIN, 2001).

Existem dois tipos de processamento bem distintos numa RNA. O aprendizado ou etapa de treinamento, onde são atualizados os pesos sinápticos a medida que a rede conhece repetidamente os dados, e o teste ou recuperação de informação, em que se calcula a saída da rede a partir da apresentação de novos valores de entrada. As seções seguintes descrevem a etapa de treinamento das redes neurais utilizadas nos modelos de previsão.

Conforme GOLDSCHMIDT e PASSOS (2005), a característica mais marcante da aplicação das RNAs é sem dúvida a habilidade de aprender. Em vez de especificar todos os detalhes de uma computação tem-se a possibilidade de treinar uma rede para fazer esta computação, fato que tem encorajado cada vez mais aplicações em problemas cujas regras apropriadas não são claras e/ou muito difíceis de conhecer previamente.

³⁹ A habilidade dos neurônios ocultos extrair estatísticas de ordem elevada é particularmente valiosa quando o tamanho da camada de entrada é grande.

Após o treinamento da rede espera-se que ela produza um conjunto de saída desejado ou pelo menos consistente, de forma que os pesos converjam para determinados valores. O procedimento de treinamento pode ser de dois tipos:

- Supervisionado – necessita de um par de vetores composto do vetor de entrada e do vetor alvo que se deseja como saída. Geralmente, a rede é treinada com vários vetores de treinamento. Conforme o vetor de entrada a rede gera um vetor de saída que é comparado com o vetor alvo. O erro encontrado é então realimentado por meio da rede e os pesos são atualizados de acordo com um algoritmo, cuja função é minimizar este erro.
- Não-supervisionado – não requer vetor alvo para as saídas e busca o melhor ajuste dos pesos de forma que os vetores de saída sejam consistentes aos vetores de entrada similares. Este processo extrai as propriedades estatísticas do conjunto de treinamento e agrupa os vetores similares em classes.

Para a metodologia de previsão de demanda, baseada em séries históricas, os valores de consumo de energia elétrica de cada segmento já são conhecidos. Tais valores podem ser utilizados como alvos para o treinamento supervisionado das redes neurais no modelo preditivo.

3.4.2 Previsor Neural da Demanda utilizando Redes MLP

PERCEPTRONS DE MÚLTIPLAS CAMADAS

O perceptron é a forma mais simples de uma rede neural usada para classificação de padrões ditos linearmente separáveis. Consiste de um único neurônio com pesos sinápticos ajustáveis e *bias*. Tipicamente, redes neurais com um conjunto de unidades sensoriais (camada de entrada), uma ou mais camadas ocultas de nós computacionais, uma camada de saída, através das quais o sinal de entrada se propaga para frente, camada por camada, são chamadas de *perceptrons de múltiplas camadas* (MLP, *multi-layer perceptron*) (HAYKIN, 2001).

O treinamento supervisionado de uma MLP pode ser realizado com um algoritmo muito popular conhecido como algoritmo de *retropropagação de erro* (*error back-propagation*). A aprendizagem por retropropagação consiste de dois passos ao longo das camadas da rede: um passo para frente, a propagação – o vetor de entrada é aplicado aos nós sensoriais da rede (pesos sinápticos fixos) e seu efeito se propaga camada por camada; e um passo para trás, a retropropagação – os pesos sinápticos são todos ajustados de acordo com uma regra de correção do erro. O sinal de erro é resultado da diferença entre a resposta da rede e a resposta desejada para a rede ou alvo. Existe uma vasta literatura sobre os algoritmos de aprendizagem utilizados no treinamento de uma MLP (HAYKIN, 2001) e (MATLAB, 2006). O escopo desta seção limita-se a apresentar apenas as técnicas utilizadas na construção do previsor neural da demanda, o algoritmo de treinamento de Levenberg-Marquardt e a regularização bayesiana, contextualizados ao problema da generalização.

CONSTRUÇÃO DO MODELO PREVISOR - MLP

A metodologia desenvolvida até aqui apresenta uma solução parcial⁴⁰ para dois problemas fundamentais: Quais as variáveis econômicas e climáticas de maior influência sobre o comportamento da demanda? Qual a técnica de previsão mais adequada para prever o comportamento da carga no médio prazo? Assim, já sabemos que o modelo predictor será alimentado com as variáveis selecionadas pelo modelo econométrico, e que tais variáveis poderão ser utilizadas nos conjuntos de entrada das redes neurais artificiais. Entretanto, a etapa crucial da construção deste modelo predictor está na definição da arquitetura da MLP assim como no seu processo de treinamento.

Como visto na Seção 3.3.2, algumas variáveis do modelo econométrico apresentam maiores níveis de correlacionamento linear com a demanda com um ou mais meses de atraso. Essa característica é bastante útil na definição das variáveis de entrada da rede neural. Se a variável X, por exemplo, apresenta um atraso mensal para máxima correlação (AMMC) igual a seis, ela pode ser útil como entrada de uma rede neural que tem por objetivo prever o consumo até seis meses à frente. Portanto, parte da arquitetura da MLP está na definição de quais variáveis deverão compor os sinais dos neurônios da camada de entrada. A Figura 3.10 apresenta um modelo de MLP com apenas uma camada oculta. Ressalta-se que todas as variáveis econômicas e climáticas selecionadas e ainda a variação do consumo (alvo) podem ser utilizadas na camada de entrada da rede mais de uma vez, desde que estejam referindo-se a meses diferentes (diferentes defasagens).

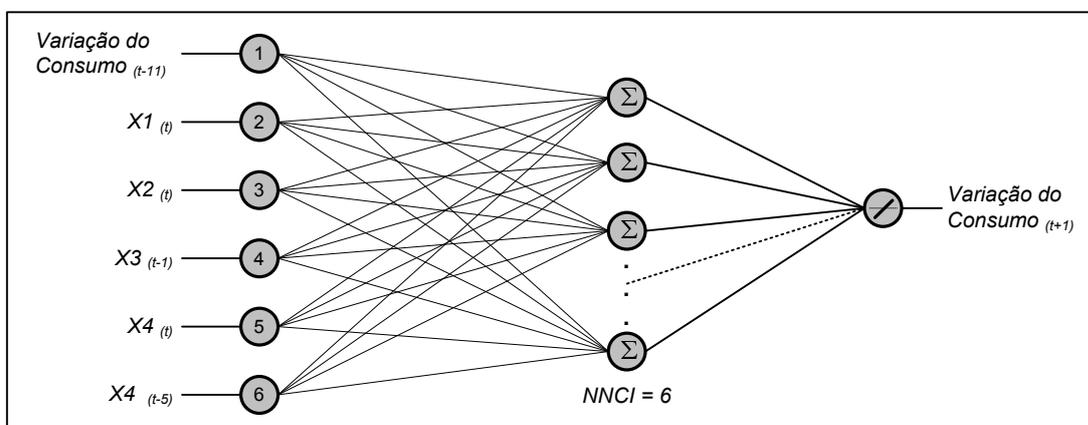


Figura 3.10 – Exemplo de Arquitetura do Modelo Predictor Neural da Demanda – MLP.

Fonte: Elaborado pelo Autor.

No exemplo acima, tem-se uma MLP com três camadas, com seis neurônios na camada intermediária – NNCI, cuja saída é uma estimativa da variação do consumo de energia elétrica para um mês à frente (t+1). Supondo que o tempo presente (t) seja o mês de dezembro de 1997, a cama-

⁴⁰ Como o modelo descritivo é responsável pela seleção das melhores variáveis para o modelo preditivo, ou seja, aquelas com melhores correlações lineares com a demanda, é provável que alguma variável econômica ou climática que apresente boa relação não linear com a demanda não participe do modelo predictor neural do consumo de energia elétrica. Espera-se que este ônus seja compensado pela agregação dos modelos econométrico para descrição e de redes neurais para previsão do consumo na mesma metodologia.

da de entrada seria alimentada: pela variação do consumo de energia elétrica ocorrida no mês de janeiro de 1997 (t-11), pelos valores medidos de X1, X2 e X4 no mês de dezembro de 1997 (t), pelo valor medido de X3 com um mês de defasagem – novembro de 1997 (t-1), e por mais um valor medido mensal de X4 com cinco meses de defasagem – julho de 1997 (t-5). Somente após a avaliação do desempenho de diferentes configurações de uma rede é possível definir sua arquitetura. Ressalta-se que as diversas configurações avaliadas não resultam de tentativas aleatórias de combinações de variáveis. Pode-se observar no Capítulo 6 que, além da experiência adquirida na elaboração dos modelos econométricos, existem relações lógicas entre as variáveis envolvidas que devem ser consideradas na definição da arquitetura da rede neural.

Entretanto, para avaliar o desempenho de cada modelo é necessário treinar a MLP, de modo que ela seja capaz de estimar as variações de consumo no futuro com boa precisão. A Figura 3.11 apresenta um fluxograma das etapas de construção do modelo predictor neural da demanda utilizando redes MLP.

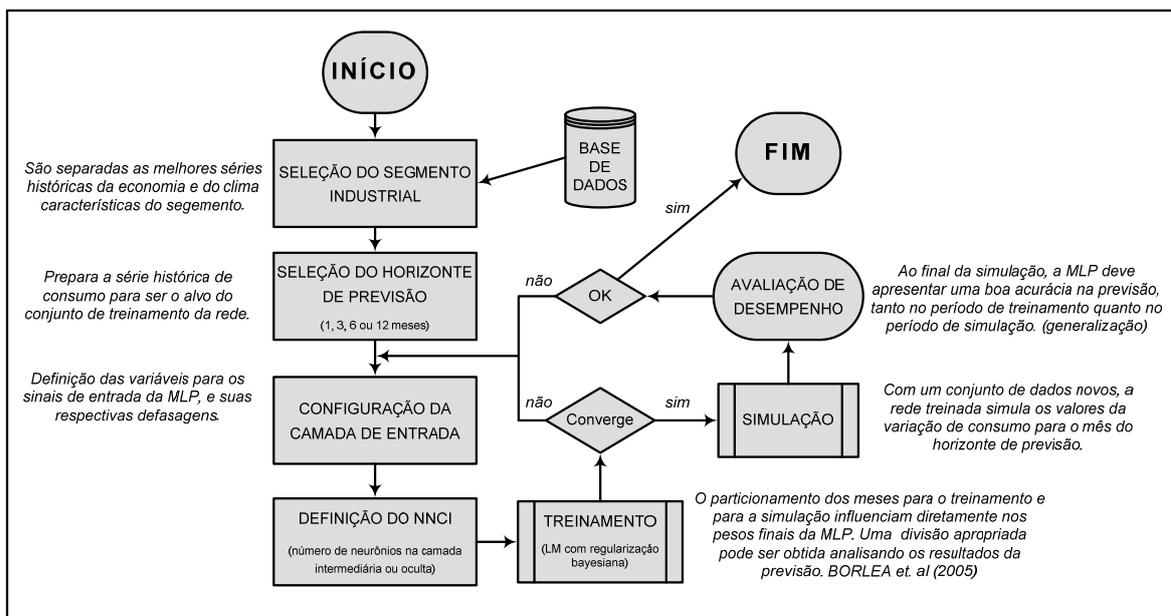


Figura 3.11 – Fluxograma das Etapas de Construção do Modelo Predictor Neural da Demanda – MLP.

Fonte: Elaborado pelo Autor.

TREINAMENTO X GENERALIZAÇÃO

A etapa de treinamento da MLP foi considerada, juntamente com as demais etapas da construção do modelo predictor, na elaboração de uma rotina computacional no programa *Matlab*, e das funções associadas à *Neural Network Toolbox*. Por se tratar de uma ferramenta computacional reconhecida na comunidade científica, todo o desenvolvimento dos modelos de previsão foi baseado nas funções disponíveis no programa. Embora, nos testes iniciais com o algoritmo de treinamento tradicional *backpropagation*, os tempos computacionais para o treinamento e convergência não

fossem elevados, optou-se pela utilização do algoritmo de treinamento de Levenberg-Marquardt, aprimoramento do *backpropagation*, com regularização bayesiana (opção *trainbr* do *Matlab*).

O aprendizado por retropropagação, por meio do cálculo do gradiente descendente, atualiza os pesos e os *biases* da rede numa direção em que a função de desempenho reduza mais rapidamente (a direção do gradiente descendente). Assim, pode-se escrever uma iteração do algoritmo como (MATLAB, 2006):

$$x_{k+1} = x_k - \lambda_k g_k \quad (3.31)$$

Em que,

x_k é um vetor com os valores correntes dos pesos e *biases* da rede.

g_k é o valor corrente do gradiente da função de desempenho.

λ_k é a taxa de aprendizagem, um importante parâmetro desse tipo de treinamento.

O algoritmo de Levenberg-Marquardt aprimora o cálculo do gradiente utilizado no *backpropagation*. A partir do método de otimização Quase-Newton (HAYKIN, 2001) e da simplificação da matriz Hessiana ($H = J'J$), o gradiente pode ser considerado como o produto escalar da matriz Jacobiana transposta (J'), que contém a primeira derivada dos erros da rede em relação aos pesos e *biases*, e o vetor de erros da rede (e). Assim, pode-se escrever uma iteração do algoritmo como (MATLAB, 2006):

$$x_{k+1} = x_k - [J'J + \mu I]^{-1} J' e \quad (3.32)$$

Em que,

μ é um parâmetro interno de controle da função de desempenho, reduz-se a cada iteração quando ocorre uma melhora nos ajustes dos pesos.

e é a diferença entre a resposta desejada para a rede (t) e a resposta da rede (a).

Tipicamente, a função de desempenho (F) é representada pelo erro médio quadrático (*MSE*, *mean square error*) das respostas da rede (E_D) para o intervalo de treinamento com N meses:

$$F = E_D = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (3.33)$$

Assim, pode-se estabelecer um valor para a função de desempenho, mais conhecida como meta, como um critério de parada para a etapa de treinamento da rede. Dependendo das configurações da rede, das séries históricas da camada de entrada, do histórico da saída desejada, e dos parâmetros de configuração do algoritmo de treinamento, a MLP poderá convergir. Ou seja, a rede não consegue mais incrementar conhecimentos adicionais (ajustes dos pesos e *biases*) com novas iterações do algoritmo, ou a meta estabelecida já foi alcançada.

A questão chave para o aprimoramento de uma MLP é que a busca da minimização da função de desempenho com a respectiva redução dos valores do vetor de erro no treinamento, como

apresentada na Equação 3.33, não garante um bom desempenho da rede para o conjunto de dados diferentes daqueles utilizados no treinamento. Assim, uma rede “*sobretreinada*” torna-se muito específica ou superajustada (*overfitting*) ao conjunto de treinamento e perde sua capacidade de generalização, ela não consegue apresentar um bom desempenho como previsora para o intervalo de simulação (com dados novos). De outro modo, diz-se que uma rede generaliza bem quando o mapeamento de entrada-saída computado por ela for correto (ou aproximadamente correto) para dados de teste/simulação não utilizados para criação ou treinamento da rede. (HAYKIN, 2001).

O processo de aprendizagem (i.e., treinamento de uma RNA) pode ser visto como um problema de ajuste de curva, no qual a rede é responsável pelo mapeamento não-linear de entrada-saída. Quando uma rede aprende um número excessivo de exemplos de entrada-saída, ela pode acabar memorizando os dados de treinamento, fazendo com que contribuições indesejáveis no espaço de entrada, devido a um ruído, por exemplo, sejam armazenados nos pesos sinápticos da rede (HAYKIN, 2001). Matematicamente, esse excesso de treinamento acarreta o aumento dos pesos das conexões da rede neural. Uma das formas de prover maior generalização ao modelo predictor neural é a utilização da função de desempenho modificada, com uma inclusão do termo E_W para a soma dos quadrados dos pesos da rede, definido pela Equação 3.34. Esse procedimento permite uma regularização do treinamento da rede, conforme a Equação 3.35 (MACKAY, 1992a):

$$E_W = \frac{1}{n} \sum_{j=1}^n \omega_j^2 \quad (3.34)$$

$$F = \beta \cdot E_D + \alpha \cdot E_W \quad (3.35)$$

Em que,

- n é o número total de neurônios da rede
- ω são os pesos sinápticos de entrada em cada um dos neurônios
- α e β são parâmetros da função de desempenho
- se $\alpha \ll \beta$, o algoritmo de treinamento priorizará a redução dos erros de previsão
- se $\alpha \gg \beta$, o algoritmo de treinamento priorizará a redução dos pesos da rede, suavizando a saída da rede com menor precisão e maior generalização.

Para exemplificar o processo de regularização do treinamento de uma MLP, a Figura 3.12 apresenta dois gráficos com os valores de saída de uma rede “*sobretreinada*” (a), e da mesma rede regularizada (b), ambas com a função de aproximar a saída dos valores alvos, sinalizados com (+). Pode-se notar o “esforço” computacional da rede para ajustar-se com precisão aos alvos em (a). Já com a regularização (b), as saídas da MLP se aproximam bem dos alvos e com menor “esforço”.

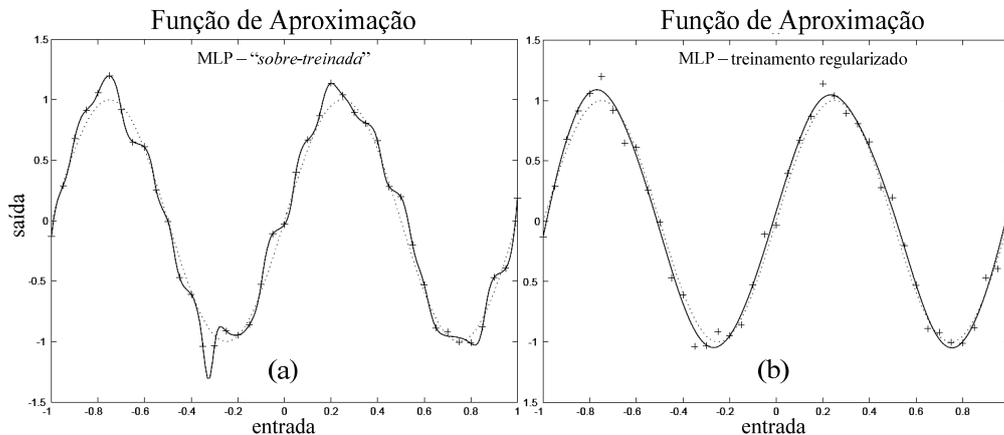


Figura 3.12 – Funções de Aproximação de MLPs (a) “sobre-treinada” e (b) regularizada.

Fonte: Adaptado de MATLAB, 2006.

REGULARIZAÇÃO BAYESIANA

A formulação modificada da função de desempenho é um dos caminhos para se obter maior generalização de uma rede durante seu treinamento. No entanto, essa solução não é definitiva, pois a escolha dos parâmetros da função de desempenho (α e β) pode resultar em inúmeros resultados de treinamento. Além disso, a complexidade da arquitetura de uma rede, que deve ser compatível à complexidade do problema ao qual ela se propõe a resolver, afeta diretamente o treinamento e a capacidade de generalização da mesma (MACKAY, 1992b).

Considerando os princípios da estatística Bayesiana, a melhor generalização obtida com treinamento de uma rede neural passa pelo problema clássico da *Navalha de Occam*⁴¹: “Se em tudo o mais forem idênticas as várias explicações de um fenômeno, a mais simples é a melhor”. A Figura 3.13 (a) ilustra este problema, comparando os erros de treinamento com os erros de simulação para uma centena de redes neurais de complexidades variadas e treinadas para o mesmo problema de aproximação de função, equivalente ao problema da previsão da demanda. Pode-se notar que as redes com menores erros de simulação são mais simples e apresentam erros de treinamento relativamente baixos, em comparação com o mínimo alcançado pelos modelos mais complexos ou com maior nível de treinamento.

A partir da aplicação da fórmula de Bayes⁴², com as funções de densidade de probabilidade referidas ao conjunto de parâmetros possíveis (α e β) da rede, MACKAY (1992a) utiliza o cálculo da *Evidência*⁴³ para determinar a relação mais provável entre α e β que provê a melhor generalização da rede. Esse procedimento, conhecido como *Regularização Bayesiana*, internaliza também a

⁴¹ A Navalha de Occam é um princípio lógico atribuído ao filósofo inglês William de Occam (século XIV), no qual a explicação para qualquer fenômeno deveria assumir apenas as premissas estritamente necessárias à sua explicação e eliminar todas as demais que não causariam qualquer diferença nas predições da hipótese (wikipédia.org).

⁴² Tal regra permite que novas informações incorporadas a determinado evento, aprimorem o cálculo da sua probabilidade. Na aplicação de Mackay, o evento está relacionado aos testes dos parâmetros da função de desempenho.

⁴³ O fator evidência pode ser visto como um fator de escala que garante a probabilidade posterior seja crescente.

solução do problema de Occam, e pode ser implementado juntamente com o algoritmo de treinamento de Levenberg-Marquardt.

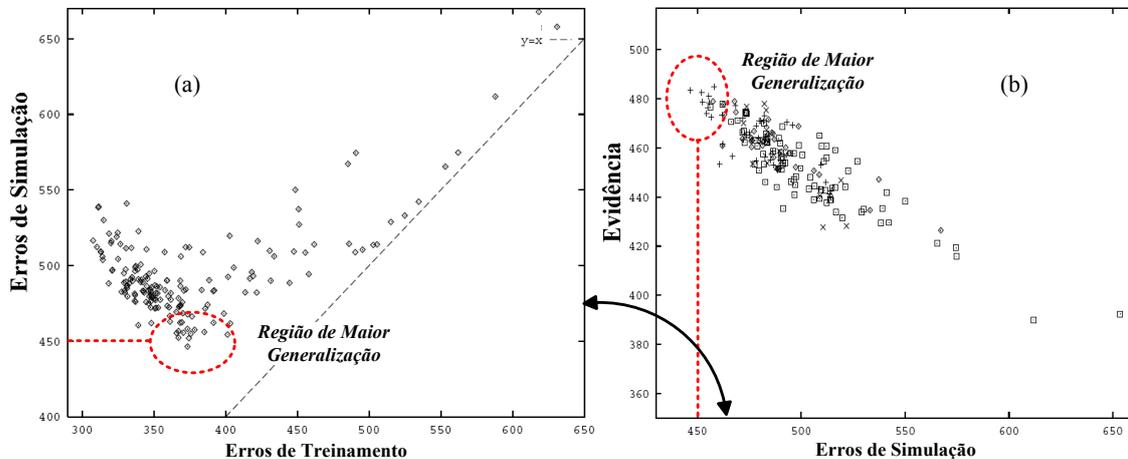


Figura 3.13 – O Cálculo da *Evidência* para Solução do Problema de Occam.

Fonte: Adaptado de MACKAY, 1992b.

Na Figura 3.13 (b) verifica-se que a maximização da *Evidência* provê a melhor generalização da rede, ou a minimização do erro de simulação. FORESEE e HAGAN (1997) apresentam um método iterativo, no qual α e β são inicializados em 0 e 1 respectivamente, e a cada iteração são atualizados conforme uma função objetivo que penaliza crescimento de E_W e de E_D . O método converge quando novas apresentações do conjunto de treinamento não modificam mais α e β . O algoritmo de treinamento “*trainbr*” do *Matlab* calcula automaticamente esses parâmetros da função de desempenho, que resultam na melhor generalização dos resultados do modelo predictor neural.

Entretanto, FERREIRA e SILVA (2007) ressaltam que a opção por um único α durante o treinamento da rede não é recomendada quando o problema de previsão envolve variáveis de entrada de naturezas distintas, ou seja, com diferentes níveis de interdependência com o consumo (por exemplo: variáveis econômicas e climáticas). Esta configuração, comum para previsão de demanda no curto ou curtíssimo prazo, pode ser melhorada com a inclusão de diferentes α_s para cada neurônio da camada de entrada. Apesar de considerar um único α , o treinamento das MLPs neste trabalho considera, de certa forma, a interdependência das variáveis de diferentes naturezas por meio do AMMC (atraso mensal para máxima correlação). Além disso, a dinâmica das relações entre as variáveis no médio prazo é bem distinta em relação àquela existente no curto ou curtíssimo prazos.

3.4.3 Previsor Neural da Demanda utilizando Redes RBF

REDES DE FUNÇÃO DE BASE RADIAL

A construção de uma *rede de função de base radial* (RBF, *radial-basis function*), em sua forma mais básica, envolve três camadas com papéis totalmente diferentes. A camada de entrada é

constituída por nós de fonte que conectam a rede ao seu ambiente. A segunda camada, a única camada oculta da rede, aplica uma transformação linear do espaço de entrada para o espaço oculto. A camada de saída é linear, fornecendo a resposta da rede ao padrão de ativação aplicado à camada de entrada. A rede RBF é projetada para realizar um mapeamento não-linear do espaço de entrada para o espaço oculto, seguido de um mapeamento linear para o espaço de saída. (HAYKIN, 2001).

A propagação dos sinais da camada de entrada até a camada de saída da RBF segue as mesmas regras. No entanto, a ativação dos neurônios da RBF, ou neurônio de base radial, é realizada de outra maneira. Na Figura 3.14, $\| \text{dist} \|$ representa o vetor da “distância” entre o vetor das entradas (x) e o vetor dos pesos (w), cujo produto escalar com o *bias* (b), representa o sinal líquido (net , n) que, avaliado pela função de transferência, resulta no sinal de ativação do neurônio (y).

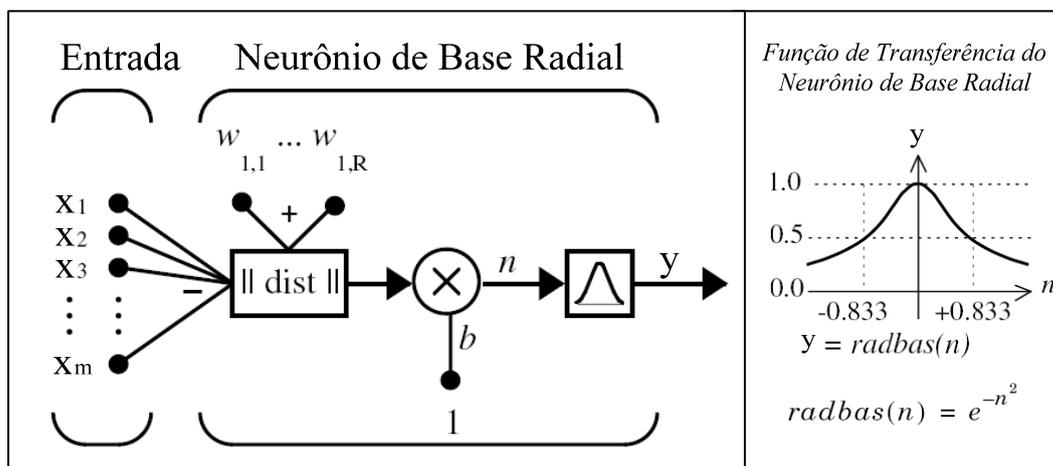


Figura 3.14 – Representação do Neurônio de Base Radial.

Fonte: Adaptado de MATLAB, 2006.

Um neurônio de base radial funciona como um detector que produz uma saída igual a 1 toda vez que o vetor de entradas for idêntico ao vetor de pesos. Para controlar a sensibilidade desse detector, pode-se modificar a função de transferência *radbas* tornando-a mais “achatada”. Com um fator de espalhamento (*spread*) igual a 10, um n de 8,33 produziria um sinal de ativação igual a 0,5.

Assim como as MLPs, as redes RBF são muito utilizadas como sistemas aproximadores de funções, pois: (i) apresentam rapidez de treinamento, embora necessitem de mais neurônios que uma MLP; (ii) permitem utilizar conhecimento à priori, para localizar neurônios; (iii) apresentam fácil regularização por meio de ajustes do espalhamento (*spread*) da função de base radial e das meta (*goal*) da função de desempenho. Com o auxílio de ferramenta gráficas, como apresentado na Figura 3.15, é possível determinar o melhor par, *spread* e *goal*, que maximizam a função de desempenho, ou que minimizam os erros da simulação da rede, ou em função de outro parâmetro de otimização para o desempenho da rede.

Erro Médio Quadrático da Simulação

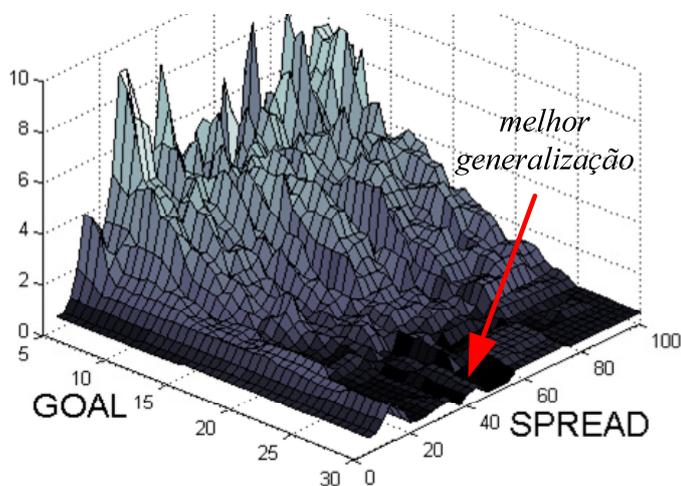


Figura 3.15 – Exemplo de Ajustamento Gráfico dos Parâmetros da RBF.

Fonte: Elaborado pelo Autor.

CONSTRUÇÃO DO MODELO PREVISOR - RBF

A construção do modelo previsor utilizando redes RBF é mais simples em relação ao modelo previsor MLP. A arquitetura da RBF é definida pela seleção das variáveis (econômicas, climáticas ou de consumo) que deverão compor os sinais dos neurônios da camada de entrada, com seus respectivos defasamentos. Novamente, ressalta-se que as configurações e arquiteturas avaliadas não resultam apenas de experiências de tentativa e erro. A experiência adquirida na elaboração dos modelos econométricos e observância de algumas relações lógicas entre as variáveis envolvidas facilitaram a definição da arquitetura das RBFs.

As redes RBF são muito úteis para a realização da previsão da demanda por faixas. Nesse caso, com dois neurônios na camada de saída da RBF, estima-se o menor e o maior consumo esperado para o horizonte de previsão. Para esse tipo de problema, nem sempre a melhor solução passa pela minimização dos erros de treinamento ou simulação. A Figura 3.16 apresenta o fluxograma das etapas de construção do modelo previsor neural da demanda utilizando redes RBF.

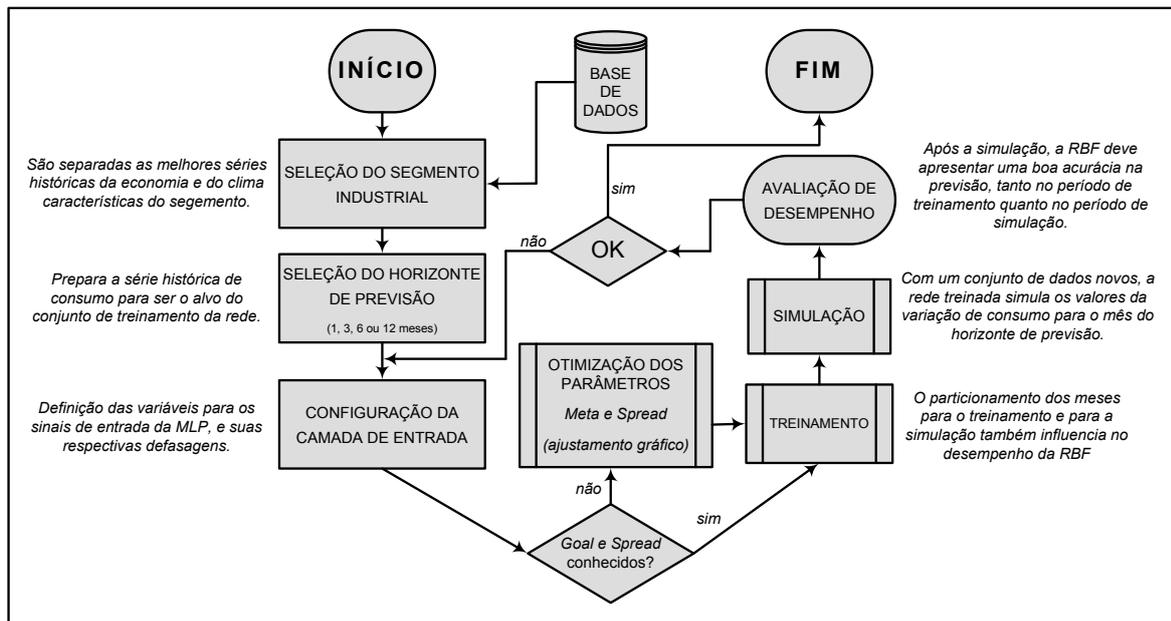


Figura 3.16 – Fluxograma das Etapas de Construção do Modelo Previsor Neural da Demanda – RBF.

Fonte: Elaborado pelo Autor.

Para o desenvolvimento do modelo previsor neural com redes de função de base radial foi elaborada uma rotina computacional no programa *Matlab*, utilizando as funções associadas à *Neural Network Toolbox*. Com a função *newrb*, por exemplo, é possível construir e treinar uma rede RBF, fornecendo o conjunto de dados de entrada, o vetor alvo para a saída, e os valores de meta e *spread* desejados. Nesse caso até o número de neurônios da camada intermediária é definido automaticamente, acompanhando a complexidade do problema de previsão.

3.5 RESUMO DO CAPÍTULO

O Capítulo 3 apresentou o embasamento teórico relacionado às técnicas de mineração de dados, à construção de modelos econométricos e ao uso de redes neurais artificiais para a previsão da demanda. Ao longo do texto, aspectos teóricos e conceituais foram apresentados de modo a subsidiar a elaboração da metodologia proposta.

A primeira parte do capítulo discorre sobre a importância das tarefas de KDD, principalmente àquelas relacionadas ao pré-processamento, para a construção das bases de dados sobre a energia, a economia e o clima. A segunda e terceira partes do capítulo podem servir de roteiro para construção de modelos descritivos e preditivos, respectivamente, sobre o comportamento da demanda dos consumidores industriais.

CAPÍTULO 4

Formação da Base de Dados

4.1 INTRODUÇÃO

A consecução dos objetivos traçados para esta pesquisa de doutorado, em especial para o modelo de descrição e previsão da demanda de energia elétrica do setor industrial, deveu-se em grande parte aos cuidados para a formação da base de dados. Além da questão organizacional necessária às tarefas de KDD, apresentadas no capítulo anterior, a qualidade e a utilidade das séries históricas selecionadas sobre a economia e o clima influenciaram diretamente no sucesso da pesquisa.

O presente capítulo apresenta o processo de formação da base de dados relacionada ao ambiente econômico e às principais variações climáticas que, com maior ou menor intensidade, influenciaram o consumo de energia elétrica dos segmentos têxtil e metalúrgico em Santa Catarina.

Considerando o período compreendido entre julho de 1996 e dezembro de 2006, pode-se construir uma grande base de dados que foi subdividida em três bases de dados primárias (BDPs), conforme a Figura 4.1:

- ➔ BDP1 – CELESC: Contém as principais informações sobre o consumo de energia elétrica das indústrias atendidas em território catarinense. Independe da situação contratual para a compra da energia elétrica, os dados obtidos junto às Centrais Elétricas de Santa Catarina S.A apresentam a variação do consumo mensal e a segmentação por atividade industrial, tanto dos clientes cativos quanto daqueles que ingressaram no ambiente de contratação de livre (ACL).

- **BDP2 – ECONOMIA:** Reúne diversas séries históricas dos parâmetros econômicos mais relacionados com o comportamento da indústria catarinense, com ênfase nos segmentos têxtil e de metalurgia. Para formação desta base de dados primária foram consultadas importantes instituições econômicas. Entre elas destacam-se: Banco Central do Brasil; IBGE – Instituto Brasileiro de Geografia e Estatística; IPEA – Instituto de Pesquisas Econômicas Aplicada; FGV – Fundação Getúlio Vargas; FMI – Fundo Monetário Internacional. Também foram obtidos dados econômicos setoriais por meio das seguintes instituições: FIESC – Federação das Indústrias do Estado de Santa Catarina; ABIT – Associação Brasileira da Indústria Têxtil; ANFAVEA – Associação Nacional dos Fabricantes de Veículos Automotores, entre outras.

- **BDP3 – CLIMA:** Apresenta as principais variáveis climáticas de 15 estações climatológicas das regiões Sul e Sudeste do Brasil, representativas do principal mercado consumidor da indústria têxtil de Santa Catarina. O INMET – Instituto Nacional de Meteorologia e a EPAGRI – Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina S.A forneceram as séries históricas mensais sobre temperaturas, pressão atmosférica, umidade relativa, etc. Além disso, esta base de dados primária dispõe dos valores normais⁴⁴ de todas as variáveis climáticas de cada uma das estações climatológicas. Isso possibilitou analisar não apenas as medidas absolutas das variáveis, mas também as anomalias, desvios de comportamento em relação aos valores esperados.

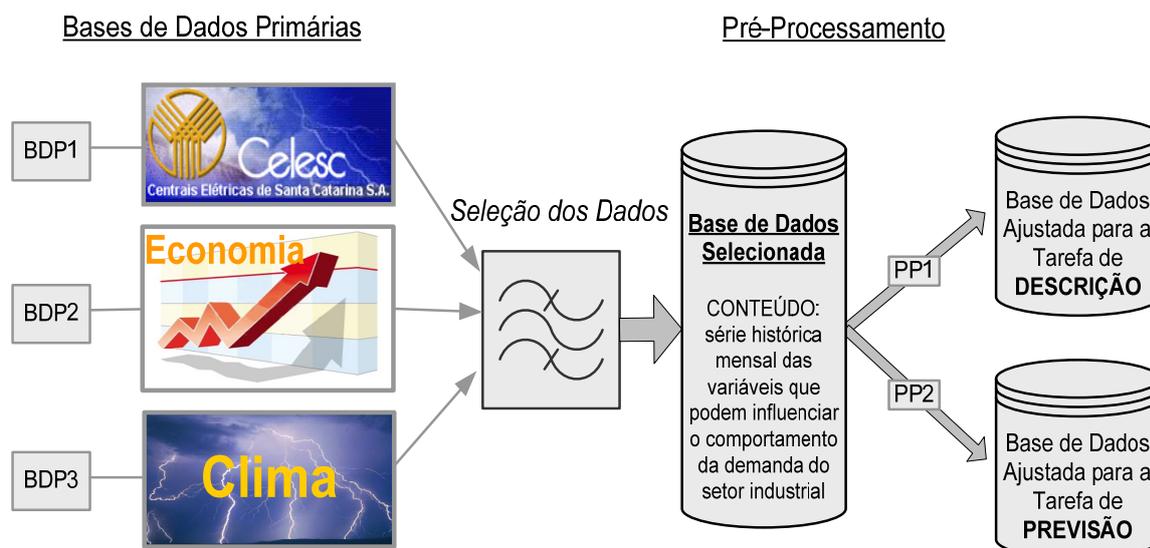


Figura 4.1 – Etapas para Formação da Base de Dados

Fonte: Elaborado pelo autor.

⁴⁴ Valores esperados para as variáveis climáticas em cada mês do ano conforme os valores médios medidos entre 1961 e 1990 em cada estação climatológica.

O processo de formação da base de dados contempla ainda a etapa de pré-processamento das séries históricas de forma a atender os requisitos das atividades de mineração de dados para descrição e previsão da demanda. Esta etapa compreende as funções relacionadas à captação, à organização e ao tratamento dos dados. Como apresentado na Seção 3.2, com o pré-processamento pode-se realizar desde a correção de dados errados até a formatação, conforme as características de entrada dos algoritmos a serem utilizados.

Além de se configurar em condição básica necessária para o desenvolvimento dos modelos descritor e previsor da demanda, a integridade do processo de formação da base de dados está diretamente relacionada com a qualidade do resultado global deste trabalho. Por melhor que sejam as técnicas para compreensão da influência da economia e do clima no consumo de energia das indústrias, seriam obtidas conclusões inconsistentes ou pouco sustentáveis quando da utilização de dados medíocres. Nas seções seguintes, apresentam-se os passos necessários para a formação das três bases de dados primárias deste trabalho.

4.2 O CONSUMO DE ENERGIA ELÉTRICA NAS INDÚSTRIAS DE SANTA CATARINA

O histórico do consumo de energia elétrica de cada indústria contém não apenas um registro das necessidades energéticas de sua planta, mas também um retrato sintomático do ambiente de negócios de sua atividade econômica. Por esse motivo, a cuidadosa formatação do consumo de energia elétrica, agregado por segmentos da indústria, representou um fator de segurança crucial para a busca de correlações reais entre a demanda e os parâmetros econômicos e climáticos determinantes do comportamento destes consumidores. Nenhuma metodologia para compreensão ou previsão da demanda sustenta-se quando a variável a ser explicada não é robusta e representativa.

Para atender aos objetivos deste trabalho, solicitamos ao Departamento Comercial da CELESC – Centrais Elétricas de Santa Catarina S.A. as séries históricas de consumo (cm) nos fornecimentos classificados como industriais em território catarinense, bem como várias outras características destes consumidores, com exceção de seus nomes, tais como: código de atividade industrial (*codativ*), número da conta do cliente na concessionária (*conta*), município (*mun*), gênero de atividade (*genativ*), e um indicador para contabilização do consumo mensal (*senal*). Em função da quantidade de informações solicitadas e da confidencialidade exigida pela concessionária, foi necessário um pedido formal do Departamento de Engenharia Elétrica da UFSC que assegurava a utilização do conteúdo dos arquivos apenas para fins acadêmicos.

Concluídos os trâmites para obtenção dos dados de consumo de energia elétrica, iniciou-se uma complexa tarefa para realizar seu pré-processamento. A partir de centenas de arquivos de dados mensais contabilizando mais de 6 milhões de registros, pode-se selecionar e preparar as séries históricas de cada segmento industrial de 1996 até 2006.

4.2.1 Pré-processamento da BDP1

Inicialmente foram selecionados os arquivos de texto (.txt) ou as planilhas (.xls) que continham informações coerentes sobre o consumo de energia elétrica das indústrias em cada mês. A Figura 4.2 apresenta a estrutura dos dados utilizada em todos os arquivos.

	A	B	C	D	E	F	G
	mês	município	conta	genero atividade	cod atividade	consumo kWh	senal
1	9	17101	3103930	2620	9261063	972418	0
2	9	2106	1235193	2749	9201064	1405692	0
3	9	11101	1235419	1511	9201064	701211	0
4	9	5101	1835495	1556	9201064	1353951	0
5	9	7101	1915712	1769	9201064	998797	0
6	9	18104	2075214	1512	9201064	2085925	0
7	9	4101	2138555	2149	9201064	283992	0
8	9	2101	2325502	1779	9201064	1985818	0
9	9	2101	2325526	1721	9201064	255761	0
10	9	16103	2446352	2021	9201064	1055342	0
11	9	13101	2473440	2641	9201064	1191109	0
12	9	10114	2493867	1512	9201064	2616976	0
13	9	4101	2495658	2141	9201064	648106	0
14	9	3101	2547840	2521	9201064	1540510	0
15	9	3101	2955325	2521	9201064	723335	0
16	9	10101	3123695	2641	9201064	1853387	0
17	9	3101	3137978	2751	9201064	5156418	0
18	9	2101	2325502	1779	9201064	0	0
19	9	2109	1235196	1769	9201063	2988705	0
20	9	3101	1235216	2751	9201063	33377820	0
21	9	4115	1235293	2121	9201063	5207902	0

Figura 4.2 – Estrutura das planilhas fornecidas pela concessionária com dados de consumo das indústrias.

Fonte: Celesc-Distribuição S.A.

O agrupamento de todas as informações mensais em uma única planilha foi uma condição importante para a realização do pré-processamento, porém o grande volume de informações desta base justificou a utilização de um software específico para banco de dados, o MySQL. Trata-se de um software *Open Source*, o que possibilita qualquer pessoa usá-lo e modificá-lo livremente, para construção e gestão de um banco de dados relacional, multiusuário e multitarefa (TONSIG, 2006). A BDP1 foi construída utilizando MySQL por este atender aos seguintes requisitos:

- ➔ Importar as tabelas de dados mensais de consumo dos arquivos de texto;
- ➔ Permitir a manipulação de tabelas com 6,3 milhões de linhas, resultado do registro mensal do consumo de cada cliente industrial por 10 anos e 6 meses;
- ➔ Dispor de ferramentas de programação para manipulação dos dados e consequente realização das tarefas de pré-processamento, como: limpeza, normalização, construção de atributos e partição das tabelas;
- ➔ Exportar os dados pré-processados para arquivos de texto ou planilhas.

A Tabela 4.1 apresenta o resultado da importação e agrupamento de todos os dados mensais de consumo dos clientes numa única tabela do MySQL, denominada COMEIND, cuja estrutu-

ra manteve-se igual à dos arquivos de dados da concessionária. A partir desta “super tabela” foram identificados muitos problemas de inconsistência que foram solucionados com a aplicação das técnicas de pré-processamento para a adequada utilização na sequência da pesquisa.

Tabela 4.1 – Exemplo de Conteúdo da Tabela COMEIND.

The screenshot shows a MySQL Query Browser window with the following query: `SELECT * FROM x_comeind_original where ano =2006 and mes=12`. The results are displayed in a table with 11 columns: Num, trio, ano, mes, mun, conta, genativ, codativ, cm, and sinal. The data rows show various records for the year 2006 and month 12, with values for each attribute.

Num	trio	ano	mes	mun	conta	genativ	codativ	cm	sinal
6359425	200612160	2006	12	1103	160	1721	201023	900	0
6359426	200612181	2006	12	1103	181	2229	201023	223	0
6359427	200612608	2006	12	1103	608	1581	201023	1060	0
6359428	200612622	2006	12	1103	622	3611	201023	340	0
6359429	200612823	2006	12	1103	823	1581	201023	3222	0
6359430	200612911	2006	12	1103	911	1581	201023	1400	0
6359431	200612952	2006	12	1103	952	2630	231023	1810	0
6359432	200612994	2006	12	1103	994	3611	201023	610	0
6359433	2006121000	2006	12	1103	1000	2010	231023	920	0
6359434	2006121090	2006	12	1103	1090	2023	201023	80	0
6359435	2006121132	2006	12	1103	1132	2842	201021	204	0

Fonte: Elaborado pelo Autor a partir dos dados fornecidos pela Celesc-Distribuição S.A.

Seguindo as orientações para organização do processo de KDD foi estabelecida uma sessão dedicada apenas ao pré-processamento da BDP1. A Tabela 4.2 resume todos os procedimentos e resultados obtidos ao final do último ciclo dessa sessão.

Tabela 4.2 – Sessão de KDD para o Pré-Processamento da BDP1.

Aplicação: Pré-Processamento		
Sessão: 1		Resumo: Preparar o grande volume de dados sobre o consumo mensal de energia elétrica de indústrias de SC para utilização nas tarefas de descrição e previsão de demanda.
Objetivo: Ajustamento das Séries Históricas Tarefa de KDD: não se especifica		
Expectativas quanto ao Modelo de Conhecimento:		
<ul style="list-style-type: none"> - Maximização da consistência das informações - Eliminação das falhas de registro dos dados 		
Plano de Ação: Verificação da unicidade dos registros (ano/mês/código do cliente) → Redução → Limpeza de inconsistências → Enriquecimento → Segmentação → Normalização das séries históricas → Criação de novos atributos.		
Ciclo nº 9 (referência ao último ciclo registrado)		
Métodos	Aplicação	Resultados
Comparação e exclusão de conjuntos de registros de dados relacionados a uma única linha das tabelas (tuplas) repetidos	<u>Verificação da Unicidade dos Registros:</u> Em razão de algumas rotinas utilizadas pela concessionária, alguns clientes apresentavam mais de um registro para a mesma tupla (ano, mês, e código de cliente), denominada <i>trio</i> , o que não seria possível. Porém, a coluna <i>sinal</i> (0/1) permitia determinar qual o valor único de consumo para cada ano/mês. Após a seleção das tuplas repetidas, estas eram substituídas por uma única com registro correto.	Número de registros: Início: 6.421.128 Excluídos: 109.926 Exclusão (%): 1,71% Final: 6.311.202

<p>Seleção e exclusão de registros</p>	<p><u>Redução:</u> Após a constatação de um volume muito grande de registros cujo ramo de atividade do cliente era a “construção civil” (código nº 45 do CNAE), todos os registros com <i>genativ</i> iniciando em 45 foram excluídos. Este fato se deve à classificação, perante a concessionária, desse tipo de fornecimentos como sendo industrial, mesmo que tratasse apenas da construção de uma residência.</p>	<p>Número de registros: Início: 6.311.202 Excluídos: 3.373.993 Exclusão (%): 53,46 % Final: 2.937.209</p>
<p>Seleção, análise e substituição de atributos</p>	<p><u>Limpeza de Inconsistências:</u> Durante os mais de 10 anos em que foram registradas todas as informações de consumo pela concessionária, é natural que ocorressem mudanças de procedimentos. Desde a mudança dos códigos do cliente ou de sua atividade industrial, até a reclassificação de municípios no sistema da concessionária foi observada. A solução foi identificar os registros em que o mesmo código de cliente sofreu alguma alteração de município ou de gênero de atividade e proceder adequações de modo a permitir o melhor aproveitamento dos dados. Apesar do número de inconsistências ser pequeno em comparação com todo o banco de dados, foram realizados dois procedimentos para correção das mesmas: - padronização do <i>mun</i> do consumidor conforme o registro de município mais recente no banco de dados; - padronização do atributo <i>genativ</i> do consumidor conforme a mediana dos gêneros de atividade registrados durante o período de registro;</p>	<p>Identificados(as): - 4.876 consumidores com alguma inconsistência; - 518 trocas de município em 422 contas; - 4.680 trocas de ramo de atividade em 4.454 contas; - 52.483 contas distintas.</p> <p>9,29% dos consumidores passaram por alguma adequação nos registros originais de município ou ramo de atividade.</p>
<p>Agregação de novas informações para o melhor aproveitamento dos dados</p>	<p><u>Enriquecimento:</u> Durante o processo de redução das inconsistências pode-se verificar que um mesmo consumidor poderia estar sendo representado no banco de dados com códigos diferentes ao longo do tempo. Procedimentos administrativos da concessionária teriam alterado códigos de conta, embora o consumidor continuasse mantendo todas as suas características de consumo, ou seja, mesmo ramo de atividade, município, tipo de contrato e nível de consumo. De modo a garantir a maior continuidade possível das séries históricas individuais foram identificados quais consumidores poderiam representar um mesmo consumidor. Assim, uma conta A poderia ser complementada por uma conta B, e seus códigos unificados, se: - os meses final e inicial de cada conta fossem subsequentes, do mesmo município e ramo de atividade;</p>	<p>Foram identificadas 571 separações de série histórica, envolvendo 1.111 contas em condições de agrupamento.</p> <p>Unificação das séries históricas das contas “gêmeas” em um único código destes consumidores.</p>

	<ul style="list-style-type: none"> - o intervalo de tempo das contas fosse superior a 36 e 24 meses, respectivamente, para priorizar os agrupamentos relevantes; - a razão entre o consumo final de A e inicial de B estivesse compreendida entre 70% e 130%. 	
Seleção e estratificação das séries históricas	<p><u>Segmentação:</u> A segmentação da BDP1 tem por objetivo disponibilizar o conteúdo das tabelas conforme as necessidades das tarefas de mineração de dados. Para o estudo da demanda, conforme o segmento industrial, todos os consumos mensais por ano e mês foram agregados na Tabela SGI, vide Figura 4.3.</p>	<p>Tabela SGI:</p> <ul style="list-style-type: none"> - 126 linhas: referente aos meses do período; - 4 colunas: referente aos segmentos industriais selecionados: Alimentos, Têxtil Metalurgia, Papel e Celulose, Confeção e Produtos do Metal
Aplicação de técnicas de normalização	<p><u>Normalização das séries históricas:</u> As informações de interesse sobre a BDP1 para o restante do processo de KDD se resumem ao conteúdo da Tabela SGI. Porém, nas tarefas de descrição e previsão da demanda, os volumes de energia elétrica consumidos são analisados em conjunto com variáveis climáticas e econômicas de diferentes magnitudes/significados. Portanto, ao final do pré-processamento foi disponibilizada uma nova tabela com consumos normalizados conforme as principais técnicas utilizadas:</p> <ul style="list-style-type: none"> - Normalização linear: o consumo varia entre 0 (mínimo da série) e 1 (máximo da série); - Normalização Euclidiana: considera a média e o desvio padrão dos consumos da série; - Normalização pelo valor máximo: atribui-se o valor 1 para o maior consumo da série e a proporção dos demais em relação ao máximo. 	<p>Tabelas normalizadas por segmento industrial:</p> <ul style="list-style-type: none"> - SGI-L - SGI-E - SGI-M
Cálculo da tendência das séries históricas de consumo ⁴⁵ (MORETTIN e TOLOI, 2004)	<p><u>Criação de novos atributos:</u> A partir das séries históricas de consumo da SGI (normalizadas ou não), foram elaboradas séries históricas que representam apenas a tendência de consumo ao longo dos anos. Essa variável apresenta menor volatilidade que o consumo original e ajuda bastante na aplicação dos modelos descritivo e preditivo.</p>	<p>Novas colunas na BDP1 com a tendência de consumo dos segmentos industrial.</p> <p>Obs.: O conteúdo completo da Tabela dos SGI está ilustrado no Anexo C.</p>

Fonte: Elaborado pelo autor.

⁴⁵ A tendência do consumo de energia elétrica, juntamente com sazonalidade do consumo mais a variação cíclica representam as componentes do consumo de energia elétrica, quando o mesmo é decomposto. No seu cálculo utilizou-se um método de suavização por média móvel, cujo significado não pode ser associado à estimativa futura de consumo, mas sim ao valor central do consumo sem o efeito das variações sazonais. Considerando T_t , uma

estimativa da tendência no tempo t da série histórica Z_t , seu cálculo é dado por: $T_t = \frac{1}{2n+1} \sum_{j=-n}^n Z_{t+j}$, em que n representa o número de meses antes e depois de t suficientes para conter a variação sazonal (foi usado, $n=6$).

Ano	Mes	Alimentos	Textil	Metalurgia	Celulose	Confeccao	prodmetal
1996	07	64332733	68757800	33345417	34990447	14399126	10592216
1996	08	67192569	72121996	36318307	38524003	14483719	10662590
1996	09	62899220	64754729	34132352	24019321	13703031	12532722
1996	10	60228032	66584439	31725934	33953322	14106867	9430709
1996	11	70171444	76421904	36703772	37278632	14953483	10400642
1996	12	65498342	65846820	30473685	33976623	12835399	9803532
1997	01	66520511	54157276	23274100	35209599	9242630	8164366
1997	02	69219459	75473096	37529092	36680948	14553976	11658948
1997	03	65127943	70889859	35106709	34156269	15176201	11955514
1997	04	72021841	73183732	38614216	41434973	15173315	12648243
1997	05	67472582	74855276	39492672	37122594	15822332	13236013
1997	06	65286012	69585463	36862430	34817235	14765679	12114031
1997	07	70475858	74790043	39575737	35340972	14544659	11669571
1997	08	68739572	74734377	41200071	35591481	14344503	11811950
1997	09	69056627	71323050	39987570	35072707	14261774	12134805
1997	10	71600472	77738889	44232039	38302485	15240388	12971850
1997	11	66274747	65273386	38016201	33607484	13405636	11621166
1997	12	74252392	65439993	37114619	37712838	11880070	10411578
1998	01	68433425	52204817	30262309	31878175	8342825	7997405
1998	02	75890607	73835583	40606036	34709344	14166220	11524368
1998	03	71404455	71380125	38056108	34297459	15236899	11583155
1998	04	72758431	72716016	39941109	36667721	15114885	12284322
1998	05	70400229	67258116	38508769	35850630	14561477	11944369
1998	06	70546871	64674835	39828731	42575726	13736188	11793662
1998	07	73942309	67635633	43692570	45651042	14700947	11965040
1998	08	72098142	66047098	43195181	41240047	14697612	12160843
1998	09	71704041	66645927	40772374	42975101	14449401	11922542
1998	10	72318803	70473668	35394689	42310930	15332204	11612157
1998	11	72185031	67334686	33659228	40935783	14942539	10796494
1998	12	75987134	65484200	30818634	47216168	15867721	10475715

Figura 4.3 – Estrutura da Tabela SGI com os consumos mensais (kWh) por segmentos da indústria.

Fonte: Elaborado pelo autor

4.3 LEVANTAMENTO DE VARIÁVEIS ECONÔMICAS

DETERMINANTES PARA A INDÚSTRIA CATARINENSE

De acordo com a metodologia apresentada no capítulo anterior, este trabalho fundamenta-se em grande parte na busca de correlações significativas entre o ambiente econômico e a evolução do consumo de energia elétrica das indústrias e na sua consequente descoberta. Para compor a BDP2 foi realizada uma seleção criteriosa de variáveis econômicas apuradas entre 1996 e 2006. Preteriu-se a simples busca exaustiva por correlações nas mais diversas estatísticas econômicas disponíveis no Brasil, pela seleção de um conjunto de variáveis potencialmente influentes na dinâmica da indústria catarinense.

Neste sentido, foi realizada uma Pesquisa de Campo com os gestores de algumas das principais indústrias e sindicatos do Estado com intuito de coletar dados e depoimentos sobre a dinâmica de seus negócios no contexto das alterações econômicas e climáticas. Além de prever o comportamento da demanda, este trabalho pretende quantificar os efeitos das principais variáveis econômicas que afetam cada um dos segmentos do setor industrial, e que podem ser características inerentes de cada um deles. Em cinco dias foram visitadas 15 empresas e/ou sindicatos das quatro atividades industriais de maior consumo de energia elétrica em Santa Catarina, a saber: Papel e Celulose, Alimentos e Bebidas, Metalurgia e Têxtil. Para isso foi preciso visitar os seguintes pólos

industriais: Itajaí, Joinville, Jaraguá do Sul, Blumenau, Brusque, Timbó e Rio do Sul, todos na região do Vale do Itajaí e Litoral Norte do Estado.

As visitas realizadas nas indústrias ou nos sindicatos patronais tiveram o objetivo básico de obter resposta para a seguinte pergunta: “Como a economia e o clima influenciam na evolução do consumo de energia elétrica em sua empresa ou atividade?” Durante o diálogo, foram apresentadas aos gestores das empresas, séries econômicas e climáticas de 1996 a 2006 que acompanhadas do consumo de energia elétrica próprio de seu segmento, possibilitaram proveitosas discussões.

O setor industrial em Santa Catarina é bastante diversificado. É possível traçar um panorama das diferentes influências que variáveis como câmbio, taxa de juros, carga tributária, renda, entre outras, têm para atividades econômicas distintas. Segmentos exportadores, por exemplo, refletem as mudanças cambiais de forma mais aguda em relação aos segmentos voltados para o mercado interno. Além disso, estimava-se que variações de padrão do clima pudessem exercer alguma influência na produção em alguns segmentos específicos como alimentos e têxtil.

Ao final da pesquisa de campo pôde-se verificar com maior clareza quais variáveis teriam seus efeitos qualitativamente mais associados a determinados segmentos da indústria catarinense. Contudo, para dar prosseguimento às tarefas de descrição e previsão da demanda e a consequente validação da metodologia, foram selecionados apenas dois segmentos da indústria. Além da consideração de critérios como: profundidade e relevância das informações obtidas na sondagem, maior representatividade no consumo total da indústria e a escolha de segmentos sujeitos à diferentes influências econômico-climáticas, os seguintes motivos foram observados nesta seleção:

- A Indústria Têxtil: por apresentar uma desaceleração na evolução do consumo de energia elétrica nos últimos anos e um elevado potencial de correlacionamento com as variáveis climáticas;
- A Indústria Metalúrgica: por apresentar uma trajetória de crescimento do consumo de energia elétrica acima da média para o setor industrial do Estado.

A composição da série histórica de consumo de cada segmento foi baseada no atributo *genativ* presente nos registros de cada consumidor industrial da BDP1. A concessionária atribui à *genativ* o respectivo ramo de atividade econômica conforme a versão 1.0 do código CNAE⁴⁶. Assim, para obter a curva de evolução do consumo no setor têxtil, por exemplo, somam-se em cada mês os consumos de todos os clientes registrados que apresentam os dois primeiros dígitos do ramo de atividade igual 17 (Fabricação de Produtos Têxteis). A Figura 4.4 apresenta a evolução do con-

⁴⁶ O Código Nacional de Atividades Econômicas (CNAE), determinado pela Comissão Nacional de Classificação do Instituto Brasileiro de Geografia e Estatística (IBGE), é amplamente utilizado para a padronização das classificações estatísticas nacionais. O código subdivide-se em seção, divisão, grupo e classe. O código D1543-1, por exemplo, identifica uma seção D (indústria de transformação), divisão 15 (fabricação de produtos alimentícios e bebidas), grupo 15.4 (laticínios) e classe 15.43-1 (fabricação de sorvetes). No âmbito deste trabalho os consumidores industriais serão segmentados considerando apenas os níveis “seção” e “divisão” do código CNAE.

sumo de energia elétrica dos segmentos pesquisados em campo. Pode-se notar as sazonalidades típicas de calendário (férias, verão, inverno de cada ano) e as diferenças no ritmo de crescimento do consumo de energia elétrica entre segmentos industriais. Essas características fazem crer que o comportamento da demanda ao longo dos anos seja influenciado por variáveis econômicas e climáticas de diferentes origens e/ou intensidades.

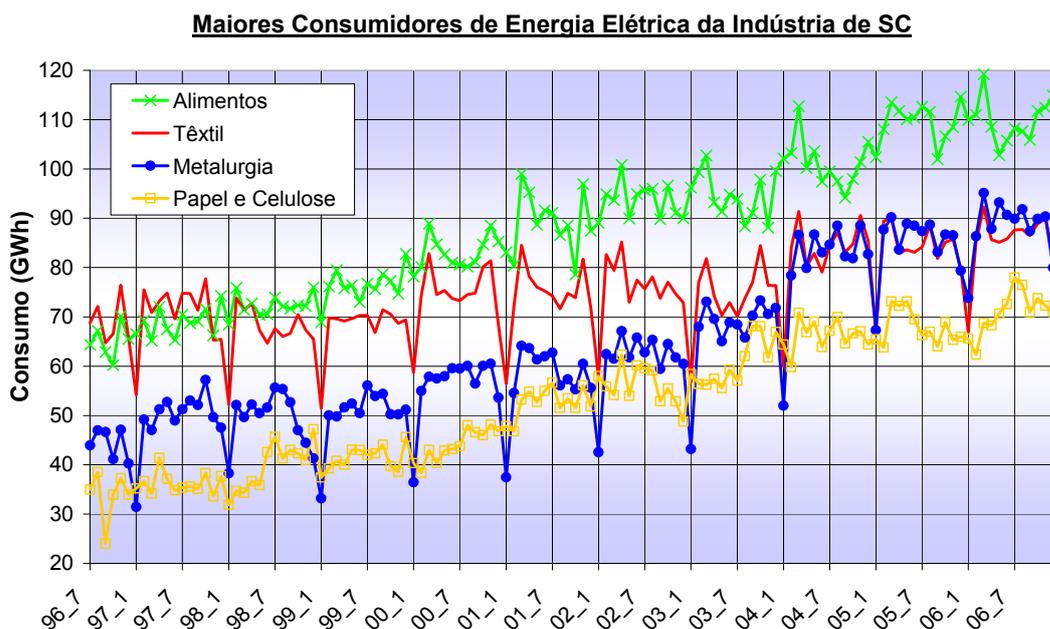


Figura 4.4 – Evolução do Consumo dos Segmentos Industriais da Pesquisa de Campo.

Fonte: Elaborado pelo autor.

4.3.1 Sondagem sobre a Dinâmica da Indústria Têxtil Catarinense

Esta seção descreve resumidamente a visão do empresariado em relação ao comportamento geral do segmento têxtil de Santa Catarina verificada durante a pesquisa de campo. Para delimitar o universo de empresas do setor têxtil, optou-se pela não inclusão do consumo de energia elétrica das indústrias de confecção de artigos do vestuário e acessórios (divisão 18 - CNAE) no consumo total do mesmo. Apesar da proximidade das cadeias produtivas, o segmento têxtil apresenta um ciclo de atividade econômica ao longo do ano distinto do segmento de confecções e vestuário. Assim, apenas as indústrias com ramo de atividade de “Fabricação de Produtos Têxteis” foram consideradas neste trabalho. A divisão 17 do código CNAE 1.0 engloba os seguintes grupos: (17.1) beneficiamento de fibras têxteis naturais, (17.2) fiação, (17.3) tecelagem, (17.4) artefatos têxteis, (17.5) acabamentos em fios e tecidos, (17.6) fabricação de artefatos têxteis exceto vestuário, (17.7) fabricação de tecidos e artigos de malha. Para a realização das entrevistas foi utilizado um único roteiro de pesquisa que abordava o comportamento da demanda segundo três aspectos:

- i. Sazonalidade da produção ao longo do ano;

- ii. Impacto da economia no desempenho da empresa ou do setor;
- iii. Impacto do clima no desempenho da empresa ou do setor (Seção 4.4);

A partir da conjunção dos relatos dos entrevistados pode-se verificar que na grande maioria das discussões e análises existia um razoável consenso. A Tabela 4.3 apresenta uma síntese das respostas obtidas sobre os dois primeiros aspectos citados, e que influenciaram sobremaneira a seleção das séries históricas da base de dados primária de economia, a BDP2.

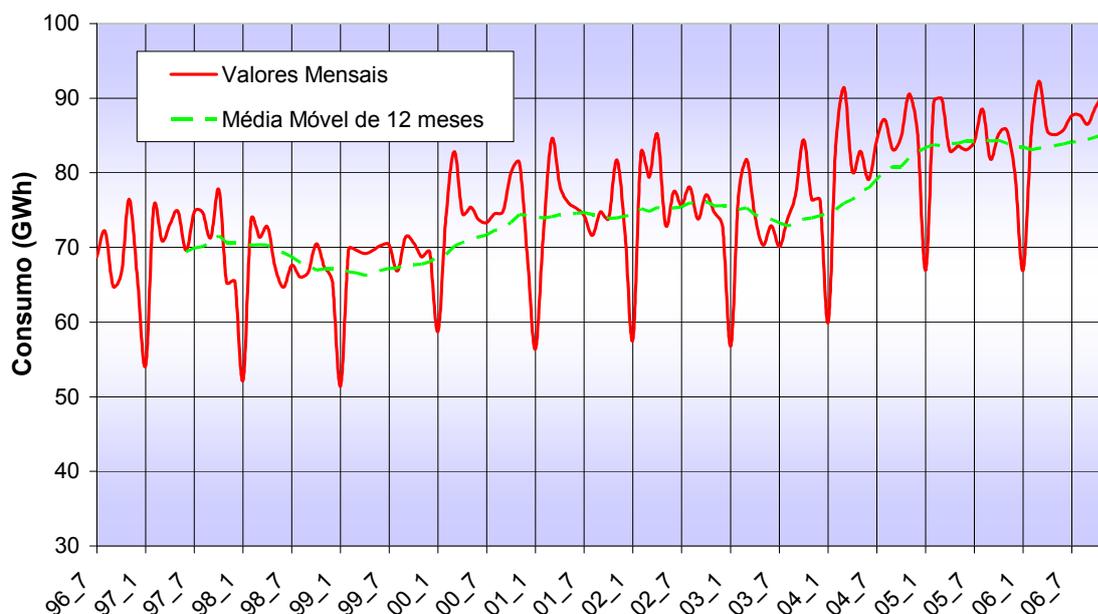
Tabela 4.3 – Diagnóstico do Comportamento da Demanda do Setor Têxtil.

A - Sazonalidade da Produção Têxtil	
<p>Pode-se observar na Figura 4.4 a repetição do padrão de consumo de energia elétrica conforme a época do ano. De forma a ajudar na compreensão deste comportamento, foi apresentado aos entrevistados um PCA – Perfil de Carga Anual equivalente para todo o setor têxtil neste período. No cálculo deste perfil considera-se somente o ano em que a curva de carga apresenta o menor desvio padrão médio dos consumos mensais em relação às curvas dos outros anos. A linha cheia em destaque no gráfico abaixo é resultado deste PCA equivalente:</p>	
<p>Perfis de Carga Anuais do Setor Têxtil de 1997 a 2006</p>	
<p style="text-align: center; margin-top: 10px;"><i>PCA equivalente dado pela curva de consumo do ano 2000</i></p>	
<p>Valores mínimos de produção em dezembro e janeiro</p>	<p>O principal motivo para esta forte redução é que a maioria das indústrias têxteis promove as férias coletivas de seus empregados entre a última quinzena de dezembro e a primeira quinzena de janeiro. Outra explicação estaria no menor volume de pedidos do comércio durante as festas de fim de ano.</p>
<p>Picos de produção entre fevereiro, março e abril</p>	<p>Nesses meses as indústrias têxteis trabalham mais para atender aos pedidos da coleção outono-inverno.</p>
<p>Redução da produção no meio do ano</p>	<p>Entre maio e agosto ocorre um período de entressafra onde o aquecimento do segmento têxtil encontra-se no comércio enquanto as indústrias se prepararam para atender a próxima estação.</p>
<p>Picos de produção entre setembro, outubro e novembro</p>	<p>Nesses meses as indústrias têxteis trabalham mais para atender aos pedidos da coleção de verão.</p>

B - Impacto da Economia no Desempenho do Segmento Têxtil

Diferentemente da análise de variações de consumo dentro de um mesmo ciclo, a sondagem sobre o impacto da economia no negócio têxtil e, por conseguinte, no consumo de energia elétrica busca explicações para a evolução da produção ao longo dos anos. Para ilustrar este comportamento, foi apresentado aos entrevistados o gráfico da curva do consumo do segmento de julho de 1996 a dezembro de 2006 acompanhada da média móvel de 12 meses:

Evolução do Consumo de Energia Elétrica no Segmento Têxtil em SC



Constatações Iniciais

Até meados de 1997 o segmento têxtil era o maior consumidor de energia elétrica da indústria de Santa Catarina. Desde então, este segmento não apresentou um ritmo de crescimento no consumo compatível com os maiores segmentos consumidores: alimentos, metalurgia, e papel e celulose (Figura 4.4). Ao final de 2006, a indústria têxtil era a terceira maior consumidora de energia elétrica, sendo superada pelos segmentos alimentício e metalúrgico. Essa desaceleração do setor têxtil encontra respaldo na deterioração do cenário econômico em que se encontravam neste período, e que só não foi pior em função da criatividade e capacidade do empresário catarinense para superar desafios.

Competição Internacional

A crescente importação de produtos têxteis dos países asiáticos, principalmente China e Índia, representa uma concorrência de peso à indústria nacional. Esse incentivo se dá em parte pela recente desvalorização das moedas destes mercados frente ao dólar americano, que por sua vez experimenta uma contínua desvalorização em relação à moeda brasileira. Além disso, o custo de capital, trabalho e de impostos nestes países em relação ao valor do produto final é bem inferior ao brasileiro. Porém é importante destacar que esta competição ocorre em duas frentes:

- No beneficiamento, com a entrada de produtos genéricos muito semelhantes aos originais e com custo inferior (concorrência ruim);
- Na fiação, com algumas indústrias catarinenses importando somente o fio, que demanda maior consumo de energia, e concentrando os esforços para agregar valor nas etapas de tecelagem e beneficiamento do seu produto final (concorrência boa).

Outra questão prejudicial ao segmento têxtil é a falta de acordos bilaterais entre o Brasil e os principais mercados consumidores na América e Europa.

Variação Cambial & Estabilidade da Moeda	Entender a influência do valor do Real em relação às principais moedas de intercâmbio do setor têxtil (Dólar americano, Yuan e Euro) não é uma questão trivial. À época das entrevistas, abril de 2007, a maior preocupação era a apreciação do Real que aumentava a concorrência internacional, principalmente na fiação (<i>commodities</i>), e dificultava a exportação dos produtos têxteis acabados. Porém, antes de 2003 as indústrias conviveram com o cenário oposto com forte desvalorização da moeda brasileira, após a adoção pelo Banco Central do Brasil da banda cambial flutuante. Nesse contexto, suspeita-se que a própria estabilidade da moeda seja um fator de redução das incertezas, capaz de favorecer o aumento do consumo de energia elétrica das indústrias. Com a análise estatística das séries históricas, no Capítulo 5, pode-se quantificar a correlação entre o consumo de energia elétrica dos segmentos com a variação cambial e com a estabilidade da moeda brasileira para o período de estudo.
Carga Tributária & Informalidade do Setor Têxtil	Assim como os demais segmentos da indústria brasileira, a desoneração de impostos talvez seja a maior preocupação dos empresários e sindicatos do segmento têxtil de Santa Catarina. Como existem muitos elos nesta cadeia produtiva, muitos impostos e contribuições incidem até chegar à sua ponta, tornando a carga tributária do setor têxtil mais elevada que a média da indústria. De 1996 a 2006 verifica-se um aumento sistemático da carga tributária (ICMS, PIS e COFINS) em relação ao PIB da indústria, aumentando a informalidade deste setor. Estes fatos podem ter influenciado negativamente na capacidade de crescimento e produção das empresas têxteis no período de estudo.
Custo da Mão de Obra	A indústria têxtil é considerada intensiva em mão de obra. Apesar de todo investimento em tecnologia, produtos finais do beneficiamento, manufatura e acabamentos têm de 30% a 35% dos seus custos comprometidos com a mão de obra. Não se consegue fazer <i>hedging</i> com o insumo trabalho da mesma forma que se faz com outros insumos da produção (fios, máquinas, capital, energia, etc.). Por isso, o aumento dos custos trabalhistas devido às contribuições sociais ou à reposição salarial negociada, têm influenciado desfavoravelmente à evolução do consumo de energia elétrica deste segmento.
Taxas de Juros & Disponibilidade de Crédito	Em geral as empresas do segmento têxtil de Santa Catarina apresentam um razoável endividamento. Neste contexto, a redução dos níveis de juros e a ampliação do crédito que ocorreram entre 1996 e 2006 podem ter beneficiado o segmento. Algumas empresas conseguiram melhorar o perfil de suas dívidas e realizar os ajustes necessários para se manterem competitivas ou até mesmo aumentar suas capacidades instaladas. Entretanto, o nível real de juros no Brasil, descontada a inflação, segue como o maior do mundo ⁴⁷ impactando negativamente no crescimento da indústria local e na conquista de novos mercados no exterior.
Renda da População	Ao longo dos 10 anos do período de estudo pode-se observar uma melhora na renda da população brasileira associada também a uma redução dos níveis de desigualdade. Porém, na análise dos empresários do setor o vestuário já não tem o mesmo papel na pirâmide de prioridades de consumo da sociedade brasileira. Ou seja, a melhora do poder de compra da população teria mais impacto na venda de produtos ligados ao acesso à informação e tecnologia (celulares, computadores, internet, etc.) do que no aquecimento da cadeia têxtil. Na análise estatística das séries históricas do Capítulo 5 pode ser constatada esta realidade.

Fonte: Elaborado pelo Autor a partir de Pesquisa de Campo.

⁴⁷ Considerando somente os países que, segundo o FMI (Fundo Monetário Internacional), vendem seus títulos de dívida pública no exterior.

4.3.2 Sondagem sobre a Dinâmica da Indústria Metalúrgica Catarinense

Esta seção descreve um pouco da visão dos empresários sobre o comportamento do segmento metalúrgico de Santa Catarina no contexto das variações da economia, verificada durante a pesquisa de campo. Neste trabalho, foram consideradas para efeito de consumo de energia elétrica, apenas as indústrias com ramo de atividade “Metalurgia Básica”. A divisão 27 do código CNAE 1.0 engloba os seguintes grupos: (27.1) produção de ferro-gusa e de ferroligas, (27.2) siderurgia, (27.3) fabricação de tubos, (27.4) metalurgia de metais não-ferrosos, (27.5) fundição.

Apesar da proximidade entre as atividades, ficam excluídas do estudo do segmento metalúrgico as variações de demanda provenientes de indústrias de “Fabricação de Produtos do Metal” (divisão 28 – CNAE). Essa desagregação se justifica pelas diferentes influências da economia em cada ramo de atividade, pautada por certa independência entre as cadeias de produção. Além disso, o consumo de energia elétrica verificado para a fabricação de produtos metálicos representa menos de ¼ daquele verificado para a indústria metalúrgica de base.

Assim como na sondagem do segmento têxtil, foi aplicado um roteiro de pesquisas para a realização das entrevistas que abordava o comportamento do consumo de energia elétrica da metalurgia segundo dois aspectos:

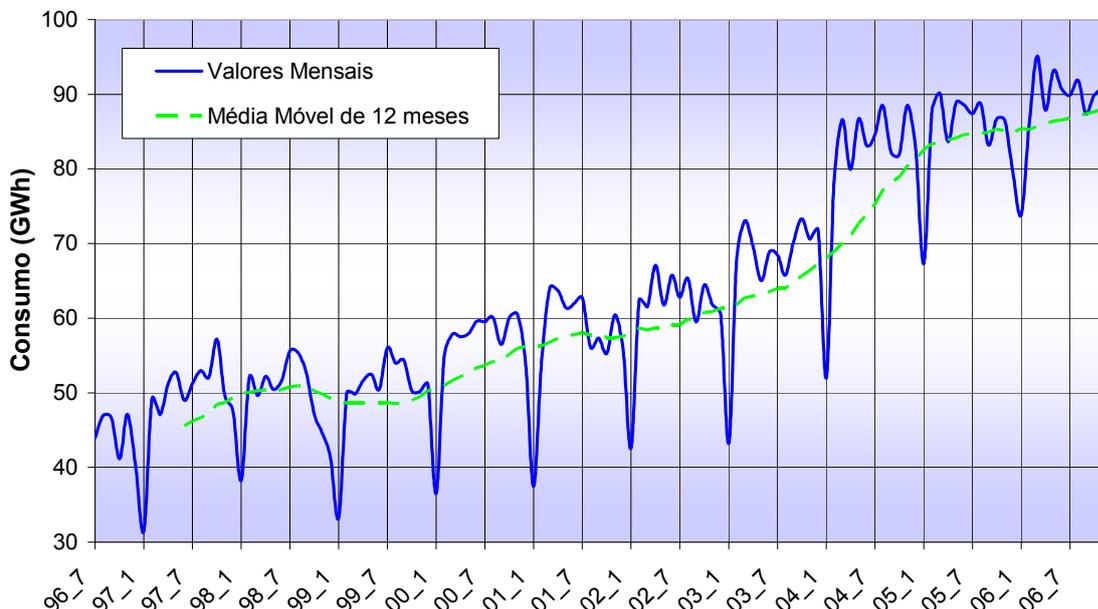
- i. Sazonalidade da produção ao longo do ano;
- ii. Impacto da economia no desempenho da empresa ou do setor;

A Tabela 4.4 apresenta uma síntese das respostas obtidas na pesquisa de campo e que também influenciaram na seleção das séries históricas da base de dados primária de economia.

Tabela 4.4 – Diagnóstico do Comportamento da Demanda do Setor Metalúrgico.

A - Sazonalidade da Produção Metalúrgica	
<p>Pode-se observar na Figura 4.4 a repetição do padrão de consumo de energia elétrica conforme a época do ano. De forma a ajudar na compreensão deste comportamento, foi apresentado aos entrevistados um PCA – Perfil de Carga Anual equivalente para toda a metalurgia neste período. Novamente, para o cálculo deste perfil considerou-se somente o ano em que a curva de carga apresenta o menor desvio padrão médio dos consumos mensais em relação às curvas dos outros anos. A linha cheia em destaque no gráfico abaixo é resultado deste PCA equivalente:</p>	
<p>Perfis de Carga Anuais do Setor Metalúrgico de 1997 a 2006</p>	
<p>Menores índices de produção em janeiro e dezembro</p>	<p>O principal motivo da forte retração do consumo em janeiro é a promoção das férias coletivas na maioria das indústrias metalúrgicas neste período. As empresas mantêm uma forte produção em boa parte do mês de dezembro para compensar o período de festas da última semana do ano. Portanto, o mês de janeiro apresenta um patamar de consumo bem inferior ao restante dos meses enquanto o mês de dezembro apresenta apenas uma tendência de redução do consumo de energia elétrica.</p>
<p>Consumo praticamente <i>flat</i> nos demais meses do ano</p>	<p>Diferentemente do segmento têxtil, a produção da metalurgia não apresenta sazonalidades significativas entre fevereiro e novembro, mantendo um mesmo nível médio de consumo de energia elétrica. Apenas no mês de setembro pode ser notar uma leve retração no consumo na maioria dos anos. Por serem base de outras cadeias produtivas importantes, como o setor de máquinas e automóveis, as metalúrgicas tem seu ritmo ditado pelo aquecimento da economia como um todo.</p>
B - Impacto da Economia no Desempenho da Metalurgia	
<p>A sondagem sobre o impacto da economia no segmento metalúrgico e, por conseguinte, no consumo de energia elétrica busca explicações para a evolução da produção ao longo dos anos. Para ilustrar este comportamento, foi apresentado aos entrevistados o gráfico abaixo com a curva suavizada do consumo do segmento entre 1996 e 2006 acompanhada da sua média móvel de 12 meses:</p>	

Evolução do Consumo de Energia Elétrica da Metalurgia em SC



<p>Constatações Iniciais</p>	<p>Entre os quatro maiores segmentos consumidores de energia elétrica considerados na pesquisa de campo, o segmento metalúrgico apresentou o melhor ritmo de crescimento de 1996 a 2006 conforme pode se verificar na Figura 4.4. Em 2006, ele já representava o segundo maior grupo industrial no consumo de energia elétrica, atrás apenas da indústria alimentícia. Na curva de evolução do consumo destaca-se a forte arrancada a partir de 2003/2004 favorecida em parte pela aceleração da indústria automobilística tanto nacional quanto internacional. Esse bom desempenho do setor metalúrgico encontra respaldo na melhora dos fundamentos da economia brasileira e na retomada do crescimento nos diversos setores. Porém, também se pode destacar aspectos econômicos que prejudicam o desempenho da indústria metalúrgica neste período.</p>
<p>Crescimento da Economia</p>	<p>Seguindo o mesmo raciocínio sobre a determinação dos setores chaves para o consumo de energia apresentado por ALCÁNTARA e PADILLA (2003), pode-se afirmar que a indústria metalúrgica apresenta uma elevada elasticidade-distribuída em comparação com sua elasticidade-própria. Ou seja, ela é mais influenciada pelo movimento de outros setores afins da economia e não consegue induzir crescimento nos mesmos quando seu segmento cresce. A maioria dos usos finais do produto metalúrgico (carros, construção civil, máquinas, etc.) estão associados ao crescimento da economia nacional e internacional. Nas séries históricas da BDP2 sobre o PIB no Brasil, nos EUA e mundial, pode-se verificar a influência positiva do aquecimento da economia de 1996 a 2006 sobre o consumo de energia elétrica do setor.</p>
<p>Desempenho dos Setores atendidos pela Indústria Metalúrgica</p>	<p>Em função das características da indústria metalúrgica em Santa Catarina, o levantamento do desempenho passado de alguns setores da economia brasileira ajudar a entender as variações do seu consumo de energia, por ordem de relevância:</p> <ul style="list-style-type: none"> - Indústria Automotiva, responsável por absorver a maior parte da produção que não é exportada; - Construção Civil, importante mercado para a produção de ferro e aço;

	<p>- Máquinas e Equipamentos, complementam os outros dois setores como os clientes-chaves da indústria metalúrgica catarinense;</p> <p>Neste trabalho, espera-se que indicadores de desempenho destes setores-chaves possam antecipar a tendência do consumo de energia elétrica do segmento.</p>
Poder de Compra da População	<p>Complementando a questão do crescimento da economia e do desempenho dos setores correlatos, surge o poder de compra da população como um fator predecessor ainda mais instigante. A renda da população brasileira experimentou um crescimento real de 1996 a 2006. Pois, além da melhoria dos salários houve também uma redução no valor do custo de vida e da cesta básica. Como consequência, o brasileiro poupou mais (indiretamente financia a construção civil), teve mais acesso ao crédito e foi às compras. Esse aumento do consumo pode ser verificado nos recordes de venda de automóveis e na aceleração da construção civil desde 2003.</p>
Variação Cambial	<p>A partir de 2003 até 2006, a apreciação da moeda brasileira ajudou as indústrias que encontravam-se em estágio de aprimoramento de tecnologia de processos, pois facilitou a importação de novos equipamentos e soluções. Por outro lado, neste período, a queda da cotação do dólar americano tornou a competição mais acirrada para o produto metalúrgico nacional nos principais mercados consumidores da Europa, Estados Unidos e Ásia.</p>
Custo Brasil	<p>O custo Brasil está associado à medida das dificuldades de qualquer empresa manter-se operando ativamente no país. Diversos aspectos podem ser considerados: câmbio, inflação, mão-de-obra, impostos, recursos naturais, taxas de juros, mercado consumidor, política de subsídios, infraestrutura em geral, risco Brasil, e etc. Para atender aos objetivos deste trabalho, apenas os principais aspectos quantificáveis e medidos ao longo do período de análise foram considerados:</p> <ul style="list-style-type: none"> - Taxas de Juros. Em geral as empresas metalúrgicas de Santa Catarina apresentam algum endividamento, e por isso podem ter melhorado o perfil de suas dívidas realizando os ajustes necessários para se manterem competitivas ou até mesmo ampliar seus negócios. Entretanto, o elevado nível real da taxa de juros no Brasil, descontada a inflação, segue impactando negativamente no desempenho financeiro da indústria catarinense e nacional; - Valor médio dos salários pagos nas indústrias, que devido ao empenho dos sindicatos tem se elevado constantemente acima da inflação; - A acomodação dos principais índices de inflação pode ter beneficiado indiretamente o desempenho da indústria metalúrgica;

Fonte: Elaborado pelo Autor a partir de Pesquisa de Campo.

4.3.3 Seleção e Pré-Processamento das Variáveis Econômicas para a BDP2

A partir do diagnóstico sobre o comportamento da demanda dos segmentos têxtil e metalúrgico, foram coletadas diversas séries históricas de parâmetros econômicos conforme as sugestões dos entrevistados. Diferentemente dos dados sobre o consumo de energia elétrica fornecidos pela concessionária, as séries econômicas exigiram muito pouco do pré-processamento. Apenas alguns cuidados foram necessários:

- Utilização somente de séries com amostragem mensal ou trimestral, com início anterior a julho de 1996 e término após dezembro de 2006;

- Correção de valores ausentes e de inconsistências de dados;
- Aplicação de técnicas de normalização.

A Tabela 4.5 apresenta um resumo das variáveis que compõem a base de dados primária sobre economia (BDP2). A seleção dessas séries históricas respalda as hipóteses previamente estabelecidas, com a revisão da literatura ou na pesquisa de campo, porém não garante sua utilização nos modelos de descrição e previsão da demanda. Somente após a realização da análise estatística das séries históricas no Capítulo 5, foi possível estabelecer quais as variáveis mais significativas para o comportamento do consumidor de energia elétrica nos segmentos selecionados.

Tabela 4.5 – Variáveis Econômicas Selecionadas para a BDP2

N.	Atributos ⁴⁸	P ⁴⁹	Fonte	Descrição
1	pib_brasil	T	IBGE	Soma do valor financeiro de todos os bens e serviços finais produzidos no Brasil.
2	pib_eua	T	FMI	Soma do valor financeiro de todos os bens e serviços finais produzidos nos Estados Unidos da América.
3	tcrc	M	BACEN	Média de taxas de câmbio reais, frente a cada um dos países pertencentes a uma determinada cesta, ponderada pela participação de cada país no total da referida cesta (deflacionada pelo IPCA).
4	tcrd	M	BACEN	Média mensal em reais do índice da taxa de câmbio real-dólar (deflacionada pelo IPCA).
5	credito	M	BACEN	Operações de crédito ao setor privado – indústria.
6	tr	M	BACEN	Taxa referencial de juros (TR) calculada pelo Banco Central do Brasil.
7	selic	M	BACEN	A taxa Selic reflete o custo do dinheiro para empréstimos bancários, com base na remuneração dos títulos públicos.
8	tjlp	M	BACEN	Taxa de Juros de Longo Prazo
9	ipca	M	IBGE	Índice de preços ao consumidor amplo, utilizado como indicador oficial do Governo Federal para medição das metas inflacionárias.
10	ipa	M	FGV	Índice de Preços no Atacado
11	igpm	M	FGV	Índice Geral de Preços a Mercado
12	incc	M	FGV	Índice Nacional do Custo da Construção Civil, que reflete o grau de aquecimento deste setor.
13	icms_sc	M	Min.Fazenda	Arrecadação estadual com imposto sobre a circulação de mercadorias – Santa Catarina
14	icms_br	M	Min.Fazenda	Arrecadação total do imposto sobre a circulação de mercadorias.
15	pis_pasep	M	Min.Fazenda	Arrecadação total de recursos para o Programa de Integração Social - PIS e para o Programa de Formação do Patrimônio do Servidor Público – PASEP.
16	conf_ind	T	FGV	Sondagem Industrial Geral - Índice de Confiança da Indústria com Ajuste Sazonal (%)

⁴⁸ São as colunas da tabela de dados no MySQL e por isso estão escritos com letras minúsculas e sem acento.

⁴⁹ Periodicidade da série histórica: (M) mensal, (T) trimestral, (A), anual.

17	expec_cons	T	CNI	Índice nacional de expectativas do consumidor
18	folha_ind	M	IBGE	Valor total da folha de pagamento do pessoal ocupado assalariado, incluindo salários contratuais, horas extras, 13º salário e outros.
19	emprego	M	Min.Trabalho	Índice Mensal do Emprego Formal no Brasil
20	emprego_ind	M	Min.Trabalho	Emprego Formal - Indústria de Transformação no Brasil
21	inv_estrang	M	CVM	Saldo do Investimento Estrangeiro em Carteira
22	export	M	SECEX	Balança Comercial Brasileira – Exportações Mensais
23	algodao	M	IPEA	Preço do algodão, em dólar americano, cotado em bolsa de mercadorias e valores no mercado internacional (Liverpool).
24	exp_textil	M	FUNCEX	Valor financeiro das exportações do setor têxtil brasileiro.
25	uci_textil_sc	M	FIESC	Utilização da capacidade instalada da indústria têxtil de SC.
26	ht_textil_sc	M	FIESC	Horas trabalhadas na indústria têxtil de SC.
27	pe_textil_sc	M	FIESC	Pessoal empregado na indústria têxtil de SC.
28	v_textil_sc	M	FIESC	Vendas totais da indústria têxtil de SC.
29	prod_autos	M	ANFAVEA	Produção total de autoveículos nacionais. Engloba automóveis, veículos leves (caminhonetes de uso misto, utilitários e caminhonetes de carga) e veículos pesados (caminhões e ônibus).
30	prod_aco	M	IBS	Produção Siderúrgica de Aço Bruto (toneladas)
31	exp_metal	M	FUNCEX	Valor financeiro das exportações do setor metalúrgico brasileiro.
32	exp_autos	M	FUNCEX	Valor financeiro total da exportação de veículos automotores.
33	uci_metal_sc	M	FIESC	Utilização da capacidade instalada da indústria metalúrgica de SC.
34	ht_metal_sc	M	FIESC	Horas trabalhadas na indústria metalúrgica de SC.
35	pe_metal_sc	M	FIESC	Pessoal empregado na indústria metalúrgica de SC.
36	v_metal_sc	M	FIESC	Vendas totais da indústria metalúrgica de SC.

Fonte: Elaborado pelo Autor.

Os valores originais das séries históricas que compõem a BDP2, isto é, antes da etapa de normalização, foram tabelados e podem ser consultados no Anexo D.

4.4 LEVANTAMENTO DE VARIÁVEIS CLIMÁTICAS DE INTERESSE PARA A INDÚSTRIA CATARINENSE

A busca de correlações entre o consumo de energia elétrica de um dado segmento da indústria e as variações de parâmetros climáticos regionais deve ser entendida como uma tentativa de aprimoramento dos modelos de previsão da demanda essencialmente voltados para os efeitos da economia. Assim, a quantificação dos efeitos do clima em alguns segmentos da indústria, mais susceptíveis à sua variação, resultaria na descoberta de conhecimento novo e útil sobre o comportamento do consumidor, além de prover maior acurácia no modelo de previsão da demanda.

Entretanto, apenas dois dos segmentos visitados na pesquisa de campo apresentam características de produção relacionadas com o clima. O setor de alimentos em função da sazonalidade dos períodos de entressafra e dos ganhos de produtividade associada às benesses do clima, além do uso

de mais tecnologia no campo. Já para a indústria têxtil, o clima e em especial a intensidade das estações climáticas são fatores determinantes do seu desempenho. Portanto, para aplicação da metodologia deste trabalho, o segmento têxtil conta com séries climáticas das regiões Sul e Sudeste do Brasil, além das variáveis econômicas já apresentadas.

Indagados sobre qual seria a influência do clima sobre o desempenho de suas empresas ou segmento, os empresários do setor apresentaram repostas um pouco divergentes. Alguns, afirmaram que invernos muito rigorosos poderiam impulsionar a produção voltada para o verão e inverno seguintes, uma vez que favoreceria a elevação das vendas no comércio, que com caixa elevado e estoque baixo demandariam mais pedidos à indústria. Por outro lado, dependendo do nicho de cada fabricante, um verão intenso teria mais impacto na produção que um inverno rigoroso.

Para analisar estatisticamente a correlação entre o clima e o consumo de energia elétrica do segmento têxtil de Santa Catarina foram desenvolvidos alguns indicadores capazes de medir a severidade do clima em cada mês (Seção 4.4.2). Para subsidiar este cálculo foram obtidas junto ao Instituto Nacional de Meteorologia (INMET) séries históricas de estações climatológicas das regiões Sul e Sudeste, principais mercados consumidores do produto têxtil catarinense.

A seção seguinte descreve a atividade de pré-processamento dos dados recebidos do INMET que compõem a base de dados primária sobre o clima, a BDP3.

4.4.1 Seleção das Variáveis Climáticas para a BDP3

Para compreender o efeito do clima na cadeia produtiva do setor têxtil é necessário conhecer o clima das regiões onde estão os principais clientes deste segmento. Por sugestão dos empresários entrevistados, com os dados das regiões Sul e Sudeste o impacto do clima estaria representado.

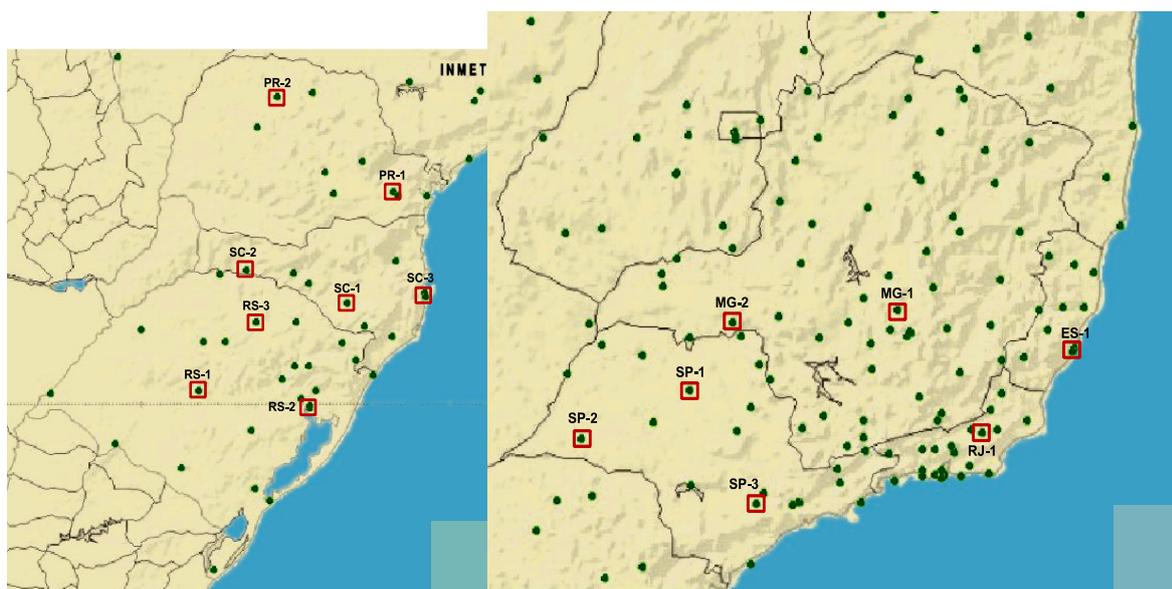


Figura 4.5 – Estações Climatológicas Convencionais das Regiões Sul e Sudeste do Brasil.

Fonte: INMET- Redes de Estações Convencionais.

Na Figura 4.5 é apresentada a localização de todas as estações climatológicas da rede de estações convencionais associadas ao INMET. Os quadrados em vermelho representam as estações selecionadas neste trabalho donde foram obtidas as séries históricas de clima. Alguns critérios foram considerados para seleção das estações climatológicas:

- Maximizar a distribuição da amostragem ao longo do território dos Estados e regiões;
- Representar bem as microrregiões com maior densidade demográfica;
- Priorizar as microrregiões de cada Estado que fossem mais representativas do ponto de vista geográfico (próximas à SC) e econômico (maior poder aquisitivo).

A Tabela 4.6 apresenta a relação com os nomes das 15 estações climatológicas selecionadas e os respectivos estados onde estão localizadas.

Tabela 4.6 – Informações sobre as Estações Climatológicas Selecionadas.

Número	Nome	Estado
RS-1	Santa Maria	Rio Grande do Sul
RS-2	Porto Alegre	Rio Grande do Sul
RS-3	Passo Fundo	Rio Grande do Sul
SC-1	Lages	Santa Catarina
SC-2	Chapecó	Santa Catarina
SC-3	Florianópolis	Santa Catarina
PR-1	Curitiba	Paraná
PR-2	Maringá	Paraná
SP-1	Catanduva	São Paulo
SP-2	Presidente Prudente	São Paulo
SP-3	Mirante de Santana	São Paulo
RJ-1	Rio de Janeiro	Rio de Janeiro
ES-1	Vitória	Espírito Santo
MG-1	Sete Lagoas	Minas Gerais
MG-2	Uberaba	Minas Gerais

Fonte: Elaborado pelo Autor.

É importante registrar que na fase inicial deste trabalho, a EPAGRI (Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina S.A) nos forneceu as principais séries históricas sobre o clima do Estado de Santa Catarina. Este fato permitiu que fossem realizados alguns testes estatísticos preliminares com dados de 12 estações climatológicas versus o consumo de energia elétrica dos segmentos têxtil e alimentício. Os resultados corresponderam moderadamente ao esperado. Porém, seguindo as recomendações dos empresários do setor têxtil, optou-se pelo presente levantamento de dados climáticos, mais abrangente, contemplando as regiões Sul e Sudeste.

Para cada uma das 15 estações selecionadas foram obtidas duas tabelas de dados. Uma com os valores normais esperados em cada mês para uma das variáveis climáticas medidas. E uma

segunda, com a série histórica mensal das variáveis entre 1996 e 2006. A listagem com os dados obtidos e utilizados na pesquisa está apresentada no Anexo E.

Tabela 4.7 – Variáveis das Estações Climatológicas que Compõem a BDP3

Atributos	Descrição	Unidade
tme	Temperatura média dos dias do mês	°C
tma	Máxima temperatura absoluta do mês	°C
tmi	Mínima temperatura absoluta do mês	°C
tmma	Média das temperaturas máximas diárias no mês	°C
tmmi	Média das temperaturas mínimas diárias no mês	°C
patm	Média mensal de pressão atmosférica	mb ou hPa
umrel	Média mensal da umidade relativa do ar	%
nebul	Nebulosidade Média mensal (0 a 10)	-
preciplu	Precipitação pluviométrica total mensal	mm
ndc	Total mensal número dias de chuva	dias
insol	Média mensal de horas de brilho solar (Insolação)	h
evap	Média mensal da evaporação	mm

Fonte: EPAGRI/INMET.

4.4.2 Pré-Processamento das Variáveis Climáticas para a BDP3

O volume de informações sobre o clima fornecido pelas instituições foi bem significativo, conforme pôde ser observado. Apesar de existir uma grande homogeneidade nos processos de medição em toda a rede de estações ligadas ao INMET, a estrutura de dados fornecida por cada uma delas não foi homogênea. Poucas estações climatológicas apresentavam medições para as 12 variáveis solicitadas. Outro problema detectado foi a ausência ou inconsistência dos dados para algumas medições nas séries históricas.

De forma análoga à formação da base de dados sobre o consumo de energia elétrica (BDP1), foi preciso executar uma tarefa de pré-processamento dos dados para constituir a BDP3, conforme a Sessão 2 de KDD apresentada na Tabela 4.8. Destaca-se, que após a realização de análises preliminares com todas as variáveis climáticas ficou constatado que apenas as medições de temperaturas deveriam compor a BDP3, pelos seguintes motivos:

- i. A alta confiabilidade e padronização das medidas de temperatura em comparação com as demais grandezas físicas medidas;
- ii. A impossibilidade de estabelecer indicadores de desconforto térmico com amostragens mensais de pressão atmosférica, umidade relativa e insolação. Esse tipo de indicador é normalmente utilizado pelas concessionárias em estudos de previsão da carga diária;
- iii. Não foi observado qualquer comportamento significativo dos indicadores de chuvas (nebulosidade, precipitação, evaporação e número de dias de chuva) ao longo das séries históricas que tivesse alguma relação com o consumo de energia elétrica na indústria têxtil.

Para correlacionar os efeitos do clima ao comportamento do consumidor industrial foram criados novos atributos na BDP3. Tratam-se de indicadores climáticos representativos de toda a região Sul e Sudeste, que procuram retratar a severidade das condições climáticas mensais. Em várias aplicações é comum a substituição dos atributos existentes pelos respectivos atributos derivados (GOLDSCHMIDT e PASSOS, 2005). A construção de indicadores climáticos regionais é um procedimento empírico fundamental para o desenvolvimento desta metodologia. Apesar desta tarefa estar incluída na sessão de pré-processamento da BDP3, devido a sua importância, a Seção 4.4.3 foi dedicada para descrever seu desenvolvimento.

Tabela 4.8 – Sessão de KDD para o Pré-Processamento da BDP3.

Aplicação: Pré-Processamento da BDP3		
<u>Sessão:</u> 2 <u>Objetivo:</u> Ajustamento das Séries Históricas	<u>Resumo:</u> Preparar as séries históricas das variáveis climáticas de cada uma das 15 estações climatológicas selecionadas nas regiões Sul e Sudeste para utilização nas tarefas de descrição e previsão da demanda.	
<u>Expectativas quanto ao Modelo de Conhecimento:</u> - Maximização da consistência das informações - Eliminação das falhas de registro dos dados - Criação de novos atributos capazes de representar a severidade das condições climáticas regionais		
<u>Plano de Ação:</u> Seleção → Limpeza → Construção de Atributos → Normalização das séries históricas		
Ciclo nº 6		
Métodos	Aplicação	Resultados
Avaliação da Contribuição Potencial das Variáveis Climáticas	<u>Seleção das Variáveis:</u> A partir das 15 planilhas com séries históricas das variáveis climáticas, foram selecionadas apenas aquelas que poderiam representar o clima de forma regional. Fatores como: (i) a confiabilidade e padronização das medidas (ii) possibilidade de estabelecer novos indicadores climáticos (iii) maior relação com o consumo de energia elétrica da indústria têxtil, do ponto de vista sistêmico e lógico.	Foram mantidas na BDP3 apenas as séries históricas de temperaturas: média, mínima, máxima, média das mínimas e média das máximas. As demais medições não cumpriram os três pré-requisitos.
Limpeza dos Dados	<u>Limpeza de Valores Nulos ou Inconsistentes:</u> As séries históricas que apresentaram falhas pontuais de registro, por não pertencerem ao conjunto de valores viáveis para a medição ou por simplesmente não terem sido registrados, tiveram seus valores substituídos pela média do mesmo mês referente aos demais anos da série.	Poucas estações climatológicas não registraram medidas em alguns meses no ano 2000. Então, nesses e outros poucos casos, os valores foram preenchidos.
Construção de Novos Atributos	<u>Criação de Variáveis Climáticas Regionais:</u> Por meio da aplicação de uma média ponderada dos valores medidos mensalmente em cada estação climatológica pode-se obter uma única série histórica equivalente das regiões Sul e Sudeste. Analogamente ao trabalho de MORAL-CARCEDO e VICÉNSOTERO (2005), utilizou-se a população da região em	Vide Seção 4.4.3

	torno da estação climatológica como fator de ponderação. Outros detalhes que complementam esta aplicação são apresentados na próxima seção.	
Aplicação de técnicas de normalização	<p><u>Normalização das séries históricas:</u> As informações de interesse sobre a BDP3 para o restante do processo de KDD se resumem às séries equivalentes para o principal mercado consumidor da indústria têxtil de Santa Catarina. Porém, nas tarefas de descrição e previsão da demanda, tais valores são analisados em conjunto com variáveis econômicas e de energia, com diferentes magnitudes/significados. Portanto, ao final do pré-processamento são disponibilizadas novas tabelas com atributos normalizados via:</p> <ul style="list-style-type: none"> - Normalização linear; - Normalização por desvio padrão; - Normalização pelo valor máximo. 	Preenchimento do banco de dados com mais 15 séries históricas, sendo 5 conjuntos de temperaturas para cada tipo de normalização.

Fonte: Elaborado pelo autor.

4.4.3 Construção de Indicadores Climáticos Regionais

Uma das contribuições mais significativas que este trabalho pode oferecer é a descoberta do nível de relacionamento entre o consumo de energia elétrica do segmento têxtil e as variações climáticas. Porém, no início do trabalho e mesmo após a revisão da literatura ainda não era possível determinar que variações climáticas medir, e como aproveitar os dados das estações climatológicas. Após a realização das entrevistas em campo, já mencionadas, a solução do problema apontava para determinação de algum indicador de severidade climática. Ou seja, algo que refletisse os períodos de inverno muito rigorosos ou os verões com calor acima da média.

As hipóteses iniciais para explicar a relação entre o consumo de energia elétrica e o clima estavam diretamente associadas aos períodos de produção das coleções outono-inverno e primavera-verão. Entretanto, resolveu-se estender este raciocínio para todos os meses ao longo da série histórica. Como a BDP3 dispunha dos valores medidos em cada mês e os valores normais esperados, foram calculadas as diferenças ou anomalias climáticas da temperatura (AT) conforme a Equação 4.1. Assim, para qualquer mês da série era possível medir se alguma das temperaturas (T) estava abaixo ou acima do valor normal esperado (\bar{T}). As equações a seguir aplicam-se igualmente para as cinco séries de temperaturas disponíveis de cada estação climatológica.

$$AT_{m,a} = T_{m,a} - \bar{T}_m \quad \text{com } a = 1996, 1997, \dots, 2006 \text{ e } m = 1, 2, \dots, 12 \quad (4.1)$$

A transição do conjunto de temperaturas dos valores absolutos medidos para as respectivas anomalias foi o primeiro passo para construir os indicadores climáticos regionais. No contexto desta pesquisa, uma série histórica da temperatura mínima absoluta mensal das regiões Sul e Sudeste pode ser entendida como um indicador climático regional. Porém, não nos pareceu lógico e

satisfatório efetuar uma média simples entre todas as 15 temperaturas mínimas disponíveis a cada mês. Ressalta-se que tal indicador tem pouco ou nenhum significado prático no contexto da meteorologia. O objetivo aqui não é saber o valor físico da anomalia regional, mas sim suas implicações em outros estudos sobre o clima. Foi possível, verificar que tais valores ajudam a explicar o comportamento dos consumidores de energia elétrica na indústria têxtil de Santa Catarina. Para que os indicadores climáticos representassem o papel de cada região, como população capaz de demandar por produtos têxteis, foi realizada uma média ponderada das temperaturas pelo mercado consumidor potencial associado a cada estação climatológica.

Como forma de estimar o mercado consumidor potencial do produto têxtil catarinense foi necessário consultar novamente alguns empresários deste segmento. Na ocasião, eles estimaram um vetor com valores entre 0 e 1 para importância comercial de cada região. Para definição dos pesos de cada uma das 15 estações, ainda foi considerada a população residente em cada Estado (IBGE, 2000) e a respectiva estimativa conforme a área de influência da estação climatológica. A Tabela 4.9 apresenta os valores usados na determinação dos pesos de cada estação climatológica:

Tabela 4.9 – Pesos para Determinação dos Indicadores Climáticos Regionais

Número	Nome	População (milhões)	Importância Comercial	População × Mercado	Peso
RS-1	Santa Maria	2,000	0,9	1,800	2,90%
RS-2	Porto Alegre	5,300	0,9	4,770	7,68%
RS-3	Passo Fundo	2,888	0,9	2,599	4,19%
SC-1	Lages	0,750	1	0,750	1,21%
SC-2	Chapecó	1,600	1	1,600	2,58%
SC-3	Florianópolis	3,006	1	3,006	4,84%
PR-1	Curitiba	5,563	0,8	4,450	7,17%
PR-2	Maringá	4,000	0,8	3,200	5,15%
SP-1	Catanduva	9,000	0,6	5,400	8,70%
SP-2	Presidente Prudente	5,032	0,6	3,019	4,86%
SP-3	Mirante de Santana	23,000	0,6	13,800	22,23%
RJ-1	Rio de Janeiro	14,391	0,5	7,196	11,59%
ES-1	Vitória	3,097	0,5	1,549	2,49%
MG-1	Sete Lagoas	14,313	0,5	7,157	11,53%
MG-2	Uberaba	3,578	0,5	1,789	2,88%

Fonte: Elaborado pelo Autor.

Assim, foi possível determinar os primeiros indicadores da severidade climática para as regiões Sul e Sudeste, sob a ótica da demanda por produtos têxteis. Uma anomalia da temperatura mínima de 3°C num dado mês, por exemplo, expressa aos modelos descritivo e preditivo que a mínima absoluta equivalente das regiões Sul e Sudeste está muito próxima dos menores valores em vários anos. O uso da anomalia facilita sobremaneira a tarefa de analisar as variações de temperaturas ao longo dos meses e seu efeito no consumo de energia elétrica. A Equação 4.2 apresenta o

cálculo das anomalias mensais das temperaturas (replicável para os cinco tipos de temperaturas medidas) conforme os pesos da Tabela 4.9:

$$AET_i = \sum_{s=1}^{15} AT_{i,s} \times P_s \quad \text{com } i = 1, 2, \dots, 132 \quad (4.2)$$

Em que,

i é o período da série histórica equivalente aos meses de jan/1996 a dez/2006.

AET é a anomalia equivalente da temperatura para toda região Sul/Sudeste

AT é anomalia da temperatura em cada estação climatológica

s é um índice de cada estação climatológica, varia de 1 a 15

P é o vetor dos pesos de cada estação climatológica, varia de 0 a 1.

A Figura 4.6 ilustra as séries históricas das anomalias equivalentes, obtidas pela aplicação da Equação 4.2 para cada uma das cinco temperaturas disponíveis. Pode-se observar que ao longo dos anos as AETs apresentaram muitas oscilações.

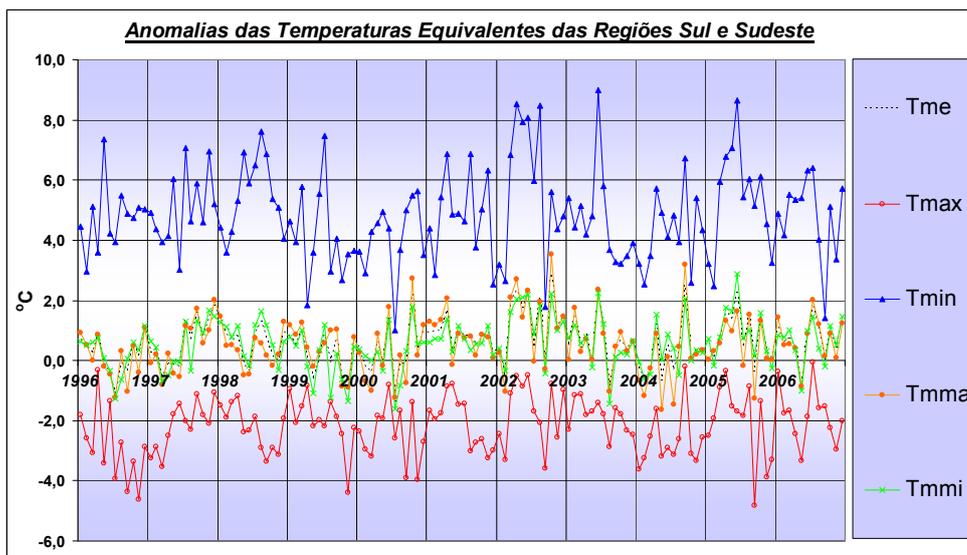


Figura 4.6 – Anomalias das Temperaturas Equivalentes das Regiões Sul e Sudeste.

Fonte: Elaborado pelo autor.

Contudo, no desenvolvimento da pesquisa, pode-se perceber que o efeito do clima estaria melhor representado se as respectivas anomalias fossem suavizadas. A variação mensal, mesmo que para dados equivalentes/regionalizados, mostrou-se bastante volátil e pouco relacionada aos acontecimentos da indústria têxtil catarinense. Então, após a análise de aspectos importantes da pesquisa de campo, como: produção voltada para coleções, o atraso entre o setor comercial e o industrial, e o comportamento do consumidor do produto têxtil, foi possível encontrar excelentes correlações entre o clima e o consumo de energia elétrica deste segmento. Em vez de considerar as AETs mensais, os indicadores climáticos regionais tornaram-se as médias móveis de 6 meses das respectivas anomalias. Com esse ajuste temporal, foi possível agregar os efeitos das estações nos

indicadores, numa transição gradual entre a tendência de períodos mais frios e períodos mais quentes. Conforme pode ser observado na Figura 4.7.

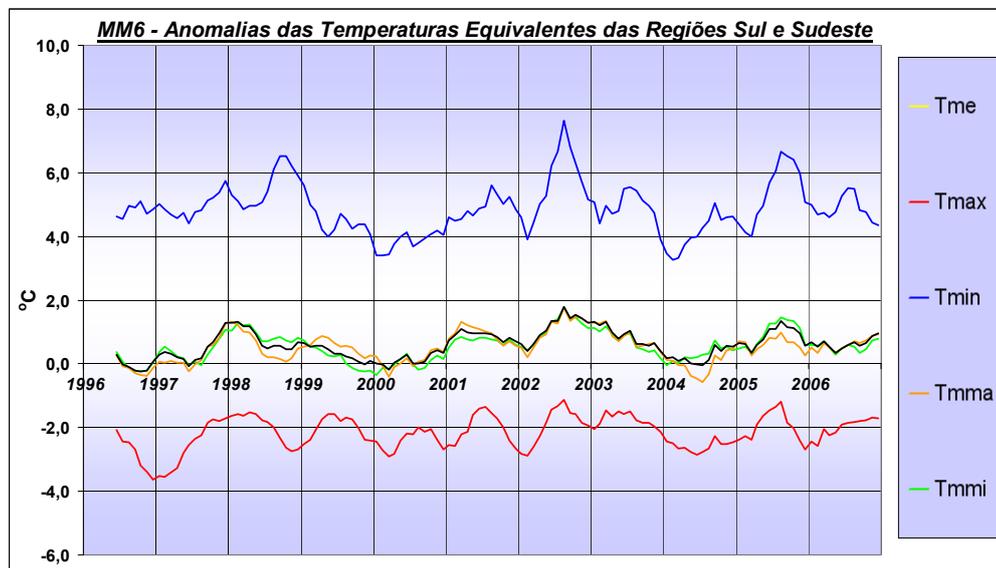


Figura 4.7 – Anomalias das Temperaturas - Média Móvel de 6 Meses.

Fonte: Elaborado pelo autor.

A notação dos indicadores climáticos regionais, relativos às anomalias das temperaturas, foi simplificada para indicar apenas qual a temperatura deu origem ao indicador e a presença de uma média móvel de 6 meses. Assim, a partir desta seção em diante, o termo mm6_Tme significa a medida móvel de 6 meses das anomalias das temperaturas médias mensais equivalente das regiões Sul/Sudeste. As notações das outras temperaturas seguem o mesmo raciocínio: mm6_Tmax, mm6_Tmin, mm6_Tmma e mm6_Tmmi.

INDICADORES CLIMÁTICOS COMPOSTOS

Antecipando etapas, foram realizados testes estatísticos entre os indicadores climáticos de temperatura e a variação do consumo de energia elétrica do segmento têxtil. Com o cálculo de coeficientes de Pearson para cada par temperatura-consumo foi possível descobrir qual fenômeno climático teve maior correlação na dinâmica da indústria têxtil: o “frio rigoroso” ou o “calor escaldante”? A resposta surpreendeu um pouco se comparada com que pudemos apurar à época da pesquisa de campo. Pois, mais frio correspondeu a crescimento do consumo de energia elétrica e mais calor correspondeu a decréscimo do consumo de energia elétrica. Os resultados estatísticos e os gráficos demonstraram, com clareza, que esta indústria está correlacionada positivamente com a presença de frio nas regiões Sul e Sudeste (vide Capítulo 5).

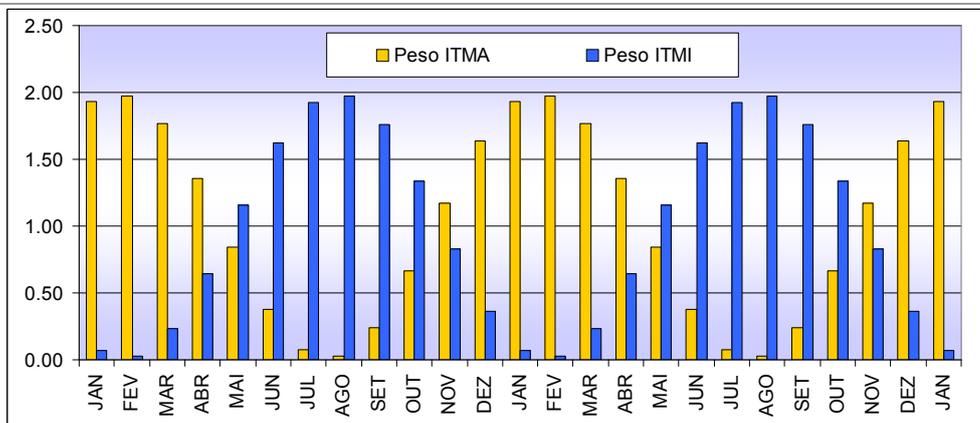
Os indicadores climáticos compostos têm o objetivo de agregar as informações das séries históricas de temperaturas (médias móveis das anomalias) para refletir uma noção de severidade climática. Ou seja, podemos agregar os indicadores: mm6_Tme, mm6_Tmin, mm6_Tmmi, em um único indicador denominado ITMI – intensidade térmica das temperaturas mínimas. Dessa forma,

obtemos um indicador mais robusto para utilizar nos modelos descritivo e preditivo. A Tabela 4.10 apresenta todos os indicadores climáticos compostos que foram testados na metodologia.

Tabela 4.10 – Indicadores Climáticos Compostos.

Notação	Descrição	Cálculo
ITMI	Intensidade Térmica das Temperaturas Mínimas: descreve a severidade climática associada às baixas temperaturas como uma média ponderada dos indicadores climáticos de temperaturas inferiores. A anomalia da temperatura média, só intensifica ITMI quando a mesma diminui. Então para fazer sentido no cálculo de ITMI, é necessário considerar seu valor complementar, dado que as séries estão normalizadas.	$ITMI_i = \frac{5\overline{Tme}_i + 3T \min_i + 2Tmmi_i}{10}$ <p>Em que: $\overline{Tme}_i = 1 - Tme_i$, e representa o complemento da anomalia de temperatura média já normalizada.</p>
ITMA	Intensidade Térmica das Temperaturas Máximas: descreve a severidade climática associada às altas temperaturas como uma média ponderada dos indicadores climáticos de temperaturas superiores.	$ITMA_i = \frac{6Tme_i + 4Tmma_i}{10}$
FRIO	Descreve a severidade climática como a combinação da “presença frio” (maior ITMI) e “ausência de calor” (menor ITMA). Então, com o complementar de ITMA e o valor de ITMI pode-se calcular o indicador climático “FRIO”.	$FRIO_i = \frac{ITMI_i + \overline{ITMA}_i}{2}$ <p>Em que: $\overline{ITMA}_i = 1 - ITMA_i$</p>
FRIO_S	Com o mesmo princípio do indicador “FRIO”, este indicador incorpora o efeito da sazonalidade anual do clima. Ou seja, no lugar de uma média simples foram atribuídos pesos para ITMA e ITMI conforme os meses do ano, mais quentes (P_q) ou mais frios (P_f). A soma desses pesos é sempre a mesma, e cada um deles varia ao longo do ano na forma de funções seno e cosseno. O gráfico abaixo ilustra essa distribuição de pesos.	$FRIO_S_i = \frac{P_f \times ITMI_i + P_q \overline{ITMA}_i}{2}$

Obs.: Os pesos dos parâmetros de cálculo dos indicadores compostos foram obtidos de forma empírica.



Fonte: Elaborado pelo Autor.

Para utilização dos indicadores climáticos compostos nos modelos descritivo e preditivo, também foram calculadas as médias móveis de seis meses das séries históricas.

Para concluir, o processo de formação da base dados sobre o clima foi preciso ter certeza de que as variáveis climáticas selecionadas e pré-processadas ajudariam a compreender a demanda. A Figura 4.8 apresenta a evolução da ITMI – Intensidade Térmica das Mínimas de 1996 até 2006 e de sua média móvel de 6 meses (MM6-ITMI), em comparação com a variação da tendência do consumo de energia elétrica mensal em relação ao mesmo período do ano anterior (V12m_Tend.Cons.Têxtil). Os valores da cada série histórica foram normalizados linearmente entre 0 e 1, para facilitar a comparação. Pode-se observar também o efeito da ITMI em relação ao consumo de energia elétrica quatro meses depois. Para isso, o gráfico apresenta a variação do consumo adiada em quatro meses (t-4). Pode-se notar, por exemplo, que em anos historicamente mais frios, como 1997, 2000 e 2004, houve um crescimento do consumo de energia elétrica da indústria têxtil de SC, na comparação com o ano anterior.

O padrão de comportamento das curvas MM6-ITMI e V12m_Tend.Cons.Têxtil(t-4), traçadas quase que no mesmo lugar geométrico, não garante uma relação de causalidade entre o clima e o consumo, mas justifica fortemente o uso de variáveis climáticas no estudo do consumo de energia elétrica deste segmento.

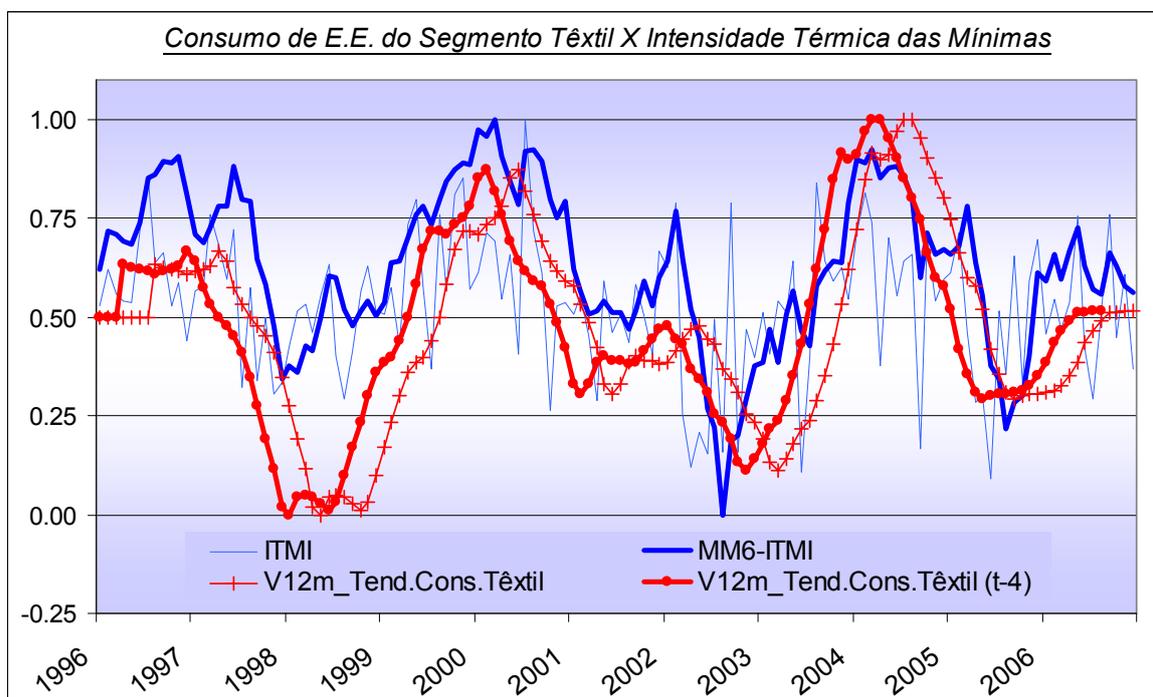


Figura 4.8 – Variação do Consumo de Energia Elétrica do Segmento Têxtil X Indicador ITMI.

Fonte: Elaborado pelo autor.

4.5 RESUMO DO CAPÍTULO

O Capítulo 4 apresentou o processo de formação das bases de dados primárias, relacionadas ao consumo de energia elétrica da indústria de Santa Catarina e às variáveis econômicas e climáticas que, com maior ou menor intensidade, influenciaram os segmentos têxtil e metalúrgico do Estado. Considerando o período compreendido entre janeiro de 1996 e dezembro de 2006, pode-se construir uma grande base de dados que foi subdividida em três bases de dados primárias (BDPs):

- ➔ BDP1 – CELESC: Contém as principais informações sobre o consumo de energia elétrica das indústrias atendidas em território catarinense.
- ➔ BDP2 – ECONOMIA: Reúne diversas séries históricas dos parâmetros econômicos mais relacionados com o comportamento da indústria catarinense, com ênfase nos segmentos têxtil e de metalurgia.
- ➔ BDP3 – CLIMA: Apresenta as principais variáveis climáticas de 15 estações climatológicas das regiões Sul e Sudeste do Brasil. Além das medidas absolutas das variáveis climatológicas medidas, foram adicionados parâmetros equivalentes do clima das duas regiões, a partir do cálculo das anomalias de temperaturas.

O processo de formação da base de dados apresentou os procedimentos para realização da etapa de pré-processamento das séries históricas de forma a atender os requisitos das atividades de mineração de dados para descrição e previsão da demanda.

Além de se configurar em condição básica necessária para o desenvolvimento dos modelos descritor e predictor da demanda, a integridade do processo de formação da base de dados está diretamente relacionada com a qualidade do resultado global deste trabalho. Por melhor que sejam as técnicas para compreensão da influência da economia e do clima no consumo de energia das indústrias, serão obtidas conclusões inconsistentes ou pouco sustentáveis quando da utilização de dados medíocres.

CAPÍTULO 5

Descrição da Demanda

5.1 INTRODUÇÃO

Uma questão de interesse na presente pesquisa refere-se à intensidade com que uma variável econômica ou climática pode estar correlacionada com o consumo de energia elétrica de um segmento da indústria. Para responder a essa questão, o desenvolvimento da metodologia, o modelo proposto na Seção 3.3 foi utilizado para descrever o consumo de energia elétrica das indústrias têxtil e metalúrgica de Santa Catarina.

A metodologia aplicada para o modelo de descrição da demanda, baseado na econometria, além de inferir sobre as correlações entre o consumo e as variáveis econômicas e climáticas, com qualidade e precisão, exerce uma função primordial na aplicação do modelo de previsão. Salienta-se que, no processo de construção e aprimoramento das redes neurais não foram utilizadas mais de 40 variáveis econômicas ou climáticas, e sim, apenas aquelas presentes nos modelos econométricos de cada segmento. Assim, os esforços para o desenvolvimento do modelo de previsão ficaram mais concentrados na melhoria da arquitetura da rede neural do que na escolha das variáveis de entrada.

A estrutura do Capítulo 5 está indicada na Figura 5.1, que representa o fluxograma do modelo descritivo apresentado na metodologia. Como um todo, este capítulo parte da base de dados ajustada até inferir quais são as variáveis econômicas e climáticas de maior influência para o consumo de energia elétrica de cada segmento industrial.

Mesmo com todas as etapas do processo de formação da base de dados, a Seção 5.2 revela algumas transformações necessárias para que as séries históricas econômicas “tornem-se” estacionárias, ampliando o conjunto de variáveis de BDP2. Ainda na Seção 5.2 são apresentadas as etapas da pré-seleção de variáveis, cujos pré-requisitos técnicos permitiram reduzir cerca de 5 vezes o número de variáveis iniciais para aplicação do modelo econométrico. Com as melhores variáveis selecionadas para cada segmento da indústria, são construídos e aprimorados modelos de descrição para a indústria têxtil e para a indústria metalúrgica. A Seção 5.3 apresenta o aprimoramento do modelo descritivo de cada segmento, desde a estimação dos parâmetros, passando pelos testes de hipóteses e avaliação do desempenho, até a obtenção do modelo final.



Figura 5.1 – Fluxograma de Aplicação do Modelo Descritivo.

Elaborado pelo Autor.

5.2 PRÉ-SELEÇÃO DAS MELHORES VARIÁVEIS

O processo de seleção de variáveis apresentado ao longo da metodologia pode ser dividido em três etapas. A primeira seleção ocorre ainda na formação da base de dados, cujo objetivo foi atender às indicações da pesquisa de campo. Uma vez estabelecidas as três bases de dados primárias, realizou-se a segunda etapa de seleção de variáveis com objetivo de atender aos pré-requisitos do modelo econométrico, denominada de pré-seleção, e é apresentada nesta seção. A terceira e última etapas de seleção acontecem naturalmente durante a própria evolução do modelo econométrico de cada segmento como apresentado na Seção 5.3.

Conforme apresentado na Seção 3.3.2, para não correr o risco de se obter uma regressão espúria⁵⁰ no modelo econométrico de regressão múltipla, a variável dependente e as variáveis explicativas devem apresentar séries históricas estacionárias. Também ficou definido, na Seção 3.3.3, que a existência de significativas relações lineares entre as principais variáveis explicativas e a variável dependente era condição necessária para o desenvolvimento deste modelo econométrico. A etapa de pré-seleção das melhores variáveis consistiu então na aplicação dos testes de presença de raiz unitária e no cálculo do coeficiente de correlação de Pearson, para um conjunto de variáveis sobre energia elétrica, clima e economia. Além disso, foi verificado se a direção da correlação entre as variáveis correspondia às hipóteses previamente estabelecidas no âmbito da teoria econômica.

Entretanto, antes da averiguação destes pré-requisitos, pode-se observar que poucas séries históricas passariam pelo teste de estacionariedade (vide Anexos C e D). Para solucionar o problema, foram realizadas algumas transformações nas séries históricas da base de dados, sem prejuízo algum para a aplicação do modelo de descrição do consumo de energia elétrica.

5.2.1 Transformações Pró-Estacionárias

A formação da base de dados foi uma condição básica para que os algoritmos da descrição e previsão pudessem ser atendidos com séries históricas sobre consumo de energia elétrica, clima e economia. Entretanto, na aplicação de modelos de regressão linear não é recomendável que as séries históricas comportem-se como passeios aleatórios ou apresentem alguma tendência. Como pode ser observado nos Anexos C e D, as séries históricas de consumo de energia elétrica e a maioria das séries relativas a índices econômicos possuem uma clara tendência de crescimento.

Segundo GUJARATI (2006), se uma série temporal tem raiz unitária, as primeiras diferenças dessa série temporal são estacionárias. Por conseguinte, a solução aqui é tomar as primeiras diferenças da série temporal. Assim o regressor X seria substituído por $X^?_i = X_i - X_{i-1}$. Entretanto, apesar deste procedimento tornar estacionária a maioria das variáveis, ele geralmente torna a série histórica muito volátil, dificultando a sua inserção na dinâmica da teoria econômica.

Uma solução muito comum na área econômica é o uso de séries econômicas indexadas ao mesmo período do ano anterior. Esse procedimento mantém o significado físico da série histórica, além de comprometer a evolução da variável às mudanças anuais do cenário econômico. Assim, foi estabelecido o primeiro tipo de transformação para várias séries históricas da base de dados. Matematicamente, a transformação, aqui denominada V12m, foi realizada pela Equação 5.1:

$$V12m_X_i = \left(\frac{X_i}{X_{i-12}} - 1 \right) \times 100 \quad (5.1)$$

Em que,

i é o período mensal da série histórica.

⁵⁰ Uma regressão espúria pode ocorrer quando se tem um alto valor para o coeficiente de determinação múltipla (R^2) sem a existência de uma relação significativa entre as variáveis (HILL et al., 2003).

Ainda com o objetivo de tornar estacionárias as séries históricas, optou-se também pela transformação de algumas variáveis por meio do cálculo de valores acumulados nos últimos 12 meses. Nesse procedimento, a nova série histórica carrega a evolução da variável frente às mudanças do cenário econômico ao longo do ano. Assim, a transformação, aqui denominada AC12m, foi aplicada aos indicadores mensais de inflação pela Equação 5.2:

$$AC12m_X_i = 1 - \prod_{i=i-12}^i (1 + X_i) \quad (5.2)$$

Em que,

i é o período mensal da série histórica.

X é a medida do valor da inflação (%) no mês.

Apenas no cálculo do saldo acumulado nos últimos 12 meses para o investimento estrangeiro não foi necessário aplicar a Equação 5.2. Como a série original era composta por valores mensais do saldo de investimento, bastou aplicar o somatório dos últimos 12 meses em cada período i .

Assim, a maioria das variáveis do modelo descritivo, inclusive as variáveis dependentes, passou por transformações pró-estacionárias. Com o objetivo de identificar tais transformações ao longo do desenvolvimento do modelo descritivo, o nome das novas séries ficou precedido dos prefixos V12m ou AC12m.

As novas séries históricas resultantes das transformações de variáveis econômicas e climáticas foram disponibilizadas nos Anexos D e E, respectivamente. As transformações das séries históricas de consumo de cada segmento industrial encontram-se no Anexo C. A Figura 5.2 exemplifica o processo de transformação pró-estacionário para duas variáveis econômicas: PIB brasileiro e o IPCA, ambos medidos pelo IBGE.

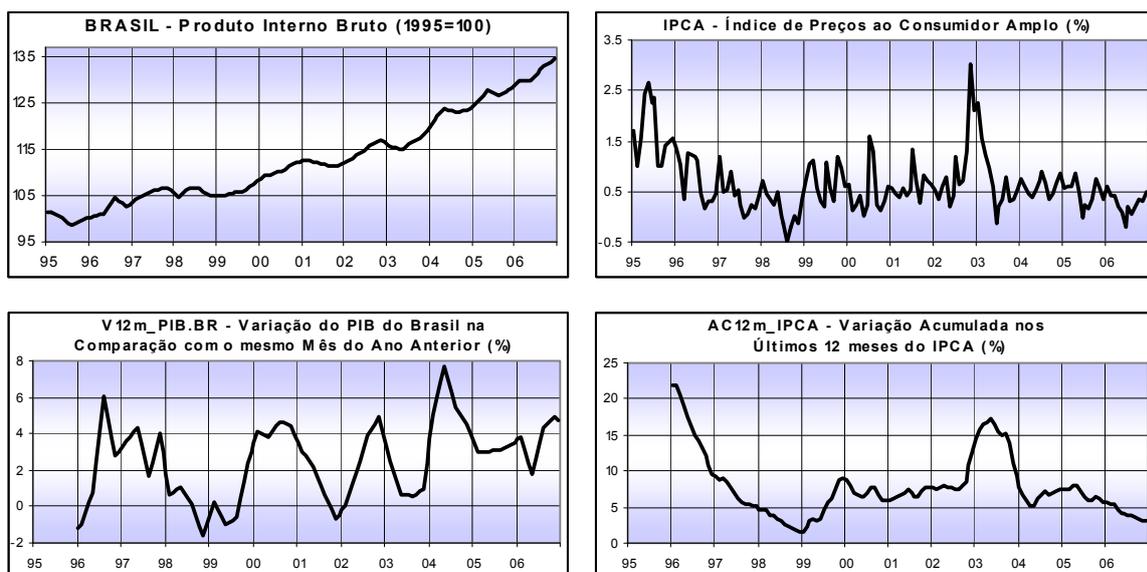


Figura 5.2 – Exemplos de Transformação Pró-Estacionária.

Fonte: Elaborado pelo Autor.

Uma das principais vantagens dessas transformações é a suavização dos efeitos da sazonalidade presente nas séries originais. É importante ressaltar que a aplicação das transformações V12m ou AC12m não garantem a estacionariedade das séries históricas transformadas.

Portanto, após a realização das transformações, o modelo de descrição de cada segmento da indústria não estava mais inferindo, de forma direta, a influência da economia e do clima no consumo de energia elétrica. A variável dependente passou a ser a variação do consumo de energia elétrica num mês em relação ao mesmo mês do ano anterior (V12m_CEE). Assim, o modelo econométrico descreve a variação do consumo de energia elétrica, e estes resultados são estendidos para calcular indiretamente o consumo de energia em cada período.

5.2.2 Comportamento Esperado

Na dinâmica do KDD, apresentada em 3.2.2, pode-se notar que o processo de descoberta de conhecimento novo e útil sobre o comportamento do consumidor não é um jogo de cartas marcadas. Nem sempre é possível antecipar as relações existentes entre os agentes econômicos e climáticos envolvidos. Algo comum no contexto do KDD é a busca de conhecimento sobre algo que não se sabe exatamente o que seja.

Neste sentido, essa seção apresenta as hipóteses preliminares sobre as variáveis explicativas do consumo de energia elétrica. A partir da revisão da literatura e da pesquisa de campo foi possível definir um comportamento ou resposta esperada para a maioria das variáveis econômicas consideradas quando correlacionadas com o consumo de energia elétrica. O que deveria favorecer ou desfavorecer o crescimento do consumo de energia elétrica nos segmentos da indústria selecionados? Para responder esta pergunta, foi elaborada a Tabela 5.1 com o comportamento esperado dos regressores e as respectivas direções (+ ou -) de correlacionamento com o consumo. A incerteza foi representada pelo sinal de interrogação (?).

Tabela 5.1 – Comportamento Esperado para as Variáveis Explicativas.

Taxas de Crescimento Econômico		
V12m_PIB.BR V12m_PIB.EUA	+	Com a integração sistêmica cada vez maior na economia mundial, espera-se algum efeito positivo nas indústrias têxtil e metalúrgica de SC em função do crescimento da economia brasileira e norteamericana.
Taxas de Câmbio		
TCER, TCRD V12m_TCER V12m_TCRD	+	Devido aos problemas relacionados à competição internacional e à necessidade de exportação de ambas indústrias, espera-se o aumento das taxas de câmbio (efetiva dólar/real) favoreçam o consumo de energia elétrica. Entretanto, também foi considerada a possibilidade do aumento do consumo estar associado a uma redução da volatilidade do câmbio.
Volat_TCER Volat_TCRD ⁵¹	-	

⁵¹ O cálculo da volatilidade das taxas de câmbio foi obtido com a aplicação do método de Black-Scholes.

Taxas de Juros e o Crédito à Indústria		
V12m_Credito	+	Aumento do volume de crédito para a indústria e a redução das taxas de juros devem estar associadas ao crescimento do consumo de energia elétrica dessas indústrias.
V12m_TR, V12m_Selic	-	
V12m_TJLP		
Indicadores de Inflação		
AC12m_IPCA AC12m_IPA AC12m_IGPM AC12m_INCC	?	A inflação acumulada nos últimos 12 meses é um dado fundamental para políticas econômicas que adotam regime de metas. Porém, nesse período, o país cresceu tanto em períodos de grande estabilidade inflacionária quanto na presença de maior inflação (vide Figura 5.2). Existe uma grande discussão nos fóruns econômicos se a elevação dos índices de preços está relacionada ao aumento da demanda por produtos, que favoreceria os segmentos industriais considerados, ou a diminuição da oferta.
Arrecadação de Impostos		
V12m_ICMS.BR V12m_ICMS.SC V12m_PISpP	+	A arrecadação de impostos estaduais e federais deve servir como um indicador do aquecimento da economia. Ao contrário da carga tributária que incide sobre a atividade têxtil e metalúrgica, espera-se que o aumento da arrecadação seja acompanhado do aumento do consumo de energia elétrica.
Indicadores de Confiança		
Confiança_Indústria Expec_Cons. V12m_Conf.Ind. V12m_Expec.Cons.	+	O aumento da confiança da indústria bem como das expectativas dos consumidores deve estar associada ao aumento do consumo, da produção e consequentemente do consumo de energia elétrica de ambos os segmentos.
Emprego e Renda		
V12m_Folha Ind. V12m_Emprego V12m_Emp.Ind.	+	O crescimento do emprego formal e da renda da população, estimada pela folha de pagamento das indústrias, devem estimular o crescimento da demanda por produtos finais da cadeia têxtil ou da cadeia metalúrgica.
Comércio Exterior		
V12m_Export. AC12m_Inv.Estrangeiro	+	O volume mensal das exportações brasileiras e saldo de investimentos estrangeiros funcionam como indicadores da competitividade do país no cenário internacional. Espera-se que o crescimento das exportações em geral e o aumento da atratividade dos investimentos estejam associados ao aumento da demanda e da oferta de produtos têxteis e metalúrgicos de SC.
Indicadores Setoriais		- Metalúrgico -
V12m_Prod.Autoveículos V12m_Prod.AçoBruto V12m_Exp. Metalurgia V12m_Exp. Autoveículos	+	Espera-se que o aumento da produção ao longo da cadeia produtiva e o crescimento da exportação na indústria de transformação favoreçam o aumento do consumo de energia elétrica da metalurgia.
V12m_UCI.Metalurgia	?	O aumento do emprego formal e do número de horas trabalhadas na indústria metalúrgica está associado ao aumento do consumo de energia elétrica. Porém, a utilização da capacidade instalada não indica com clareza o crescimento da produção pois as indústrias estão em constante processo de ampliação. As vendas da indústria podem refletir no processo produtivo, porém, seus efeitos estão mais relacionados à dinâmica logística da cadeia metalúrgica.
V12m_Horas.Metalurgia V12m_Empreg.Metalurgia	+	
V12m_Vendas.Metalurgia	?	

Indicadores Climáticos		- Têxtil -
MM6-Tmmi, MM6-Tmin MM6-ITMI, MM6-FRIO_S, MM6-FRIO	+	Após a realização das pesquisas de campo, esperava-se que as temperaturas extremas (muito frio ou muito calor) pudessem favorecer a demanda por produtos têxteis. Porém, os indicadores climáticos representativos do clima das regiões Sul e Sudeste revelaram comportamentos parcialmente diferentes. O aumento das anomalias associadas às baixas temperaturas correlaciona-se positivamente com o consumo de energia elétrica do setor. Contrariando as informações da pesquisa de campo, o crescimento das anomalias associadas às altas temperaturas é acompanhado de redução do consumo.
MM6-Tme, MM6-Tmax, MM6-Tmma, MM6-TMA	-	
Indicadores Setoriais		- Têxtil -
V12m_Exp. Têxtil	+	Espera-se que o aumento das exportações brasileiras de produtos têxteis esteja relacionado com o aumento do consumo de energia elétrica.
V12m_Algodão	?	Por se tratar da principal <i>commoditie</i> da indústria têxtil, a cotação de referência para o algodão poderia apresentar alguma correlação com o desempenho da indústria têxtil de SC.
V12m_UCI.Têxtil	?	O aumento do emprego formal e do número de horas trabalhadas na indústria têxtil está associado ao aumento do consumo de energia elétrica. Porém, a utilização da capacidade instalada não indica com clareza o crescimento da produção, pois é mascarada pela ampliação das unidades. As vendas da indústria podem refletir no processo produtivo, porém, seus efeitos estão mais relacionados à dinâmica logística da cadeia têxtil.
V12m_Horas.Têxtil V12m_Empreg.Têxtil	+	
V12m_Vendas.Têxtil	?	

Fonte: Elaborado pelo Autor.

5.2.3 Testes de Estacionariedade

Conforme apresentado na metodologia, é altamente recomendável que todas as séries históricas do modelo descritivo sejam estacionárias. Essa seção apresenta os resultados da aplicação dos testes de raiz unitária de Dickey-Fuller (DF) e Phillips-Perron (PP) ao conjunto de variáveis candidatas ao modelo econométrico. Foram testadas diferentes defasagens para os termos da regressão da Equação 3.4 na aplicação de cada teste: DF (de 0 a 4 meses) e PP (1, 3, 6 e 12 meses). As configurações diferenciadas têm o objetivo de aproveitar ao máximo as informações de cada método para a identificação da estacionariedade.

O primeiro passo para aplicação desses métodos foi a identificação do modelo de processo estocástico que poderia representar cada uma das séries históricas. Assim, todas as variáveis candidatas foram classificadas em dois grupos, conforme as características das séries históricas: PA – passeio aleatório ou PE – processo estacionário. Em seguida foram realizados os testes considerando três níveis de significância para aplicação da estatística *tau* (90%, 95% e 99%). A Tabela 5.2 apresenta os resultados dos testes de estacionariedade para as variáveis de cada base de dados. Ressalta-se, que o consumo de energia elétrica dos segmentos têxtil (CEE-T) e metalúrgico (CEE-M), assim como suas respectivas tendências de consumo (TCEE-T e TCEE-M), precisam apresentar séries históricas estacionárias.

CAPÍTULO 5 – Descrição da Demanda

Tabela 5.2 – Resultado dos Testes de Raiz Unitária.

BDP1 – CONSUMO DE ENERGIA ELÉTRICA					
N	Modelo	Série Histórica	99%	95%	90%
1	PA	V12m_CEE-T	DF-PP		
2	PA	V12m_TCEE-T	DF		PP
3	PA	V12m_CEE-M	DF-PP		PP
4	PA	V12m_TCEE-M	DF		
BDP2 - ECONOMIA					
N	Modelo	Série Histórica	99%	95%	90%
1	PA	V12m_PIB.BR	DF	PP	
2	PA	V12m_PIB.EUA	(R E P R O V A D A)		
3	PA	TCER	(R E P R O V A D A)		
4	PA	TCRD	(R E P R O V A D A)		
5	PA	V12m_TCER	DF		PP
6	PA	V12m_TCRD		DF	PP
7	PA	Volat_TCER			DF
8	PA	Volat_TCRD			DF
9	PA	V12m_Credito	PP	DF	
10	PA	V12m_TR	DF-PP		
11	PA	V12m_Selic	DF-PP		
12	PA	V12m_TJLP		DF	
13	PA	AC12m_IPCA	DF-PP		
14	PA	AC12m_IPA		DF	
15	PA	AC12m_IGPM		DF	
16	PA	AC12m_INCC	DF-PP		
17	PA	V12m_ICMS.BR	DF-PP		
18	PA	V12m_ICMS.SC	DF-PP		
19	PA	V12m_PISp	DF-PP		
20	PA	Confiança_Indústria		DF	
21	PA	Expec_Cons			DF
22	PA	V12m_Conf.Ind	DF		
23	PE	V12m_Expec.Cons	DF-PP		
24	PA	V12m_FolhaInd			DF-PP
25	PA	V12m_Emprego	(R E P R O V A D A)		
26	PA	V12m_Emp.Ind.	(R E P R O V A D A)		
27	PA	V12m_Export	DF-PP		
28	PE	AC12m_Inv.Estrangeiro	(R E P R O V A D A)		
29	PA	V12m_Prod.Autoveículos	DF-PP		
30	PA	V12m_Prod.AçoBruto	DF-PP		
31	PA	V12m_Exp. Metalurgia	DF-PP		
32	PA	V12m_Exp. Autoveículos	DF-PP		
33	PE	V12m_UCI.Metalurgia	DF-PP		
34	PA	V12m_Horas.Metalurgia	DF-PP		
35	PA	V12m_Empreg.Metalurgia	DF		
36	PA	V12m_Vendas.Metalurgia	DF-PP		

N	Modelo	Série Histórica	99%	95%	90%
37	PA	V12m_Exp. Têxtil	DF-PP		
38	PA	V12m_Algodão		DF	PP
39	PE	V12m_UCI.Têxtil	DF-PP		
40	PE	V12m_Horas.Têxtil	DF-PP		
41	PE	V12m_Empreg.Têxtil	DF-PP		
42	PE	V12m_Vendas.Têxtil	DF-PP		
BDP3 - CLIMA					
N	Modelo	Série Histórica	99%	95%	90%
1	PA	MM6-Tme	DF-PP		
2	PA	MM6-Tmax	DF-PP		
3	PA	MM6-Tmin	DF-PP		
4	PA	MM6-Tmma	DF-PP		
5	PA	MM6-Tmmi	DF-PP		
6	PA	MM6-ITMA	DF-PP		
7	PA	MM6-ITMI	DF-PP		
8	PA	MM6 FRIO_S	DF-PP		
9	PA	MM6 FRIO	DF-PP		

Fonte: Elaborado pelo Autor.

O resultado do teste de estacionariedade reprovou apenas 6 das 55 séries históricas analisadas. Para a grande maioria das variáveis não foi detectada a presença de raiz unitária em pelo menos um dos métodos utilizados, com uma significância estatística maior ou igual a 90%. O bom número de variáveis candidatas ao modelo econométrico deveu-se, essencialmente, à aplicação das transformações pró-estacionárias nas séries históricas originais.

5.2.4 Correlações Lineares

Os gráficos do consumo de energia elétrica dos segmentos industriais selecionados para aplicação do modelo descritivo (Anexo C) apresentam uma grande variação ao longo dos meses. Boa parte das variáveis econômicas, em especial as macroeconômicas, não apresenta variações bruscas compatíveis com a dinâmica do consumo de energia elétrica. O mesmo raciocínio pode ser aplicado para os indicadores climáticos desta pesquisa. Portanto, para cumprir seu objetivo no contexto da metodologia, o modelo descritivo buscou conhecer também a influência da economia e do clima sobre a curva de tendência de consumo dos segmentos. Por tratar de séries históricas mais comportadas, os modelos de descrição das tendências de consumo (TCEE) foram bem significativos. O processo de pré-seleção das variáveis candidatas ao modelo econométrico de cada segmento foi concluído com classificação das variáveis mais correlacionadas às variações do consumo e da tendência de consumo de cada segmento. A Tabela 5.3 apresenta os coeficientes de correlação de Pearson entre cada variável candidata, com defasagens variando de 0 a 12 meses (AM – atraso mensal), e a variável dependente: (a) V12m_CEE-T, (b) V12m_TCEE -T, (c) V12m_CEE-M e (d) V12m_TCEE-M.

Tabela 5.3 (a) - Coeficientes de Correlação Linear - Variáveis Explicativas X Variação do Consumo de Energia Elétrica do Segmento Têxtil.

N	V12m_CEE-T	AM = 0	AM = 1	AM = 2	AM = 3	AM = 4	AM = 5	AM = 6	AM = 7	AM = 8	AM = 9	AM = 10	AM = 11	AM = 12
1	V12m_PIB.BR	0.457	0.413	0.370	0.323	0.240								
2	V12m_PIB.EUA													0.247
3	TCER												0.261	0.278
4	TCRD												0.408	0.362
5	V12m_TCER												0.429	0.394
6	V12m_TCRD													
7	Volat_TCER						0.250	0.248	0.244	0.288	0.317	0.373	0.408	0.362
8	Volat_TCRD						-0.246	0.248	0.286	0.327	0.352	0.403	0.429	0.394
9	V12m_Credito	-0.390	-0.372	-0.373	-0.280	-0.242	-0.246	0.250	0.244	0.288	0.317	0.373	0.408	0.362
10	V12m_TR	-0.344	-0.384	-0.340	-0.273	-0.273	-0.320	-0.263	-0.250	0.286	0.352	0.403	0.429	0.394
11	V12m_Selic	-0.529	-0.456	-0.433	-0.428	-0.442	-0.447	-0.429	-0.354	0.286	0.352	0.403	0.429	0.394
12	V12m_TJLP	-0.372	-0.352	-0.323	-0.260								0.276	0.356
13	AC12m_IPCA										0.236	0.252	0.250	0.250
14	AC12m_IPA												0.269	0.272
15	AC12m_IGPM												0.281	0.282
16	AC12m_INCC								0.236	0.256	0.269	0.266	0.236	
17	V12m_ICMS.BR	0.390		0.250										
18	V12m_ICMS.SC	0.327												
19	V12m_PISPP										0.268	0.294	0.351	0.423
20	Confiança_Indústria	0.595	0.518	0.447	0.389	0.354	0.293							
21	Exp_Cons													
22	V12m_Conf.Ind	0.559	0.518	0.491	0.481	0.491	0.461	0.377	0.268					
23	V12m_FolhaInd	0.366	0.363	0.342	0.302	0.268								
24	V12m_Emprego													
25	V12m_Emp.Ind.	0.345	0.274											
26	V12m_Export	0.317	0.253											0.256
27	V12m_Algodão													
28	V12m_Exp. Têxtil		0.254		0.308	0.370	0.355	0.410	0.296	0.315	0.242	0.288	0.237	
29	V12m_Exp.Cons													
30	AC12m_Inv.Estrangeiro	0.261	0.278	0.241	0.237									-0.278
31	V12m_UCI.Têxtil	0.351	0.297	0.297	0.324	0.293	0.281							
32	V12m_Horas.Têxtil	0.476	0.389	0.356	0.353	0.381	0.277	0.274						
33	V12m_Empreg.Têxtil	0.412	0.427	0.414	0.398	0.364	0.314	0.274	0.248					
34	V12m_Vendas.Têxtil											-0.243		
35	MM6-Tme	-0.432	-0.520	-0.518	-0.533	-0.542	-0.502	-0.481	-0.399	-0.338				
36	MM6-Tmax	-0.297	-0.356	-0.347	-0.348	-0.351	-0.325	-0.297						
37	MM6-Tmin	0.433	0.475	0.440	0.439	0.432	0.401	0.388	0.346	0.298				
38	MM6-Tmma	-0.387	-0.460	-0.457	-0.466	-0.481	-0.450	-0.426	-0.335	-0.269				
39	MM6-Tmmi	0.445	0.533	0.529	0.535	0.537	0.491	0.477	0.406	0.349	0.261			
40	MM6-ITMA	-0.424	-0.507	-0.505	-0.517	-0.529	-0.491	-0.469	-0.381	-0.318				
41	MM6-ITMI	0.466	0.545	0.532	0.543	0.548	0.507	0.489	0.414	0.354	0.251			
42	MM6 FRIO_S	0.426	0.510	0.507	0.519	0.531	0.493	0.470	0.363	0.319				
43	MM6 FRIO	0.454	0.536	0.528	0.540	0.548	0.508	0.487	0.405	0.342				

Fonte: Elaborado pelo Autor.

Tabela 5.3 (b) - Coeficientes de Correlação Linear - Variáveis Explicativas X Variação da Tendência do Consumo de Energia Elétrica do Segmento Têxtil.

N	V12m_TCEE-T	AM = 0	AM = 1	AM = 2	AM = 3	AM = 4	AM = 5	AM = 6	AM = 7	AM = 8	AM = 9	AM = 10	AM = 11	AM = 12
1	V12m_PIB.BR	0.676	0.612	0.528	0.432	0.331	0.274	0.256					-0.286	-0.331
2	V12m_PIB.EUA		0.253	0.273	0.282	0.282	0.246	0.264	0.282	0.298	0.309	0.317	0.323	0.327
3	TCER											0.241	0.257	0.271
4	TCRD											0.239	0.267	0.290
5	V12m_TCER													
6	V12m_TCRD													
7	Volat_TCER					0.236	0.305	0.368	0.420	0.460	0.492	0.516	0.534	0.548
8	Volat_TCRD					0.295	0.362	0.423	0.472	0.508	0.535	0.552	0.561	0.566
9	V12m_Credito	-0.462	-0.470	-0.471	-0.465	-0.454	-0.420	-0.358	-0.287					
10	V12m_TR	-0.451	-0.483	-0.491	-0.478	-0.454	-0.407	-0.353	-0.289					
11	V12m_Selic	-0.637	-0.682	-0.695	-0.675	-0.633	-0.566	-0.484	-0.402	-0.325	-0.242			
12	V12m_TJLP	-0.590	-0.512	-0.418	-0.318						0.295	0.391	0.469	0.528
13	AC12m_IPCA						0.240	0.240	0.280	0.312	0.335	0.347	0.349	0.343
14	AC12m_IPA									0.250	0.290	0.331	0.368	0.400
15	AC12m_IJGPM									0.267	0.311	0.354	0.393	0.425
16	AC12m_INCC		0.238	0.261	0.286	0.315	0.342	0.364	0.381	0.392	0.393	0.384	0.368	0.348
17	V12m_ICMS.BR	0.471	0.431	0.404	0.361	0.310	0.277	0.241	0.241	0.271	0.245			
18	V12m_ICMS.SC	0.318	0.320	0.319	0.303	0.295	0.311	0.303	0.279	0.271	0.245			
19	V12m_PIS/PP						0.247	0.247	0.316	0.368	0.395	0.412	0.428	0.446
20	Confiança_Industria	0.810	0.770	0.708	0.627	0.530	0.422	0.310						-0.279
21	Exp_Cons													
22	V12m_Conf.Ind	0.762	0.777	0.761	0.721	0.662	0.594	0.521	0.448	0.374	0.293			
23	V12m_Folhalnd	0.569	0.538	0.496	0.452	0.411	0.360	0.300	0.238					
24	V12m_Emprego	0.304	0.250											
25	V12m_Emp.Ind.	0.492	0.387	0.289	0.256									
26	V12m_Export	0.416	0.357	0.302	0.256									
27	V12m_Algodão										0.256	0.287	0.314	0.337
28	V12m_Exp_Têxtil	0.385	0.426	0.453	0.467	0.477	0.483	0.483	0.463	0.449	0.431	0.385	0.341	0.288
29	V12m_Exp.Cons													
30	AC12m_Inv.Estrangelro	0.310	0.326	0.330	0.318	0.281							-0.245	-0.324
31	V12m_UCI_Têxtil	0.415	0.424	0.416	0.396	0.368	0.331	0.280						
32	V12m_Horas_Têxtil	0.549	0.538	0.517	0.511	0.483	0.435	0.370	0.277					
33	V12m_Empreg.Têxtil	0.591	0.592	0.586	0.571	0.547	0.506	0.445	0.372	0.293				
34	V12m_Vendas_Têxtil												-0.254	-0.294
35	MM6-Tme	-0.621	-0.685	-0.722	-0.731	-0.718	-0.686	-0.632	-0.556	-0.459	-0.352	-0.236		
36	MM6-Tmax	-0.463	-0.484	-0.490	-0.477	-0.448	-0.400	-0.339	-0.258					0.251
37	MM6-Tmin	0.620	0.648	0.661	0.652	0.631	0.597	0.546	0.478	0.398	0.318			
38	MM6-Tmma	-0.566	-0.617	-0.644	-0.644	-0.620	-0.580	-0.520	-0.441	-0.343	-0.237			
39	MM6-Tmtn	0.630	0.691	0.728	0.739	0.732	0.705	0.654	0.578	0.482	0.377	0.263		
40	MM6-ITMA	-0.612	-0.673	-0.706	-0.711	-0.694	-0.658	-0.601	-0.522	-0.423	-0.314			
41	MM6-ITMI	0.667	0.723	0.755	0.762	0.748	0.716	0.659	0.579	0.480	0.374	0.260		
42	MM6 FRIO_S	0.616	0.676	0.709	0.714	0.697	0.661	0.604	0.525	0.426	0.317			
43	MM6 FRIO	0.652	0.711	0.744	0.751	0.734	0.699	0.641	0.560	0.460	0.350			

Fonte: Elaborado pelo Autor.

Tabela 5.3 (c) - Coeficientes de Correlação Linear - Variáveis Explicativas X Variação do Consumo de Energia Elétrica do Segmento Metalúrgico.

N	V12m_CEE-M	AM = 0	AM = 1	AM = 2	AM = 3	AM = 4	AM = 5	AM = 6	AM = 7	AM = 8	AM = 9	AM = 10	AM = 11	AM = 12
1	V12m_PIB.BR	0.548	0.540	0.499	0.452	0.375	0.306	0.243						-0.246
2	V12m_PIB.EUA		0.239	0.250	0.250	0.242								0.235
3	TCER													
4	TCRD													
5	V12m_TCER	-0.240												
6	V12m_TCRD													
7	Volat_TCER								0.245	0.299	0.325	0.357	0.370	0.347
8	Volat_TCRD								0.272	0.323	0.348	0.376	0.378	0.345
9	V12m_Credito	-0.411	-0.382	-0.415	-0.369	-0.354	-0.357	-0.318	-0.294	-0.243				
10	V12m_TR			-0.237	-0.242									
11	V12m_Selic	-0.314	-0.380	-0.413	-0.479	-0.418	-0.366	-0.316	-0.268					
12	V12m_TJLP	-0.528	-0.507	-0.453	-0.365	-0.293								
13	AC12m_IPCA	0.253	0.288	0.310	0.329	0.353	0.378	0.422	0.468	0.497	0.519	0.530	0.526	0.512
14	AC12m_IPA								0.254	0.277	0.305	0.317	0.308	0.316
15	AC12m_IGPM								0.315	0.344	0.380	0.398	0.399	0.411
16	AC12m_INCC	0.376	0.408	0.421	0.426	0.438	0.441	0.458	0.470	0.483	0.495	0.493	0.461	0.430
17	V12m_ICMS.BR	0.388	0.267	0.255	0.268	0.255								
18	V12m_ICMS.SC	0.323						0.263	0.267	0.328		0.269	0.300	
19	V12m_PISp							0.305	0.253	0.300	0.346	0.291	0.343	0.347
20	Confianca_Industria	0.560	0.565	0.539	0.488	0.419	0.336	0.255						
21	Expc_Cons													
22	V12m_Conf.Ind	0.502	0.561	0.577	0.548	0.523	0.479	0.436	0.383	0.345	0.308	0.267		
23	V12m_FolhaInd	0.469	0.478	0.452	0.427	0.413	0.379	0.339	0.286	0.253				
24	V12m_Emprego													
25	V12m_Emp.Ind.	0.332	0.240									-0.256	-0.257	-0.270
26	V12m_Prod.Autoveiculos	0.550	0.497	0.446	0.395	0.396	0.308	0.240						
27	V12m_Prod.AçoBruto	0.311	0.341	0.317	0.294	0.290								
28	V12m_Export	0.442	0.405	0.382	0.304	0.262	0.244							
29	V12m_Exp.Metalurgia					0.240						0.247		
30	V12m_Exp.Autoveiculos	0.486	0.411	0.332	0.254							-0.235	-0.297	-0.336
31	V12m_Horas.Metalurgia	0.649	0.439	0.293								-0.256	-0.325	-0.325
32	V12m_Empreg.Metalurgia	0.386	0.253					-0.257	-0.325	-0.379	-0.383	-0.424	-0.422	-0.417
33	V12m_Vendas.Metalurgia													
34	V12m_UCI.Metalurgia	0.556	0.511	0.358	0.380	0.322	0.265							
35	V12m_Exp.Cons													
36	AC12m_Inv.Estrangeiro	0.323	0.390	0.438	0.479	0.428	0.375	0.327	0.273					

Fonte: Elaborado pelo Autor.

Tabela 5.3 (d) - Coeficientes de Correlação Linear - Variáveis Explicativas X Variação da Tendência do Consumo de Energia Elétrica do Segmento Metalúrgico

N	V12m_TCEE-M	AM = 0	AM = 1	AM = 2	AM = 3	AM = 4	AM = 5	AM = 6	AM = 7	AM = 8	AM = 9	AM = 10	AM = 11	AM = 12
1	V12m_PIB_BR	0.661	0.642	0.609	0.568	0.514	0.448	0.360	0.257					
2	V12m_PIB_EUA	0.294	0.305	0.306	0.296	0.278	0.252							
3	TCER						0.245	0.261	0.274	0.285	0.294	0.301	0.307	0.312
4	TCRD									0.244	0.259	0.274	0.288	0.300
5	V12m_TCER	-0.343	-0.307	-0.263										
6	V12m_TCRD	-0.368	-0.336	-0.298	-0.255									
7	Volat_TCER	-0.245						0.256	0.312	0.360	0.402	0.437	0.467	0.486
8	Volat_TCRD						0.235	0.296	0.345	0.384	0.420	0.447	0.468	0.477
9	V12m_Credito	-0.531	-0.545	-0.549	-0.533	-0.506	-0.470	-0.417	-0.350	-0.280				
10	V12m_TR	-0.238	-0.256	-0.256	-0.245									
11	V12m_Selic	-0.409	-0.445	-0.462	-0.472	-0.480	-0.481	-0.467	-0.433	-0.380	-0.317	-0.248		
12	V12m_TJLP	-0.565	-0.552	-0.530	-0.494	-0.439	-0.369	-0.286						
13	AC12m_IPCA	0.351	0.394	0.441	0.492	0.542	0.590	0.632	0.667	0.696	0.718	0.732	0.735	0.729
14	AC12m_IPA			0.249	0.275	0.300	0.318	0.338	0.356	0.377	0.398	0.422	0.440	0.451
15	AC12m_IGPM	0.260	0.287	0.315	0.344	0.372	0.395	0.420	0.446	0.476	0.507	0.541	0.570	0.589
16	AC12m_INCC	0.521	0.549	0.575	0.599	0.621	0.640	0.652	0.659	0.662	0.661	0.653	0.637	0.616
17	V12m_ICMS_BR	0.328	0.323	0.340	0.334	0.323	0.321	0.295	0.267	0.252				
18	V12m_ICMS_SC		0.244	0.287	0.301	0.326	0.357	0.389	0.354	0.354	0.347	0.322	0.339	0.328
19	V12m_PISpp				0.275	0.329	0.359	0.377	0.406	0.440	0.464	0.484	0.499	0.506
20	Confiança_Industria	0.660	0.651	0.627	0.590	0.540	0.475	0.395	0.299					
21	Expc_Cons	0.235	0.251	0.267	0.277	0.280	0.279	0.273	0.262	0.252	0.252	0.253	0.248	0.238
22	V12m_Conf.Ind	0.577	0.623	0.651	0.665	0.684	0.645	0.610	0.558	0.496	0.428	0.360	0.294	
23	V12m_FolhaInd	0.634	0.630	0.606	0.580	0.554	0.515	0.467	0.414	0.359	0.309	0.265		
24	V12m_Emprego													
25	V12m_Emp.Ind.	0.410	0.306							-0.244	-0.287	-0.320	-0.342	-0.355
26	V12m_Prod.Autoveiculos	0.604	0.588	0.561	0.530	0.477	0.439	0.373	0.271					
27	V12m_Prod.AçoBruto	0.397	0.400	0.398	0.388	0.371	0.335	0.302	0.264					
28	V12m_Export	0.556	0.518	0.473	0.419	0.352	0.287	0.237						
29	V12m_Exp. Metalurgia							0.236	0.241	0.238				
30	V12m_Exp. Autoveiculos	0.568	0.511	0.432	0.350	0.275							-0.272	-0.336
31	V12m_Horas.Metalurgia	0.580	0.459	0.358	0.290								-0.235	-0.273
32	V12m_Empreg.Metalurgia	0.473	0.319										-0.484	-0.512
33	V12m_Vendas.Metalurgia													
34	V12m_UCI.Metalurgia	0.603	0.568	0.520	0.470	0.417	0.349	0.272						
35	V12m_Exp.Cons										0.242	0.273	0.301	0.327
36	AC12m_Inv.Estrangeiro	0.480	0.520	0.539	0.545	0.521	0.482	0.430	0.374	0.305				

Fonte: Elaborado pelo Autor

O cálculo de 2.054 correlações lineares entre o consumo de energia elétrica e as variáveis candidatas à regressoras, segmentos têxtil (43) e metalúrgico (36), para diferentes defasagens de tempo possibilitou a obtenção de um mapa das relações mais significativas entre a economia, o clima e o comportamento do consumidor industrial. Com o objetivo de enaltecer as informações mais relevantes da Tabela 5.3 ficou convencionado algumas regras na sua diagramação:

- ➔ Os maiores níveis de correlação linear de cada variável candidata estão destacados com fundo colorido (laranja para o segmento têxtil e azul para o segmento metalúrgico);
- ➔ As correlações lineares que não apresentaram valores significativos⁵² ficaram em branco;
- ➔ As variáveis que foram reprovadas para estacionariedade estão com o fundo cinza;
- ➔ Os nomes das variáveis que apresentaram maior sensibilidade no cálculo das correlações para diferentes atrasos mensais (AM) foram grifadas em itálico.

5.2.5 Regressores Selecionados

A partir dos resultados da Tabela 5.3 foi realizada uma análise detalhada de cada grupo de variáveis candidatas: indicadores de inflação, arrecadação de impostos, indicadores climáticos, etc. O objetivo dessa análise é comparar a qualidade das correlações obtidas com o comportamento esperado de cada variável frente ao consumo de energia elétrica dos segmentos (Tabela 5.1).

Ao final do processo de pré-seleção e análise individual das variáveis candidatas, apresentado no Anexo F, foi possível definir quais os regressores iriam participar dos modelos descritivos dos segmentos têxtil e metalúrgico. Nos dois casos, foram 8 os regressores que apresentaram condições de participar da modelagem econométrica da demanda.

As Tabelas 5.4(a) e 5.4(b) apresentam os resultados obtidos pelos os regressores pré-selecionados de cada segmento nos testes de raiz unitária e de correlação linear. Pode-se notar que o nível das correlações é mais significativo quando a variável dependente é uma tendência de consumo e não o consumo efetivo mensal, mais difícil de ser explicado.

Tabela 5.4 (a) – Regressores Pré-Selecionados para a Descrição do Consumo de Energia Elétrica – Têxtil.

Têxtil		Testes de Raiz Unitária			Correlações Lineares			
N	Regressores	99%	95%	90%	V12m_CEE-T	AMMC	V12m_TCEE-T	AMMC
1	Confiança_Indústria		DF		0.60	0	0.81	0
2	MM6-ITMI	DF-PP			0.55	4	0.76	3
3	V12m_Selic	DF-PP			-0.53	0	-0.70	2
4	V12m_PIB.BR	DF	PP		0.46	0	0.68	0
5	V12m_FolhaInd			DF-PP	0.37	0	0.57	0
6	V12m_Exp. Têxtil	DF-PP			0.41	6	0.48	6
7	V12m_ICMS.BR	DF-PP			0.39	0	0.47	0
8	V12m_Emp.Ind.				0.35	0	0.49	0

Fonte: Elaborado pelo Autor.

⁵² Nos testes DF e PP foi utilizado nível de significância de 0,01.

Tabela 5.4 (b) – Regressores Pré-Selecionados para a Descrição do Consumo de Energia Elétrica – Metalúrgico.

Metalúrgico		Testes de Raiz Unitária			Correlações Lineares			
N	Regressores	99%	95%	90%	V12m_CEE-M	AMMC	V12m_TCEE-M	AMMC
1	AC12m_IPCA	DF-PP			0.53	10	0.74	11
2	V12m_Conf.Ind	DF			0.58	2	0.67	3
3	V12m_PIB.BR	DF	PP		0.55	0	0.66	0
4	V12m_Prod.Autoveiculos	DF-PP			0.55	0	0.60	0
5	V12m_TJLP		DF		-0.53	0	-0.57	0
6	V12m_FolhaInd			DF-PP	0.48	1	0.63	0
7	V12m_Exp. Autoveiculos	DF-PP			0.49	0	0.57	0
8	AC12m_ Inv.Estrangeiro				0.48	3	0.55	3

Fonte: Elaborado pelo Autor.

Cada segmento apresenta um oitavo regressor que foi reprovado nos testes de estacionariedade. Entretanto, como a presença de raiz unitária não foi verificada em níveis de significância de 85%, foi delegado ao aprimoramento do modelo econométrico a tarefa de excluí-lo, ou não, do conjunto de variáveis regressoras.

O conjunto de regressores pré-selecionados apresentou níveis de correlação linear acima do esperado, se for considerada a natureza e a complexidade do processo de descrição do consumo numa escala tão específica da demanda energética brasileira. Como apresentado no Capítulo 2, quanto maior for o nível de desagregação dos modelos de descrição ou previsão da demanda, pode-se obter sistemas mais eficientes e especializados. Porém, passa-se a considerar variáveis mais dinâmicas e de maior frequência na modelagem.

Os atrasos mensais que maximizaram as correlações (AMMCs) foram condizentes com o comportamento esperado para os regressores. No geral, os resultados obtidos nesta etapa não contrariaram as expectativas geradas após a realização da pesquisa de campo. Ressalta-se que elevados níveis de correlação linear não garantem a permanência dos regressores ao final do modelo econométrico. Até o aprimoramento da regressão múltipla, vários testes de significância ainda foram aplicados.

5.3 APRIMORAMENTO DOS MODELOS ECONOMÉTRICOS

A última etapa no desenvolvimento dos modelos descritivos do consumo é fundamental para a significância dos resultados obtidos. Ainda que o processo de pré-seleção tenha reduzido o conjunto de variáveis explicativas de algumas dezenas para apenas 8 regressores, nada garante que um modelo econométrico do segmento têxtil ou do metalúrgico esteja corretamente ajustado, ou que tais regressores e seus coeficientes parciais estejam próximos da realidade.

O fluxograma da Figura 5.1 apresenta as etapas para o aprimoramento dos modelos econométricos. Inicialmente, todas as oito variáveis pré-selecionadas de cada segmento foram consideradas regressores da equação de regressão múltipla (5.3) e tiveram seus parâmetros estimados conforme a metodologia. Em seguida, este modelo inicial, denominado *Modelo1*, passou por todos os

testes de hipóteses e de avaliação de desempenho propostos na metodologia. Interativamente, novos modelos econométricos eram propostos à medida que a análise dos testes de hipóteses e de desempenho não apresentava um resultado satisfatório.

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \beta_3 X_{3i} + \beta_4 X_{4i} + \beta_5 X_{5i} + \beta_6 X_{6i} + \beta_7 X_{7i} + \beta_8 X_{8i} + v_i \quad (5.3)$$

Em que,

Y_i é o regressando (consumo efetivo ou tendência de consumo de cada segmento)

X_1 a X_8 são as oito variáveis explicativas ou regressores de cada segmento

β_0 é o coeficiente linear ou intercepto da regressão

β_1 a β_8 são os coeficientes parciais da regressão

v_i é o termo de erro estocástico

Ao longo dessa seção são apresentadas tabelas que descrevem o processo de aprimoramento de cada um dos modelos econométricos analisados. Para compactar as informações nas tabelas e não estender em demasia os resultados dos testes de hipóteses e de desempenho foram adotados alguns procedimentos:

- ➔ Apenas para o melhor modelo econométrico de cada segmento foram apresentados, na primeira linha das tabelas, os parâmetros estimados da regressão múltipla com as séries históricas padronizadas⁵³;
- ➔ As variáveis, cujas linhas estão em branco, foram excluídas dos respectivos modelos;
- ➔ As variáveis que compõem cada modelo apresentam um código (A-B-C) para representar três importantes resultados dos testes de hipóteses:
 - {parte A} Se o coeficiente parcial do regressor é significativo (S) ou não-significativo (NS);
 - {parte B} O tipo de causalidade entre o regressor e o regressando: nenhuma causalidade (nc), X causa Y (XcY), Y causa X (YcX) e a causalidade bidirecional (BC);
 - {parte C} O valor obtido no teste *F* para verificar a contribuição marginal de cada regressor ao modelo econométrico;
- ➔ Para definir as relações de causalidade, quando necessário, são apresentados: o nível de confiança, o defasamento (d) e o resultado do teste de Fisher (F). Por exemplo, o regressor (a) pode preceder temporalmente ou causar (b) com 99% de confiança, com 2 períodos de defasagem e com F significativo de 13,20, (99% d=2 F=13,20);

⁵³ Diz-se que uma variável é padronizada se subtrairmos o valor da média da variável de seus valores individuais e dividirmos a diferença pelo desvio-padrão dessa variável. Uma propriedade importante das variáveis padronizadas é que sua média é sempre zero e seu desvio padrão é sempre igual a um (GUJARATI, 2006).

- O índice condicional (IC) da multicolineariedade e os indicadores de desempenho foram calculados para cada modelo. Os valores em negrito indicam os melhores valores obtidos por cada indicador ao longo do aprimoramento;
- O melhor modelo de cada simulação teve seu sombreamento destacado nas tabelas;
- Na busca do modelo econométrico satisfatório foram consideradas as seguintes diretrizes:
 - Escolha de modelos com menores valores para os critérios de informação de Schwarz, de Akaike, e R^2 -Ajustado, com prioridade para o primeiro;
 - Escolha de modelos com menores níveis de multicolineariedade;
 - Preferência por regressores com maior contribuição marginal ao modelo;
 - Preferência por regressores que apresentaram alguma relação de precedência temporal com o regressando (XcY ou BC);
 - Os critérios puramente quantitativos como R^2 e MAPE não são dominantes para a escolha do modelo.

No processo interativo de aprimoramento dos modelos, a questão do critério de parada está intimamente relacionada à parcimônia no uso de ferramentas econométricas. Nem sempre considerar diversos aspectos da dinâmica nas relações entre a energia, a economia e o clima, é garantia de resultados significativos para o “mundo real”, ainda não simulado. O ideal é que o modelo seja simples, para ter aceitação e aplicabilidade prática, e preciso, para efetivamente contribuir à complexidade do problema.

Finalmente, ressalta-se que para viabilizar o aprimoramento deste modelo econométrico foi desenvolvida no programa *Matlab* uma rotina computacional para atender as especificidades da metodologia. O programa desenvolvido possibilitou executar e analisar com precisão e rapidez todas as etapas do modelo descritivo, incluindo a extensa pré-seleção de variáveis. O Anexo G apresenta os resultados gerados pelo programa para os modelos descritivos finais de cada segmento industrial, com todos os procedimentos, previstos na metodologia, executados.

5.3.1 Descrição do Consumo de Energia Elétrica –Têxtil

Conforme a Tabela 5.5, o modelo inicial para descrição do consumo de energia elétrica do segmento têxtil (M1) não apresentou resultados satisfatórios: alta multicolineariedade e três regressores com contribuição marginal muito pequena. Após novas interações, com diferentes composições de regressores, foram avaliados mais oito modelos (M2, M3, ... , M9). Os resultados dos testes de hipóteses e de avaliação de desempenho para escolha do melhor modelo econométrico são apresentados na Tabela 5.5.

CAPÍTULO 5 – Descrição da Demanda

Tabela 5.5 – Evolução do Modelo Descritivo do Consumo de Energia Elétrica – Têxtil.

TÊXTIL										
V12m_CEE = + 0,290 ITMI - 0,276 Selic + 0,252 Exp.Têxtil + 0,181 ICMS.BR										
<i>Consumo Efetivo</i>										
N	Série Histórica	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9
1	Confiança_Indústria	NS-BC-1	NS-BC-1,4	NS-BC-1,4	NS-BC-1,4	S-BC-5,2				
2	MM6-ITMI	S-XcY-8	S-XcY-8,0	S-XcY-9,4	S-XcY-9,6	S-XcY-9,2	S-XcY-11,6	S-XcY-12,7	S-XcY-17,0	S-XcY-35,1
3	V12m_Selic	S-nc-5	S-nc-5,0	S-nc-6,4	S-nc-6,4	S-nc-6,0	S-nc-10,5	S-nc-14,3	S-nc-14,1	
4	V12m_PIB.BR	NS-BC-0,2	NS-BC-0,2	NS-BC-0,2						
5	V12m_FolhaInd	NS-BC-0,1								
6	V12m_Exp. Têxtil	S-nc-5	S-nc-5,1	S-nc-5,6	S-nc-5,7	S-nc-4,5	S-nc-11,4	S-nc-12,1		
7	V12m_ICMS.BR	NS-nc-2	NS-nc-2,2	NS-nc-2,2	NS-nc-2,1		S-nc-5,9			
8	V12m_Emp.Ind.	NS-XcY-0,2	NS-XcY-0,1							
Multicolinearidade (IC)		alta (40)	alta (35)	forte(28)	moderada(21)	moderada(18)	fraca (4)	fraca (4)	fraca (4)	inexistente
R2		0.487	0.486	0.486	0.485	0.475	0.479	0.450	0.385	0.300
R2 Ajustado		0.450	0.454	0.458	0.462	0.457	0.460	0.436	0.375	0.294
Akaïke		29.4	29.0	28.5	28.1	28.2	28.0	29.0	31.9	35.7
Schwarz		36.3	35.0	33.6	32.3	31.6	31.0	31.8	34.2	37.4
MAPE		3.765	3.763	3.767	3.766	3.765	3.818	3.828	4.126	4.472

Fonte: Elaborado pelo Autor.

Resumidamente, as razões que conduziram a escolha dos regressores em cada etapa do processo de aprimoramento deste modelo econométrico, foram:

- ➔ M1→M2: O regressor (5) apresentava o pior resultado no teste de contribuição marginal e estava correlacionado com (1) e com (8).
- ➔ M2→M3: O regressor (8) apresentava o pior resultado no teste de contribuição marginal. Apesar da boa relação de causalidade de (8) com o consumo de energia elétrica (99% d=2 F=10,9), o mesmo estava correlacionado com (1), um regressor mais significativo.
- ➔ M3→M4: O regressor (4) apresentava o pior resultado no teste de contribuição marginal, estava correlacionado com o (1), que por sua vez apresenta boa precedência temporal para (4) (99% d=2 F=7,54).
- ➔ Duas possibilidades para se testar: tirar (1) ou tirar (7). O regressor (1) apresentava resultado pior no teste de contribuição marginal que o (7). Porém, o regressor (1) apresenta boa precedência temporal para (7) (99% d=1 F=16,78) e uma relação bicausal com o consumo, enquanto que para (7) não foi identificada causalidade com o consumo.
- ➔ M4→M5: foi retirado (7) e M4→M6: foi retirado (1) – opção melhor.
- ➔ M6→M7: O regressor (7) apresentava o pior resultado no teste de contribuição marginal. O desempenho do modelo piorou.
- ➔ M8 e M9 servem apenas para demonstrar que o desempenho do modelo segue piorando com a retirada de regressores significativos.

INTERPRETAÇÃO DO CONHECIMENTO

O modelo econométrico N° 6 representa o melhor conhecimento que se pôde extrair, com esta metodologia, sobre a variação do consumo de energia elétrica do segmento têxtil, na comparação com o mesmo mês do ano anterior. Com uso de variáveis econômicas (taxa Selic, exportações de produtos têxteis, e arrecadação do ICMS) e uma climática (intensidade térmica das mínimas) foi possível explicar 47,9% do comportamento de $V12m_CEE-T$. Embora tal percentual não seja elevado, ressalta-se que a importância do modelo descritivo, nesta metodologia, está na significância do modelo econométrico. E, após iniciar a pesquisa com 43 variáveis candidatas, obteve-se um modelo descritivo com apenas 4 variáveis explicativas, de considerável significância e contribuição marginal. Para facilitar a interpretação do modelo, a Equação de regressão (5.4) foi obtida com os valores medidos nas séries históricas. Por simplificação de grafia, os regressores não aparecem com seus prefixos de transformação ($V12m$, $MM6$, e etc.) na equação.

$$V12m_CEE_T = -6,63 + 10,21ITMI - 0,071Selic + 0,086Exp.Têxtil + 0,17ICMS.BR \quad (5.4)$$

Tabela 5.6 – Interpretação do Modelo Descritivo do Consumo de Energia Elétrica - Têxtil.

Interpretação dos Coeficientes Parciais		
β_1	+10,21	Uma elevação de 1°C na média móvel de 6 meses da intensidade térmica das mínimas, nas regiões Sul e Sudeste, teria o efeito de, após 4 meses, aumentar em 10,21% a variação do consumo de energia do segmento têxtil, medido na comparação com o mesmo mês do ano anterior.
β_2	-0,071	Um crescimento de 10% na variação da taxa Selic, medida na comparação com o mesmo mês do ano anterior, teria o efeito de reduzir em 0,71% a variação do consumo de energia do segmento têxtil, medido na comparação com o mesmo mês do ano anterior.
β_3	+0,086	Um crescimento de 10% na variação das exportações de produtos têxteis, medida na comparação com o mesmo mês do ano anterior, teria o efeito de, após 6 meses, aumentar em 0,86% a variação do consumo de energia do segmento têxtil, medido na comparação com o mesmo mês do ano anterior.
β_4	+0,17	Um crescimento de 10% na arrecadação do ICMS no Brasil, medida na comparação com o mesmo mês do ano anterior, teria o efeito de aumentar em 1,7% a variação do consumo de energia do segmento têxtil, medido na comparação com o mesmo mês do ano anterior.

Fonte: Elaborado pelo Autor.

Para avaliar a importância relativa de cada regressor no modelo econométrico deve-se considerar a equação da Tabela 5.5, que foi obtida com as séries históricas padronizadas. A dimensão dos coeficientes da Equação 5.4, obtida com valores físicos medidos, não permite comparar a elasticidade da demanda entre as variáveis explicativas, pois as mesmas apresentam amplitudes distintas ao longo das séries históricas. Esse raciocínio se aplica para as equações 5.5, 5.6, e 5.7 e para as respectivas Tabelas 5.7, 5.9 e 5.11.

AJUSTAMENTO GRÁFICO – PREVISÃO DENTRO DA AMOSTRA

A partir dos valores estimados para o V12m_CEE-T pelo modelo econométrico foram construídos dois gráficos na Figura 5.3. O primeiro apresenta os valores históricos ocorridos e os estimados pelo modelo. Considerando um intervalo de confiança de 95% foram traçados os valores mínimos e máximos estimados. O segundo gráfico apresenta os valores históricos do CEE-T e os valores de consumo estimados a partir da estimação de V12m_CEE-T. Pode-se notar a complexidade do comportamento do consumo, bem como os erros percentuais absolutos ao longo dos 10 anos considerados.

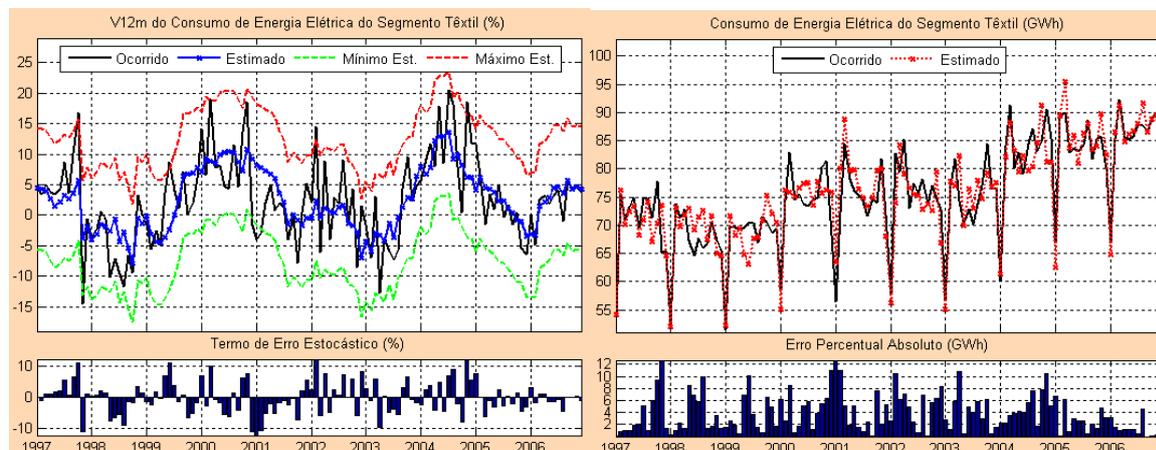


Figura 5.3 – Ajustamento Gráfico do Modelo Descritivo – V12m_CEE-T.

Fonte: Elaborado pelo Autor.

5.3.2 Descrição da Tendência do Consumo de Energia Elétrica - Têxtil

Conforme a Tabela 5.7, o modelo inicial para descrição da tendência do consumo de energia elétrica do segmento têxtil (M1) não apresentou resultados qualitativos satisfatórios: alta multicolineariedade e dois regressores com contribuição marginal muito pequena. Após novas interações, com diferentes composições de regressores, foram avaliados mais oito modelos (M2, M3, ... , M9). Os resultados dos testes de hipóteses e de avaliação de desempenho para escolha do melhor modelo econométrico são apresentados na Tabela 5.7.

CAPÍTULO 5 – Descrição da Demanda

Tabela 5.7 – Evolução do Modelo Descritivo da Tendência do Consumo de Energia Elétrica – Têxtil.

TÊXTIL										
V12m_TCEE = + 0,315 Confiança.Ind + 0,463 ITMI - 0,167 Selic + 0,229 Folhalnd										
<i>Tendência de Consumo</i>										
N	Série Histórica	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9
1	Confiança_Indústria	S-BC-15	S-BC-13	S-BC-17	S-BC-19	S-BC-19	S-BC-57	S-BC-27	S-BC-66	S-BC-66
2	MM6-ITMI	S-BC-42	S-BC-45	S-BC-47	S-BC-47	S-BC-50	S-BC-41	S-BC-61	S-BC-55	
3	V12m_Selic	S-YcX-7	S-YcX-9	S-YcX-11	S-YcX-11	S-YcX-10	S-YcX-8			
4	V12m_PIB.BR	NS-YcX-0,0	NS-YcX-0,0							
5	V12m_Folhalnd	S-BC-12	S-BC-11	S-BC-12	S-BC-12	S-BC-16		S-BC-13		
6	V12m_Exp. Têxtil	NS-YcX-1	NS-YcX-0,4	NS-YcX-0,4	NS-YcX-0,5					
7	V12m_ICMS.BR	NS-BC-0,0	NS-BC-0,0	NS-BC-0,0						
8	V12m_Emp.Ind.	NS-YcX-2								
Multicolinearidade (IC)		alta (38)	alta (32)	forte(26)	forte(24)	moderada(21)	moderada(14)	moderada(15)	fraca (4)	inexistente
R2		0.858	0.855	0.855	0.855	0.854	0.831	0.839	0.819	0.656
R2 Ajustado		0.848	0.846	0.847	0.849	0.849	0.827	0.835	0.816	0.653
Akaike		2.947	2.964	2.915	2.868	2.834	3.231	3.070	3.408	6.310
Schwarz		3.633	3.569	3.430	3.297	3.183	3.546	3.369	3.654	6.664
MAPE		1.322	1.332	1.332	1.331	1.341	1.431	1.367	1.441	2.021

Fonte: Elaborado pelo Autor.

Resumidamente, as razões que conduziram a escolha dos regressores em cada etapa do processo de aprimoramento deste modelo econométrico, foram:

- M1→M2: O regressor (8) havia sido inserido no modelo devido à boa correlação que tinha com o regressando, pois ele já apresentava problema de estacionariedade. Porém, ele não apresentou contribuição marginal ao modelo e ainda estava correlacionada com (1) e com (5), sendo que a (5) precede temporalmente a (8) com (99% d=3 F=4.96).
- M2→M3: O regressor (4) não apresentava contribuição marginal para o modelo, estava correlacionado com o (1), que por sua vez apresenta precedência temporal para (4) (99% d=2 F=7,54).
- M3→M4: Os regressores (6) e (7) não apresentam contribuição marginal para o modelo, porém o teste F da contribuição de (6) é 10x maior que de (7). Embora (7) preceda temporalmente (6) (90% d=2 F=2,55).
- M4→M5: O regressor (6) continuava não apresentando contribuição marginal para o modelo.
- M5→M6: Na tentativa de eliminar a multicolineariedade, o regressor (5) foi retirado do modelo. O desempenho do mesmo piorou.
- M5→M7: Com intenção de reduzir regressores, foi removido o regressor (3) que apresentava menor contribuição marginal, embora significativa. O desempenho do modelo piorou.
- M8 e M9 servem apenas para demonstrar que o desempenho do modelo segue piorando com a retirada de regressores significativos.

INTERPRETAÇÃO DO CONHECIMENTO

O modelo econométrico N° 5 representa o melhor conhecimento que se pôde extrair, com esta metodologia, sobre a variação da tendência do consumo de energia elétrica do segmento têxtil, na comparação com o mesmo mês do ano anterior. Com uso de variáveis econômicas (confiança da indústria, taxa Selic, e folha de pagamento da indústria) e uma climática (intensidade térmica das mínimas) foi possível explicar 85,4% do comportamento de V12m_TCEE-T. Após iniciar a pesquisa com 43 variáveis candidatas, obteve-se um modelo descritivo com apenas 4 variáveis explicativas, de ótima significância e contribuição marginal. Para facilitar a interpretação do modelo, a equação de regressão (5.5) foi obtida com os valores medidos nas séries históricas. Por simplificação de grafia, os regressores não aparecem com seus prefixos de transformação (V12m, MM6, e etc.) na equação.

$$V12m_TCEE_T = -18,91 + 0,143Confiança + 9,83ITMI - 0,026Selic + 0,137Folha_Ind \quad (5.5)$$

Tabela 5.8 – Interpretação do Modelo Descritivo da Tendência do Consumo de Energia Elétrica - Têxtil.

Interpretação dos Coeficientes Parciais	
β_1	+0,143
	Um crescimento de 10% no indicador de confiança da indústria, medida na comparação com o mesmo mês do ano anterior, teria o efeito de aumentar em 1,43% a variação da tendência do consumo de energia do segmento têxtil, medido na comparação com o mesmo mês do ano anterior.
β_2	+9,83
	Uma elevação de 1°C na média móvel de 6 meses da intensidade térmica das mínimas, nas regiões Sul e Sudeste, teria o efeito de, após 3 meses, aumentar em 9,83% a variação da tendência do consumo de energia do segmento têxtil, medido na comparação com o mesmo mês do ano anterior.
β_3	-0,026
	Um crescimento de 10% na variação da taxa Selic, medida na comparação com o mesmo mês do ano anterior, teria o efeito de, após 2 meses, reduzir em 0,26% a variação da tendência do consumo de energia do segmento têxtil, medido na comparação com o mesmo mês do ano anterior.
β_4	+0,137
	Um crescimento de 10% na “renda”, representada pela folha de pagamento da indústria e medida na comparação com o mesmo mês do ano anterior, teria o efeito de aumentar em 1,37% a variação da tendência do consumo de energia do segmento têxtil, medido na comparação com o mesmo mês do ano anterior.

Fonte: Elaborado pelo Autor.

AJUSTAMENTO GRÁFICO – PREVISÃO DENTRO DA AMOSTRA

A partir dos valores estimados para a V12m_TCEE-T pelo modelo econométrico foram construídos dois gráficos na Figura 5.4. O primeiro apresenta os valores históricos ocorridos e os estimados pelo modelo. Considerando um intervalo de confiança de 95% foram traçados os valores mínimos e máximos estimados. O segundo gráfico apresenta os valores históricos da TCEE-T e os valores de consumo estimados a partir da estimação de V12m_TCEE-T. Pode-se notar que comportamento da tendência do consumo é bem mais suave que do consumo efetivo. Com isso, em com-

paração com a Figura 5.3, houve um estreitamento das bandas de estimação e uma redução dos termos de erro dos gráficos.

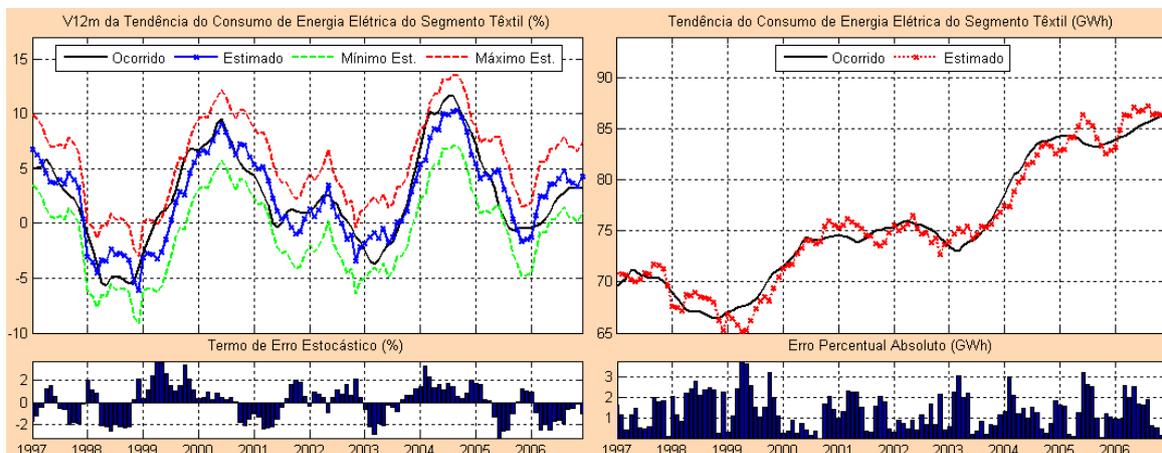


Figura 5.4 - Ajustamento Gráfico do Modelo Descritivo – V12m_TCEE-T.

Fonte: Elaborado pelo Autor.

5.3.3 Descrição do Consumo de Energia Elétrica - Metalúrgico

Conforme a Tabela 5.9, o modelo inicial para descrição do consumo de energia elétrica do segmento metalúrgico (M1) já se apresentava razoavelmente bem: com baixa multicolineariedade e poucos regressores com contribuição marginal muito pequena. Porém, após novas interações, com diferentes composições de regressores, foram avaliados mais sete modelos (M2, M3, ... , M8). Os resultados dos testes de hipóteses e de avaliação de desempenho para escolha do melhor modelo econométrico são apresentados na Tabela 5.9.

Tabela 5.9 – Evolução do Modelo Descritivo do Consumo de Energia Elétrica – Metalúrgico.

METALÚRGICO		V12m_CEE = + 0,336 IPCA + 0,463 Confiança.Ind + 0,227 Exp.Autos						Consumo Efetivo	
N	Série Histórica	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8
1	AC12m_IPCA	S-XcY-9,4	S-XcY-9,4	S-XcY-9,1	S-XcY-8,6	S-XcY-11,8	S-XcY-19,0	S-XcY-31,9	
2	V12m_Conf.Ind	S-nc-19,8	S-nc-19,6	S-nc-27,1	S-nc-29,9	S-nc-30,8	S-nc-35,9	S-nc-38,0	S-nc-38,9
3	V12m_PIB.BR	NS-XcY-2,3	NS-XcY-2,6	NS-XcY-2,2					
4	V12m_Prod.Autoveículos	NS-nc-1,0	NS-nc-0,7						
5	V12m_TJLP	NS-XcY-0,4							
6	V12m_FolhaInd	NS-XcY-2,2	NS-XcY-2,7	S-XcY-4,1	NS-XcY-2,3	NS-XcY-2,5			
7	V12m_Exp. Autoveículos	S-YcX-3,3	S-YcX-3,7	S-YcX-5,6	S-YcX-5,3	S-YcX-9,3	S-YcX-9,4		
8	AC12m_Inv.Estrangeiro	S-nc-4,2	S-nc-4,3	S-nc-3,8	NS-nc-2,5				
Multicolineariedade (IC)		fraca (6,0)	fraca (5,3)	fraca (4,7)	fraca (4,0)	fraca (3,4)	fraca (2,8)	fraca (2,3)	inexistente
R2		0.587	0.585	0.583	0.575	0.565	0.555	0.516	0.333
R2 Ajustado		0.557	0.560	0.561	0.556	0.550	0.544	0.508	0.327
Akaike		44.3	43.7	43.2	43.4	43.6	43.8	46.9	63.6
Schwarz		54.6	52.7	50.9	49.9	48.9	48.1	50.3	66.5
MAPE		4.410	4.415	4.412	4.512	4.485	4.401	4.466	5.649

Fonte: Elaborado pelo Autor.

Resumidamente, as razões que conduziram a escolha dos regressores em cada etapa do processo de aprimoramento deste modelo econométrico, foram:

- ➔ M1→M2: O regressor (5) apresentava o pior resultado no teste de contribuição marginal e estava correlacionado moderadamente com (3), (4) e (7), que apresentavam melhor contribuição ao modelo. Além disso, o regressor (5) não apresentava correlação parcial negativa com o consumo, como era esperado.
- ➔ M2→M3: O regressor (4) apresentava menor contribuição marginal e estava correlacionado com (2), (3) e (6) que apresentavam melhor contribuição ao modelo.
- ➔ M3→M4: O regressor (3) apresentava o pior resultado no teste de contribuição marginal e não apresenta correlação parcial positiva com o consumo, como era esperado.
- ➔ M4→M5: Os regressores (6) e (8) apresentavam as menores contribuições marginais para o modelo. Porém, o regressor (8) foi preterido devido a sua não-estacionariedade, e por não apresentar nenhuma relação de precedência com o consumo, como o regressor (6).
- ➔ M5→M6: O regressor (6) apresentava a menor contribuição marginal para o modelo, bem inferior ao segundo pior regressor.
- ➔ M7 e M8 servem apenas para demonstrar que o desempenho do modelo segue piorando com a retirada de regressores significativos.

INTERPRETAÇÃO DO CONHECIMENTO

O modelo econométrico N° 6 representa o melhor conhecimento que se pôde extrair, com esta metodologia, sobre a variação do consumo de energia elétrica do segmento metalúrgico, na comparação com o mesmo mês do ano anterior. Com uso das variáveis IPCA, confiança da indústria, e exportação de autoveículos, foi possível explicar 55,5% do comportamento de $V12m_CEE_M$. Embora tal percentual não seja elevado, ressalta-se que a importância do modelo descritivo, nesta metodologia, está na significância do modelo econométrico. Após iniciar a pesquisa com 36 variáveis candidatas, obteve-se um modelo descritivo com 3 variáveis explicativas, de considerável significância e contribuição marginal. Para facilitar a interpretação do modelo, a equação de regressão (5.6) foi obtida com os valores medidos nas séries históricas. Por simplificação de grafia, os regressores não aparecem com seus prefixos de transformação ($V12m$ e $AC12m$) na equação.

$$V12m_CEE_M = -0,17 + 0,823IPCA + 0,316Confiança + 0,048Exp.Autoveículos \quad (5.6)$$

AJUSTAMENTO GRÁFICO – PREVISÃO DENTRO DA AMOSTRA

A partir dos valores estimados para o $V12m_CEE_M$ pelo modelo econométrico foram construídos dois gráficos na Figura 5.5. O primeiro apresenta os valores históricos ocorridos e os estimados pelo modelo. Considerando um intervalo de confiança de 95% foram traçados os valores mínimos e máximos estimados.

Tabela 5.10 – Interpretação do Modelo Descritivo do Consumo de Energia Elétrica - Metalúrgico.

Interpretação dos Coeficientes Parciais		
β_1	+0,823	Um crescimento de 10% no índice de preços ao consumidor amplo, medido pelo acumulado dos últimos 12 meses, teria o efeito de, após 10 meses, aumentar em 8,23% a variação do consumo de energia do segmento metalúrgico, medido na comparação com o mesmo mês do ano anterior.
β_2	+0,316	Um crescimento de 10% no indicador de confiança da indústria, medida na comparação com o mesmo mês do ano anterior, teria o efeito de, após 2 meses, aumentar em 3,16% a variação do consumo de energia do segmento metalúrgico, medido na comparação com o mesmo mês do ano anterior.
β_3	+0,048	Um crescimento de 10% na variação das exportações de autoveículos, medida na comparação com o mesmo mês do ano anterior, teria o efeito de aumentar em 0,48% a variação do consumo de energia do segmento metalúrgico, medido na comparação com o mesmo mês do ano anterior.

Fonte: Elaborado pelo Autor.

O segundo gráfico apresenta os valores históricos do CEE-M e os valores de consumo estimados a partir da estimação de V12m_CEE-M. Pode-se notar a complexidade do comportamento do consumo, bem como os erros percentuais absolutos ao longo dos 10 anos considerados.

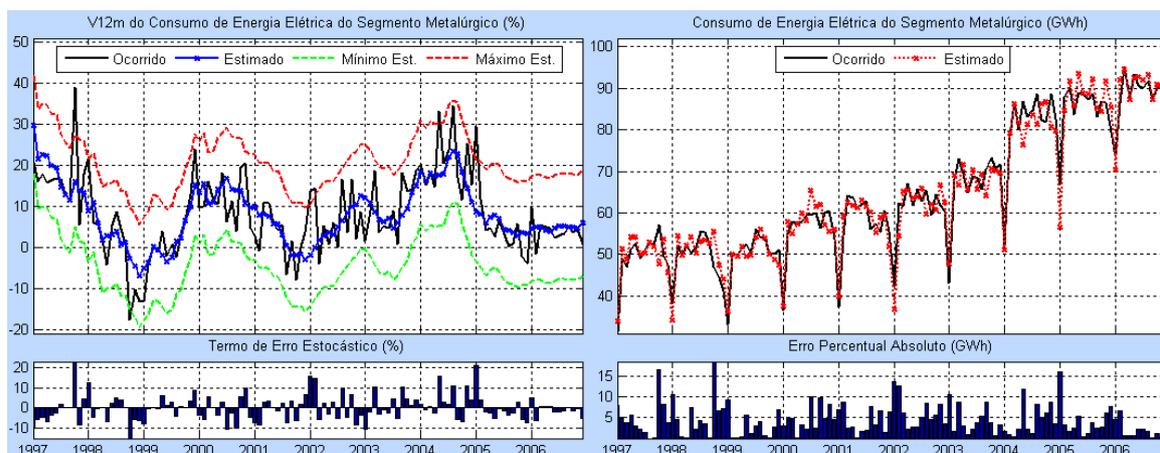


Figura 5.5 – Ajustamento Gráfico do Modelo Descritivo – V12m_CEE-M.

Fonte: Elaborado pelo Autor.

5.3.4 Descrição da Tendência do Consumo de Energia Elétrica- Metalúrgico

Conforme a Tabela 5.11, o modelo inicial para descrição da tendência do consumo de energia elétrica do segmento metalúrgico (M1) já se apresentava razoavelmente bem: com baixa multicolineariedade e com apenas 2 regressores não significativos. Porém, após novas interações, com diferentes composições de regressores, foram avaliados mais sete modelos (M2, M3, ... , M8). Os resultados dos testes de hipóteses e de avaliação de desempenho para escolha do melhor modelo econométrico são apresentados na Tabela 5.11.

Tabela 5.11 – Evolução do Modelo Descritivo da Tendência do Consumo de Energia Elétrica – Metalúrgico.

METALÚRGICO		V12m_TCEE = + 0,484 IPCA + 0,431 Confiança.Ind + 0,187 Folha_Ind + 0,169 Exp.Autos						Tendência de Consumo	
N	Série Histórica	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8
1	AC12m_IPCA	S-XcY-57	S-XcY-56	S-XcY-56	S-XcY-54	S-XcY-60	S-XcY-69	S-XcY-77	S-XcY-63
2	V12m_Conf.Ind	S-BC-52	S-BC-52	S-BC-57	S-BC-56	S-BC-57	S-BC-59	S-BC-68	
3	V12m_PIB.BR	NS-YcX-2							
4	V12m_Prod.Autoveículos	NS-YcX-3	NS-YcX-2						
5	V12m_TJLP	S-XcY-8	S-XcY-9	S-XcY-7					
6	V12m_FolhaInd	S-YcX-11	S-YcX-9	S-YcX-18	S-YcX-16	S-YcX-16	S-YcX-14		
7	V12m_Exp. Autoveículos	S-YcX-7	S-YcX-7	S-YcX-11	S-YcX-10	S-YcX-15			
8	AC12m_Inv.Estrangeiro	S-BC-10	S-BC-8	S-BC-6	S-BC-2				
Multicolinearidade (IC)		fraca (5,9)	fraca (5,6)	fraca (4,6)	fraca (4,0)	fraca (3,3)	fraca (2,8)	fraca (2,3)	inexistente
R2		0.873	0.871	0.868	0.859	0.857	0.835	0.812	0.541
R2 Ajustado		0.864	0.863	0.861	0.853	0.852	0.831	0.808	0.537
Akaike		6.237	6.256	6.273	6.606	6.588	7.448	8.379	20.096
Schwarz		7.687	7.534	7.381	7.594	7.399	8.174	8.983	21.051
MAPE		1.812	1.857	1.855	1.933	1.943	2.054	2.193	3.278

Fonte: Elaborado pelo Autor.

Resumidamente, as razões que conduziram a escolha dos regressores em cada etapa do processo de aprimoramento deste modelo econométrico, foram:

- ➔ M1→M2: O regressor (3) apresentava o pior resultado no teste de contribuição marginal e estava correlacionado moderadamente com (2), (4) e (5), que apresentavam melhor contribuição ao modelo.
- ➔ M2→M3: O regressor (4) apresentava o pior resultado no teste de contribuição marginal e estava correlacionado moderadamente com (2), (5) e (6), que apresentavam melhor contribuição ao modelo.
- ➔ M3→M4: Os regressores (5) e (8) apresentavam as menores contribuições marginais para o modelo além de serem moderadamente correlacionados. Porém, o (5) não apresentava correlação parcial negativa com o consumo, como era esperado.
- ➔ M4→M5: O regressor (8) apresentava o pior resultado no teste de contribuição marginal e com o agravante da não-estacionariedade.
- ➔ M5→M6: Os regressores (6) e (7) apresentavam as menores contribuições marginais para o modelo. Porém, (6) apresenta precedência temporal para (7) (95% d=2 F=3,36).
- ➔ M7 e M8: Servem apenas para demonstrar que o desempenho do modelo segue piorando com a retirada de regressores significativos.

INTERPRETAÇÃO DO CONHECIMENTO

O modelo econométrico N° 5 representa o melhor conhecimento que se pôde extrair, com esta metodologia, sobre a variação da tendência do consumo de energia elétrica do segmento metalúrgico, na comparação com o mesmo mês do ano anterior. Com uso das variáveis IPCA, confiança da indústria, folha de pagamento da indústria, e exportação de autoveículos, foi possível explicar

85,7% do comportamento de $V12m_TCEE-M$. Após iniciar a pesquisa com 36 variáveis candidatas, obteve-se um modelo descritivo com apenas 4 variáveis explicativas, de alta significância e contribuição marginal. Para facilitar a interpretação do modelo, a equação de regressão (5.7) foi obtida com os valores medidos nas séries históricas. Por simplificação de grafia, os regressores não aparecem com seus prefixos de transformação ($V12m$ e $AC12m$) na equação.

$$V12m_TCEE_M = -0,084 + 0,764IPCA + 0,198Conf + 0,171Folha.Ind + 0,024Exp.Autovs \quad (5.7)$$

Tabela 5.12 – Interpretação do Modelo Descritivo da Tendência do Consumo de Energia Elétrica - Metalúrgico.

Interpretação dos Coeficientes Parciais		
β_1	+0,764	Um crescimento de 10% no índice de preços ao consumidor amplo, medido pelo acumulado dos últimos 12 meses, teria o efeito de, após 11 meses, aumentar em 7,64% a variação da tendência do consumo de energia do segmento metalúrgico, medido na comparação com o mesmo mês do ano anterior.
β_2	+0,198	Um crescimento de 10% no indicador de confiança da indústria, medida na comparação com o mesmo mês do ano anterior, teria o efeito de, após 3 meses, aumentar em 1,98% a variação da tendência do consumo de energia do segmento metalúrgico, medido na comparação com o mesmo mês do ano anterior.
β_3	+0,171	Um crescimento de 10% na “renda”, representada pela folha de pagamento da indústria e medida na comparação com o mesmo mês do ano anterior, teria o efeito de aumentar em 1,71% a variação da tendência do consumo de energia do segmento metalúrgico, medido na comparação com o mesmo mês do ano anterior.
β_4	+0,024	Um crescimento de 10% na variação das exportações de autoveículos, medida na comparação com o mesmo mês do ano anterior, teria o efeito de aumentar em 0,24% a variação da tendência do consumo de energia do segmento metalúrgico, medido na comparação com o mesmo mês do ano anterior.

Fonte: Elaborado pelo Autor.

AJUSTAMENTO GRÁFICO – PREVISÃO DENTRO DA AMOSTRA

A partir dos valores estimados para o $V12m_TCEE-M$ pelo modelo econométrico foram construídos dois gráficos na Figura 5.6. O primeiro apresenta os valores históricos ocorridos e os estimados pelo modelo. Considerando um intervalo de confiança de 95% foram traçados os valores mínimos e máximos estimados. O segundo gráfico apresenta os valores históricos do CEE-M e os valores de consumo estimados a partir da estimação de $V12m_CEE-M$. Pode-se notar novamente que comportamento da tendência do consumo é bem mais suave que do consumo efetivo. Com isso, em comparação com a Figura 5.4, houve um estreitamento das bandas de estimação e uma redução dos termos de erro dos gráficos.

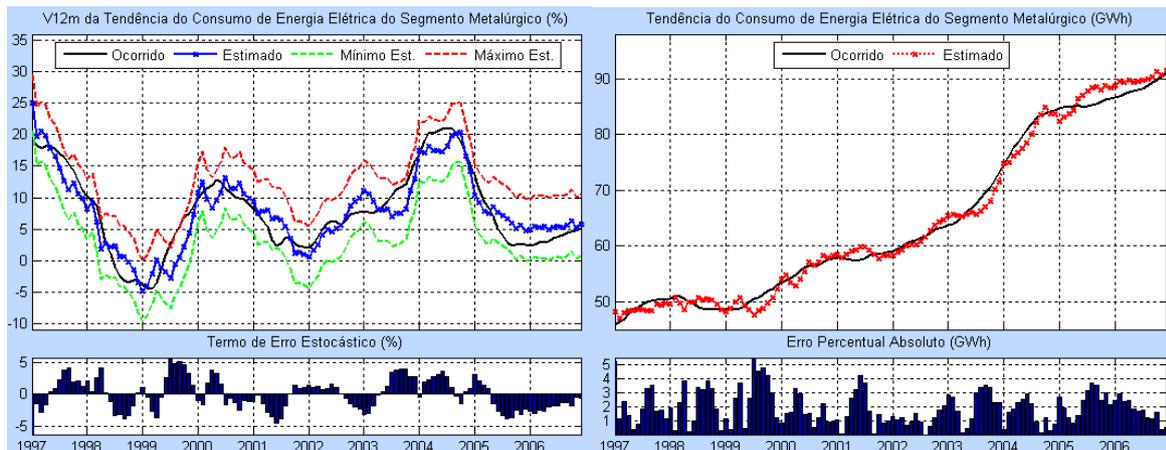


Figura 5.6 - Ajustamento Gráfico do Modelo Descritivo – V12m_TCEE-M.

Fonte: Elaborado pelo Autor.

5.4 RESUMO DO CAPÍTULO

O Capítulo 5 apresentou as etapas para o desenvolvimento e aplicação do modelo de descrição da demanda dos consumidores industriais de energia elétrica. A partir da base de dados construída no Capítulo 4 foi possível inferir quais as variáveis econômicas e climáticas de maior influência para o consumo de energia elétrica dos segmentos têxtil e metalúrgico de Santa Catarina.

Para o correto desenvolvimento do modelo econométrico, foram realizadas algumas transformações nas séries históricas, relacionadas ao consumo e à economia, para torná-las estacionárias. Por meio do cálculo do coeficiente de correlação linear de Pearson foi possível classificar um grupo de variáveis candidatas, cerca de 5 vezes menor que o número de variáveis iniciais dos modelos econométricos. Com as melhores variáveis selecionadas para cada segmento da indústria, foram construídos e aprimorados modelos de descrição para a indústria têxtil e para a indústria metalúrgica. Nessa etapa, os modelos descritivos de cada segmento, foram avaliados desde a estimação dos parâmetros, passando pelos testes de hipóteses e avaliação do desempenho, até a obtenção do modelo final. A interpretação das equações de regressão múltipla permitiu conhecer melhor o grau de influência de cada regressor sobre a variação da demanda e, além disso, revelou interessantes defasagens existentes entre as variações do consumo nos segmentos industriais em relação à economia e ao clima (AMMCs de até 11 meses).

Geralmente, o efeito da variação de indicadores econômicos e climáticos na dinâmica das indústrias pode ocorrer de forma gradativa e numa frequência mais baixa de tempo. Para ajudar a descrever o comportamento da demanda, foram elaborados modelos econométricos para a tendência do consumo de energia elétrica. A tendência, uma curva mais suavizada, apresentou correlações importantes para as variáveis consideradas, tanto no segmento metalúrgico como no têxtil.

CAPÍTULO 6

Previsão da Demanda

6.1 INTRODUÇÃO

A aplicação do modelo proposto para a previsão do consumo de energia elétrica às séries históricas dos segmentos têxtil e metalúrgico da indústria catarinense encerra a última etapa deste trabalho. A descoberta de conhecimento novo e útil sobre o comportamento da demanda dessas indústrias foi delineada até aqui pela realização de uma pesquisa de campo, por uma ampla e cuidadosa etapa de pré-processamento e mineração de dados, e pelo uso da econometria na determinação das variáveis econômicas e climáticas de maior influência.

Conforme a revisão da literatura, apresentada no Capítulo 2, nos últimos 20 anos a aplicação de técnicas de inteligência artificial – IA, em especial o uso de redes neurais artificiais (RNAs), para solução dos problemas de previsão da demanda conquistou um enorme espaço não apenas no setor energético, mas nas mais diversas áreas do conhecimento. Por esse motivo, a etapa de previsão da demanda, que poderia ser realizada com o uso de métodos econométricos, foi reservada para a solução com uso de redes neurais artificiais. Entretanto, acredita-se que a qualidade dos resultados de previsão obtidos, bem como o menor tempo necessário para a construção das RNAs, deveu-

se à aplicação prévia de um modelo econométrico. A descoberta das correlações de maior influência com a demanda, embora elas fossem de natureza linear, permitiu uma grande redução do número de variáveis explicativas a serem usadas nas camadas de entrada das redes neurais. Com a concentração das melhores informações disponíveis em poucas séries históricas, a tarefa de configuração das RNAs, ainda que tenha sido cuidadosamente desenvolvida, foi bastante facilitada.

No desenvolvimento deste capítulo foram implementadas RNAs de dois tipos: MLP e RBF. Como apresentado na Seção 3.4, ambas as tipologias são utilizadas na literatura como aproximadores de funções, capazes de mapear o efeito das variáveis econômicas e climáticas sobre o comportamento da demanda no período de treinamento e generalizar suas saídas para os meses à frente (simulação). Porém, com o objetivo de proporcionar maior aplicabilidade prática ao modelo preditivo, apresenta-se, além da tradicional previsão de consumo mensal, a previsão da faixa de consumo mensal de energia elétrica. Essa abordagem peculiar, quando se faz uso de técnicas de IA, permite aos gestores de planejamento das distribuidoras/comercializadoras de energia elétrica estabelecer cenários de menor e maior consumo esperado do segmento industrial.

O presente capítulo foi organizado em quatro seções. Após a introdução, na Seção 6.2 são apresentados os resultados de previsão do consumo mensal de energia elétrica para os horizontes de 1, 3, 6 e 12 meses à frente, dos segmentos têxtil e metalúrgico de Santa Catarina. A Seção 6.3 apresenta os resultados da previsão da faixa de consumo mensal de energia elétrica para os mesmos segmentos industriais, nos horizontes de 1 e 12 meses à frente. Finalmente, a Seção 6.4 apresenta as considerações finais sobre o capítulo.

6.2 PREVISÃO DO CONSUMO MENSAL DE ENERGIA ELÉTRICA

O processo de construção de redes neurais artificiais com o propósito de prever o comportamento futuro do consumo de energia elétrica depende essencialmente dos objetivos da previsão e da quantidade e qualidade dos dados disponíveis. Assim como na aplicação do modelo de descrição da demanda, todas as séries históricas das bases de dados primárias foram disponibilizadas para o modelo preditivo. Porém, com o conhecimento gerado no capítulo anterior, pôde-se qualificar a seleção das variáveis a serem testadas nas RNAs conforme suas performances no modelo econométrico descritivo.

Por outro lado, a quantidade de dados disponíveis em cada série histórica estava limitada a no máximo 132 meses, com o consumo mensal de energia elétrica (CEE) de janeiro de 1996 a dezembro de 2006. Como no modelo econométrico, a variável a ser prevista, diretamente⁵⁴, é a varia-

⁵⁴ Uma vez prevista a V12m_CEE, prevê-se indiretamente o consumo de energia elétrica (CEE).

ção do consumo de energia elétrica em relação ao mesmo mês do ano anterior⁵⁵ (V12m_CEE), o conjunto de dados de treinamento deveria iniciar em janeiro de 1997. Entretanto, os melhores resultados de previsão foram obtidos com a inclusão da V12m_CEE, atrasada 12 meses em relação ao mês do horizonte de previsão, na camada de entrada das RNAs. Assim, o primeiro mês para treinamento do modelo preditivo, que permitia a utilização do V12m_CEE com 12 meses de atraso, era janeiro de 1998. Com 108 meses disponíveis, optou-se pelo particionamento de treinamento e simulação das redes em 84 e 24 meses respectivamente. A Figura 6.1 ilustra as partições das séries históricas, onde: os anos de 1996 e 1997 servem para defasar as variáveis de entrada, os anos de 1998 a 2004 são utilizados para o treinamento, e os anos de 2005 e 2006 são os anos de simulação.

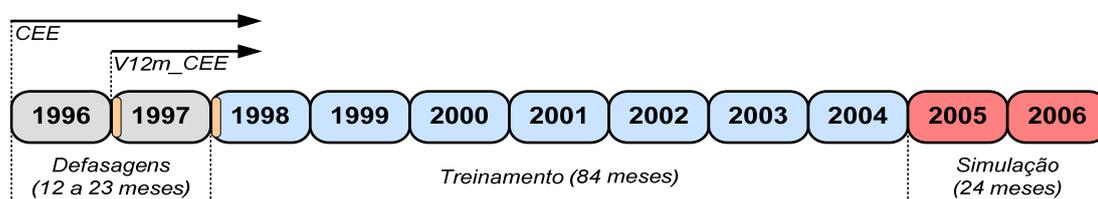


Figura 6.1 – Particionamento das Séries Históricas para Aplicação nas RNAs.

Fonte: Elaborado pelo Autor.

A qualidade dos resultados do modelo preditivo tende a diminuir à medida que o horizonte de previsão avança nos meses futuros. Para não estender em demasia a apresentação dos resultados do capítulo, foram construídas 4 RNAs para cada segmento industrial com horizontes de previsão de 1, 3, 6 e 12 meses à frente. Nas Tabela 6.1 e 6.2, ao final da subseção, pode-se verificar o desempenho das previsões para cada um dos horizontes citados.

A Figura 6.2 apresenta um fluxograma com as etapas realizadas para construção de redes neurais artificiais para previsão do consumo de energia elétrica. Todos os procedimentos foram implementados com auxílio do programa computacional *Matlab* (*Neural Network Toolbox*).

⁵⁵ Face aos resultados obtidos para a previsão do consumo de energia elétrica, foi dispensada a previsão da curva suavizada de tendência do consumo (V12m_TCEE).

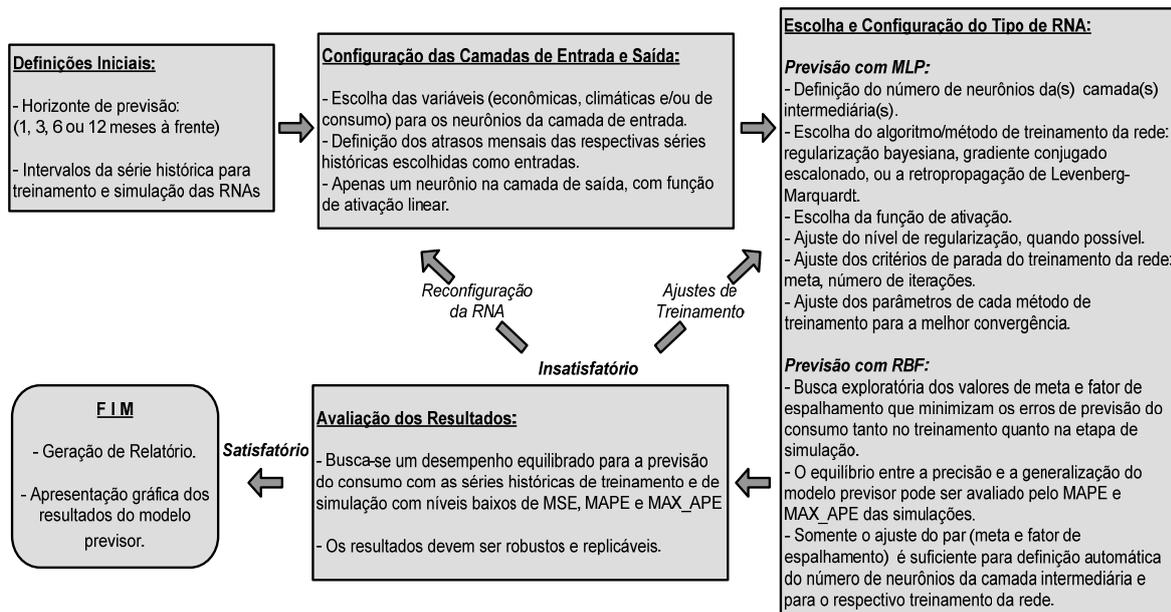


Figura 6.2 – Fluxograma da Construção de RNAs para Previsão do Consumo.

Fonte: Elaborado pelo autor.

APRENDIZADO X ABSTRAÇÃO

Uma questão em especial foi determinante para a configuração dos modelos previsores: a busca do equilíbrio entre o aprendizado e a capacidade de abstração das RNAs. Com a impossibilidade de aumentar o conjunto de dados disponíveis, proveu-se maior generalização com a aplicação de técnicas de treinamento supervisionado. Conforme as opções apresentadas na Seção 3.4.2, cada tipo de RNA foi regularizada durante sua configuração. As MLPs apresentaram os melhores resultados quando treinadas pelo método de regularização bayesiana. Já as RBFs necessitaram de um processo de ajustamento de metas e do fator de espalhamento conforme os objetivos da previsão.

Em suma, o modo de atuação da regularização é interromper o aprendizado da rede antes que a mesma fique “sobretreinada”, mas em tempo para que ela possa abstrair conhecimento suficiente para aplicação da previsão com dados desconhecidos. A Figura 6.3 exemplifica esta questão com resultados ruins de previsão do consumo do segmento têxtil para um mês à frente. Foi utilizada uma MLP treinada com algoritmo de Levenberg-Marquardt livre de regularização. Pode-se observar que os resultados de previsão na região de simulação são muito inferiores aqueles obtidos pela rede durante o treinamento.

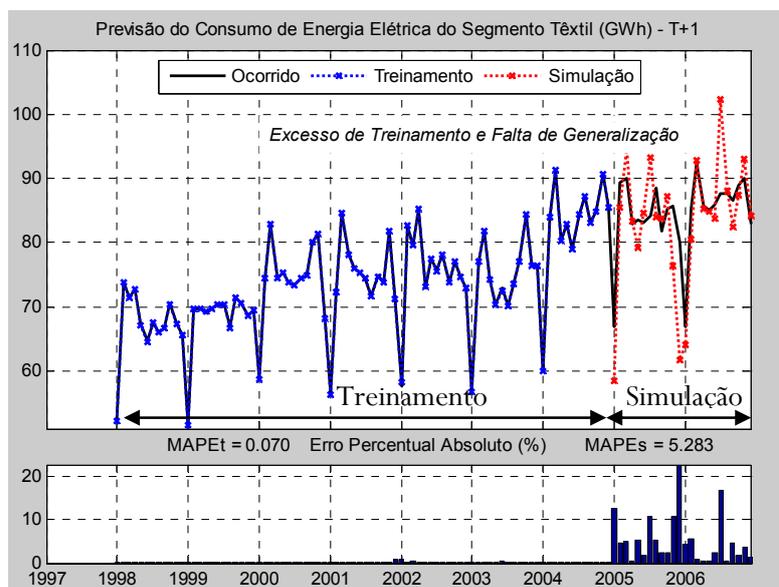


Figura 6.3 – Resultados de Previsão com a MLP “Sobretreinada”.

Fonte: Elaborado pelo Autor.

APRESENTAÇÃO DOS RESULTADOS

Com o intuito de facilitar o entendimento de cada um dos previsores pesquisados, optou-se pela utilização de um conjunto padronizado dos resultados. Inicialmente, apresenta-se a arquitetura da RNA com sua configuração, e em seguida os gráficos com o desempenho obtido para previsão.

A arquitetura básica das redes revela: i) quais variáveis foram utilizadas na camada de entrada e suas respectivas defasagens; ii) o número de neurônios da camada intermediária – NNCI⁵⁶; iii) o horizonte de previsão para a variável da camada de saída. Além disso, os neurônios são representados simbolicamente de acordo com as funções por eles desempenhadas:

- ① ... ② → representação sequencial dos neurônios da camada de entrada.
- ⊖ → representação do neurônio com função de base radial da RBF.
- ⊕ → representação do modelo geral de neurônio da MLP.
- ⊘ → representação do neurônio da camada de saída com função de ativação linear.

Além da normalização das séries históricas utilizadas, por meio da média e do desvio padrão, tanto as MLPs quanto as RBFs implementadas apresentaram algumas configurações fixas em todos os modelos de previsão:

⁵⁶ Todas as redes neurais foram construídas com apenas uma única camada intermediária.

- MLP: treinamento supervisionado pelo algoritmo de regularização bayesiana (“trainbr”), com valores padronizados da função no *Matlab*, e função de ativação de tangente hiperbólica (“tansig”).
- RBF: procedimento padrão para construção de redes com função de base radial do Matlab (“newRB”) seguido da otimização da meta e do fator de espalhamento.

Cada modelo de previsão foi identificado com a seguinte nomenclatura: tipo de rede (MLP ou RBF), tipo de previsão (C – consumo | F – faixa de consumo), segmento da indústria (T – têxtil | M – metalúrgico) e o horizonte de previsão em meses. Por exemplo, o modelo MLP_CT6 representa o previsor do consumo de segmento têxtil para o sexto mês à frente obtido com uma rede MLP.

O desempenho dos modelos construídos pode ser verificado nos gráficos de previsão da variação do consumo e do consumo efetivo (CEE), ao longo do treinamento e da simulação das RNAs. Os gráficos são acompanhados de medidas tradicionais de precisão das previsões: para V12m_CEE foi calculado o MSE (*mean square error*) e para o CEE foram calculados: o MAPE (*mean absolute percentual error*), e o MAX_APE (*maximum absolute percentual error*). Nos dois casos houve uma separação dos períodos de treinamento e simulação.

6.2.1 Resultados para o Segmento Têxtil

O resultado final do modelo descritivo do segmento têxtil permitiu explicar quase 50% do comportamento do consumo de energia elétrica, conforme a Tabela 5.5. Na oportunidade, apenas as relações lineares existentes entre três variáveis econômicas (taxa Selic, exportações de produtos têxteis, e arrecadação do ICMS) e uma climática (intensidade térmica das mínimas) foram consideradas. Praticamente as mesmas variáveis da descrição, acrescidas da confiança e do emprego formal da indústria, foram suficientes para obtenção dos modelos de previsão da demanda.

PREVISÃO DO CONSUMO PARA O MÊS SEGUINTE (T+1)

Para construção deste modelo predictor foram utilizadas quatro variáveis econômicas e uma climática, propositadamente defasadas conforme os atrasos mensais de máxima correlação (AMMC). Entretanto, foi possível aprimorar ainda mais os resultados com a inclusão, na camada de entrada da MLP, da V12m_CEE do mês alvo da previsão, porém do ano anterior (t-1). A Figura 6.4 apresenta a arquitetura final do predictor MLP_CT1.

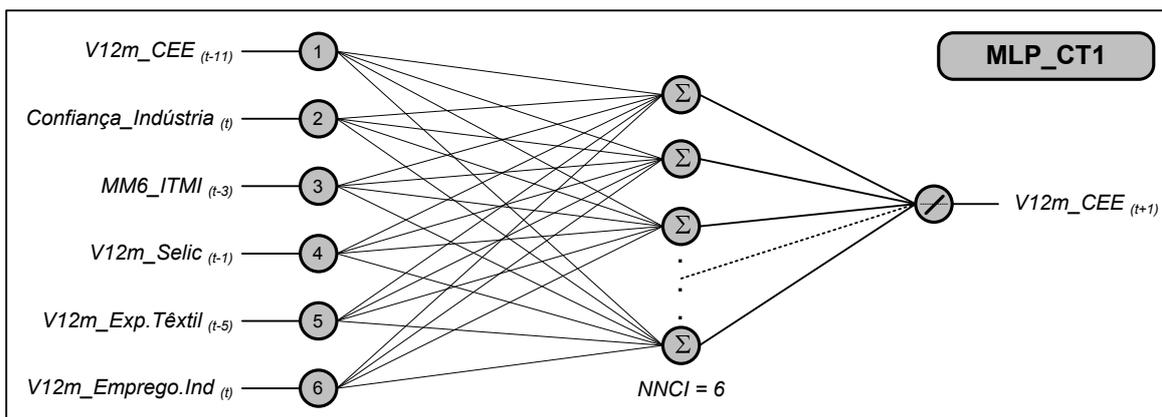


Figura 6.4 – Arquitetura do Modelo Predictor do Consumo do Segmento Têxtil (T+1).

Fonte: Elaborado pelo Autor.

Após o treinamento supervisionado, este modelo com seis neurônios na camada intermediária apresentou o melhor resultado de previsão deste trabalho. Com um conjunto de variáveis de entrada mais significativo que aquele utilizado no segmento metalúrgico, devido a inclusão do clima, e um horizonte de previsão mais curto (T+1), tal desempenho relativo para o MLP_CT1 já era esperado. Na Figura 6.5 pode-se observar que apenas 3 dos 24 meses de previsão da simulação apresentaram erros absolutos um pouco acima de 5%. Todos os demais períodos apresentaram erros absolutos abaixo de 2%.

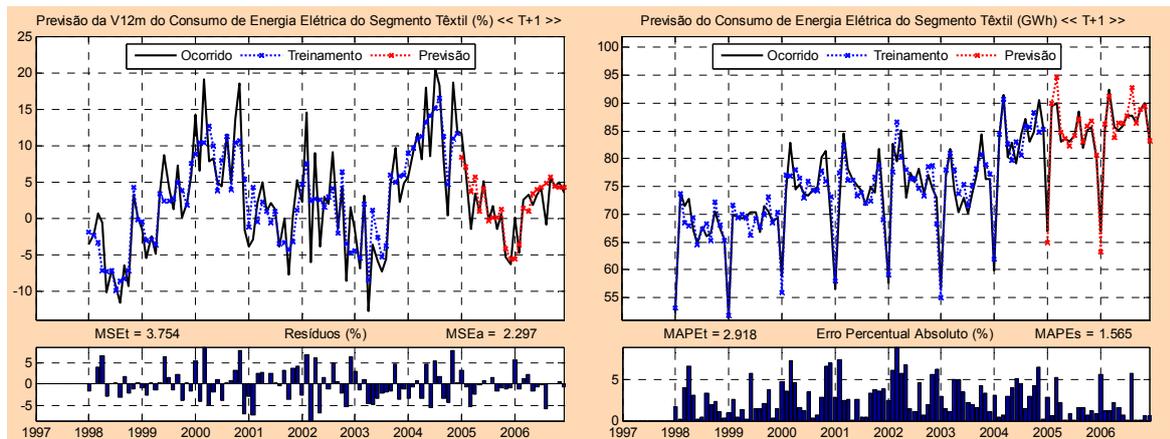


Figura 6.5 – Desempenho do Modelo Predictor do Consumo do Segmento Têxtil (T+1).

Fonte: Elaborado pelo Autor.

PREVISÃO DO CONSUMO PARA O TERCEIRO MÊS À FRENTE (T+3)

O modelo predictor para o terceiro mês à frente segue praticamente a mesma arquitetura da previsão do mês seguinte. Os resultados foram obtidos apenas com o ajuste nos defasamentos das variáveis com maiores atrasos mensais, para atender as necessidades do novo horizonte de previsão. A Figura 6.6 apresenta a arquitetura final do predictor MLP_CT3.

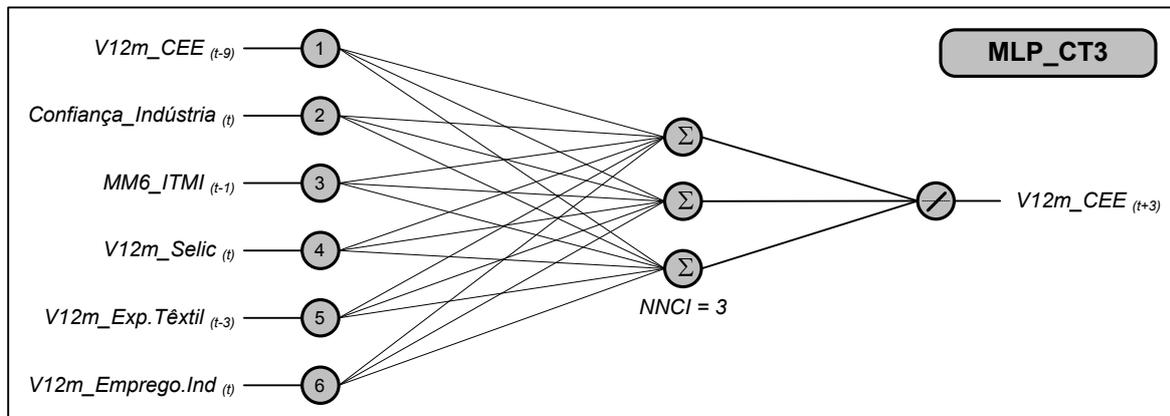


Figura 6.6 – Arquitetura do Modelo Predictor do Consumo do Segmento Têxtil (T+3).

Fonte: Elaborado pelo Autor.

Durante a elaboração deste modelo verificou-se que apenas três neurônios na camada intermediária seriam suficientes para obter a melhor generalização da MLP. Mesmo com o aumento do horizonte de previsão, o MLP_CT3 apresentou resultados muito próximos quando comparados ao modelo anterior. Na Figura 6.7 pode-se observar que apenas os mesmos meses atípicos apresentaram erros absolutos de previsão do consumo próximos a 5%. Nos demais períodos da previsão os erros absolutos permaneceram abaixo de 2,5%.

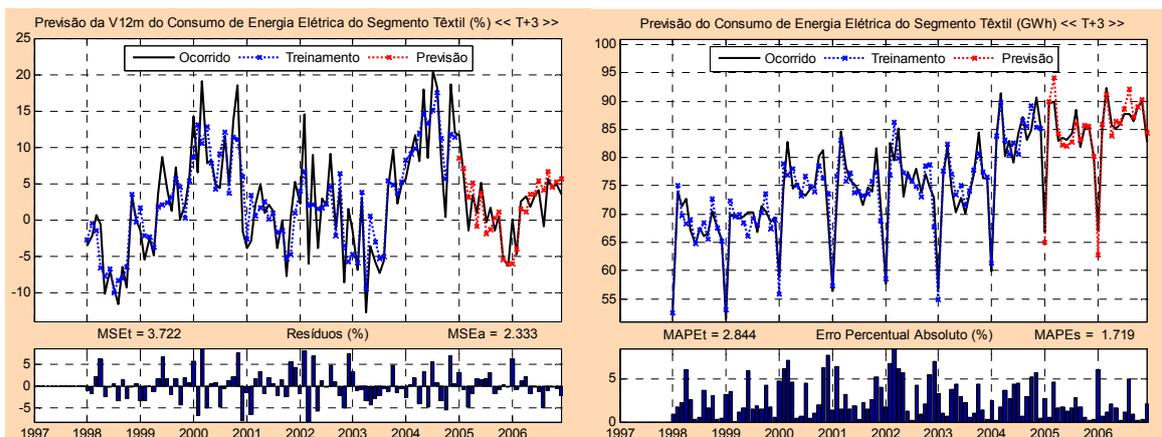


Figura 6.7 – Desempenho do Modelo Predictor do Consumo do Segmento Têxtil (T+3).

Fonte: Elaborado pelo Autor.

PREVISÃO DO CONSUMO PARA O SEXTO MÊS À FRENTE (T+6)

Após testar várias configurações, a melhor previsão para o sexto mês à frente foi obtida com a exclusão da série histórica do emprego formal na indústria da camada de entrada da MLP. Com o horizonte de previsão maior ou igual a seis meses, não foi possível defasar qualquer das variáveis econômicas ou climáticas. Apenas a série de exportações do produto têxtil ($AMMC = 6$) ainda manteve um elevado efeito de correlação linear com o consumo no mês alvo da previsão. A Figura 6.8 apresenta a arquitetura final do predictor MLP_CT6.

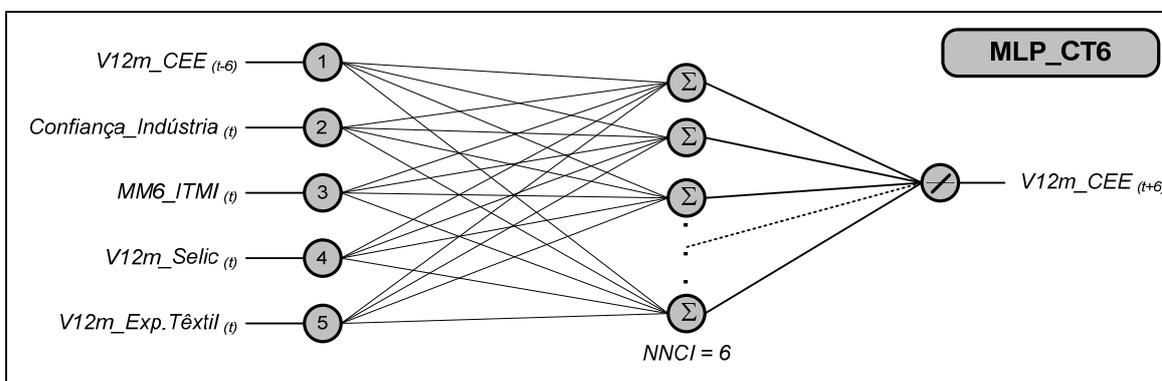


Figura 6.8 – Arquitetura do Modelo Predictor do Consumo do Segmento Têxtil (T+6).

Fonte: Elaborado pelo Autor.

Devido à capacidade de aprendizado e abstração do conhecimento das RNAs foi possível obter resultados de previsão do consumo de energia do segmento têxtil muito significativos mesmo para meio ano à frente. Verificou-se que com seis neurônios na camada intermediária obter-se-ia uma boa generalização da MLP. Na Figura 6.9 pode-se observar que um número maior de meses apresentou erros absolutos de previsão do consumo próximos a 5%.

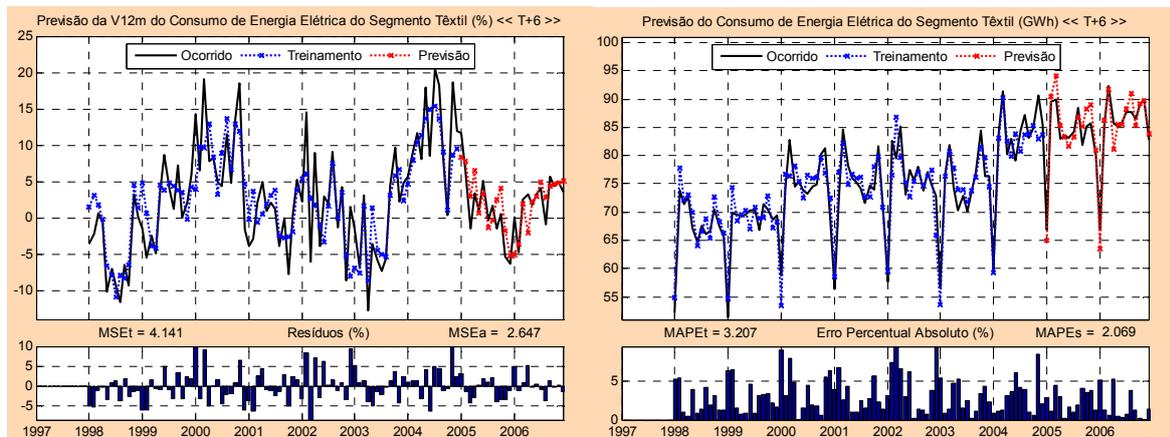


Figura 6.9 – Desempenho do Modelo Predictor do Consumo do Segmento Têxtil (T+6).

Fonte: Elaborado pelo Autor.

PREVISÃO DO CONSUMO PARA UM ANO À FRENTE (T+12)

A ampliação do conjunto de variáveis econômicas, na camada de entrada da MLP, foi a solução encontrada para proporcionar maior capacidade de abstração ao modelo de previsão no horizonte de tempo mais elevado. Além disso, as três variáveis com maiores atrasos mensais foram replicadas na camada de entrada para permitir a rerepresentação das relações de precedência temporal existentes entre elas e a variação do consumo atual, $V12m_CEE(t)$. A Figura 6.10 apresenta a arquitetura final do predictor MLP_CT12.

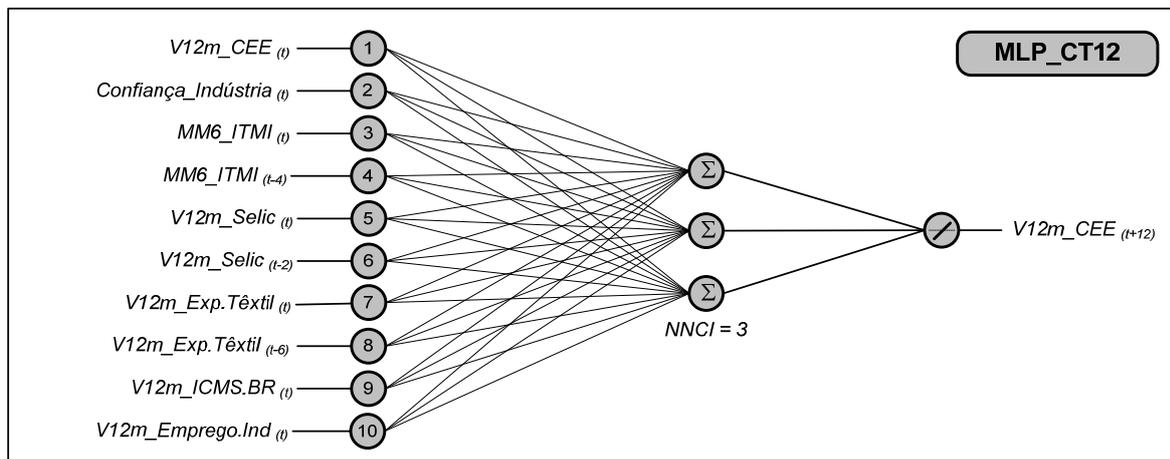


Figura 6.10 – Arquitetura do Modelo Predictor do Consumo do Segmento Têxtil (T+12).

Fonte: Elaborado pelo Autor.

Em virtude do maior número de neurônios na camada de entrada, o treinamento da MLP fica mais susceptível à elevação do nível de aprendizado em detrimento da capacidade de abstração. Mesmo com uso da regularização bayesiana para melhoria da generalização, apenas com 3 neurônios na camada intermediária que se pode obter bons resultados de previsão do consumo para

o décimo segundo mês à frente. Na Figura 6.11 pode-se observar um desempenho significativo e equilibrado do modelo predictor tanto no intervalo de treinamento quanto no intervalo de simulação.

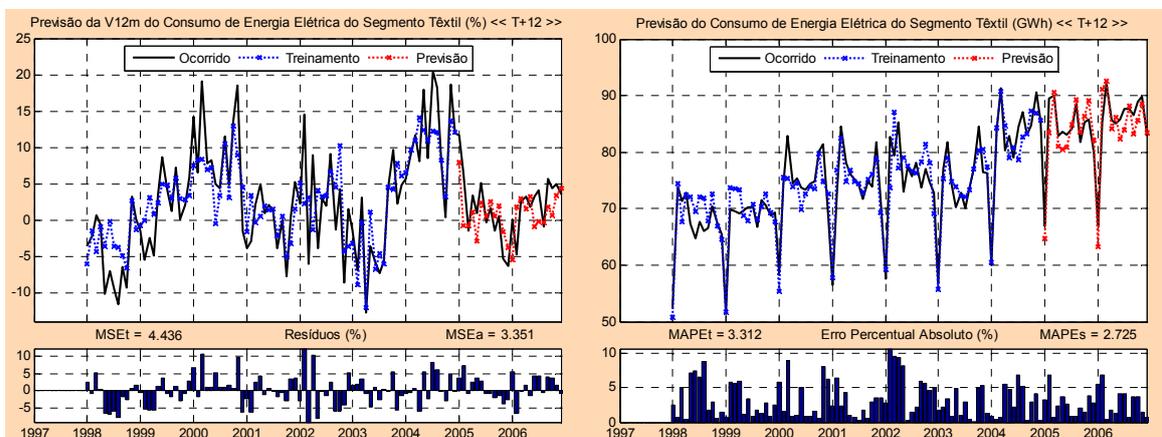


Figura 6.11 – Desempenho do Modelo Predictor do Consumo do Segmento Têxtil (T+12).

Fonte: Elaborado pelo Autor.

A Tabela 6.1 apresenta um resumo do desempenho dos modelos de previsão do consumo de energia elétrica do segmento têxtil. Pode-se notar que, apesar da diminuição da precisão com o aumento do horizonte de previsão, todos os modelos apresentam resultados significativos.

Tabela 6.1 – Resumo do Desempenho dos Modelos de Previsão do Consumo de Energia Elétrica - Têxtil.

Horizonte	MSE _t	MSE _s	MAPE _t	MAX_APE _t	MAPE _s	MAX_APE _s
T+1	3.75	2.30	2.92	8.95	1.57	5.75
T+3	3.72	2.33	2.84	8.54	1.72	6.10
T+6	4.14	2.65	3.21	9.42	2.07	5.19
T+12	4.43	3.35	3.31	10.73	2.73	6.87

Fonte: Elaborado pelo Autor.

6.2.2 Resultados para o Segmento Metalúrgico

O resultado final do modelo descritivo do segmento metalúrgico permitiu explicar cerca de 55% do comportamento do consumo de energia elétrica, conforme a Tabela 5.9. Na oportunidade, apenas as relações lineares existentes entre três variáveis econômicas (IPCA, confiança da indústria e a exportação de automóveis) foram consideradas. Entretanto, para obtenção dos modelos preditivos deste segmento, todas as 8 variáveis candidatas do modelo de descrição foram utilizadas nas entradas das RNAs. Conforme o horizonte de previsão, algumas dessas variáveis candidatas eram dispensadas.

PREVISÃO DO CONSUMO PARA O MÊS SEGUINTE (T+1)

Para construção deste modelo predictor foram utilizadas quatro variáveis econômicas, propositalmente defasadas conforme os atrasos mensais de máxima correlação (AMMC), mais a V12m_CEE do mês alvo da previsão referenciada ao ano anterior (t-11). Porém, os testes realizados com redes de função de base radial apresentaram resultados superiores aos obtidos na modelagem com percéptrons de múltiplas camadas. A Figura 6.12 apresenta a arquitetura final do predictor RBF_CM1 obtida após o ajuste dos parâmetros de meta e spread. Ressalta-se que a definição do número de neurônios na camada intermediária é obtida automaticamente no momento da criação da RBF pela função *newRB* do *Matlab*.

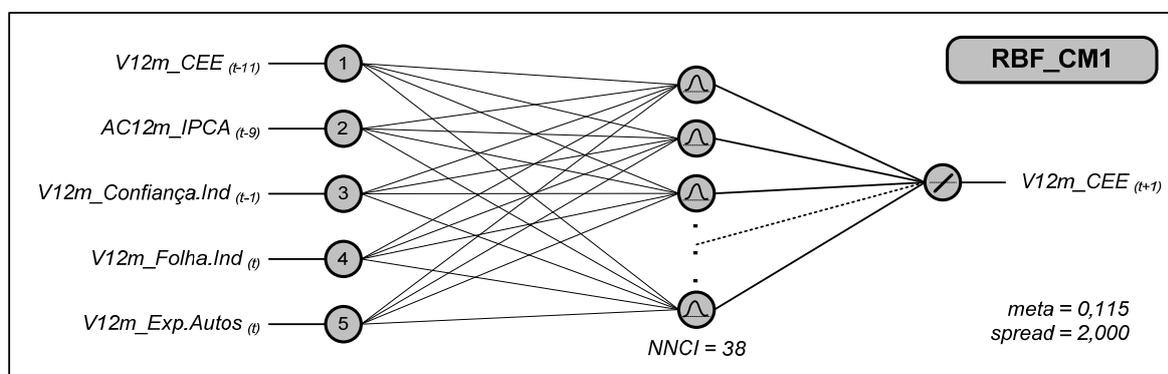


Figura 6.12 – Arquitetura do Modelo Predictor do Consumo do Segmento Metalúrgico (T+1).

Fonte: Elaborado pelo Autor.

O conjunto de variáveis de entrada deste modelo é formado pelas mesmas variáveis do melhor modelo econométrico obtido no capítulo anterior acrescido da V12m da folha de pagamento da indústria (renda). Embora este e os demais modelos predictors da metalurgia apresentem desempenhos significativos, eles são sistematicamente inferiores aqueles obtidos para o segmento têxtil. Um dos fatores que poderia justificar esta diferença é a mudança brusca do padrão de crescimento do consumo de energia elétrica da metalurgia entre 2004 e 2005, fronteira entre o treinamento e a simulação. Na Figura 6.13 pode-se observar que a maioria dos meses de previsão apresentou erros absolutos abaixo de 2,5% com picos em torno de 5,0%.

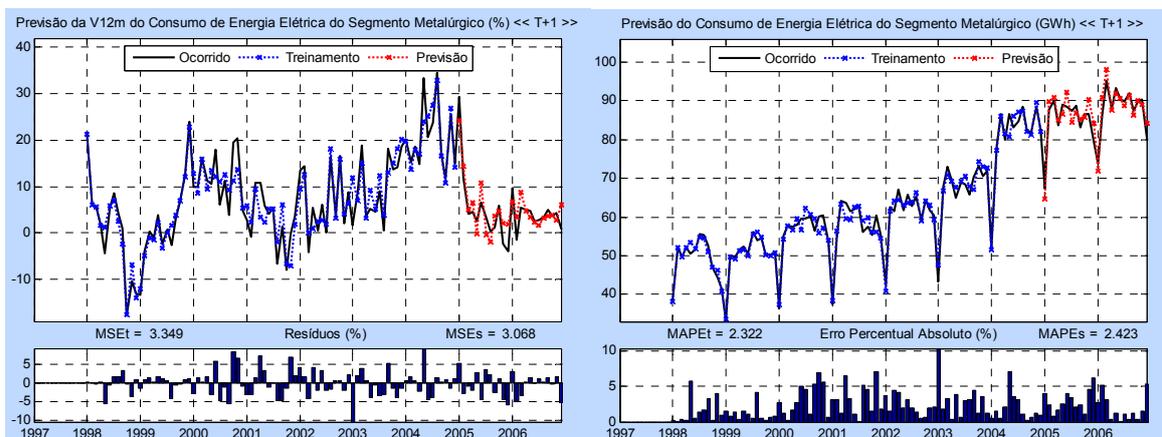


Figura 6.13 – Desempenho do Modelo Previsor do Consumo do Segmento Metalúrgico (T+1).

Fonte: Elaborado pelo Autor.

PREVISÃO DO CONSUMO PARA O TERCEIRO MÊS À FRENTE (T+3)

O modelo previsor para o terceiro mês à frente apresenta o mesmo conjunto de variáveis de entrada do modelo previsor do mês seguinte, porém com o uso de uma MLP. Também foram realizados ajustes nos defasamentos das variáveis com maiores atrasos mensais, para atender as necessidades do novo horizonte de previsão. A Figura 6.14 apresenta a arquitetura final do previsor MLP_CM3.

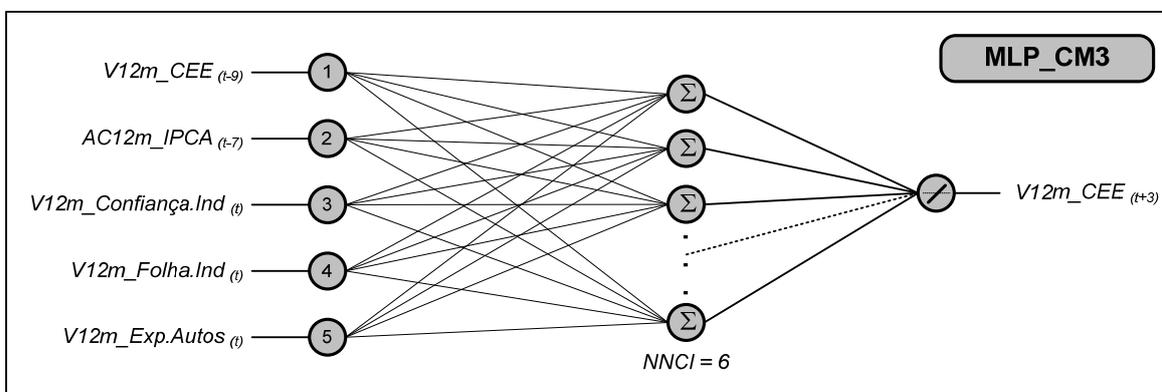


Figura 6.14 – Arquitetura do Modelo Previsor do Consumo do Segmento Metalúrgico (T+3).

Fonte: Elaborado pelo Autor.

Durante a elaboração deste modelo verificou-se que seis neurônios na camada intermediária seriam suficientes para obter a melhor generalização da MLP. Mesmo com o aumento do horizonte de previsão, o MLP_CM3 apresentou resultados próximos quando comparados ao modelo anterior. Na Figura 6.15 pode-se observar que 5 dos 24 meses da região de simulação apresentaram erros absolutos de previsão do consumo acima de 5%. Nos demais períodos da previsão os erros absolutos permaneceram abaixo de 2,5%. O mês de janeiro de 2005 é um exemplo clássico de “ponto fora da curva”, pois a redução do consumo, efeito na concentração de férias coletivas da indústria, foi bem menor que nos outros janeiros da série histórica.

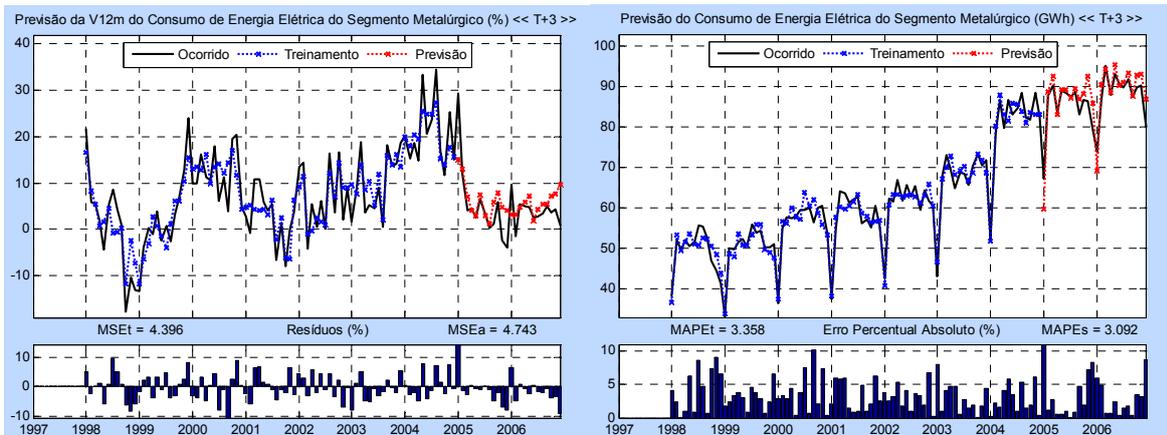


Figura 6.15 – Desempenho do Modelo Predictor do Consumo do Segmento Metalúrgico (T+3).

Fonte: Elaborado pelo Autor.

PREVISÃO DO CONSUMO PARA O SEXTO MÊS À FRENTE (T+6)

Após testar várias configurações, a melhor solução encontrada para proporcionar maior capacidade de abstração à rede foi a ampliação do conjunto de variáveis econômicas na camada de entrada de uma RBF. Apenas a série do IPCA acumulado nos últimos 12 meses, cujo AMMC é igual a 10, ainda manteve um elevado efeito de correlação linear com o consumo no mês alvo da previsão. A Figura 6.16 apresenta a arquitetura final do predictor RBF_CM6 obtida após o ajuste dos parâmetros de meta e spread.

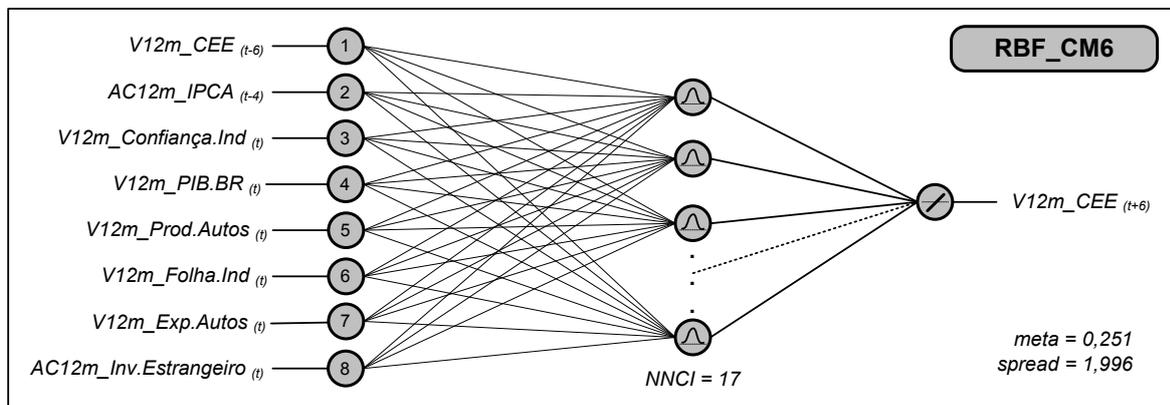


Figura 6.16 – Arquitetura do Modelo Predictor do Consumo do Segmento Metalúrgico (T+6).

Fonte: Elaborado pelo Autor.

Devido à capacidade de aprendizado e abstração do conhecimento das RNAs foi possível obter resultados significativos de previsão do consumo de energia do segmento metalúrgico mesmo para meio ano à frente. Com exceção do mês de janeiro de 2005, praticamente todos os demais períodos de treinamento e simulação apresentam erros absolutos de previsão do consumo abaixo de 9%. Na Figura 6.17 pode-se observar também que ao longo de 2005 e 2006 a maioria dos meses apresentou pequenos erros absolutos de previsão.

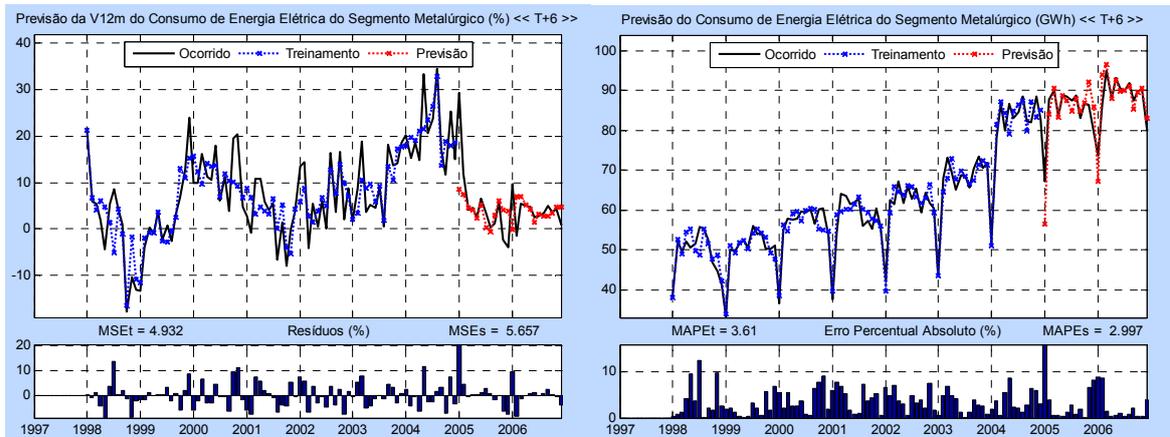


Figura 6.17 – Desempenho do Modelo Previsor do Consumo do Segmento Metalúrgico (T+6).

Fonte: Elaborado pelo Autor.

PREVISÃO DO CONSUMO PARA UM ANO À FRENTE (T+12)

Novamente, a ampliação do conjunto de variáveis econômicas, na camada de entrada da MLP, foi a solução encontrada para proporcionar maior capacidade de abstração ao modelo de previsão no horizonte de tempo mais elevado. Com um ano de antecedência para previsão, não foi possível defasar qualquer das variáveis econômicas e manter o efeito de correlação linear com o consumo no mês alvo (AMMC<12, para todos os regressores). A Figura 6.18 apresenta a arquitetura final do previsor MLP_CM12.

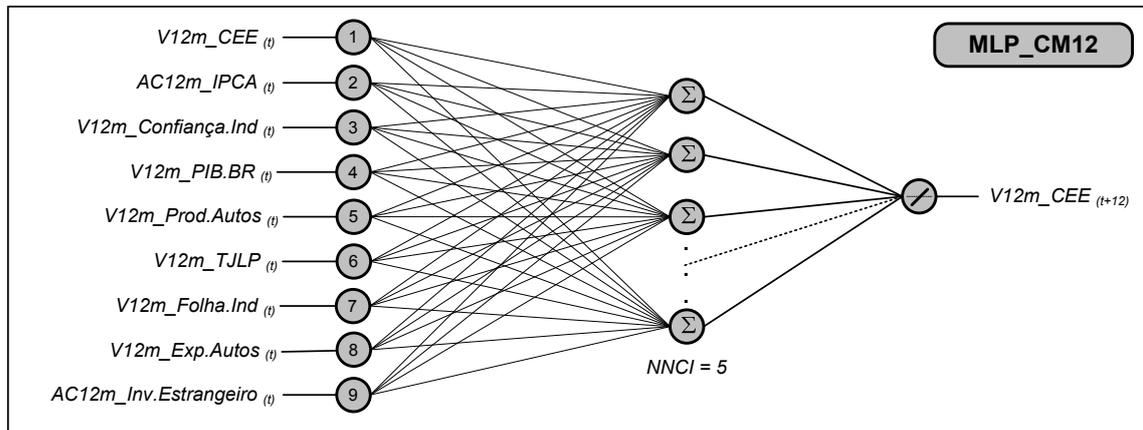


Figura 6.18 – Arquitetura do Modelo Previsor do Consumo do Segmento Metalúrgico (T+12).

Fonte: Elaborado pelo Autor.

Em virtude do maior número de neurônios na camada de entrada, o treinamento da MLP exigiu maior cuidado para garantir a generalização dos resultados. Mesmo com uso da regularização, apenas com 5 neurônios na camada intermediária que se pode obter bons resultados de previsão do consumo para o décimo segundo mês à frente. Na Figura 6.19 pode-se observar, com exceção de poucos meses atípicos, um desempenho significativo e equilibrado do modelo previsor tanto no intervalo de treinamento quanto no intervalo de simulação.

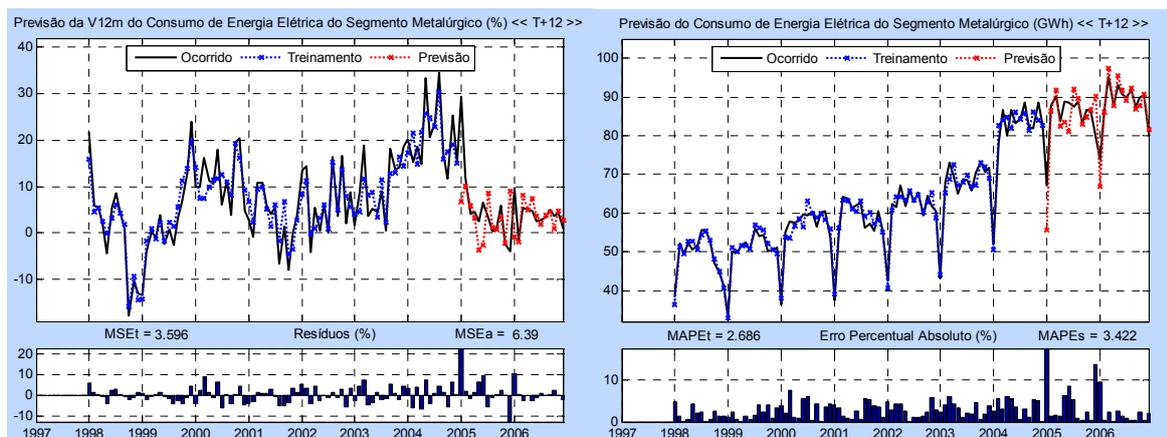


Figura 6.19 – Desempenho do Modelo Previsor do Consumo do Segmento Metalúrgico (T+12).

Fonte: Elaborado pelo Autor.

A Tabela 6.2 apresenta um resumo do desempenho dos modelos de previsão do consumo de energia elétrica do segmento metalúrgico. Pode-se notar que, apesar da diminuição natural da precisão com o aumento do horizonte de previsão, todos os modelos apresentam resultados significativos. O aspecto negativo dos resultados deste segmento, o MAX_APE, está diretamente relacionado ao mês atípico de janeiro de 2005.

Tabela 6.2 – Resumo do Desempenho dos Modelos de Previsão do Consumo de Energia Elétrica - Metalúrgico.

Horizonte	MSE _t	MSE _s	MAPE _t	MAX_APE _t	MAPE _s	MAX_APE _s
T+1	3.35	3.07	2.32	10.32	2.42	6.12
T+3	4.40	4.74	3.36	10.16	3.09	11.05
T+6	4.93	5.66	3.61	12.60	2.99	16.08
T+12	3.60	6.39	2.68	7.45	3.42	17.41

Fonte: Elaborado pelo Autor

6.3 PREVISÃO DA FAIXA DE CONSUMO DE ENERGIA ELÉTRICA

A segunda parte da aplicação de modelos previsores de demanda, baseado em redes neurais artificiais, é dedicada à previsão das faixas de consumo de energia elétrica de cada segmento da indústria. Entende-se que essa abordagem, complementar à previsão de um único valor de consumo, facilita a utilização desse novo conhecimento sobre a demanda no âmbito do planejamento estratégico e de auxílio à tomada de decisões por parte dos agentes envolvidos. Normalmente, os gestores das empresas de distribuição ou comercialização definem suas ações com base na evolução de diferentes cenários.

Modificando a forma de aprendizado das RNAs, com a introdução de dois vetores para a variação de consumo (V12m_CEE), afastados de mais e menos um valor delta (%), faz-se com que a rede “aprenda a errar” o consumo mensal para mais e para menos. Assim, com a configuração de

uma RBF com dois neurônios na camada de saída é possível estabelecer os limites inferior e superior da faixa de consumo para os períodos seguintes. SILVA e MOULIN (2000) apresentam e comparam diferentes técnicas para prever intervalos de confiança utilizando redes neurais. Os autores destacam que o desempenho deste tipo de estimação é fortemente dependente da similaridade entre os dados históricos e os dados atuais, e que a estimação dos erros de previsão, obtidos diretamente na camada de saída da RNA, apresenta maior complexidade e baixo desempenho quando se considera muitos períodos à frente.

Os mesmos problemas de ajustamento das redes da previsão tradicional, precisão & abstração, foram equacionados para previsão por faixa. Entretanto, o uso de técnicas de regularização não é suficiente para atender aos objetivos deste tipo de previsão. A qualidade das faixas de previsão do consumo está relacionada a dois fatores:

- **Precisão:** inversamente proporcional ao número de falhas nas faixas (períodos em que o consumo efetivo no mês ficou fora dos limites superior e inferior da faixa).
- **Largura ou Range:** diferença entre o menor e o maior consumo previsto em cada mês.

Para otimizar tais características das faixas, foram utilizadas neste tipo de previsão apenas as redes de função de base radial, devido as suas características de aproximadores de funções. Ao longo desta seção são apresentados dois tipos de faixas, nos horizontes de 1 e 12 meses à frente, com e sem falhas. A Figura 6.20 apresenta um fluxograma com as etapas realizadas para construção de redes neurais artificiais para previsão das faixas do consumo de energia elétrica.

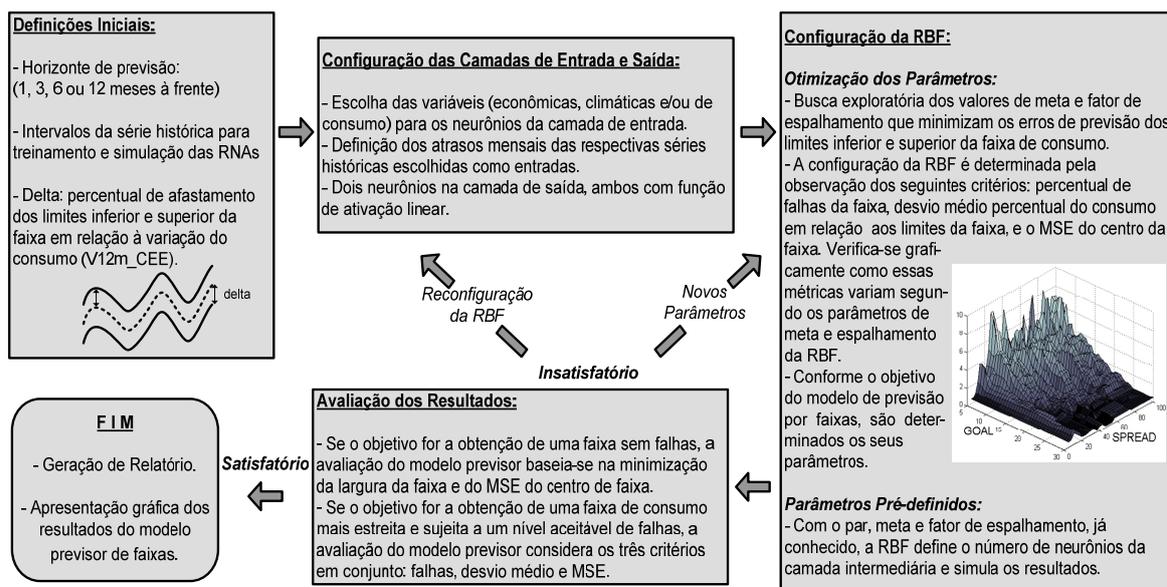


Figura 6.20 – Fluxograma da Construção de RBFs para Previsão das Faixas de Consumo.

Fonte: Elaborado pelo autor.

RISCO X RETORNO

Com a aplicação dos modelos de previsão por faixa é possível obter diversos resultados conforme a escolha do delta de afastamento. Como o objetivo principal desta pesquisa é apresentar novas ferramentas para descoberta de conhecimento novo e útil sobre a demanda optou-se por não apontar qual tipo de previsão por faixas é a melhor.

Se por uma lado é mais confiável utilizar uma faixa sem falhas, por outro, pode não ser viável planejar com cenários de consumo de energia elétrica tão distintos. O mesmo raciocínio se aplica para previsão de uma faixa mais estreita, cujos cenários de menor e maior consumo facilitam o planejamento, porém um menor grau de confiança nos seus limites. De acordo com o nível de aversão ao risco, presente nas estratégias de gestão das empresas do setor elétrico, pode-se utilizar uma previsão por faixas com nível compatível de incerteza sobre o comportamento da demanda. Para ilustrar essa relação custo-benefício foram simuladas faixas com e sem falhas, cujos resultados são apresentados ao longo da seção.

APRESENTAÇÃO DOS RESULTADOS

A mesma estrutura utilizada para apresentar os resultados dos modelos de previsão do consumo é utilizada nesta seção de resultados da previsão por faixas: arquiteturas seguidas dos gráficos de previsão. Apenas o desempenho dos modelos, apresentado nos gráficos, foi obtido com o uso de outros indicadores de qualidade:

- MSE – erro médio quadrático entre o centro das faixas previstas e a V12m_CEE ocorrida ao longo dos meses.
- Desvios do Centro da Faixa (%): descreve a diferença entre o valor central das faixas prevista e a V12m_CEE ocorrida em cada mês.
- Extrapolação das Faixas (%): representa, quando na ocorrência de falhas, a diferença percentual entre o consumo efetivo no mês e o valor da extremo da faixa que foi extrapolado (superior ou inferior).
- Desvio Médio (%): representa, quando na ocorrência de falhas, a soma das extrapolações das faixas dividida pelo número todas de meses do intervalo (treinamento ou simulação).

6.3.1 Resultados para o Segmento Têxtil (por faixa)

PREVISÃO DA FAIXA DE CONSUMO PARA O MÊS SEGUINTE (T+1)

Para conseguir prever os limites superior e inferior do consumo mensal de energia elétrica para o mês seguinte, foi construída uma RBF com praticamente as mesmas variáveis de entrada da previsão tradicional. A Figura 6.21 apresenta a arquitetura final do previsor RBF_FT1.

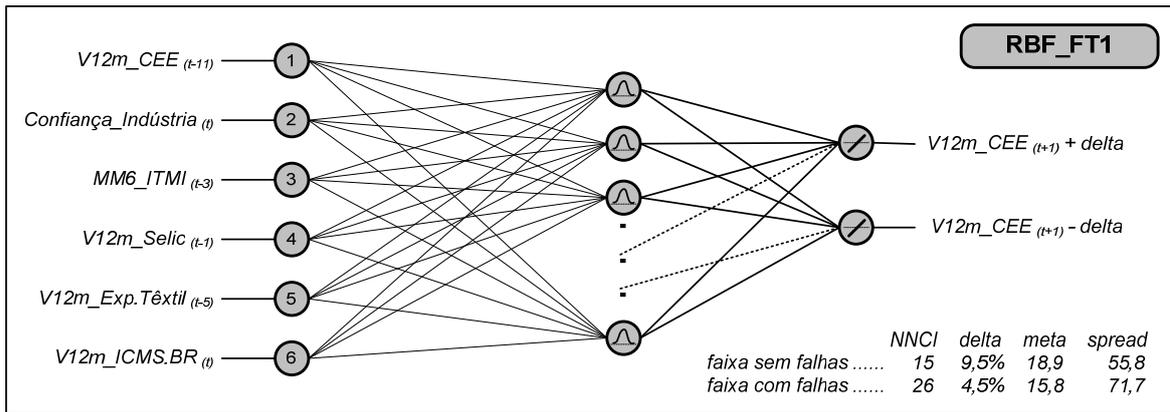


Figura 6.21 – Arquitetura do Modelo Previsor da Faixa de Consumo do Segmento Têxtil (T+1).

Fonte: Elaborado pelo Autor.

Para conseguir uma previsão de faixas sem a ocorrência de falhas foi necessário usar metas mais elevadas e um delta de quase 10%. A Figura 6.22 apresenta o desempenho da previsão por faixas de maior precisão, com uma largura média de faixa de 15,8 GWh.

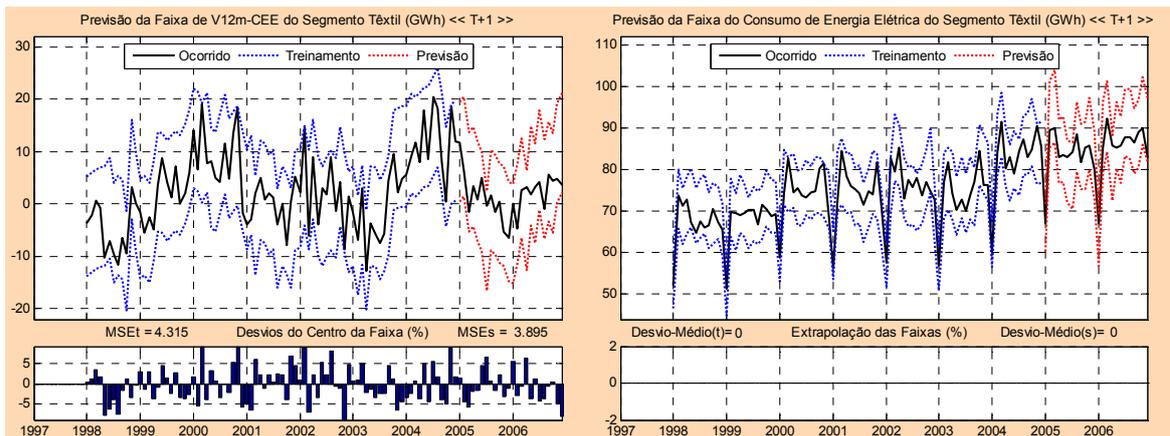


Figura 6.22 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Têxtil (T+1 s/falhas).

Fonte: Elaborado pelo Autor.

Considerando um delta, inferior a metade do anterior, pode-se conseguir uma previsão de faixas mais estreita e sujeita a falhas. A Figura 6.23 apresenta o desempenho da previsão com 21,3% de falhas no treinamento e 16,6% na simulação, com uma largura média de faixa bem menor, cerca de 7,5 GWh.

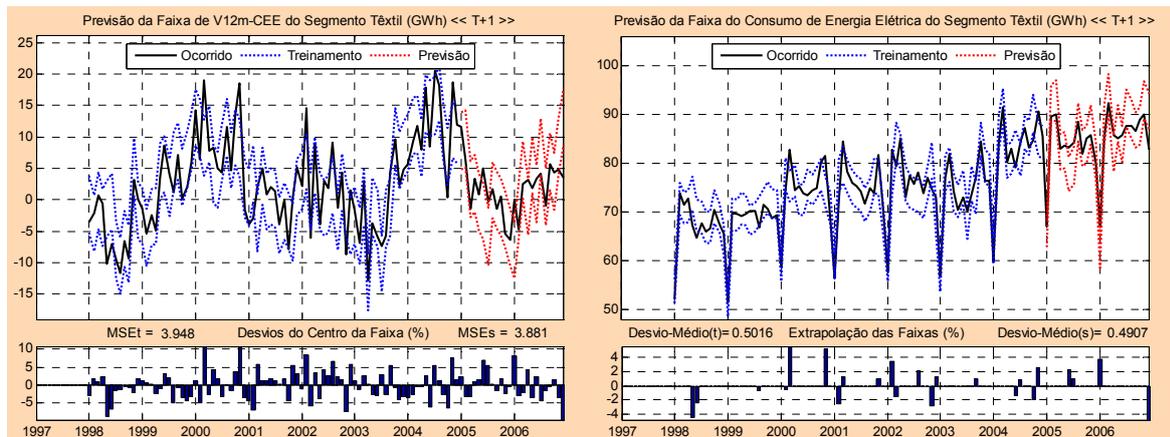


Figura 6.23 – Desempenho do Modelo Predictor da Faixa de Consumo do Segmento Têxtil (T+1 c/falhas).

Fonte: Elaborado pelo Autor.

PREVISÃO DA FAIXA DE CONSUMO PARA UM ANO À FRENTE (T+12)

Em comparação com as configurações do modelo da previsão de consumo para o mesmo horizonte de tempo, houve “apenas” a troca do tipo de rede neural para se obter a previsão por faixas. Foi possível aproveitar o conhecimento anterior e utilizar as mesmas variáveis e defasagens na camada de entrada da RBF. A Figura 6.24 apresenta a arquitetura final do predictor RBF_FT12.

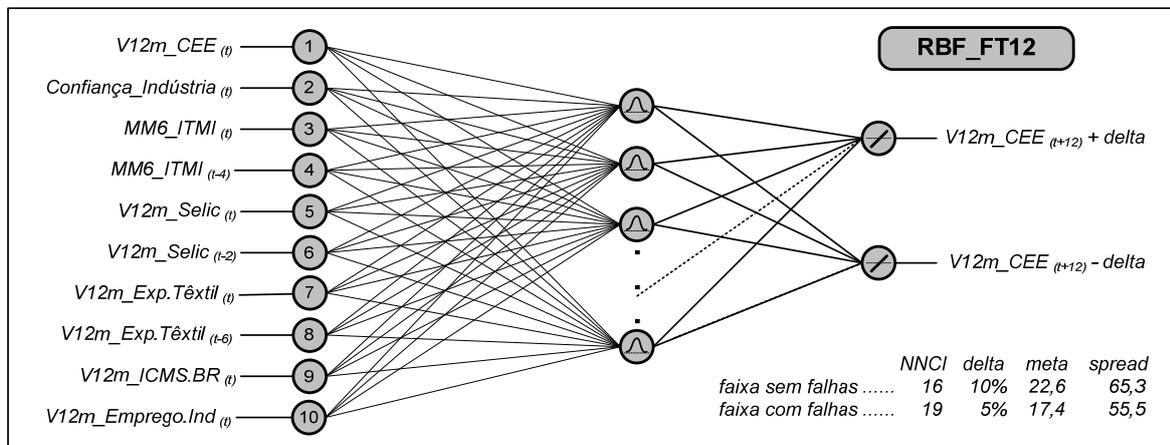


Figura 6.24 – Arquitetura do Modelo Predictor da Faixa de Consumo do Segmento Têxtil (T+12).

Fonte: Elaborado pelo Autor.

Para conseguir uma previsão de faixas sem a ocorrência de falhas num horizonte de tempo tão amplo, foi necessário um delta de 10% com uma meta ainda maior que em RBF_FT1. A Figura 6.25 apresenta o desempenho da previsão por faixas de maior precisão, com uma largura média de faixa de 16,6 GWh.

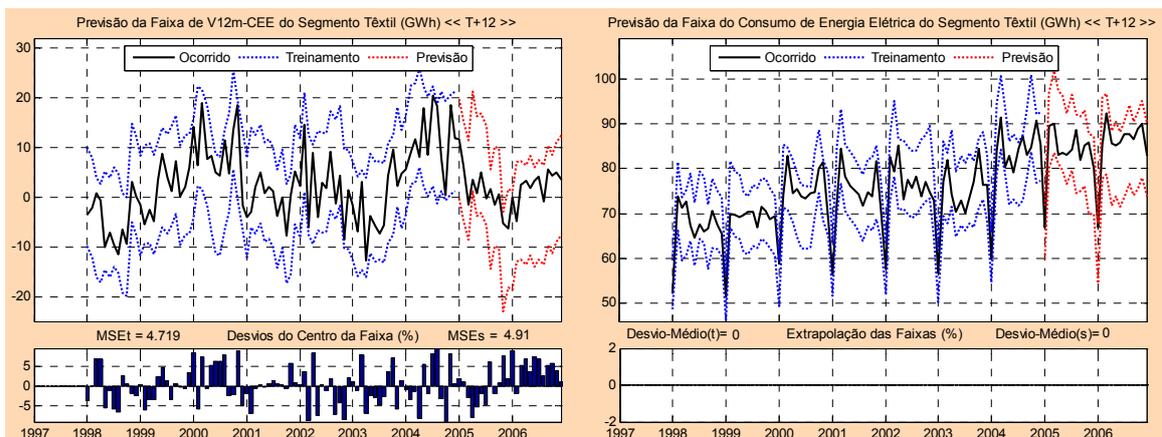


Figura 6.25 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Têxtil (T+12 s/falhas).

Fonte: Elaborado pelo Autor.

Considerando um valor de delta metade daquele utilizado para obtenção de faixas sem falhas, pode-se obter uma previsão com limites mais estreitos e sujeita à falhas. A Figura 6.26 apresenta o desempenho da previsão com 19,4% de falhas no treinamento, 16,7% de falhas na simulação, e com uma largura média de faixa metade de 8,3 GWh.

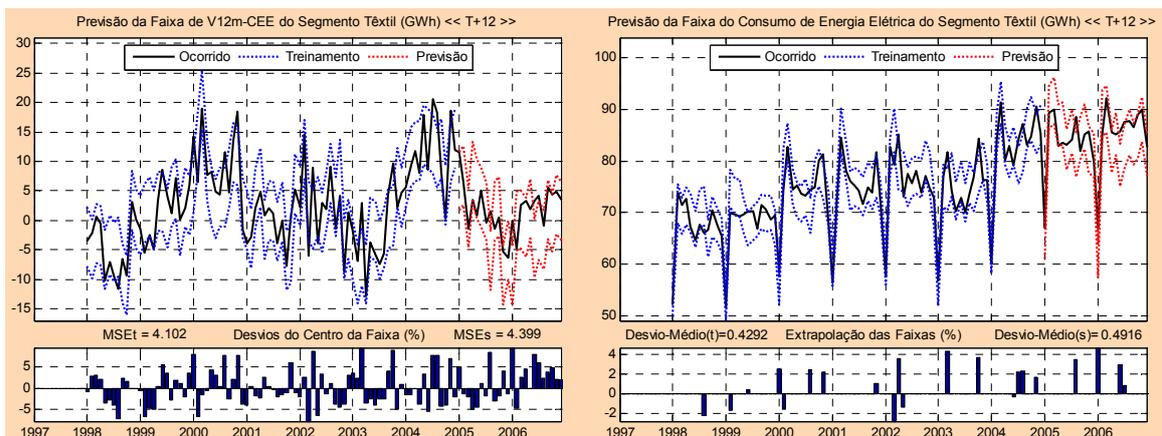


Figura 6.26 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Têxtil (T+12 c/falhas).

Fonte: Elaborado pelo Autor.

Os resultados da previsão por faixas, para ambos os horizontes de tempo e níveis de precisão, encoraja sua aplicação no processo de planejamento e gestão do mercado consumidor de energia elétrica composto pelas indústrias têxteis de Santa Catarina. Mesmo para estimações de cenários distantes, 12 meses à frente, se considerada a complexidade/volatilidade da demanda desagregada e as limitações desta metodologia, pode-se afirmar que os modelos de previsão por faixas reduzem o nível de incerteza sobre a demanda.

6.3.2 Resultados para o Segmento Metalúrgico (por faixa)

PREVISÃO DA FAIXA DE CONSUMO PARA O MÊS SEGUINTE (T+1)

Para conseguir prever, para o mês seguinte, os limites superior e inferior do consumo mensal de energia elétrica do segmento metalúrgico, foi construída uma RBF com as mesmas variáveis de entrada da previsão de consumo por montante (RBF_CM1). A Figura 6.27 apresenta a arquitetura final do previsor RBF_FM1.

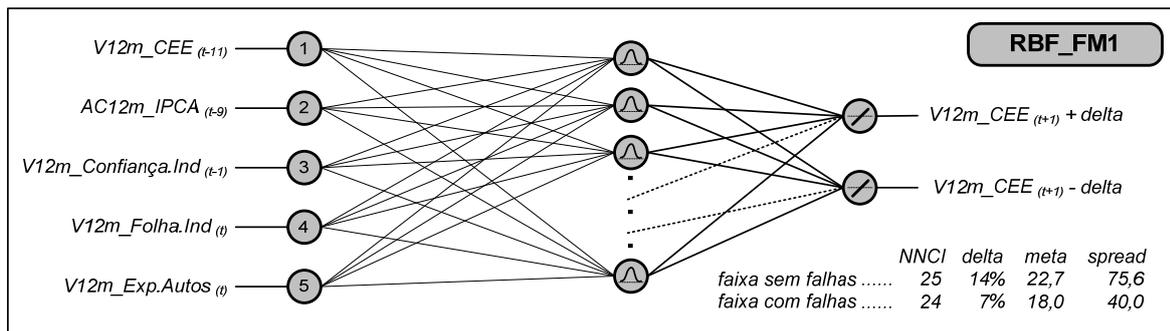


Figura 6.27 – Arquitetura do Modelo Previsor da Faixa de Consumo do Segmento Metalúrgico (T+1).

Fonte: Elaborado pelo Autor.

Devido à menor acurácia dos modelos de previsão obtidos na metalurgia, em comparação com o segmento têxtil, a obtenção de faixas de consumo sem a ocorrência de falhas exigiu uma maior generalização da RBF. A solução então foi utilizar metas mais elevadas, para antecipar o treinamento da rede, e um delta de 14%. A Figura 6.28 apresenta o desempenho da previsão por faixas de maior precisão, cuja largura média foi de 23,2 GWh ao longo dos anos.

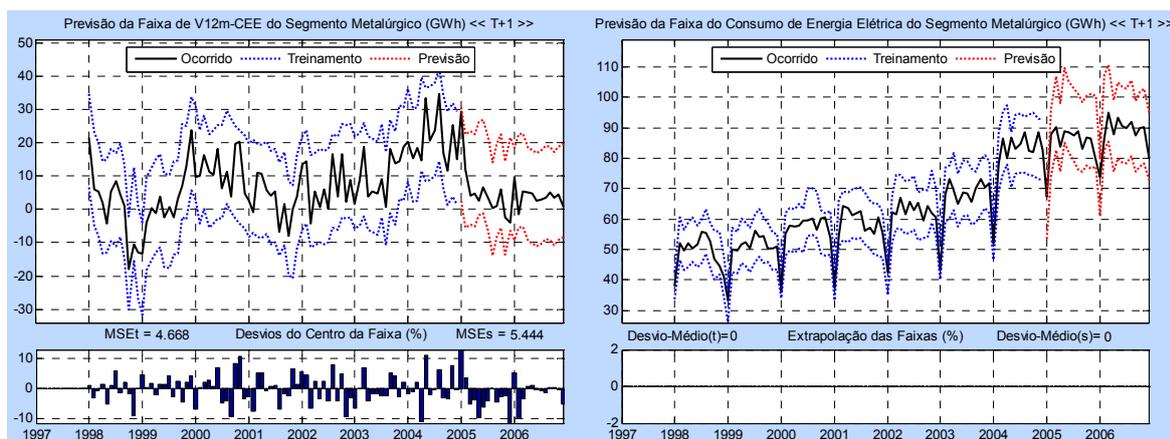


Figura 6.28 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Metalúrgico (T+1 s/falhas).

Fonte: Elaborado pelo Autor.

Novamente, considerando um delta, inferior à metade do anterior, pode-se conseguir uma previsão de faixas mais estreita e sujeita a falhas. A Figura 6.29 apresenta o desempenho da previsão com 10,2% de falhas no treinamento e 12,5% na simulação, com uma largura média de faixa de 11,6 GWh, equivalente à metade daquela apresentada na previsão sem falhas.

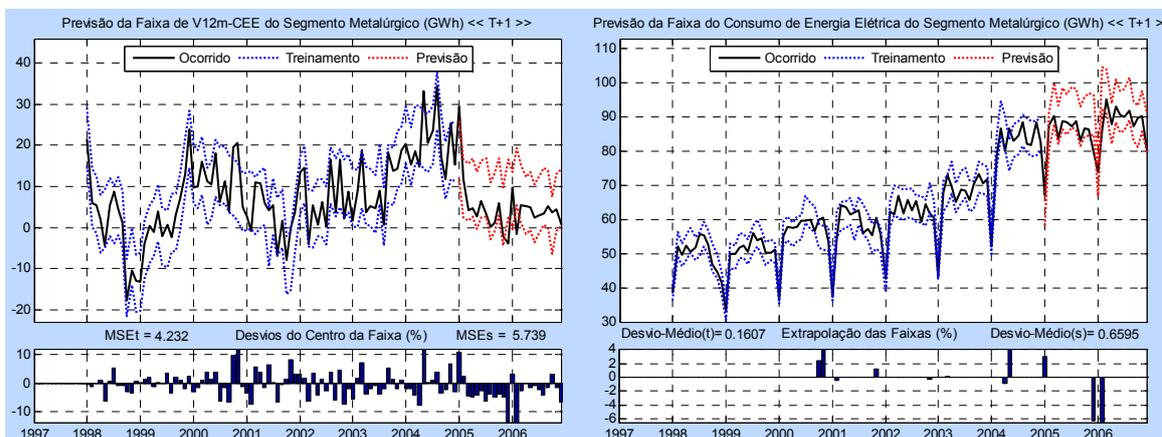


Figura 6.29 – Desempenho do Modelo Previsor da Faixa de Consumo do Segmento Metalúrgico (T+1 c/falhas).

Fonte: Elaborado pelo Autor.

PREVISÃO DA FAIXA DE CONSUMO PARA UM ANO À FRENTE (T+12)

Em comparação com as configurações do modelo da previsão de consumo para o mesmo horizonte de tempo, houve “apenas” a troca do tipo de rede neural para se obter a previsão por faixas. Foi possível aproveitar o conhecimento anterior e utilizar as mesmas variáveis e defasagens na camada de entrada da RBF. A Figura 6.30 apresenta a arquitetura final do previsor RBF_FM12.

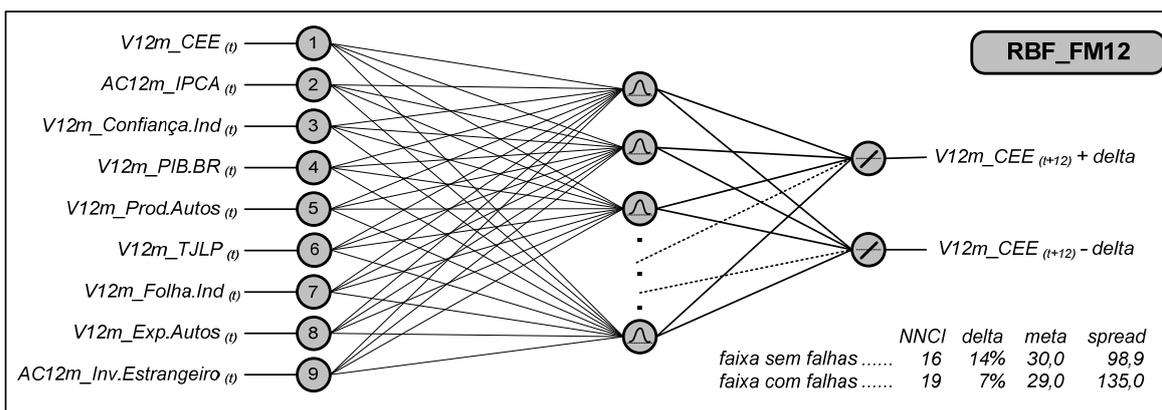


Figura 6.30 – Arquitetura do Modelo Previsor da Faixa de Consumo do Segmento Metalúrgico (T+12).

Fonte: Elaborado pelo Autor.

Com o mesmo delta de afastamento do modelo de previsão por faixas do mês seguinte (RBF_FM1), foi possível obter uma boa previsão de faixas, sem a ocorrência de falhas, num horizonte de tempo 12 meses. Com o uso de metas e *spreads* mais elevados proveu-se as condições necessárias para o equilíbrio entre o aprendizado e a abstração da RBF. A Figura 6.31 apresenta o

desempenho da previsão por faixas sem a ocorrência de falhas, cuja largura média foi de 23,2 GWh ao longo dos anos.

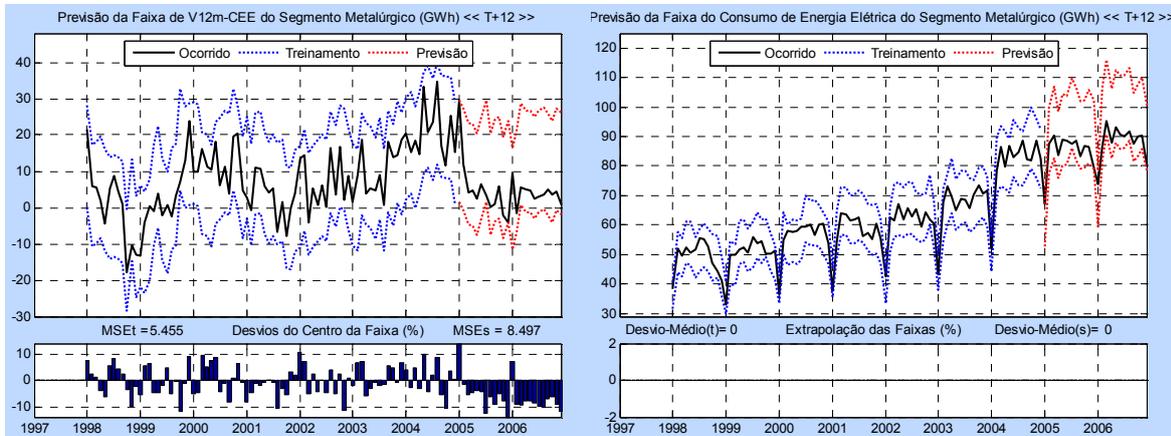


Figura 6.31 – Desempenho do Modelo Predictor da Faixa de Consumo do Segmento Metalúrgico (T+12 s/falhas).

Fonte: Elaborado pelo Autor.

Considerando um valor de delta metade daquele utilizado para obtenção de faixas sem falhas, pode-se obter uma previsão com limites mais estreitos e sujeita à ocorrência de falhas. A Figura 6.32 apresenta o desempenho da previsão com 18,5% de falhas no treinamento, 12,5% de falhas na simulação, e com uma largura média de faixa metade de 11,6 GWh.

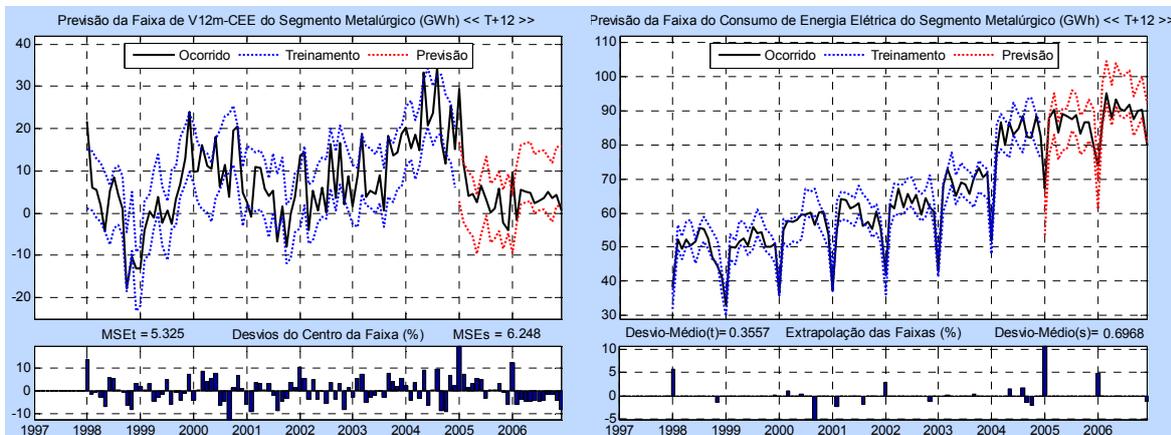


Figura 6.32 – Desempenho do Modelo Predictor da Faixa de Consumo do Segmento Metalúrgico (T+12 c/falhas).

Fonte: Elaborado pelo Autor.

Apesar das diferenças nas larguras de faixas e na precisão dos limites inferior e superior, apresentadas nos modelos dos segmentos têxtil e metalúrgico, pode-se afirmar que este último equilibrou a qualidade dos resultados. Para ambos os horizontes de tempo e níveis de precisão, encoraja-se a aplicação destes modelos no processo de planejamento e gestão do mercado consumidor de energia elétrica composto pelas indústrias metalúrgicas de Santa Catarina. No mínimo, pode-se afirmar que os modelos de previsão por faixas conseguem reduzir o nível de incerteza sobre os cenários futuros da demanda.

6.4 CONSIDERAÇÕES FINAIS

O Capítulo 6 apresentou as etapas para o desenvolvimento e aplicação do modelo de previsão da demanda dos consumidores industriais de energia elétrica. Essa última etapa da metodologia para descoberta de conhecimento novo e útil sobre o comportamento da demanda foi baseada na pesquisa de campo, na formação da base de dados, na aplicação de modelos econométricos, e no uso de técnicas de inteligência artificial para previsão da demanda no médio prazo.

Conforme a revisão da literatura, nos últimos 20 anos o uso de redes neurais artificiais (RNAs) para solução dos problemas de previsão da demanda tem conquistado maior espaço em várias áreas do conhecimento. Por esse motivo, a etapa de previsão da demanda, que poderia ser realizada com o uso de métodos econométricos, foi reservada para a solução com uso de redes neurais artificiais. Após analisar a qualidade das previsões obtidas, ficou evidente a grande contribuição do modelo econométrico previamente desenvolvido. A descoberta das correlações de maior influência permitiu uma grande redução do número de variáveis explicativas a serem usadas nas camadas de entrada das redes. A tarefa de configuração das RNAs foi bastante facilitada.

Neste capítulo foram implementados dois tipos de redes neurais: MLP e RBF. Ambas as tipologias são utilizadas na literatura como aproximadores de funções, capazes de mapear o efeito das variáveis explicativas sobre o comportamento da demanda no período de treinamento e generalizar suas saídas para os meses à frente (horizontes de previsão de 1, 3, 6 e 12 meses). A inclusão de uma variável climática no modelo preditivo do segmento têxtil contribuiu decisivamente para a melhor acurácia da previsão. Considerando os quatro horizontes de previsão, os modelos previsores da indústria têxtil apresentaram MAPE entre 1,57% e 2,73%. Embora os modelos previsores da metalurgia apresentem desempenhos significativos, eles foram inferiores aqueles obtidos para o segmento têxtil, devido à consideração “apenas” de variáveis econômicas ou à mudança brusca do padrão de crescimento do consumo de energia elétrica da metalurgia entre 2004 e 2005. Os modelos previsores da indústria metalúrgica apresentaram MAPE entre 2,42% e 3,42%, para os horizontes de previsão considerados.

Com o objetivo de proporcionar maior aplicabilidade prática ao modelo preditivo, foi apresentado um modelo para previsão da faixa de consumo mensal de energia elétrica, capaz de reduzir o nível de incerteza sobre os cenários futuros da demanda. Essa abordagem permite aos gestores de planejamento estabelecer cenários de menor e maior consumo esperado do segmento industrial. Foram apresentados dois tipos de previsão por faixa: i) com bandas mais largas e com alto nível de precisão; ii) com bandas mais estreitas e com uma maior probabilidade de serem extrapoladas. De acordo com o nível de aversão ao risco, pode-se utilizar uma previsão por faixas com nível compatível de incerteza sobre o comportamento da demanda. Os resultados obtidos, tanto para o segmento têxtil como para o metalúrgico, demonstraram a viabilidade desta abordagem para a previsão da demanda dos consumidores industriais de energia elétrica.

CAPÍTULO 7

Conclusões

Os capítulos anteriores apresentaram a proposta da tese para um “*Novo Modelo para Descrição e Previsão da Demanda dos Consumidores Industriais de Energia Elétrica*”. Neste capítulo, faz-se necessário estabelecer algumas ponderações sobre os resultados alcançados durante a pesquisa, à luz dos objetivos pretendidos. Apresentam-se ainda, alguns aspectos relacionados à aplicabilidade da metodologia proposta, bem como as suas limitações, além de sugestões para trabalhos futuros.

Ao longo deste trabalho foi possível desenvolver e aplicar uma nova metodologia para descobrir conhecimento novo e útil sobre a demanda por energia elétrica, característica de cada segmento industrial, por meio de técnicas de mineração de dados aplicadas ao conjunto das variáveis socioeconômicas e climáticas que mais a influenciam.

Em função da complexidade e da variedade dos problemas relacionados ao estudo da demanda por energia elétrica, foi realizada uma cuidadosa organização e análise das referências da literatura, com vistas à contextualização das contribuições pretendidas nesta tese. Para facilitar a análise da bibliografia utilizada neste trabalho, caracterizado pela multidisciplinariedade, apresentou-se um Mapa Temático com todas as citações agrupadas por áreas de conhecimento. Além de prover melhorias na organização do texto, este procedimento facilita a busca por referências de temas específicos de interesse do leitor.

O diferencial deste trabalho, na comparação com todas as obras revisadas na literatura (Capítulo 2), está na aplicação de técnicas de mineração de dados como suporte à integração do modelo econométrico descritivo com o modelo de redes neurais preditivo.

A opção pela utilização da demanda, de forma mais desagregada, acarretou a análise de uma relação custo-benefício para escolha do nível de desagregação adequado. Ao considerar a demanda dos consumidores industriais de energia elétrica por segmento, este trabalho permitiu estimar características específicas das atividades econômicas consideradas, porém, às custas de uma maior habilidade em capturar as diferenças entre os segmentos. Justamente para prover um maior conhecimento sobre a dinâmica dos principais segmentos industriais de Santa Catarina, foi realizada uma Pesquisa de Campo, diretamente com as empresas e sindicatos. Assim, foram estabelecidas as condições necessárias para uma abordagem com alto nível de desagregação para a demanda. Seria de grande interesse uma comparação do desempenho do modelo proposto com trabalhos mais agregados, considerando, por exemplo, toda a demanda do setor industrial de SC. Com foco em outros objetivos, o modelo deste trabalho foi aplicado somente em dois segmentos da indústria catarinense: têxtil e metalúrgico.

Foi possível observar na literatura que vários autores analisaram o comportamento da demanda sem considerar outras variáveis, senão a própria série histórica do consumo de energia elétrica. Esses modelos, às vezes chamados de autorregressivos, também apresentam resultados interessantes, principalmente no curto prazo, porém são mais susceptíveis aos erros quando ocorrem variações bruscas na economia, por exemplo. Considerando os objetivos propostos neste trabalho e os resultados alcançados, recomenda-se a utilização de variáveis independentes e com potencial para caracterização do comportamento da demanda de cada segmento industrial. Dos conjuntos de variáveis de influência possíveis, esta metodologia considerou os indicadores da economia e os indicadores climáticos mensais, este último apenas para o segmento têxtil.

Considerando os dois segmentos da indústria mencionados, foram analisadas mais de 50 séries históricas de variáveis econômicas, contabilizando as medidas originais e as transformações

pró-estacionárias. Apesar do grande conjunto de dados da economia, ressaltam-se algumas limitações do trabalho: (i) como o foco da pesquisa estava na demanda dos consumidores industriais de segmentos específicos, com clientes contratados tanto no mercado cativo quanto no mercado livre, e sujeitos a uma complexa variação do preço da energia, não foi possível utilizar uma série histórica de preço, que provavelmente melhoraria o modelo descritivo proposto; (ii) uma das grandes preocupações dos empresários estava relacionada à questão da carga tributária, porém, foi possível considerar apenas a arrecadação dos impostos que mais afetam a indústria, dado que, o histórico das alíquotas e a variação do percentual da carga tributária sobre o PIB setorial é de difícil obtenção; (iii) devido à proximidade da relação entre os indicadores de desempenho da indústria, como utilização da capacidade instalada, produção, pessoal empregado e vendas, com a variação do consumo de energia elétrica, optou-se pela não utilização das séries históricas da FIESC. Podem-se verificar outros modelos de previsão que as utilizam.

O conjunto de variáveis climáticas de maior influência para o segmento têxtil foi representado por apenas 5 medidas de temperatura mensais: média, máxima absoluta, mínima absoluta, média das máximas e média das mínimas. Por outro lado, foi necessário reunir as séries históricas de 15 estações climatológicas das regiões Sul e Sudeste do Brasil, que pudessem representar o efeito das anomalias climáticas nos principais Estados de destino da produção têxtil de Santa Catarina. Essa abordagem propiciou uma conotação espacial para os dados de entrada do clima no âmbito da previsão de demanda, de característica temporal.

Observam-se na literatura, diversos trabalhos sobre a influência do clima, ao longo dos meses, em países da Europa. As características do clima das regiões Sul e Sudeste do Brasil, com boa amplitude térmica anual, possibilitaram a aplicação da mesma abordagem para análise da influência da temperatura, ao longo dos meses, no comportamento da demanda industrial. Para regiões mais tropicais, o uso do clima, como apresentado, não deverá ter o mesmo desempenho.

A utilização de variáveis climáticas, mais especificamente do indicador ITMI – *Intensidade Térmica das Mínimas*, para os modelos de descrição e previsão do segmento têxtil mostrou-se eficiente. Além de apresentar o maior nível de significância para explicação do consumo no modelo econométrico, o ITMI apresentou relação de causalidade com a demanda com 99% de confiança. Ressalta-se ainda, a presença desse indicador na camada de entrada de todos os modelos previsores da demanda do segmento têxtil, e sua contribuição para o nível de precisão alcançado. Para análises num horizonte de médio prazo de indústrias afetadas pelo clima, o uso de indicadores climáticos regionais parece ser uma boa alternativa.

Os objetivos do modelo econométrico proposto nesta metodologia foram além da tarefa de descrever o comportamento da demanda. A econometria foi utilizada também como ferramenta para seleção das variáveis de entrada do modelo de previsor neural da demanda. Assim como outros métodos científicos, o uso da econometria exige extremo cuidado na modelagem para que o teor das conclusões e análises obtidas seja verdadeiramente significativo. Os modelos descritivos

dos segmentos têxtil e metalúrgico consideraram as questões relacionadas: à estacionariedade, ao coeficiente de correlação linear de Pearson, à estimação dos parâmetros, aos testes de hipóteses e à avaliação do desempenho. Ressalta-se a importância da seleção dos melhores modelos econométricos conforme o *Critério de Informação de Schwartz*. A interpretação das equações de regressão múltipla permitiu conhecer o grau de influência de cada regressor sobre a variação da demanda com alto nível de significância. A metodologia também observou o efeito do atraso mensal nas séries históricas de clima e economia sobre o consumo. Essa abordagem permitiu um maior aproveitamento no modelo preditivo daquelas variáveis que apresentavam maiores defasagens na correlação com consumo.

Um aspecto interessante para seleção de variáveis explicativas foi estabelecer correlações com a tendência do consumo de energia elétrica. Geralmente, o efeito da variação de indicadores econômicos e climáticos na dinâmica das indústrias pode ocorrer de forma gradativa e numa frequência mais baixa de tempo. A tendência, por ser mais suave, apresentou correlações importantes para as variáveis consideradas, tanto no segmento metalúrgico como no têxtil.

A grande maioria dos trabalhos de descrição, projeção e previsão da demanda, quando consideram variáveis econômicas, utilizam como dado de entrada o PIB – Produto Interno Bruto. Provavelmente, devido ao alto nível de desagregação adotado neste trabalho, nenhum dos modelos econométricos finais apresentou o PIB como variável de entrada. Outras variáveis, em especial o índice de confiança da indústria, supriram esta lacuna. Além disso, este indicador da FGV já apresenta uma apuração mensal de rápida divulgação, enquanto o PIB tem apuração trimestral com um prazo de divulgação mais demorado. Dependendo do horizonte de análise do planejamento e do nível de desagregação da demanda, o tradicional indicador de crescimento da economia pode ser suprimido.

A última etapa da metodologia proposta, a previsão da demanda dos consumidores industriais de energia elétrica, foi desenvolvida utilizando todos os resultados obtidos tanto na formação da base de dados quanto na descrição da demanda, que permitiu uma grande redução do número de variáveis explicativas. Para construir os modelos preditivos de cada segmento, foram testadas diversas configurações de redes neurais artificiais MLP e RBF. A maior dificuldade encontrada nesta etapa foi a estabelecer modelos com boa capacidade de generalização, com erros de simulação baixos e próximos aos erros de treinamento. A melhor solução encontrada, no caso das redes MLP, foi a utilização da regularização bayesiana para o treinamento da rede. No caso das redes RBF a otimização dos parâmetros de meta e espalhamento mostraram-se eficientes, principalmente nos modelos de previsão da demanda por faixa.

Em função das características da variável prevista, variação do consumo de energia elétrica em relação ao mesmo mês do ano anterior, não foi necessário configurar redes neurais específicas de determinados meses, acompanhando a sazonalidade. Foram construídos modelos previso-res específicos para diferentes horizontes de tempo (1, 3, 6 e 12 meses), que permitiram dimensionar a

sensibilidade da precisão com o aumento do horizonte. Mesmo para os horizontes mais dilatados foram obtidas previsões com alto nível de precisão. Tais resultados refletem a grande contribuição do modelo econométrico previamente desenvolvido.

Apesar de não contemplar horizontes de previsão voltados para o longo prazo, como 24, 60 ou 120 meses, o modelo econométrico em conjunto com as redes neurais poderiam realizar boas estimativas para o consumo industrial. Nesse caso, provavelmente, a utilização de cenários, a previsão de variáveis de entrada, a realimentação de variáveis de saída e um grande e confiável conjunto de dados históricos seriam necessários.

Na comparação do desempenho dos modelos preditivos do segmento têxtil e do segmento metalúrgico, verificou-se certa vantagem a favor do primeiro. Pode-se perceber que a inclusão de uma variável climática no modelo preditivo do segmento têxtil contribuiu decisivamente para a acurácia da previsão. Os modelos previsores da indústria têxtil apresentaram MAPE entre 1,57% e 2,73%, dependendo do horizonte de previsão, enquanto os modelos previsores da metalurgia apresentaram MAPE entre 2,42% e 3,42%.

Essa nova abordagem para previsão no médio prazo tornou-se mais completa e aplicável com a inclusão de modelos para previsão da faixa de consumo mensal de energia elétrica. A partir de seus resultados, os gestores de planejamento podem estabelecer cenários de menor e maior consumo esperado para o segmento industrial no médio prazo. Nos segmentos têxtil e metalúrgico, foi possível verificar a redução do nível de incerteza sobre a demanda, demonstrando a viabilidade desta abordagem para a previsão da demanda desagregada.

Algumas barreiras ao desenvolvimento deste tipo de pesquisa, especialmente na obtenção de dados, e a impossibilidade da consideração de todos os fatores de impacto no comportamento do consumo de energia elétrica, permitem a apresentação de algumas sugestões para trabalhos futuros:

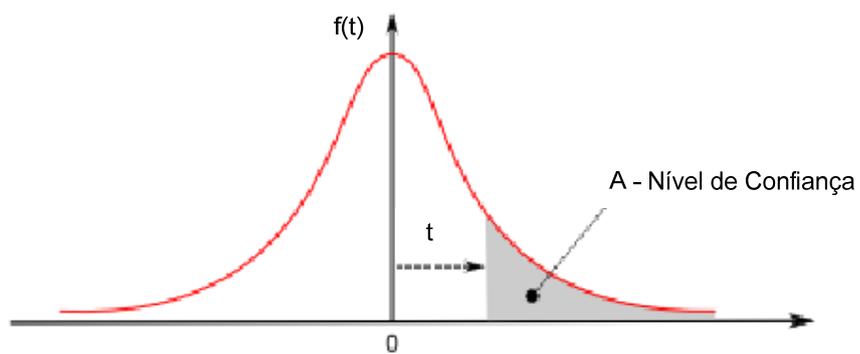
- Obtenção de mais séries históricas representativas da dinâmica dos segmentos industriais: preço da energia elétrica, preço de energéticos substitutos, alíquotas de impostos, nível de inadimplência, indicadores do Risco-Brasil, comércio exterior, competitividade, etc.
- Descoberta da elasticidade-preço em cada um dos segmentos industriais considerando os respectivos ambientes de contratação e os períodos de crescimento e retração da economia.
- A utilização de fenômenos climáticos precedentes, como por exemplo, os efeitos El Niño e La Niña sobre o clima das regiões Sul e Sudeste;
- Adequar à presente metodologia um processo de seleção automática das variáveis explicativas para camada de entrada do modelo previsor neural, comprometido com as expectativas de relacionamento da teoria econômica e/ou da física;

- Aprimorar o processo de treinamento das MLPs para que diferentes valor de α possam adequar a função de desempenho às diferentes naturezas das variáveis de entrada;
- Considerar a demanda ainda mais desagregada, conforme os perfis de carga anuais dos clientes dentro de cada segmento industrial. Nesse caso, os modelos de previsão da demanda de cada perfil, individualmente, poderiam apresentar elevada precisão.

Finalmente, espera-se que “*Um Modelo para Descrição e Previsão da Demanda dos Consumidores Industriais de Energia Elétrica*” possa contribuir positivamente para os estudos sobre o comportamento da demanda. De forma resumida, esta tese propôs uma interligação entre um modelo descritivo e um modelo preditivo, fundamentada na compreensão das relações existentes entre a economia, o clima, e a ação de consumir energia elétrica.

- ANEXO A -

Tabela da Distribuição t de *Student*

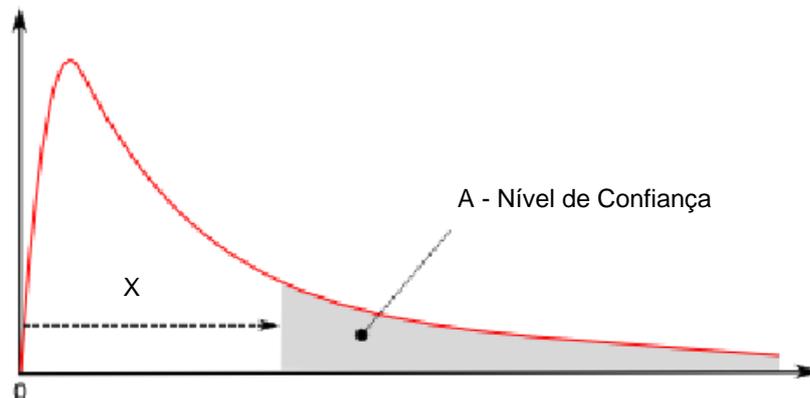


A primeira coluna especifica o parâmetro grau de liberdade (ν) para cada linha. Os números na mesma linha do símbolo ν indicam, para cada coluna, as probabilidades de valores acima dos valores de t de cada linha.

v/A	0,2500	0,2000	0,1500	0,1000	0,0500	0,0250	0,0100	0,0050	0,0025	0,0010	0,0005
001	1,000	1,376	1,963	3,078	6,314	12,710	31,820	63,660	127,300	318,300	636,600
002	0,816	1,061	1,386	1,886	2,920	4,303	6,965	9,925	14,090	22,330	31,600
003	0,765	0,978	1,250	1,638	2,353	3,182	4,541	5,841	7,453	10,210	12,920
004	0,741	0,941	1,190	1,533	2,132	2,776	3,747	4,604	5,598	7,173	8,610
005	0,727	0,920	1,156	1,476	2,015	2,571	3,365	4,032	4,773	5,893	6,869
006	0,718	0,906	1,134	1,440	1,943	2,447	3,143	3,707	4,317	5,208	5,959
007	0,711	0,896	1,119	1,415	1,895	2,365	2,998	3,499	4,029	4,785	5,408
008	0,706	0,889	1,108	1,397	1,860	2,306	2,896	3,355	3,833	4,501	5,041
009	0,703	0,883	1,100	1,383	1,833	2,262	2,821	3,250	3,690	4,297	4,781
010	0,700	0,879	1,093	1,372	1,812	2,228	2,764	3,169	3,581	4,144	4,587
011	0,697	0,876	1,088	1,363	1,796	2,201	2,718	3,106	3,497	4,025	4,437
012	0,695	0,873	1,083	1,356	1,782	2,179	2,681	3,055	3,428	3,930	4,318
013	0,694	0,870	1,079	1,350	1,771	2,160	2,650	3,012	3,372	3,852	4,221
014	0,692	0,868	1,076	1,345	1,761	2,145	2,624	2,977	3,326	3,787	4,140
015	0,691	0,866	1,074	1,341	1,753	2,131	2,602	2,947	3,286	3,733	4,073
016	0,690	0,865	1,071	1,337	1,746	2,120	2,583	2,921	3,252	3,686	4,015
017	0,689	0,863	1,069	1,333	1,740	2,110	2,567	2,898	3,222	3,646	3,965
018	0,688	0,862	1,067	1,330	1,734	2,101	2,552	2,878	3,197	3,610	3,922
019	0,688	0,861	1,066	1,328	1,729	2,093	2,539	2,861	3,174	3,579	3,883
020	0,687	0,860	1,064	1,325	1,725	2,086	2,528	2,845	3,153	3,552	3,850
021	0,686	0,859	1,063	1,323	1,721	2,080	2,518	2,831	3,135	3,527	3,819
022	0,686	0,858	1,061	1,321	1,717	2,074	2,508	2,819	3,119	3,505	3,792
023	0,685	0,858	1,060	1,319	1,714	2,069	2,500	2,807	3,104	3,485	3,767
024	0,685	0,857	1,059	1,318	1,711	2,064	2,492	2,797	3,091	3,467	3,745
025	0,684	0,856	1,058	1,316	1,708	2,060	2,485	2,787	3,078	3,450	3,725
026	0,684	0,856	1,058	1,315	1,706	2,056	2,479	2,779	3,067	3,435	3,707
027	0,684	0,855	1,057	1,314	1,703	2,052	2,473	2,771	3,057	3,421	3,690
028	0,683	0,855	1,056	1,313	1,701	2,048	2,467	2,763	3,047	3,408	3,674
029	0,683	0,854	1,055	1,311	1,699	2,045	2,462	2,756	3,038	3,396	3,659
030	0,683	0,854	1,055	1,310	1,697	2,042	2,457	2,750	3,030	3,385	3,646
040	0,681	0,851	1,050	1,303	1,684	2,021	2,423	2,704	2,971	3,307	3,551
050	0,679	0,849	1,047	1,299	1,676	2,009	2,403	2,678	2,937	3,261	3,496
060	0,679	0,848	1,045	1,296	1,671	2,000	2,390	2,660	2,915	3,232	3,460
080	0,678	0,846	1,043	1,292	1,664	1,990	2,374	2,639	2,887	3,195	3,416
100	0,677	0,845	1,042	1,290	1,660	1,984	2,364	2,626	2,871	3,174	3,390
120	0,677	0,845	1,041	1,289	1,658	1,980	2,358	2,617	2,860	3,160	3,373
∞	0,674	0,842	1,036	1,282	1,645	1,960	2,326	2,576	2,807	3,090	3,291

- ANEXO B -

Tabelas da Distribuição F (Fisher-Snedecor)



V1: Graus de liberdade da variável do numerador (primeira linha).
V2: Graus de liberdade da variável do denominador (primeira coluna a esquerda da tabela).

Tabella para A = 0,1 ou 10%

v_2/v_1	1	2	3	4	5	6	7	8	9	10	12	15	20	24	30	40	60	120	∞
1	39,86	49,50	53,59	55,83	57,24	58,20	58,91	59,44	59,86	60,19	60,71	61,22	61,74	62,00	62,26	62,53	62,79	63,06	63,33
2	8,526	9,000	9,162	9,243	9,293	9,326	9,349	9,367	9,381	9,392	9,408	9,425	9,441	9,450	9,458	9,466	9,475	9,483	9,491
3	5,538	5,462	5,391	5,343	5,309	5,285	5,266	5,252	5,240	5,230	5,216	5,200	5,184	5,176	5,168	5,160	5,151	5,143	5,134
4	4,545	4,325	4,191	4,107	4,051	4,010	3,979	3,955	3,936	3,920	3,896	3,870	3,844	3,831	3,817	3,804	3,790	3,775	3,761
5	4,060	3,780	3,619	3,520	3,453	3,405	3,368	3,339	3,316	3,297	3,268	3,238	3,207	3,191	3,174	3,157	3,140	3,123	3,105
6	3,776	3,463	3,289	3,181	3,108	3,055	3,014	2,983	2,958	2,937	2,905	2,871	2,836	2,818	2,800	2,781	2,762	2,742	2,722
7	3,589	3,257	3,074	2,961	2,883	2,827	2,785	2,752	2,725	2,703	2,668	2,632	2,595	2,575	2,555	2,535	2,514	2,493	2,471
8	3,458	3,113	2,924	2,806	2,726	2,668	2,624	2,589	2,561	2,538	2,502	2,464	2,425	2,404	2,383	2,361	2,339	2,316	2,293
9	3,360	3,006	2,813	2,693	2,611	2,551	2,505	2,469	2,440	2,416	2,379	2,340	2,298	2,277	2,255	2,232	2,208	2,184	2,159
10	3,285	2,924	2,728	2,605	2,522	2,461	2,414	2,377	2,347	2,323	2,284	2,244	2,201	2,178	2,155	2,132	2,107	2,082	2,055
11	3,225	2,860	2,660	2,536	2,451	2,389	2,342	2,304	2,274	2,248	2,209	2,167	2,123	2,100	2,076	2,052	2,026	2,000	1,972
12	3,177	2,807	2,606	2,480	2,394	2,331	2,283	2,245	2,214	2,188	2,147	2,105	2,060	2,036	2,011	1,986	1,960	1,932	1,904
13	3,136	2,763	2,560	2,434	2,347	2,283	2,234	2,195	2,164	2,138	2,097	2,053	2,007	1,983	1,958	1,931	1,904	1,876	1,848
14	3,102	2,726	2,522	2,395	2,307	2,243	2,193	2,154	2,122	2,095	2,054	2,010	1,962	1,938	1,912	1,885	1,857	1,828	1,797
15	3,073	2,695	2,490	2,361	2,273	2,208	2,158	2,119	2,086	2,059	2,017	1,972	1,924	1,899	1,873	1,845	1,817	1,787	1,755
16	3,048	2,668	2,462	2,333	2,244	2,178	2,128	2,088	2,055	2,028	1,985	1,940	1,891	1,866	1,839	1,811	1,782	1,751	1,718
17	3,026	2,645	2,437	2,308	2,218	2,152	2,102	2,061	2,028	2,001	1,958	1,912	1,862	1,836	1,809	1,781	1,751	1,719	1,686
18	3,007	2,624	2,416	2,286	2,196	2,130	2,079	2,038	2,005	1,977	1,933	1,887	1,837	1,810	1,783	1,754	1,723	1,691	1,657
19	2,990	2,606	2,397	2,266	2,176	2,109	2,058	2,017	1,984	1,956	1,912	1,865	1,814	1,787	1,759	1,730	1,699	1,666	1,631
20	2,975	2,589	2,380	2,249	2,158	2,091	2,040	1,999	1,965	1,937	1,892	1,845	1,794	1,767	1,738	1,708	1,677	1,643	1,607
21	2,961	2,575	2,365	2,233	2,142	2,075	2,023	1,982	1,948	1,920	1,875	1,827	1,776	1,748	1,719	1,689	1,657	1,623	1,586
22	2,949	2,561	2,351	2,219	2,128	2,061	2,008	1,967	1,933	1,904	1,859	1,811	1,759	1,731	1,702	1,671	1,639	1,604	1,567
23	2,937	2,549	2,339	2,207	2,115	2,047	1,995	1,953	1,919	1,890	1,845	1,796	1,744	1,716	1,686	1,655	1,622	1,587	1,549
24	2,927	2,538	2,327	2,195	2,103	2,035	1,983	1,941	1,906	1,877	1,832	1,783	1,730	1,702	1,672	1,641	1,607	1,571	1,533
25	2,918	2,528	2,317	2,184	2,092	2,024	1,971	1,929	1,895	1,866	1,820	1,771	1,718	1,689	1,659	1,627	1,593	1,557	1,518
26	2,909	2,519	2,307	2,174	2,082	2,014	1,961	1,919	1,884	1,855	1,809	1,760	1,706	1,677	1,647	1,615	1,581	1,544	1,504
27	2,901	2,511	2,299	2,165	2,073	2,005	1,952	1,909	1,874	1,845	1,799	1,749	1,695	1,666	1,636	1,603	1,569	1,531	1,491
28	2,894	2,503	2,291	2,157	2,064	1,996	1,943	1,900	1,865	1,836	1,790	1,740	1,685	1,656	1,625	1,593	1,558	1,520	1,478
29	2,887	2,495	2,283	2,149	2,057	1,988	1,935	1,892	1,857	1,827	1,781	1,731	1,676	1,647	1,616	1,583	1,547	1,509	1,467
30	2,881	2,489	2,276	2,142	2,049	1,980	1,927	1,884	1,849	1,819	1,773	1,722	1,667	1,638	1,606	1,573	1,538	1,499	1,456
40	2,835	2,440	2,226	2,091	1,997	1,927	1,873	1,829	1,793	1,763	1,715	1,662	1,605	1,574	1,541	1,506	1,467	1,425	1,377
60	2,791	2,393	2,177	2,041	1,946	1,875	1,819	1,775	1,738	1,707	1,657	1,603	1,543	1,511	1,476	1,437	1,395	1,348	1,291
120	2,748	2,347	2,130	1,992	1,896	1,824	1,767	1,722	1,684	1,652	1,601	1,545	1,482	1,447	1,409	1,368	1,320	1,265	1,193
∞	2,706	2,303	2,084	1,945	1,847	1,774	1,717	1,670	1,632	1,599	1,546	1,487	1,421	1,383	1,342	1,295	1,240	1,169	1,000

Tabella para A = 0,05 ou 5%

v_2/v_1	1	2	3	4	5	6	7	8	9	10	12	15	20	24	30	40	60	120	∞
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9	243,9	245,9	248,0	249,1	250,1	251,1	252,2	253,3	254,3
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40	19,41	19,43	19,45	19,45	19,46	19,47	19,48	19,49	19,50
3	10,13	9,552	9,277	9,117	9,014	8,941	8,887	8,845	8,812	8,786	8,745	8,703	8,660	8,639	8,617	8,594	8,572	8,549	8,526
4	7,709	6,944	6,591	6,388	6,256	6,163	6,094	6,041	5,999	5,964	5,912	5,858	5,803	5,774	5,746	5,717	5,688	5,658	5,628
5	6,608	5,786	5,410	5,192	5,050	4,950	4,876	4,818	4,773	4,735	4,678	4,619	4,558	4,527	4,496	4,464	4,431	4,399	4,365
6	5,987	5,143	4,757	4,534	4,387	4,284	4,207	4,147	4,099	4,060	4,000	3,938	3,874	3,842	3,808	3,774	3,740	3,705	3,669
7	5,591	4,737	4,347	4,120	3,972	3,868	3,787	3,726	3,677	3,637	3,575	3,511	3,445	3,411	3,376	3,340	3,304	3,267	3,230
8	5,318	4,459	4,066	3,838	3,688	3,581	3,501	3,438	3,388	3,347	3,284	3,218	3,150	3,115	3,079	3,043	3,005	2,967	2,928
9	5,117	4,257	3,863	3,633	3,482	3,374	3,293	3,230	3,179	3,137	3,073	3,006	2,937	2,901	2,864	2,826	2,787	2,748	2,707
10	4,985	4,103	3,708	3,478	3,326	3,217	3,136	3,072	3,020	2,978	2,913	2,845	2,774	2,737	2,700	2,661	2,621	2,580	2,538
11	4,844	3,982	3,587	3,357	3,204	3,095	3,012	2,948	2,896	2,854	2,788	2,719	2,646	2,609	2,571	2,531	2,490	2,448	2,405
12	4,747	3,885	3,490	3,259	3,106	2,996	2,913	2,849	2,796	2,753	2,687	2,617	2,544	2,506	2,466	2,426	2,384	2,341	2,296
13	4,667	3,806	3,411	3,179	3,025	2,915	2,832	2,767	2,714	2,671	2,604	2,533	2,459	2,420	2,380	2,339	2,297	2,252	2,206
14	4,600	3,739	3,344	3,112	2,958	2,848	2,764	2,699	2,646	2,602	2,534	2,463	2,388	2,349	2,308	2,266	2,223	2,178	2,131
15	4,543	3,682	3,287	3,056	2,901	2,791	2,707	2,641	2,588	2,544	2,475	2,403	2,328	2,288	2,247	2,204	2,160	2,114	2,066
16	4,494	3,634	3,239	3,007	2,852	2,741	2,657	2,591	2,538	2,494	2,425	2,352	2,276	2,235	2,194	2,151	2,106	2,059	2,010
17	4,451	3,592	3,197	2,965	2,810	2,699	2,614	2,548	2,494	2,450	2,381	2,308	2,230	2,190	2,148	2,104	2,058	2,011	1,960
18	4,414	3,555	3,160	2,928	2,773	2,661	2,577	2,510	2,456	2,412	2,342	2,269	2,191	2,150	2,107	2,063	2,017	1,968	1,917
19	4,381	3,522	3,127	2,895	2,740	2,628	2,544	2,477	2,423	2,378	2,308	2,234	2,156	2,114	2,071	2,026	1,980	1,930	1,878
20	4,351	3,493	3,098	2,866	2,711	2,599	2,514	2,447	2,393	2,348	2,278	2,203	2,124	2,083	2,039	1,994	1,946	1,896	1,843
21	4,325	3,467	3,073	2,840	2,685	2,573	2,488	2,421	2,366	2,321	2,250	2,176	2,096	2,054	2,010	1,965	1,917	1,866	1,812
22	4,301	3,443	3,049	2,817	2,661	2,549	2,464	2,397	2,342	2,297	2,226	2,151	2,071	2,028	1,984	1,938	1,889	1,838	1,783
23	4,279	3,422	3,028	2,796	2,640	2,528	2,442	2,375	2,320	2,275	2,204	2,128	2,048	2,005	1,961	1,914	1,865	1,813	1,757
24	4,260	3,403	3,009	2,776	2,621	2,508	2,423	2,355	2,300	2,255	2,183	2,108	2,027	1,984	1,939	1,892	1,842	1,790	1,733
25	4,242	3,385	2,991	2,759	2,603	2,490	2,405	2,337	2,282	2,237	2,165	2,089	2,008	1,964	1,919	1,872	1,822	1,768	1,711
26	4,225	3,369	2,975	2,743	2,587	2,474	2,388	2,321	2,266	2,220	2,148	2,072	1,990	1,946	1,901	1,853	1,803	1,749	1,691
27	4,210	3,354	2,960	2,728	2,572	2,459	2,373	2,305	2,250	2,204	2,132	2,056	1,974	1,930	1,884	1,836	1,785	1,731	1,672
28	4,196	3,340	2,947	2,714	2,558	2,445	2,359	2,291	2,236	2,190	2,118	2,041	1,959	1,915	1,869	1,820	1,769	1,714	1,654
29	4,183	3,328	2,934	2,701	2,545	2,432	2,346	2,278	2,223	2,177	2,105	2,028	1,945	1,901	1,854	1,806	1,754	1,698	1,638
30	4,171	3,316	2,922	2,690	2,534	2,421	2,334	2,266	2,211	2,165	2,092	2,015	1,932	1,887	1,841	1,792	1,740	1,684	1,622
40	4,085	3,232	2,839	2,606	2,450	2,336	2,249	2,180	2,124	2,077	2,004	1,925	1,839	1,793	1,744	1,693	1,637	1,577	1,509
60	4,001	3,150	2,758	2,525	2,368	2,254	2,167	2,097	2,040	1,993	1,917	1,836	1,748	1,700	1,649	1,594	1,534	1,467	1,389
120	3,920	3,072	2,680	2,447	2,290	2,175	2,087	2,016	1,959	1,911	1,834	1,751	1,659	1,608	1,554	1,495	1,429	1,352	1,254
∞	3,842	2,996	2,605	2,372	2,214	2,099	2,010	1,938	1,880	1,831	1,752	1,666	1,571	1,517	1,459	1,394	1,318	1,221	1,000

Tabela para A = 0,01 ou 1%

v_2/v_1	1	2	3	4	5	6	7	8	9	10	12	15	20	24	30	40	60	120	∞
1	4052	5000	5403	5625	5784	5859	5928	5981	6022	6058	6108	6157	6209	6235	6261	6287	6313	6339	6368
2	98,50	99,00	99,17	99,25	99,30	99,33	99,36	99,37	99,39	99,40	99,42	99,43	99,45	99,46	99,47	99,47	99,48	99,49	99,50
3	34,12	30,82	29,46	28,71	28,24	27,91	27,67	27,49	27,35	27,23	27,05	26,87	26,69	26,60	26,51	26,41	26,32	26,22	26,13
4	21,20	18,00	16,69	15,98	15,52	15,21	14,98	14,80	14,66	14,55	14,37	14,20	14,02	13,93	13,84	13,75	13,65	13,56	13,46
5	16,26	13,27	12,06	11,39	10,97	10,67	10,46	10,29	10,16	10,05	9,888	9,722	9,553	9,466	9,379	9,291	9,202	9,112	9,020
6	13,75	10,93	9,780	9,148	8,746	8,466	8,260	8,102	7,976	7,874	7,718	7,559	7,396	7,313	7,229	7,143	7,057	6,969	6,880
7	12,25	9,547	8,451	7,847	7,460	7,191	6,993	6,840	6,719	6,620	6,469	6,314	6,155	6,074	5,992	5,908	5,824	5,737	5,650
8	11,26	8,649	7,591	7,006	6,632	6,371	6,178	6,029	5,911	5,814	5,667	5,515	5,359	5,279	5,198	5,116	5,032	4,946	4,859
9	10,56	8,022	6,992	6,422	6,057	5,802	5,613	5,467	5,351	5,257	5,111	4,962	4,808	4,729	4,649	4,567	4,483	4,398	4,311
10	10,04	7,559	6,552	5,994	5,636	5,386	5,200	5,057	4,942	4,849	4,706	4,558	4,405	4,327	4,247	4,165	4,082	3,996	3,909
11	9,646	7,206	6,217	5,668	5,316	5,069	4,886	4,744	4,632	4,539	4,397	4,251	4,099	4,021	3,941	3,860	3,776	3,690	3,602
12	9,330	6,927	5,953	5,412	5,064	4,821	4,640	4,499	4,388	4,296	4,155	4,010	3,858	3,780	3,701	3,619	3,535	3,449	3,361
13	9,074	6,701	5,739	5,205	4,862	4,620	4,441	4,302	4,191	4,100	3,960	3,815	3,665	3,587	3,507	3,425	3,341	3,255	3,165
14	8,862	6,515	5,564	5,035	4,695	4,456	4,278	4,140	4,030	3,939	3,800	3,656	3,505	3,427	3,348	3,266	3,181	3,094	3,004
15	8,683	6,359	5,417	4,893	4,556	4,318	4,142	4,004	3,895	3,805	3,666	3,522	3,372	3,294	3,214	3,132	3,047	2,959	2,868
16	8,531	6,226	5,292	4,773	4,437	4,202	4,026	3,890	3,780	3,691	3,553	3,409	3,259	3,181	3,101	3,018	2,933	2,845	2,753
17	8,400	6,112	5,185	4,669	4,336	4,102	3,927	3,791	3,682	3,593	3,455	3,312	3,162	3,084	3,003	2,920	2,835	2,746	2,653
18	8,285	6,013	5,092	4,579	4,248	4,015	3,841	3,705	3,597	3,508	3,371	3,227	3,077	2,999	2,919	2,835	2,749	2,660	2,566
19	8,185	5,926	5,010	4,500	4,171	3,939	3,765	3,631	3,523	3,434	3,297	3,153	3,003	2,925	2,844	2,761	2,674	2,584	2,489
20	8,096	5,849	4,938	4,431	4,103	3,871	3,699	3,564	3,457	3,368	3,231	3,088	2,938	2,859	2,778	2,695	2,608	2,517	2,421
21	8,017	5,780	4,874	4,369	4,042	3,812	3,640	3,506	3,398	3,310	3,173	3,030	2,880	2,801	2,720	2,636	2,548	2,457	2,360
22	7,945	5,719	4,817	4,313	3,988	3,758	3,587	3,453	3,346	3,258	3,121	2,978	2,827	2,749	2,667	2,583	2,495	2,403	2,305
23	7,881	5,664	4,765	4,264	3,939	3,710	3,539	3,406	3,299	3,211	3,074	2,931	2,781	2,702	2,620	2,535	2,447	2,354	2,256
24	7,823	5,614	4,718	4,218	3,895	3,667	3,496	3,363	3,256	3,168	3,032	2,889	2,738	2,659	2,577	2,492	2,403	2,310	2,211
25	7,770	5,568	4,675	4,177	3,855	3,627	3,457	3,324	3,217	3,129	2,993	2,850	2,699	2,620	2,538	2,453	2,364	2,270	2,169
26	7,721	5,526	4,637	4,140	3,818	3,591	3,421	3,288	3,182	3,094	2,958	2,815	2,664	2,585	2,503	2,417	2,327	2,233	2,131
27	7,677	5,488	4,601	4,106	3,785	3,558	3,388	3,256	3,149	3,062	2,926	2,783	2,632	2,552	2,470	2,384	2,294	2,198	2,097
28	7,636	5,453	4,568	4,074	3,754	3,528	3,358	3,226	3,120	3,032	2,896	2,753	2,602	2,522	2,440	2,354	2,263	2,167	2,064
29	7,598	5,420	4,538	4,045	3,725	3,499	3,330	3,198	3,092	3,005	2,868	2,726	2,574	2,495	2,412	2,325	2,234	2,138	2,034
30	7,562	5,390	4,510	4,018	3,699	3,473	3,304	3,173	3,067	2,979	2,843	2,700	2,549	2,469	2,386	2,299	2,208	2,111	2,006
40	7,314	5,179	4,313	3,828	3,514	3,291	3,124	2,993	2,888	2,801	2,665	2,522	2,369	2,288	2,203	2,114	2,019	1,917	1,805
60	7,077	4,977	4,126	3,649	3,339	3,119	2,953	2,823	2,718	2,632	2,496	2,352	2,198	2,115	2,028	1,936	1,836	1,726	1,601
120	6,851	4,787	3,949	3,480	3,174	2,956	2,792	2,663	2,559	2,472	2,336	2,192	2,035	1,950	1,860	1,763	1,656	1,533	1,381
∞	6,635	4,605	3,782	3,319	3,017	2,802	2,639	2,511	2,407	2,321	2,185	2,039	1,878	1,791	1,696	1,592	1,473	1,325	1,000

- ANEXO C -

BDP1 – Base de Dados Primária 1
Consumo de Energia Elétrica de Segmentos Indústrias de SC

<< Valores Mensais de julho/1996 a dezembro/2006>>
<< Gráficos do Consumo e da Tendência do Consumo de Energia Elétrica dos Segmentos Têxtil e Metalúrgico>>

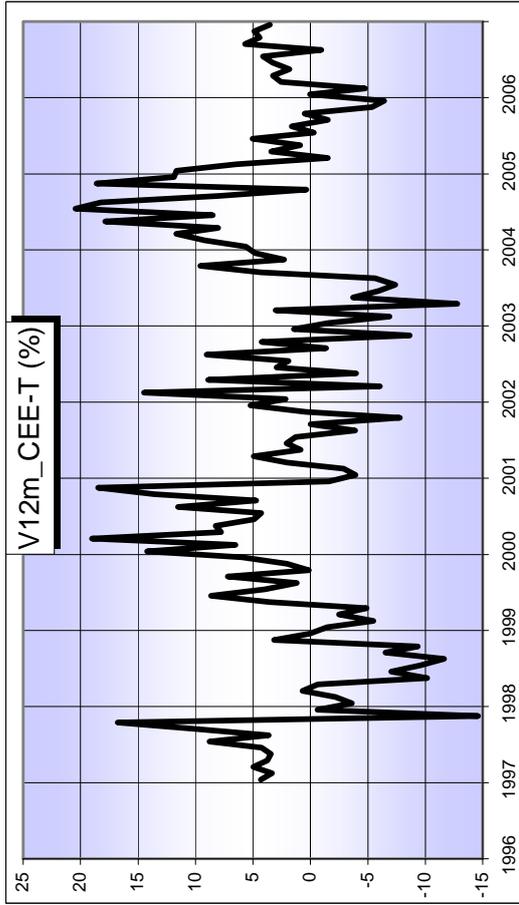
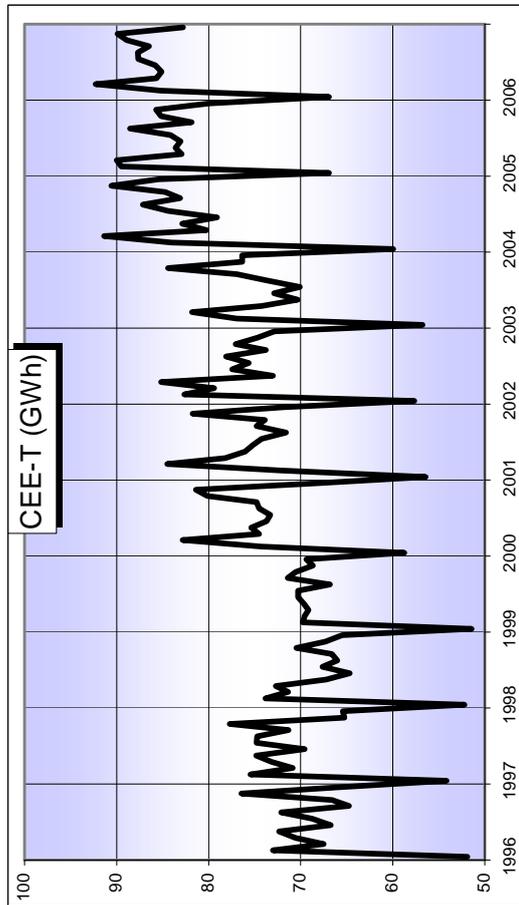
Consumo Mensal de Energia Elétrica por Segmento Industrial de SC (GWh)

	Alimentos	Textil	Metalurgia	Celulose
jul/96	64.3	68.8	33.3	35.0
ago/96	67.2	72.1	36.3	38.5
set/96	62.9	64.8	34.1	24.0
out/96	60.2	66.6	31.7	34.0
nov/96	70.2	76.4	36.7	37.3
dez/96	65.5	65.8	30.5	34.0
jan/97	66.5	54.2	23.3	35.2
fev/97	69.2	75.5	37.5	36.7
mar/97	65.1	70.9	35.1	34.2
abr/97	72.0	73.2	38.6	41.4
mai/97	67.5	74.9	39.5	37.1
jun/97	65.3	69.6	36.9	34.8
jul/97	70.5	74.8	39.6	35.3
ago/97	68.7	74.7	41.2	35.6
set/97	69.1	71.3	40.0	35.1
out/97	71.6	77.7	44.2	38.3
nov/97	66.3	65.3	38.0	33.6
dez/97	74.3	65.4	37.1	37.7
jan/98	68.4	52.2	30.3	31.9
fev/98	75.9	73.8	40.6	34.7
mar/98	71.4	71.4	38.1	34.3
abr/98	72.8	72.7	39.9	36.7
mai/98	70.4	67.3	38.5	35.9
jun/98	70.5	64.7	39.8	42.6
jul/98	73.9	67.6	43.7	45.7
ago/98	72.1	66.0	43.2	41.2
set/98	71.7	66.6	40.8	43.0
out/98	72.3	70.5	35.4	42.3
nov/98	72.2	67.3	33.7	40.9
dez/98	76.0	65.5	30.8	47.2
jan/99	68.9	51.4	25.5	37.4
fev/99	76.1	69.8	38.5	39.3
mar/99	79.5	69.6	37.6	40.8
abr/99	75.8	69.2	39.2	40.0
mai/99	76.4	69.7	39.3	43.1
jun/99	73.0	70.3	38.4	43.0
jul/99	76.8	70.3	43.7	42.0
ago/99	75.6	66.8	41.8	42.3
set/99	78.7	71.4	42.1	44.1
out/99	77.3	70.6	37.6	39.7
nov/99	74.7	68.7	38.6	38.6
dez/99	82.8	69.4	38.7	45.6
jan/00	78.2	58.7	26.8	40.4
fev/00	80.1	74.3	41.8	38.4
mar/00	89.0	82.8	43.6	43.0
abr/00	84.7	74.5	42.7	40.4
mai/00	82.7	75.4	42.8	42.9
jun/00	81.0	73.7	43.8	43.2
jul/00	80.6	73.3	44.4	43.8
ago/00	80.2	74.5	45.5	48.0
set/00	81.2	74.8	42.5	46.6
out/00	84.7	80.1	45.6	46.0
nov/00	88.5	81.4	46.7	48.2
dez/00	85.3	68.3	40.5	46.8
jan/01	83.1	56.4	27.6	47.8
fev/01	80.4	72.2	41.1	46.8
mar/01	99.0	84.5	47.7	53.2
abr/01	95.3	78.2	47.2	54.9
mai/01	88.7	76.0	45.6	52.7
jun/01	91.6	75.2	47.1	55.0
jul/01	91.1	74.3	47.9	56.6
ago/01	86.6	71.6	42.0	51.6
set/01	88.6	74.8	43.8	53.5
out/01	78.6	73.9	41.8	51.6
nov/01	97.0	81.7	46.2	56.1
dez/01	87.5	71.8	42.4	51.8

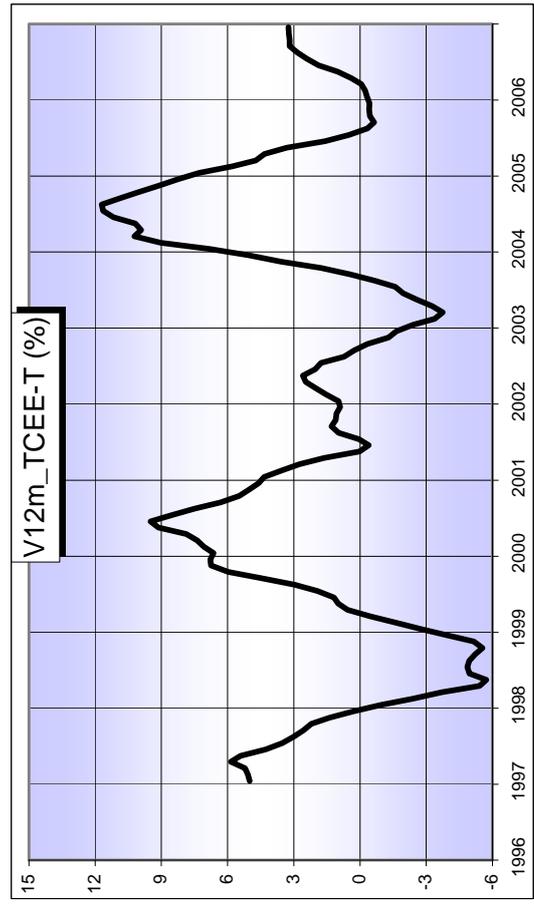
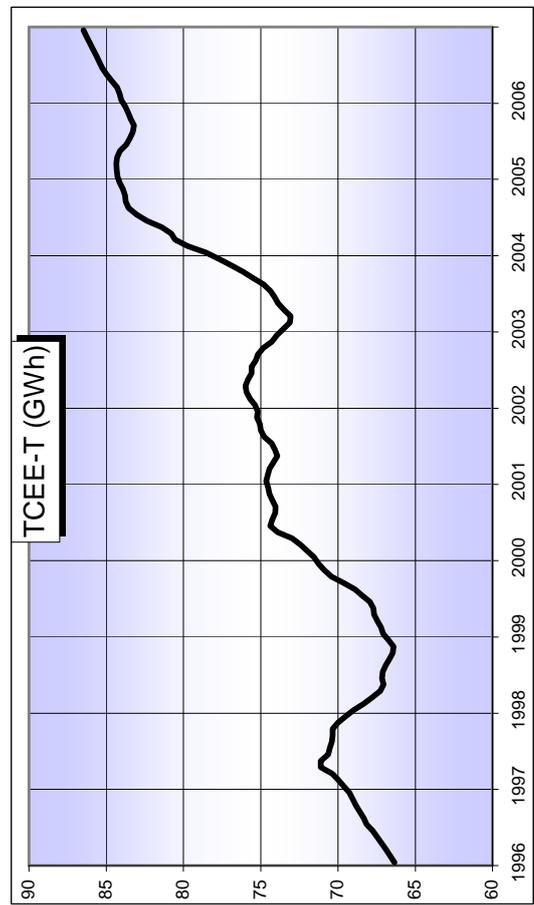
	Alimentos	Textil	Metalurgia	Celulose
jan/02	89.1	57.7	33.2	58.0
fev/02	94.9	82.6	47.1	55.9
mar/02	93.6	79.4	46.4	54.1
abr/02	100.8	85.2	50.6	62.3
mai/02	90.0	73.0	46.8	54.0
jun/02	94.9	77.5	50.6	60.2
jul/02	95.7	75.7	47.3	59.6
ago/02	96.0	78.1	50.0	59.1
set/02	89.8	73.8	45.2	52.9
out/02	96.6	77.0	49.2	55.5
nov/02	91.1	74.7	47.1	52.9
dez/02	90.0	72.9	46.0	48.8
jan/03	96.2	56.8	32.8	58.4
fev/03	99.3	77.0	51.7	56.4
mar/03	102.7	81.8	55.6	56.2
abr/03	93.2	74.3	52.8	57.4
mai/03	91.3	70.3	49.5	55.5
jun/03	94.8	72.9	52.6	59.3
jul/03	93.9	70.1	51.5	57.1
ago/03	88.4	73.7	49.1	62.0
set/03	91.1	77.0	52.6	68.2
out/03	97.8	84.4	54.9	68.1
nov/03	88.1	76.4	49.1	61.8
dez/03	99.6	76.4	50.8	67.0
jan/04	102.1	60.0	36.3	64.4
fev/04	103.2	84.0	55.0	59.8
mar/04	112.7	91.4	58.6	70.8
abr/04	100.2	80.2	53.9	66.9
mai/04	103.6	82.9	59.0	69.0
jun/04	97.4	79.1	56.6	63.9
jul/04	99.5	84.4	58.5	67.2
ago/04	97.5	87.1	60.3	70.0
set/04	94.2	83.1	56.5	64.6
out/04	98.0	84.7	56.1	66.6
nov/04	101.4	90.6	60.9	67.1
dez/04	105.5	85.4	55.8	64.4
jan/05	102.4	66.9	46.5	65.5
fev/05	108.1	89.5	59.1	63.8
mar/05	113.5	90.0	61.3	73.2
abr/05	111.8	83.0	55.8	72.2
mai/05	110.1	83.6	59.4	73.1
jun/05	110.4	83.1	59.6	69.5
jul/05	112.6	84.2	59.3	66.3
ago/05	111.6	88.5	61.8	67.0
set/05	102.0	81.8	56.3	64.0
out/05	106.7	85.2	59.2	68.9
nov/05	108.5	85.7	60.0	65.3
dez/05	114.7	80.0	52.0	66.0
jan/06	109.9	67.0	49.7	65.6
fev/06	110.9	85.2	57.7	62.3
mar/06	119.2	92.3	62.7	68.8
abr/06	108.6	85.7	56.5	68.3
mai/06	102.8	85.1	61.5	70.7
jun/06	105.8	85.8	59.8	72.6
jul/06	108.2	87.6	58.9	78.0
ago/06	107.7	87.7	61.7	76.5
set/06	105.9	86.5	57.5	70.9
out/06	111.8	88.9	59.3	73.8
nov/06	112.4	89.9	60.8	72.3
dez/06	114.9	82.8	49.2	71.0

Fonte: Celesc Distribuição S.A.

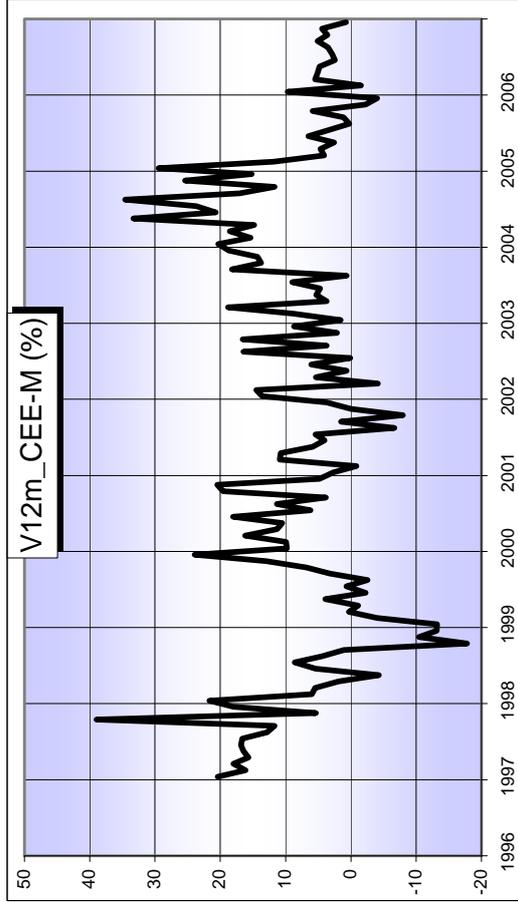
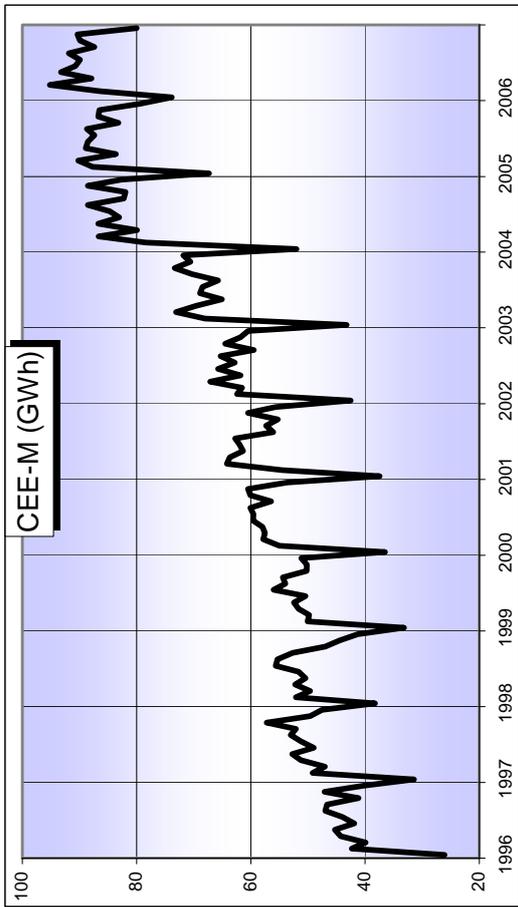
CONSUMO DE ENERGIA ELÉTRICA - SEGMENTO TÊXTIL



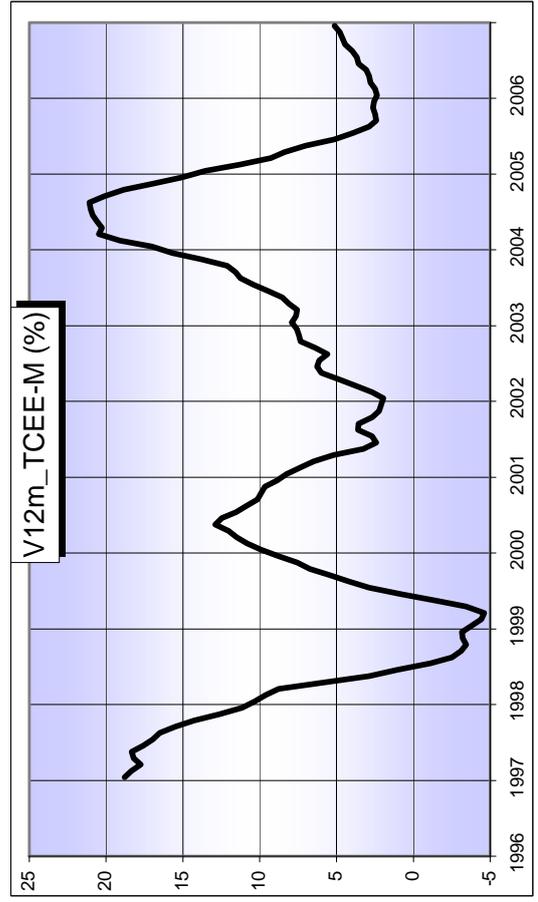
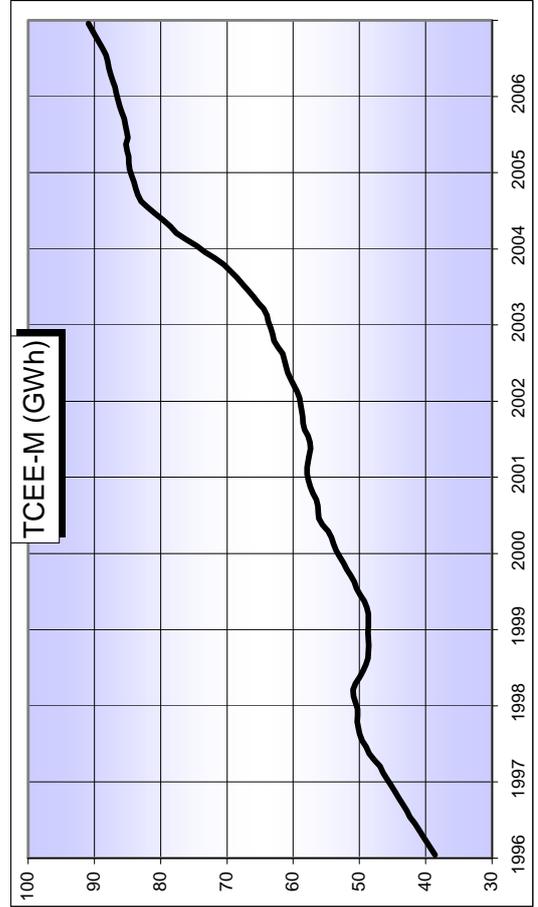
TENDÊNCIA DO CONSUMO DE ENERGIA ELÉTRICA - SEGMENTO TÊXTIL



CONSUMO DE ENERGIA ELÉTRICA - SEGMENTO METALÚRGICO



TENDÊNCIA DO CONSUMO DE ENERGIA ELÉTRICA - SEGMENTO METALÚRGICO



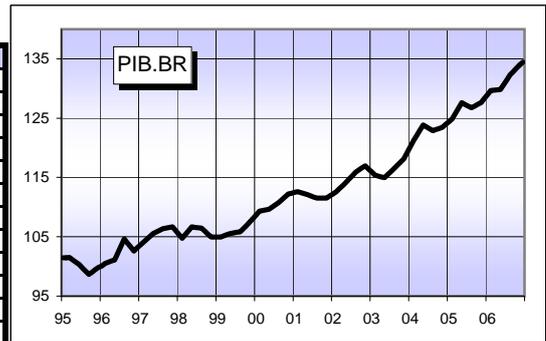
- ANEXO D -

BDP2 – Base de Dados Primária 2
Séries Históricas das Variáveis Econômicas

<< Valores Mensais de janeiro/1995 a dezembro/2006>>
<< Gráficos dos Valores Originais e Transformados>>

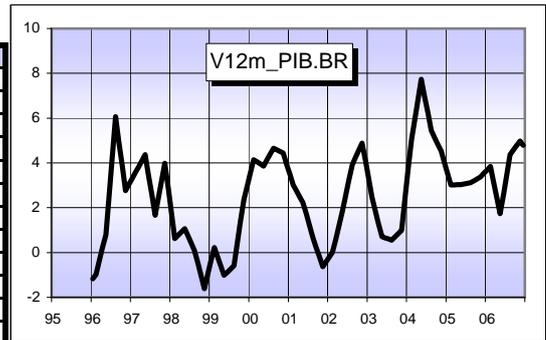
PIB.BR - Produto Interno Bruto Brasileiro Trimestral e Dessazonalizado (Núm. Índice 1995=100) - IBGE

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	101.5	101.5	101.5	101.1	100.7	100.3	99.75	99.19	98.64	99.04	99.45	99.86
1996	100.1	100.5	100.7	100.9	101.1	102.3	103.4	104.6	103.9	103.3	102.6	103.1
1997	103.6	104.1	104.6	105.0	105.5	105.8	106.1	106.4	106.5	106.6	106.7	106.0
1998	105.4	104.7	105.4	106.0	106.7	106.6	106.5	106.5	106.0	105.5	105.0	105.0
1999	105.0	105.0	105.2	105.4	105.6	105.7	105.7	105.8	106.4	106.9	107.5	108.1
2000	108.7	109.3	109.4	109.5	109.6	110.0	110.4	110.8	111.3	111.7	112.2	112.4
2001	112.5	112.6	112.4	112.3	112.1	111.9	111.7	111.5	111.5	111.5	111.5	111.9
2002	112.3	112.6	113.1	113.6	114.2	114.7	115.3	115.9	116.3	116.6	117.0	116.4
2003	115.9	115.4	115.2	115.1	115.0	115.5	116.0	116.5	117.1	117.6	118.1	119.2
2004	120.2	121.2	122.1	123.0	123.9	123.5	123.2	122.9	123.1	123.3	123.5	123.9
2005	124.4	124.9	125.8	126.7	127.6	127.3	127.0	126.7	127.0	127.3	127.6	128.3
2006	129.0	129.7	129.7	129.8	129.8	130.6	131.5	132.3	132.8	133.4	134.0	134.4



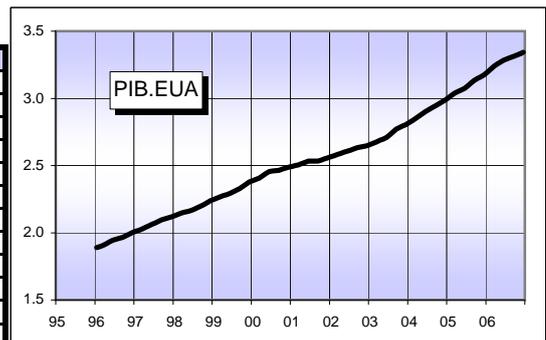
V12m_PIB.BR - Variação do Produto Interno Bruto Brasileiro Trimestral e Dessazonalizado em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-1.2	-1.0	-0.4	0.2	0.8	2.6	4.3	6.1	5.0	3.9	2.8	3.0
1997	3.3	3.6	3.8	4.1	4.4	3.5	2.6	1.7	2.4	3.2	4.0	2.9
1998	1.7	0.6	0.8	0.9	1.1	0.7	0.4	0.1	-0.5	-1.0	-1.6	-1.0
1999	-0.4	0.2	-0.2	-0.6	-1.0	-0.9	-0.7	-0.6	0.4	1.4	2.4	3.0
2000	3.6	4.1	4.1	4.0	3.9	4.1	4.4	4.7	4.6	4.5	4.4	4.0
2001	3.5	3.0	2.8	2.5	2.2	1.7	1.2	0.7	0.2	-0.2	-0.6	-0.4
2002	-0.2	0.0	0.6	1.2	1.8	2.5	3.2	3.9	4.3	4.6	4.9	4.1
2003	3.3	2.5	1.9	1.3	0.7	0.6	0.6	0.7	0.8	1.0	2.3	
2004	3.7	5.0	5.9	6.8	7.7	7.0	6.2	5.5	5.1	4.8	4.5	4.0
2005	3.5	3.0	3.0	3.0	3.0	3.1	3.1	3.1	3.2	3.3	3.4	3.5
2006	3.7	3.8	3.1	2.4	1.7	2.6	3.5	4.4	4.6	4.8	5.0	4.8



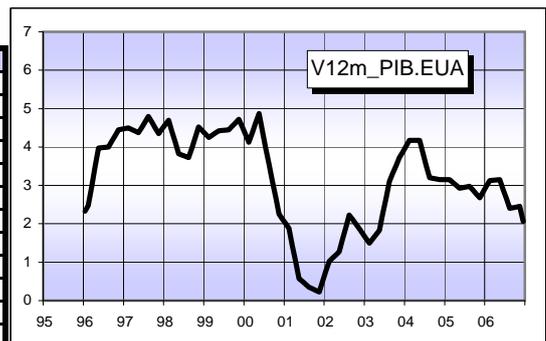
PIB.EUA - Produto Interno Bruto Norte-Americano Trimestral e Anualizado (US\$ trilhões) - Fundo Monetário Internacional

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	1.9	1.9	1.9	1.9	1.9	1.9	2.0	2.0	2.0	2.0	2.0	2.0
1997	2.0	2.0	2.0	2.0	2.1	2.1	2.1	2.1	2.1	2.1	2.1	2.1
1998	2.1	2.1	2.1	2.2	2.2	2.2	2.2	2.2	2.2	2.2	2.2	2.2
1999	2.2	2.3	2.3	2.3	2.3	2.3	2.3	2.3	2.3	2.3	2.4	2.4
2000	2.4	2.4	2.4	2.4	2.4	2.5	2.5	2.5	2.5	2.5	2.5	2.5
2001	2.5	2.5	2.5	2.5	2.5	2.5	2.5	2.5	2.5	2.5	2.5	2.6
2002	2.6	2.6	2.6	2.6	2.6	2.6	2.6	2.6	2.6	2.6	2.6	2.6
2003	2.7	2.7	2.7	2.7	2.7	2.7	2.7	2.8	2.8	2.8	2.8	2.8
2004	2.8	2.8	2.9	2.9	2.9	2.9	2.9	2.9	2.9	3.0	3.0	3.0
2005	3.0	3.0	3.0	3.1	3.1	3.1	3.1	3.1	3.1	3.1	3.2	3.2
2006	3.2	3.2	3.2	3.3	3.3	3.3	3.3	3.3	3.3	3.3	3.3	3.3



V12m_PIB.EUA - Variação do Produto Interno Bruto Norte-Americano Trimestral e Dessazonalizado em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	2.3	2.5	3.0	3.5	4.0	4.0	4.0	4.2	4.2	4.3	4.5	4.5
1997	4.5	4.5	4.5	4.4	4.4	4.5	4.7	4.8	4.7	4.5	4.4	4.5
1998	4.6	4.7	4.4	4.1	3.8	3.8	3.8	3.7	4.0	4.3	4.5	4.4
1999	4.3	4.3	4.3	4.4	4.4	4.4	4.4	4.5	4.5	4.6	4.7	4.5
2000	4.3	4.1	4.4	4.6	4.9	4.4	4.0	3.6	3.1	2.7	2.3	2.1
2001	2.0	1.9	1.4	1.0	0.6	0.5	0.4	0.4	0.3	0.3	0.2	0.5
2002	0.8	1.0	1.1	1.2	1.3	1.6	1.9	2.2	2.1	2.0	1.9	1.8
2003	1.6	1.5	1.6	1.7	1.8	2.3	2.7	3.1	3.3	3.5	3.7	3.9
2004	4.0	4.2	4.2	4.2	4.2	3.9	3.5	3.2	3.2	3.2	3.2	3.2
2005	3.2	3.2	3.1	3.0	2.9	2.9	3.0	3.0	2.9	2.8	2.7	2.8
2006	3.0	3.1	3.1	3.1	3.2	2.9	2.7	2.4	2.4	2.4	2.5	2.1



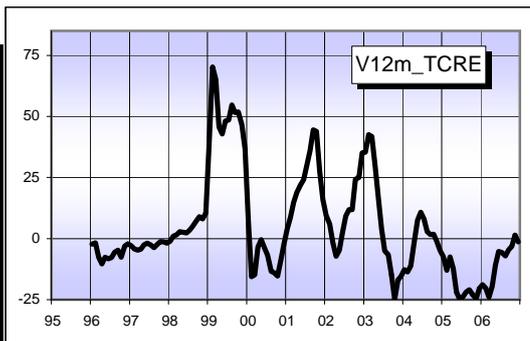
TCRE - Taxa de Câmbio Real Efetiva (Núm. Índice junho/1994=100) - BACEN

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	72.18	71.61	76.37	77.92	74.91	74.99	74.59	73.52	73.09	75.34	72.27	71.13
1996	70.5	70.4	70.6	69.9	69.2	68.8	68.9	69.5	69.6	69.6	70.1	69.6
1997	68.5	67.4	67.2	66.8	67.5	67.5	67.1	66.9	67.9	68.7	69.1	68.3
1998	67.7	68.1	68.2	68.7	69.2	69.1	69.5	70.3	72.7	74.9	74.6	75.4
1999	93.3	116.0	112.6	100.0	98.7	102.4	103.2	108.8	110.2	113.7	109.4	103.1
2000	100.5	97.9	95.9	96.6	98.2	98.6	96.2	94.2	94.8	96.2	99.6	100.9
2001	104.5	106.4	110.1	114.8	119.7	122.3	125.1	128.2	136.9	138.5	126.8	117.0
2002	114.4	112.8	108.2	106.5	114.1	125.5	136.6	143.4	153.1	172.0	158.6	158.0
2003	154.9	160.8	153.3	138.5	133.5	130.9	129.8	133.9	130.4	129.5	131.7	133.8
2004	135.1	138.9	136.3	135.7	143.6	145.0	140.2	137.7	132.5	131.8	130.0	127.4
2005	125.1	120.9	126.1	119.2	112.3	108.9	106.9	107.6	104.8	101.6	98.0	101.3
2006	101.5	96.3	95.9	95.9	100.0	103.1	100.8	100.0	100.0	98.4	99.4	100.0



V12m_TCRE - Variação da Taxa de Câmbio Real Efetiva em Relação ao Mesmo Período do Ano Anterior (%)

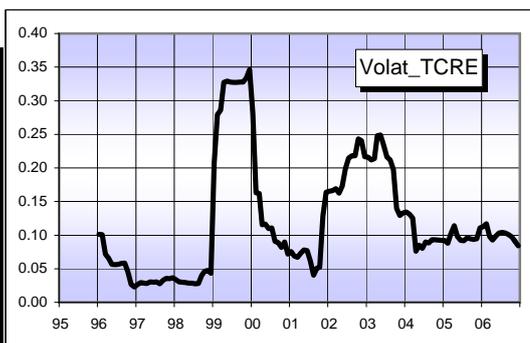
	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-2.3	-1.7	-7.6	-10.3	-7.6	-8.3	-7.7	-5.5	-4.8	-7.7	-3.0	-2.1
1997	-2.9	-4.2	-4.8	-4.4	-2.5	-1.9	-2.5	-3.7	-2.4	-1.2	-1.4	-1.8
1998	-1.1	1.1	1.5	2.8	2.5	2.4	3.5	5.2	7.1	9.0	8.0	10.3
1999	37.9	70.3	65.1	45.7	42.8	48.2	48.6	54.8	51.5	51.8	46.6	36.7
2000	7.7	-15.6	-14.8	-3.4	-0.5	-3.7	-6.8	-13.4	-14.0	-15.4	-9.0	-2.1
2001	3.9	8.7	14.8	18.8	21.9	24.1	30.0	36.1	44.5	43.9	27.4	15.9
2002	9.5	6.0	-1.8	-7.2	-4.7	2.6	9.2	11.8	11.9	24.2	25.0	35.1
2003	35.3	42.6	41.8	30.0	17.0	4.3	-5.0	-6.6	-14.9	-24.7	-17.0	-15.3
2004	-12.8	-13.6	-11.1	-2.0	7.5	10.8	8.0	2.8	1.7	1.7	-1.2	-4.8
2005	-7.4	-13.0	-7.5	-12.2	-21.8	-24.9	-23.8	-21.8	-20.9	-22.9	-24.7	-20.5
2006	-18.9	-20.3	-24.0	-19.6	-10.9	-5.3	-5.7	-7.1	-4.6	-3.2	1.4	-1.3



Volat_TCRE - Volatilidade da Taxa de Câmbio Real Efetiva equação de Black-Scholes

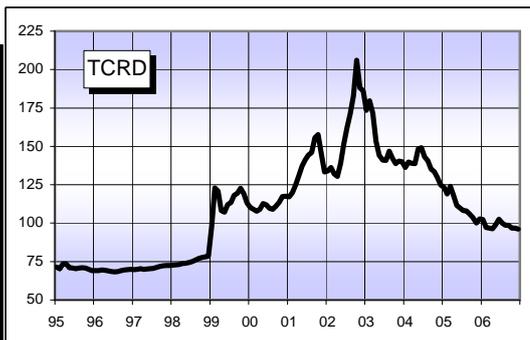
Obtida pela

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.10	0.10	0.07	0.07	0.06	0.06	0.06	0.06	0.06	0.05	0.03	0.02
1997	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.04	0.04	0.04
1998	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.04	0.05	0.05	0.04
1999	0.21	0.28	0.29	0.33	0.33	0.33	0.33	0.33	0.33	0.33	0.33	0.35
2000	0.28	0.16	0.16	0.12	0.12	0.11	0.11	0.09	0.09	0.08	0.09	0.07
2001	0.08	0.07	0.07	0.07	0.08	0.08	0.06	0.04	0.05	0.05	0.13	0.16
2002	0.17	0.17	0.17	0.16	0.17	0.20	0.21	0.22	0.22	0.24	0.24	0.22
2003	0.22	0.21	0.21	0.25	0.25	0.23	0.22	0.21	0.20	0.14	0.13	0.13
2004	0.13	0.13	0.13	0.08	0.09	0.08	0.09	0.09	0.09	0.09	0.09	0.09
2005	0.09	0.09	0.10	0.11	0.10	0.09	0.09	0.10	0.09	0.09	0.09	0.11
2006	0.11	0.12	0.10	0.09	0.10	0.10	0.10	0.10	0.10	0.10	0.09	0.08



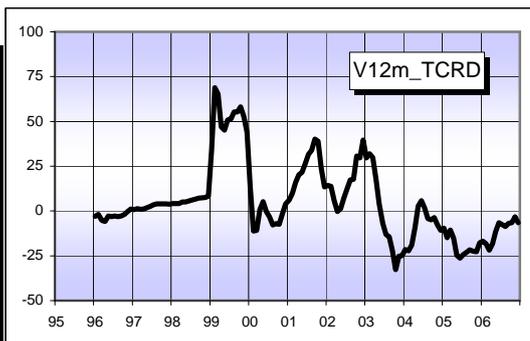
TCRD - Taxa de Câmbio Real-Dólar (Núm. Índice junho+A50/1994=100) - BACEN

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	71.33	70.39	73.52	73.55	70.91	70.8	70.3	70.77	71.03	70.79	70.01	69.17
1996	69.2	69.1	69.6	69.3	68.9	68.6	68.3	68.6	69.1	69.5	69.8	69.9
1997	69.7	70.0	70.3	70.0	70.2	70.3	70.7	71.3	71.8	72.2	72.5	72.5
1998	72.6	72.8	73.2	73.6	73.8	74.3	74.9	76.1	76.9	77.6	78.0	78.5
1999	97.3	122.9	120.9	108.1	107.1	112.1	113.4	118.1	119.4	122.7	119.2	113.1
2000	110.3	109.1	107.7	108.9	112.7	111.8	109.7	109.0	111.1	113.6	117.4	117.5
2001	117.1	119.9	124.9	130.8	137.1	141.3	144.4	146.0	155.6	157.7	145.1	133.4
2002	133.9	136.3	132.1	130.3	139.0	151.6	162.1	171.3	183.1	206.1	188.0	186.3
2003	173.5	179.8	171.5	153.3	144.2	141.0	140.8	146.8	142.3	138.7	140.4	140.1
2004	136.2	139.8	138.9	138.9	148.3	149.0	143.1	140.6	135.2	133.6	129.6	124.9
2005	123.3	118.9	124.0	118.0	111.6	109.9	108.3	108.1	106.0	103.6	100.2	102.8
2006	102.4	97.2	96.8	96.4	99.0	102.6	100.1	98.7	98.6	96.8	96.8	96.1



V12m_TCRD - Variação da Taxa de Câmbio Real-Dólar em Relação ao Mesmo Período do Ano Anterior (%)

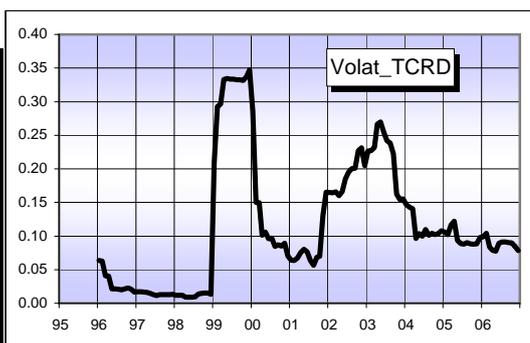
	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-3.0	-1.8	-5.4	-5.8	-2.8	-3.2	-2.8	-3.1	-2.7	-1.8	-0.3	1.1
1997	0.8	1.3	1.0	1.1	1.9	2.6	3.4	3.9	3.9	3.9	3.9	3.8
1998	4.1	4.1	4.1	5.1	5.1	5.7	6.0	6.7	7.2	7.4	7.6	8.2
1999	34.2	68.7	65.2	46.9	45.1	50.9	51.4	55.3	55.3	58.1	52.7	44.1
2000	13.4	-11.2	-10.9	0.8	5.2	-0.2	-3.3	-7.8	-7.0	-7.4	-1.5	3.9
2001	6.1	9.9	16.0	20.1	21.7	26.4	31.6	34.0	40.1	38.9	23.6	13.5
2002	14.3	13.7	5.8	-0.4	1.4	7.2	12.3	17.4	17.7	30.7	29.6	39.6
2003	29.6	31.9	29.8	17.7	3.7	-6.9	-13.2	-14.3	-22.3	-32.7	-25.3	-24.8
2004	-21.5	-22.2	-19.0	-9.4	2.8	5.7	1.7	-4.2	-4.9	-3.7	-7.7	-10.8
2005	-9.5	-15.0	-10.7	-15.0	-24.7	-26.3	-24.3	-23.1	-21.7	-22.4	-22.7	-17.7
2006	-16.9	-18.3	-21.9	-18.3	-11.3	-6.6	-7.6	-8.7	-7.0	-6.6	-3.4	-6.5



Volat_TCRD - Volatilidade da Taxa de Câmbio Real-Dólar equação de Black-Scholes

Obtida pela

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.06	0.06	0.04	0.04	0.02	0.02	0.02	0.02	0.02	0.02	0.02	0.02
1997	0.02	0.02	0.02	0.02	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01
1998	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.02	0.01	0.01
1999	0.21	0.29	0.30	0.33	0.33	0.33	0.33	0.33	0.33	0.33	0.34	0.35
2000	0.29	0.15	0.15	0.10	0.11	0.10	0.10	0.08	0.09	0.09	0.09	0.07
2001	0.06	0.06	0.07	0.08	0.08	0.08	0.06	0.06	0.07	0.07	0.13	0.17
2002	0.16	0.16	0.17	0.16	0.17	0.19	0.20	0.20	0.20	0.23	0.23	0.20
2003	0.23	0.23	0.23	0.27	0.27	0.25	0.24	0.24	0.22	0.16	0.15	0.16
2004	0.15	0.14	0.14	0.10	0.10	0.10	0.11	0.10	0.10	0.10	0.10	0.11
2005	0.11	0.10	0.12	0.12	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.10
2006	0.10	0.10	0.08	0.08	0.08	0.09	0.09	0.09	0.09	0.09	0.08	0.08



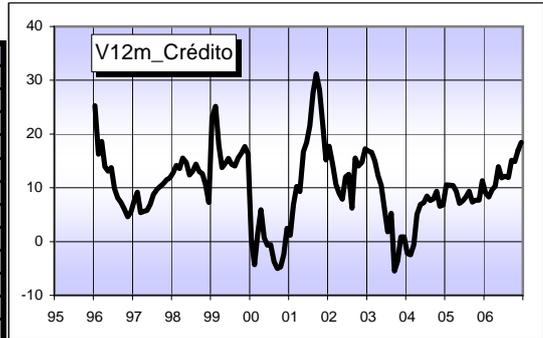
Crédito - Operações de Crédito ao Setor Privado - Indústria (R\$ milhões) - BACEN

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	44	47	48	50	51	51	52	53	54	55	56	57
1996	55	55	57	57	58	58	58	57	58	58	59	60
1997	60	60	60	61	61	62	63	63	64	64	65	67
1998	67	69	69	69	70	70	71	72	72	73	72	72
1999	83	86	81	79	80	81	81	82	83	84	85	84
2000	83	82	82	84	81	80	81	79	79	80	83	86
2001	84	88	91	91	94	95	98	101	104	103	101	99
2002	99	101	100	100	102	106	110	107	120	118	116	116
2003	116	117	115	112	112	113	112	113	113	113	117	117
2004	113	114	115	118	120	121	122	122	122	124	125	125
2005	125	126	127	129	129	130	132	133	131	134	134	139
2006	136	137	139	142	147	145	148	149	151	154	157	165



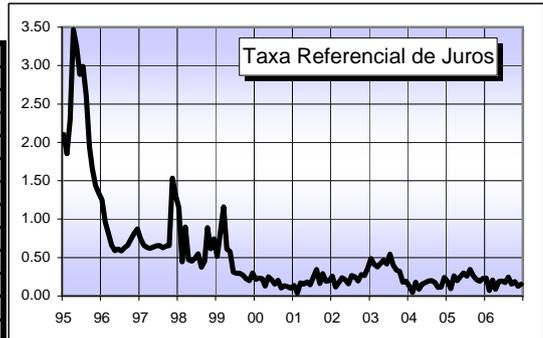
V12m_Crédito - Variação das Operações de Crédito ao Setor Privado - Indústria, em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	25.3	16.2	18.6	14.0	13.1	13.8	9.8	8.1	7.3	6.1	4.6	5.5
1997	7.6	9.2	5.4	5.6	5.8	6.9	8.8	9.7	10.2	10.8	11.5	11.8
1998	12.8	14.2	13.6	15.5	14.7	12.4	13.1	14.4	13.0	12.6	10.6	7.3
1999	23.0	25.2	17.9	13.7	14.5	15.5	14.3	14.1	15.5	16.4	17.7	16.3
2000	0.5	-4.3	1.5	5.9	0.7	-0.7	-0.5	-3.8	-5.0	-4.7	-2.4	2.5
2001	1.2	6.9	10.2	9.3	16.7	18.4	21.6	27.7	31.2	28.2	21.9	15.2
2002	17.7	14.4	10.7	9.0	7.9	12.0	12.5	6.2	15.5	14.0	14.8	17.3
2003	16.9	16.6	15.0	12.3	10.4	6.0	1.8	5.3	-5.5	-3.6	0.9	0.8
2004	-2.2	-2.5	-0.6	5.1	6.9	7.2	8.5	7.6	7.9	9.4	6.5	6.8
2005	10.5	10.5	10.5	9.4	7.1	7.6	8.3	9.4	7.3	7.7	7.7	11.3
2006	9.0	8.3	9.6	10.3	14.0	11.8	12.2	11.9	15.1	14.9	17.0	18.4



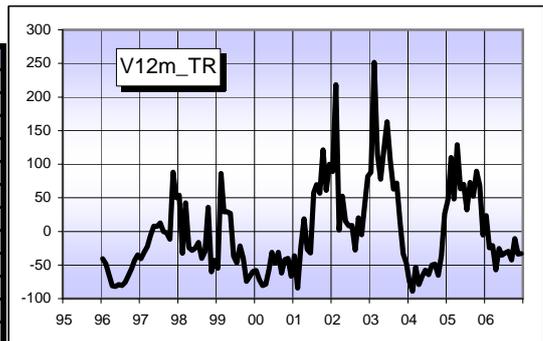
TR - Taxa Referencial de Juros (% a.m.) - BACEN

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	2.10	1.85	2.30	3.47	3.25	2.89	2.99	2.60	1.94	1.65	1.44	1.34
1996	1.25	0.96	0.81	0.66	0.59	0.61	0.59	0.63	0.66	0.74	0.81	0.87
1997	0.74	0.66	0.63	0.62	0.64	0.65	0.66	0.63	0.65	0.66	1.53	1.31
1998	1.15	0.45	0.90	0.47	0.45	0.49	0.55	0.37	0.45	0.89	0.61	0.74
1999	0.52	0.83	1.16	0.61	0.58	0.31	0.29	0.29	0.27	0.23	0.20	0.30
2000	0.21	0.23	0.22	0.13	0.25	0.21	0.15	0.20	0.10	0.13	0.12	0.10
2001	0.14	0.04	0.17	0.15	0.18	0.15	0.24	0.34	0.16	0.29	0.19	0.20
2002	0.26	0.12	0.18	0.24	0.21	0.16	0.27	0.25	0.20	0.28	0.26	0.36
2003	0.49	0.41	0.38	0.42	0.47	0.42	0.55	0.40	0.34	0.32	0.18	0.19
2004	0.13	0.05	0.18	0.09	0.15	0.18	0.20	0.20	0.17	0.11	0.11	0.24
2005	0.19	0.10	0.26	0.20	0.25	0.30	0.26	0.35	0.26	0.21	0.19	0.23
2006	0.23	0.07	0.21	0.09	0.19	0.19	0.18	0.24	0.15	0.19	0.13	0.15



V12m_TR - Variação da Taxa Referencial de Juros em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-40.4	-48.1	-64.6	-81.0	-81.9	-78.9	-80.4	-75.9	-65.9	-55.1	-43.4	-34.9
1997	-40.6	-31.3	-22.4	-5.9	7.9	7.1	12.5	-0.1	-2.2	-11.7	88.2	50.1
1998	54.0	-32.6	42.4	-24.0	-28.5	-24.8	-16.4	-40.2	-30.3	35.7	-60.0	-43.2
1999	-54.9	86.0	29.1	29.1	26.8	-36.7	-46.7	-21.4	-39.8	-74.5	-67.4	-59.7
2000	-58.4	-71.9	-80.7	-78.6	-56.7	-31.1	-47.3	-31.2	-61.8	-41.9	-40.1	-66.9
2001	-36.3	-84.2	-23.1	18.8	-26.7	-31.9	57.8	69.7	56.7	121.4	61.1	100.1
2002	89.3	218.2	2.0	52.5	15.1	8.5	8.8	-27.8	20.2	-5.0	37.1	82.0
2003	88.3	251.5	115.1	77.5	121.2	163.3	105.8	62.8	72.1	16.1	-32.8	-47.4
2004	-73.8	-88.9	-53.0	-79.1	-66.8	-57.7	-64.3	-50.3	-48.6	-65.5	-35.5	26.4
2005	46.9	110.0	48.2	129.2	63.5	70.0	31.9	72.9	52.6	89.5	68.3	-5.5
2006	23.7	-24.6	-21.3	-57.3	-25.3	-35.3	-32.0	-29.7	-42.3	-10.7	-33.5	-32.9



Selic - Taxa de Juros Selic (% a.m.) - BACEN

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	3.37	3.25	4.26	4.26	4.25	4.04	4.02	3.84	3.32	3.09	2.88	2.78
1996	2.58	2.35	2.22	2.07	2.01	1.98	1.93	1.97	1.90	1.86	1.80	1.80
1997	1.73	1.67	1.64	1.66	1.58	1.61	1.60	1.59	1.59	1.67	3.04	2.97
1998	2.67	2.13	2.20	1.71	1.63	1.60	1.70	1.48	2.49	2.94	2.63	2.40
1999	2.18	2.38	3.33	2.35	2.02	1.67	1.66	1.57	1.49	1.38	1.39	1.60
2000	1.46	1.45	1.45	1.30	1.49	1.39	1.31	1.41	1.22	1.29	1.22	1.20
2001	1.27	1.02	1.26	1.19	1.34	1.27	1.50	1.60	1.32	1.53	1.39	1.39
2002	1.53	1.25	1.37	1.48	1.41	1.33	1.54	1.44	1.38	1.65	1.54	1.74
2003	1.97	1.83	1.78	1.87	1.97	1.86	2.08	1.77	1.68	1.64	1.34	1.37
2004	1.27	1.08	1.38	1.18	1.23	1.23	1.29	1.29	1.25	1.21	1.25	1.48
2005	1.38	1.22	1.53	1.41	1.50	1.59	1.51	1.66	1.50	1.41	1.38	1.47
2006	1.43	1.43	1.42	1.08	1.28	1.18	1.17	1.26	1.06	1.09	1.02	0.94



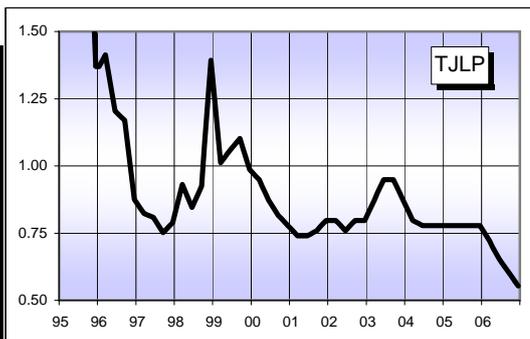
V12m_Selic - Variação da Taxa de Juros Selic Mensal em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-23.4	-27.7	-47.9	-51.4	-52.7	-51.0	-52.0	-48.7	-42.8	-39.8	-37.5	-35.3
1997	-32.9	-28.9	-26.1	-19.8	-21.4	-18.7	-17.1	-19.3	-16.3	-10.2	68.9	65.0
1998	54.3	27.5	34.1	3.0	3.2	-0.6	6.2	-6.9	56.6	76.0	-13.5	-19.2
1999	-18.4	11.7	51.4	37.4	23.9	4.4	-2.4	6.1	-40.2	-53.1	-47.1	-33.3
2000	-33.0	-39.1	-56.5	-44.7	-26.2	-16.8	-21.1	-10.2	-18.1	-6.5	-12.2	-25.0
2001	-13.0	-29.7	-13.1	-8.5	-10.1	-8.6	14.5	13.5	8.2	18.6	13.9	15.8
2002	20.5	22.5	8.7	24.4	5.2	4.7	2.7	-10.0	4.5	7.8	10.8	25.2
2003	28.8	46.4	29.9	26.4	39.7	39.8	35.1	22.9	21.7	-0.6	-13.0	-21.3
2004	-35.5	-41.0	-22.5	-36.9	-37.6	-33.9	-38.0	-27.1	-25.6	-26.2	-6.7	8.0
2005	8.7	13.0	10.9	19.5	22.0	29.3	17.1	28.7	20.0	16.5	10.4	-0.7
2006	3.6	16.8	-7.2	-23.4	-14.7	-25.8	-22.5	-24.1	-29.3	-22.7	-26.1	-36.1



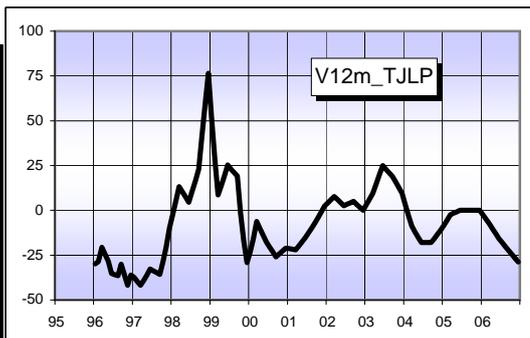
TJLP - Taxa de Juros de Longo Prazo (% a.m.) - BACEN

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	1.95	1.95	1.78	1.78	1.78	1.86	1.86	1.86	1.67	1.67	1.67	1.37
1996	1.37	1.39	1.41	1.34	1.27	1.20	1.19	1.18	1.17	1.07	0.97	0.88
1997	0.86	0.84	0.82	0.82	0.81	0.81	0.79	0.77	0.75	0.76	0.78	0.79
1998	0.84	0.88	0.93	0.90	0.87	0.85	0.87	0.90	0.92	1.08	1.24	1.39
1999	1.27	1.14	1.01	1.03	1.04	1.06	1.07	1.09	1.10	1.06	1.02	0.99
2000	0.97	0.96	0.95	0.92	0.90	0.87	0.85	0.84	0.82	0.80	0.79	0.78
2001	0.77	0.75	0.74	0.74	0.74	0.74	0.75	0.75	0.76	0.77	0.78	0.80
2002	0.80	0.80	0.80	0.78	0.77	0.76	0.77	0.78	0.80	0.80	0.80	0.80
2003	0.82	0.85	0.87	0.90	0.92	0.95	0.95	0.95	0.95	0.92	0.90	0.87
2004	0.85	0.82	0.80	0.79	0.78	0.78	0.78	0.78	0.78	0.78	0.78	0.78
2005	0.78	0.78	0.78	0.78	0.78	0.78	0.78	0.78	0.78	0.78	0.78	0.78
2006	0.76	0.74	0.72	0.70	0.68	0.66	0.64	0.62	0.60	0.59	0.57	0.55



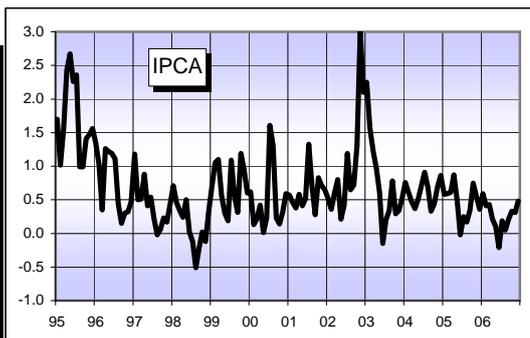
V12m_TJLP - Variação da Taxa de Juros de Longo Prazo em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-29.8	-28.7	-20.6	-24.5	-28.5	-35.3	-35.9	-36.5	-30.0	-35.9	-41.7	-36.1
1997	-37.4	-39.6	-41.8	-39.1	-36.1	-32.8	-33.8	-34.7	-35.7	-28.7	-20.2	-9.8
1998	-2.4	5.2	13.3	10.4	7.5	4.5	10.4	16.6	23.1	41.5	59.3	76.6
1999	51.3	28.8	8.6	13.8	19.4	25.3	23.1	21.1	19.1	-1.6	-17.2	-29.2
2000	-23.1	-15.6	-6.2	-10.1	-13.9	-17.5	-20.4	-23.2	-25.9	-24.4	-22.8	-21.1
2001	-21.4	-21.7	-22.0	-19.9	-17.7	-15.3	-12.7	-9.9	-7.0	-4.0	-0.8	2.5
2002	4.2	5.9	7.8	6.0	4.3	2.6	3.4	4.2	5.0	3.3	1.6	0.0
2003	3.2	6.4	9.5	14.5	19.7	25.0	22.9	20.9	19.0	15.8	12.7	9.5
2004	3.1	-3.0	-8.7	-12.0	-15.1	-18.0	-18.0	-18.0	-18.0	-15.7	-13.4	-10.9
2005	-8.2	-5.4	-2.4	-1.6	-0.8	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2006	-2.5	-4.9	-7.4	-10.2	-13.0	-15.8	-18.0	-20.2	-22.3	-24.5	-26.7	-28.9



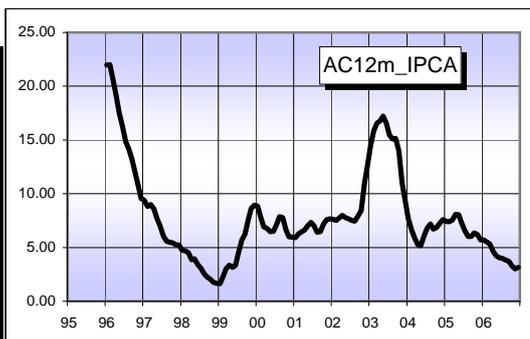
IPCA - Índice de Preços ao Consumidor Amplo (% a.m.) - IBGE

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	1.70	1.02	1.55	2.43	2.67	2.26	2.36	0.99	0.99	1.41	1.47	1.56
1996	1.34	1.03	0.35	1.26	1.22	1.19	1.11	0.44	0.15	0.30	0.32	0.47
1997	1.18	0.50	0.51	0.88	0.41	0.54	0.22	-0.02	0.06	0.23	0.17	0.43
1998	0.71	0.46	0.34	0.24	0.50	0.02	-0.12	-0.51	-0.22	0.02	-0.12	0.33
1999	0.70	1.05	1.10	0.56	0.30	0.19	1.09	0.56	0.31	1.19	0.95	0.60
2000	0.62	0.13	0.22	0.42	0.01	0.23	1.61	1.31	0.23	0.14	0.32	0.59
2001	0.57	0.46	0.38	0.58	0.41	0.52	1.33	0.70	0.28	0.83	0.71	0.65
2002	0.52	0.36	0.60	0.80	0.21	0.42	1.19	0.65	0.72	1.31	3.02	2.10
2003	2.25	1.57	1.23	0.97	0.61	-0.15	0.20	0.34	0.78	0.29	0.34	0.52
2004	0.76	0.61	0.47	0.37	0.51	0.71	0.91	0.69	0.33	0.44	0.69	0.86
2005	0.58	0.59	0.61	0.87	0.49	-0.02	0.25	0.17	0.35	0.75	0.55	0.36
2006	0.59	0.41	0.43	0.21	0.10	-0.21	0.19	0.05	0.21	0.33	0.31	0.48



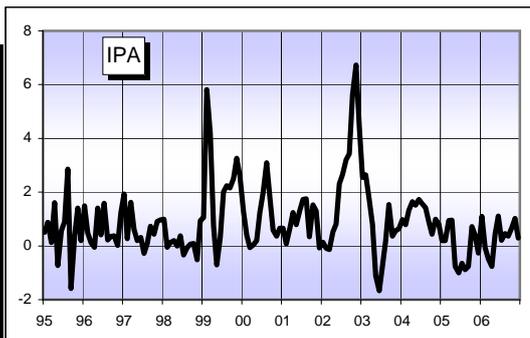
AC12m_IPCA - Índice de Preços ao Consumidor Amplo Acumulado nos Últimos 12 Meses (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	22.0	22.0	20.5	19.2	17.5	16.3	14.8	14.2	13.3	12.0	10.8	9.6
1997	9.4	8.8	9.0	8.6	7.7	7.0	6.1	5.6	5.5	5.4	5.3	5.2
1998	4.7	4.7	4.5	3.9	3.9	3.4	3.1	2.6	2.3	2.1	1.8	1.7
1999	1.6	2.2	3.0	3.3	3.1	3.3	4.6	5.7	6.3	7.5	8.6	8.9
2000	8.9	7.9	6.9	6.8	6.5	6.5	7.1	7.9	7.8	6.7	6.0	6.0
2001	5.9	6.3	6.4	6.6	7.0	7.3	7.1	6.4	6.5	7.2	7.6	7.7
2002	7.6	7.5	7.7	8.0	7.8	7.7	7.5	7.5	7.9	8.4	10.9	12.5
2003	14.5	15.8	16.6	16.8	17.2	16.6	15.4	15.1	15.1	14.0	11.0	9.3
2004	7.7	6.7	5.9	5.3	5.2	6.1	6.8	7.2	6.7	6.9	7.2	7.6
2005	7.4	7.4	7.5	8.1	8.1	7.3	6.6	6.0	6.0	6.4	6.2	5.7
2006	5.7	5.5	5.3	4.6	4.2	4.0	4.0	3.8	3.7	3.3	3.0	3.1



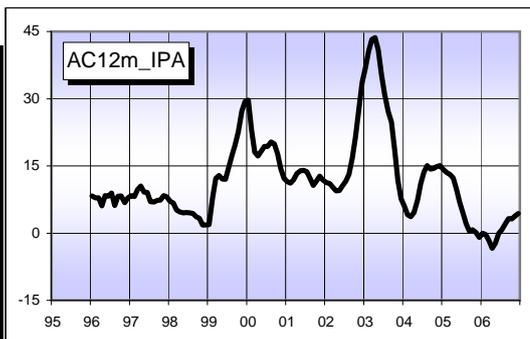
IPA - Índice de Preços no Atacado (% a.m.) - FGV

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	0.51	0.88	0.12	1.61	-0.73	0.56	0.90	2.86	-1.58	0.33	1.41	0.20
1996	1.49	0.48	0.13	-0.05	1.41	0.41	1.59	0.22	0.35	0.37	0.02	1.23
1997	1.93	0.27	1.62	0.61	0.20	0.32	-0.28	0.09	0.73	0.44	0.91	0.97
1998	0.99	-0.05	0.12	0.20	-0.01	0.38	-0.34	-0.06	0.07	0.09	-0.52	0.94
1999	1.05	5.82	4.16	0.76	-0.70	0.33	2.01	2.24	2.16	2.50	3.26	2.60
2000	1.29	0.41	-0.06	0.04	0.20	1.25	1.98	3.10	1.81	0.59	0.36	0.66
2001	0.66	0.08	0.65	1.24	0.79	1.31	1.73	1.75	0.34	1.53	1.30	-0.08
2002	0.14	-0.09	-0.14	0.52	0.81	2.31	2.66	3.20	3.43	5.62	6.73	4.45
2003	2.55	2.64	1.72	0.80	-1.11	-1.67	-0.75	0.20	1.54	0.36	0.57	0.64
2004	0.98	0.79	1.33	1.65	1.52	1.73	1.58	1.42	0.90	0.44	0.99	0.81
2005	0.20	0.20	0.94	0.96	-0.77	-1.00	-0.65	-0.88	-0.76	0.72	0.40	-0.27
2006	1.10	-0.06	-0.48	-0.77	0.43	1.11	0.21	0.46	0.36	0.65	1.02	0.29



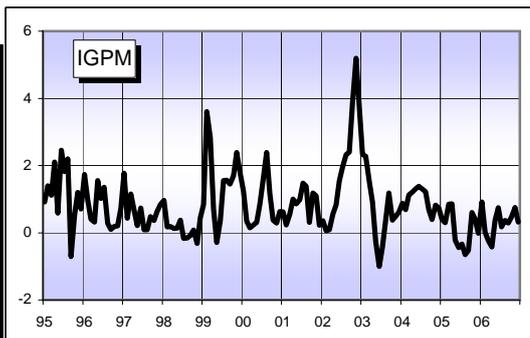
AC12m_IPA - Índice de Preços no Atacado Acumulado nos Últimos 12 Meses (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	8.3	7.8	7.9	6.1	8.4	8.2	9.0	6.2	8.2	8.3	6.8	7.9
1997	8.4	8.1	9.8	10.5	9.2	9.1	7.1	6.9	7.3	7.4	8.4	8.1
1998	7.1	6.7	5.2	4.7	4.5	4.6	4.5	4.4	3.7	3.3	1.8	1.8
1999	1.9	7.9	12.2	12.8	12.1	12.0	14.6	17.3	19.7	22.6	27.3	29.4
2000	29.7	23.0	18.1	17.2	18.3	19.4	19.3	20.3	19.9	17.7	14.4	12.2
2001	11.5	11.2	11.9	13.3	14.0	14.0	13.7	12.2	10.6	11.7	12.7	11.9
2002	11.3	11.1	10.2	9.5	9.5	10.6	11.6	13.2	16.6	21.3	27.8	33.6
2003	36.9	40.6	43.2	43.6	40.9	35.4	30.9	27.1	24.8	18.6	11.7	7.6
2004	6.0	4.1	3.7	4.6	7.3	11.1	13.7	15.0	14.3	14.4	14.9	15.1
2005	14.2	13.5	13.1	12.3	9.8	6.8	4.5	2.1	0.4	0.7	0.1	-0.9
2006	0.0	-0.3	-1.7	-3.4	-2.2	-0.1	0.7	2.1	3.2	3.2	3.8	4.4



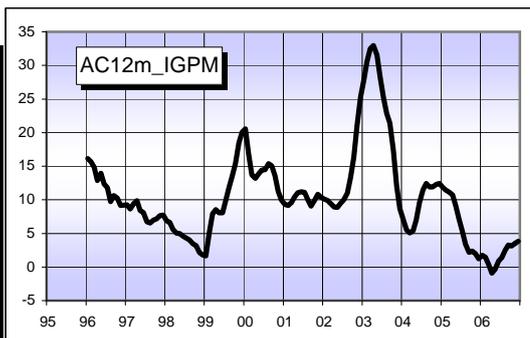
IGPM - Índice Geral de Preços a Mercado (% a.m.) - FGV

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	0.92	1.39	1.12	2.1	0.58	2.46	1.82	2.2	-0.71	0.52	1.2	0.71
1996	1.7	1.0	0.4	0.3	1.6	1.0	1.4	0.3	0.1	0.2	0.2	0.7
1997	1.8	0.4	1.2	0.7	0.2	0.7	0.1	0.1	0.5	0.4	0.6	0.8
1998	1.0	0.2	0.2	0.1	0.1	0.4	-0.2	-0.2	-0.1	0.1	-0.3	0.5
1999	0.8	3.6	2.8	0.7	-0.3	0.4	1.6	1.6	1.5	1.7	2.4	1.8
2000	1.2	0.4	0.2	0.2	0.3	0.9	1.6	2.4	1.2	0.4	0.3	0.6
2001	0.6	0.2	0.6	1.0	0.9	1.0	1.5	1.4	0.3	1.2	1.1	0.2
2002	0.4	0.1	0.1	0.6	0.8	1.5	2.0	2.3	2.4	3.9	5.2	3.8
2003	2.3	2.3	1.5	0.9	-0.3	-1.0	-0.4	0.4	1.2	0.4	0.5	0.6
2004	0.9	0.7	1.1	1.2	1.3	1.4	1.3	1.2	0.7	0.4	0.8	0.7
2005	0.4	0.3	0.9	0.9	-0.2	-0.4	-0.3	-0.7	-0.5	0.6	0.4	0.0
2006	0.9	0.0	-0.2	-0.4	0.4	0.8	0.2	0.4	0.3	0.5	0.8	0.3



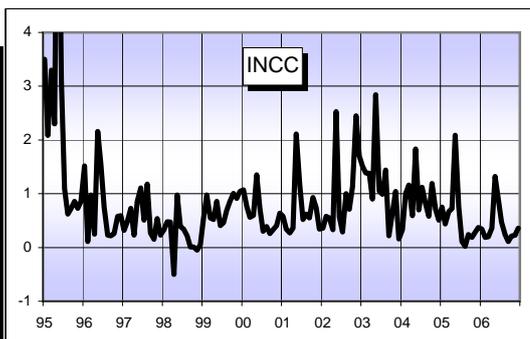
AC12m_IGPM - Índice Geral de Preços a Mercado Acumulado nos Últimos 12 Meses (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	16.2	15.7	14.9	12.9	13.9	12.3	11.8	9.7	10.6	10.3	9.2	9.2
1997	9.2	8.6	9.5	9.9	8.4	8.1	6.8	6.6	7.0	7.2	7.6	7.7
1998	6.9	6.6	5.6	5.0	5.0	4.6	4.3	4.0	3.5	3.2	2.2	1.8
1999	1.7	5.1	7.9	8.5	8.1	8.1	9.9	11.8	13.5	15.4	18.5	20.1
2000	20.6	16.8	13.7	13.2	13.9	14.4	14.5	15.4	15.1	13.6	11.2	10.0
2001	9.3	9.1	9.6	10.4	11.0	11.2	11.1	10.0	9.1	9.9	10.8	10.4
2002	10.1	9.9	9.4	8.9	8.9	9.5	10.0	11.0	13.3	16.3	21.0	25.3
2003	27.8	30.6	32.5	33.0	31.5	28.2	25.2	22.9	21.4	17.3	12.1	8.7
2004	7.2	5.5	5.1	5.4	7.0	9.6	11.5	12.4	11.9	11.9	12.3	12.4
2005	11.9	11.4	11.1	10.7	9.1	7.1	5.4	3.4	2.2	2.4	2.0	1.2
2006	1.7	1.4	0.4	-0.9	-0.3	0.9	1.4	2.4	3.3	3.1	3.5	3.8



INCC - Índice Nacional do Custo da Construção Civil (% a.m.) - FGV

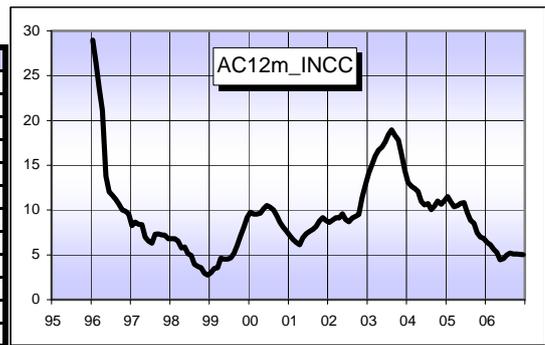
	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	3.50	2.09	3.30	2.30	8.77	3.12	1.09	0.62	0.72	0.86	0.73	0.86
1996	1.52	0.11	0.98	0.25	2.16	1.54	0.75	0.23	0.22	0.26	0.58	0.59
1997	0.32	0.48	0.73	0.23	0.86	1.11	0.51	1.18	0.27	0.15	0.54	0.23
1998	0.33	0.48	0.47	-0.50	0.98	0.39	0.34	0.22	0.01	0.01	-0.05	0.05
1999	0.55	0.98	0.55	0.52	0.86	0.41	0.46	0.69	0.86	1.01	0.91	1.04
2000	1.07	0.77	0.56	0.60	1.35	0.73	0.30	0.39	0.26	0.33	0.41	0.64
2001	0.58	0.34	0.27	0.36	2.11	1.16	0.52	0.62	0.55	0.93	0.74	0.34
2002	0.36	0.58	0.55	0.33	2.53	0.57	0.29	1.00	0.71	1.13	2.45	1.70
2003	1.51	1.39	1.38	0.90	2.84	1.05	0.99	1.44	0.22	0.65	1.04	0.16
2004	0.33	1.00	1.16	0.59	1.83	0.70	1.12	0.81	0.58	1.19	0.71	0.51
2005	0.75	0.44	0.67	0.72	2.09	0.76	0.11	0.02	0.24	0.19	0.28	0.37
2006	0.34	0.19	0.20	0.36	1.32	0.90	0.47	0.24	0.11	0.21	0.23	0.36



AC12m_INCC - Índice Nacional do Custo da Construção Civil Acumulado nos Meses (%)

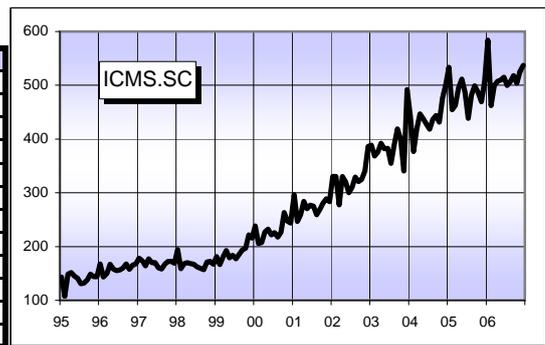
Últimos 12

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	29.0	26.5	23.6	21.1	13.8	12.0	11.7	11.2	10.7	10.0	9.9	9.6
1997	8.3	8.7	8.4	8.4	7.0	6.5	6.3	7.3	7.4	7.2	7.2	6.8
1998	6.8	6.8	6.5	5.8	5.9	5.1	5.0	4.0	3.7	3.5	2.9	2.8
1999	3.0	3.5	3.6	4.6	4.5	4.5	4.7	5.2	6.0	7.1	8.1	9.2
2000	9.8	9.5	9.6	9.6	10.2	10.5	10.3	10.0	9.4	8.6	8.1	7.7
2001	7.1	6.7	6.4	6.1	6.9	7.4	7.6	7.9	8.2	8.8	9.2	8.8
2002	8.6	8.9	9.2	9.1	9.6	8.9	8.7	9.1	9.3	9.5	11.4	12.9
2003	14.2	15.1	16.0	16.7	17.0	17.6	18.4	18.9	18.4	17.8	16.2	14.4
2004	13.1	12.7	12.4	12.1	11.0	10.6	10.7	10.0	10.4	11.0	10.7	11.0
2005	11.5	10.9	10.4	10.5	10.8	10.8	9.7	8.9	8.5	7.4	7.0	6.8
2006	6.4	6.1	5.6	5.3	4.5	4.6	5.0	5.2	5.1	5.1	5.0	5.0



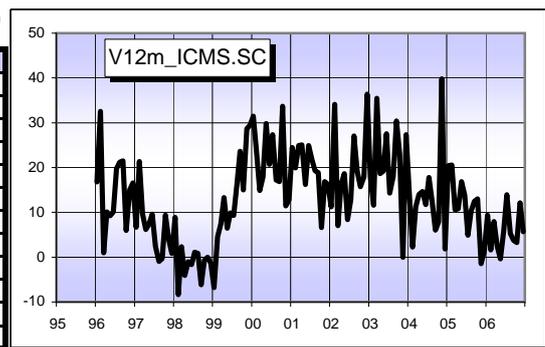
ICMS.SC - Arrecadação do Imposto sobre a Circulação de Mercadorias em SC (R\$ milhões) - Ministério da Fazenda

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	143	108	149	152	145	141	131	132	138	149	144	144
1996	167	143	150	167	158	155	157	160	168	158	165	168
1997	179	174	164	177	170	170	160	158	167	172	172	169
1998	194	159	168	170	168	167	162	160	157	171	172	167
1999	181	166	181	193	179	184	177	185	194	197	222	216
2000	238	205	207	227	232	226	217	227	227	263	247	244
2001	297	246	259	284	270	277	275	259	269	281	289	283
2002	330	330	277	330	321	300	310	329	321	325	341	386
2003	388	369	376	392	382	383	355	389	419	400	341	492
2004	443	377	418	447	438	428	418	437	444	431	476	501
2005	534	454	463	495	512	487	438	482	499	488	469	508
2006	584	462	500	508	510	515	499	507	518	504	526	537



V12m_ICMS.SC - Variação da Arrecadação do Imposto sobre a Circulação de Mercadorias em SC em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	16.8	32.5	1.0	10.1	9.2	10.1	19.8	21.2	21.5	6.0	15.0	16.6
1997	6.7	21.3	9.6	6.1	7.4	9.6	2.4	-0.9	-0.3	9.4	4.0	0.8
1998	8.9	-8.4	2.3	-4.1	-1.0	-1.7	1.1	0.8	-6.2	-0.7	0.0	-1.4
1999	-6.8	4.6	7.4	13.3	6.5	9.9	9.3	16.2	23.7	15.0	28.7	29.5
2000	31.5	23.6	14.9	17.9	29.9	20.7	27.3	17.2	16.8	33.7	11.5	12.8
2001	24.5	19.9	24.9	25.1	16.2	24.9	21.9	19.3	18.8	6.6	16.9	16.3
2002	11.3	34.1	7.0	16.3	18.6	8.4	12.8	27.1	19.2	15.7	18.0	36.4
2003	17.6	11.6	35.5	18.6	19.2	27.5	14.3	18.1	30.4	23.0	0.0	27.4
2004	14.1	2.2	11.3	14.0	14.6	11.7	17.8	12.3	6.0	7.9	39.8	1.8
2005	20.4	20.6	10.6	10.8	16.9	13.9	4.9	10.3	12.4	13.0	-1.5	1.4
2006	9.4	1.6	8.0	2.5	-0.4	5.7	13.9	5.2	3.8	3.3	12.1	5.7



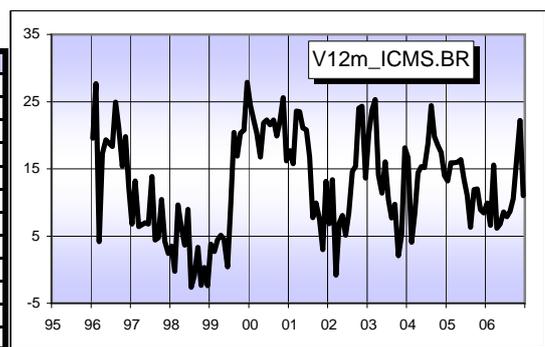
ICMS.BR - Arrecadação Total do Imposto sobre a Circulação de Mercadorias (R\$ milhões) - Ministério da Fazenda

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	3.836	3.292	4.014	3.879	3.832	3.9	3.901	3.815	3.958	4.086	4.114	4.572
1996	4.6	4.2	4.2	4.5	4.6	4.6	4.6	4.8	4.8	4.7	4.9	5.1
1997	4.9	4.8	4.4	4.9	4.9	4.9	5.3	5.0	5.0	5.2	5.1	5.3
1998	5.1	4.7	4.9	5.1	5.1	5.4	5.1	4.9	5.2	5.1	5.2	5.1
1999	5.3	4.9	5.1	5.4	5.3	5.4	5.6	5.9	6.1	6.1	6.2	6.6
2000	6.5	6.0	6.1	6.3	6.5	6.6	6.8	7.3	7.3	7.5	7.8	7.6
2001	7.7	6.9	7.6	7.8	7.8	8.0	8.0	7.8	8.0	8.0	8.0	8.6
2002	8.2	7.8	7.5	8.3	8.4	8.4	8.6	9.0	9.2	10.0	10.0	9.8
2003	9.9	9.7	9.4	9.5	9.4	9.8	9.5	9.7	10.1	10.2	10.5	11.6
2004	11.6	10.1	10.2	10.9	10.8	11.2	11.3	12.0	12.1	12.1	12.4	13.2
2005	13.1	11.7	11.8	12.6	12.6	12.7	12.6	12.8	13.6	13.5	13.5	14.3
2006	14.4	12.5	13.7	13.4	13.5	13.8	13.6	13.9	15.0	15.7	16.4	15.9



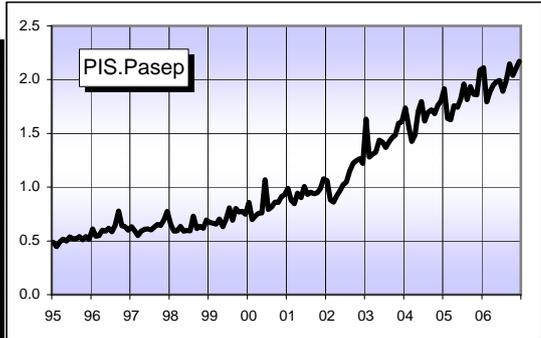
V12m_ICMS.BR - Variação da Arrecadação do Imposto sobre a Circulação de Mercadorias em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	19.6	27.7	4.2	17.3	19.3	18.8	18.3	24.9	21.1	15.4	19.8	12.3
1997	6.8	13.2	6.4	6.7	7.0	6.8	13.8	4.4	4.7	10.4	4.2	2.4
1998	3.5	-0.3	9.6	6.1	3.6	9.0	-2.6	-0.8	3.3	-2.4	0.3	-2.4
1999	3.8	2.7	4.5	5.1	4.5	0.4	9.7	20.4	16.9	20.3	20.7	27.9
2000	24.4	22.3	20.3	16.8	21.8	22.3	21.6	22.3	19.9	22.2	25.6	16.2
2001	17.7	15.8	23.6	23.5	21.1	20.8	16.8	7.8	9.9	7.5	3.0	13.1
2002	6.8	13.4	-0.8	6.9	8.0	5.1	8.5	14.6	15.4	24.0	24.3	13.6
2003	20.3	23.7	25.3	14.1	11.4	16.0	10.4	7.7	9.7	2.1	5.2	18.1
2004	16.7	4.1	8.4	14.4	15.3	15.2	18.8	24.4	19.8	18.5	17.4	14.0
2005	13.2	15.9	15.9	16.0	16.4	13.4	11.0	6.3	11.9	12.0	8.9	8.4
2006	9.9	6.6	15.6	6.2	6.8	8.6	7.9	8.7	10.6	16.1	22.2	11.0



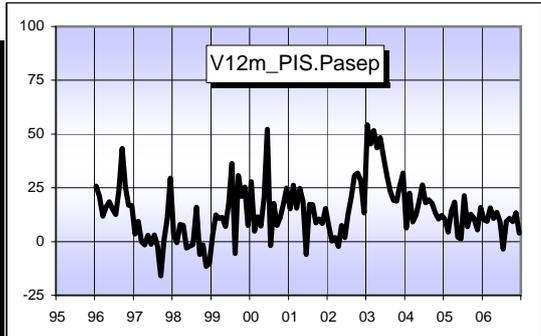
PIS.Pasep - Arrecadação Total das Contribuições do PIS/Pasep (R\$ bilhões) - Ministério da Fazenda

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	0.49	0.45	0.49	0.52	0.50	0.54	0.52	0.52	0.54	0.51	0.54	0.51
1996	0.61	0.54	0.55	0.60	0.59	0.62	0.58	0.64	0.78	0.64	0.63	0.60
1997	0.63	0.59	0.55	0.59	0.61	0.61	0.60	0.63	0.65	0.65	0.70	0.78
1998	0.65	0.59	0.59	0.63	0.59	0.60	0.59	0.73	0.61	0.64	0.62	0.70
1999	0.67	0.66	0.66	0.71	0.63	0.70	0.81	0.69	0.80	0.77	0.78	0.75
2000	0.86	0.70	0.73	0.76	0.76	1.07	0.79	0.81	0.86	0.86	0.91	0.93
2001	0.99	0.88	0.85	0.94	0.90	1.01	0.93	0.95	0.94	0.95	0.99	1.08
2002	1.06	0.88	0.86	0.92	0.97	1.02	1.05	1.15	1.22	1.25	1.26	1.22
2003	1.63	1.28	1.31	1.32	1.44	1.42	1.37	1.42	1.46	1.48	1.59	1.61
2004	1.74	1.57	1.43	1.49	1.71	1.79	1.62	1.69	1.72	1.68	1.76	1.80
2005	1.92	1.64	1.63	1.76	1.74	1.82	1.96	1.81	1.94	1.87	1.86	2.09
2006	2.11	1.79	1.88	1.95	1.98	1.99	1.89	1.98	2.15	2.04	2.11	2.17



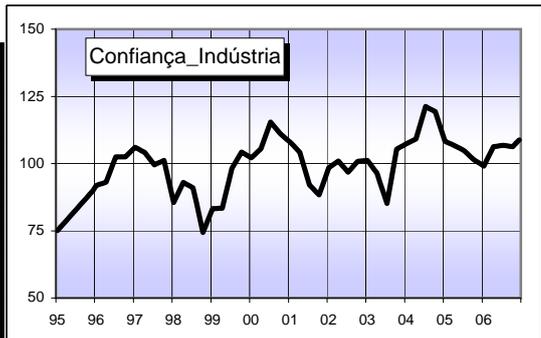
V12m_PIS.Pasep - Variação da Arrecadação Total das Contribuições do PIS/Pasep em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	25.7	21.2	11.9	16.2	18.5	15.1	12.6	23.9	43.3	25.5	16.8	16.7
1997	3.4	9.4	-0.1	-1.6	2.9	-1.2	3.1	-2.1	-16.0	0.7	10.7	29.5
1998	3.1	-0.5	8.0	7.4	-3.1	-2.2	-1.4	16.0	-6.0	-1.5	-11.5	-10.3
1999	2.9	12.4	10.8	11.2	7.0	17.6	36.3	-5.5	30.7	21.1	25.3	7.4
2000	27.8	4.9	11.6	7.3	20.4	52.2	-1.9	17.8	7.5	11.3	17.4	24.8
2001	15.2	26.2	15.5	24.7	18.6	-5.9	17.3	17.1	8.7	10.5	8.4	15.3
2002	7.2	0.2	1.8	-2.3	7.5	1.8	12.7	20.6	30.6	31.8	28.1	13.3
2003	54.2	45.4	51.6	43.6	48.4	38.7	30.5	23.5	19.3	18.8	26.1	31.9
2004	6.3	22.5	9.2	12.2	18.8	26.4	18.0	19.3	17.7	13.4	10.5	12.1
2005	10.4	4.4	14.1	18.4	2.1	1.3	21.4	7.0	12.7	10.9	5.4	15.8
2006	10.2	9.4	15.7	10.8	13.5	9.5	-3.5	9.4	10.8	9.3	13.3	4.0



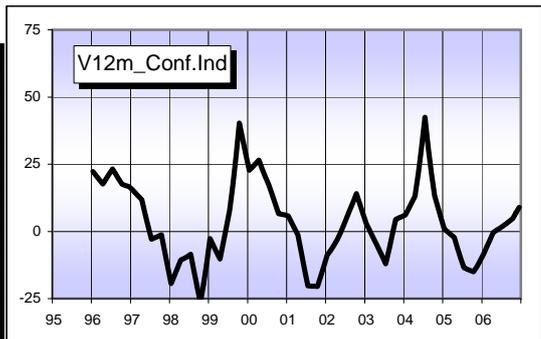
Confiança_Indústria - Índice de Confiança da Indústria - FGV

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	75	76	78	79	80	82	83	85	86	87	89	90
1996	92	92	93	93	96	99	103	103	103	103	104	105
1997	106	105	105	104	103	101	100	100	101	101	96	91
1998	86	88	91	93	92	92	91	85	80	74	77	80
1999	83	83	83	83	88	93	98	100	102	104	104	103
2000	102	103	104	106	109	112	115	114	113	111	110	109
2001	108	107	105	104	100	96	92	91	90	88	92	95
2002	98	99	100	101	100	98	97	98	99	101	101	101
2003	101	100	98	96	93	89	85	92	99	105	106	107
2004	107	108	109	109	113	117	121	121	120	119	116	112
2005	108	108	107	107	106	105	105	104	103	101	101	100
2006	99	102	104	106	106	107	107	107	106	106	108	109



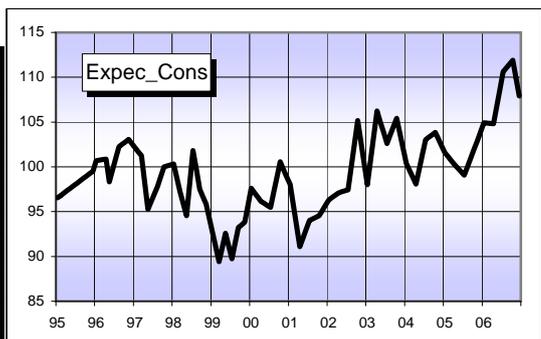
V12m_Conf.Ind - Variação do Índice de Confiança da Indústria em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	22.2	20.6	19.1	17.6	19.6	21.4	23.2	21.3	19.4	17.5	17.1	16.7
1997	15.6	14.3	13.1	11.8	6.6	1.7	-2.9	-2.4	-1.8	-1.3	-7.5	-13.5
1998	-19.4	-16.5	-13.6	-10.7	-10.0	-9.3	-8.5	-14.6	-20.6	-26.6	-19.5	-11.6
1999	-2.7	-5.4	-7.9	-10.3	-4.3	1.7	7.9	17.3	28.0	40.4	34.0	28.2
2000	22.7	24.0	25.2	26.5	23.2	20.2	17.5	13.7	10.1	6.6	6.3	6.1
2001	5.8	3.4	1.1	-1.2	-8.0	-14.3	-20.3	-20.4	-20.4	-20.5	-16.7	-12.8
2002	-8.9	-7.0	-5.1	-3.2	-0.6	2.2	5.2	8.1	11.0	14.0	10.0	6.3
2003	2.8	0.4	-2.1	-4.5	-6.9	-9.5	-12.1	-6.4	-0.9	4.5	5.0	5.6
2004	6.1	8.4	10.7	13.2	22.1	31.8	42.4	31.3	21.7	13.3	9.1	4.9
2005	0.8	-0.2	-1.2	-2.2	-6.2	-10.0	-13.5	-14.0	-14.5	-15.0	-13.0	-10.8
2006	-8.5	-5.8	-3.1	-0.4	0.4	1.1	1.9	2.9	3.8	4.8	6.9	9.0



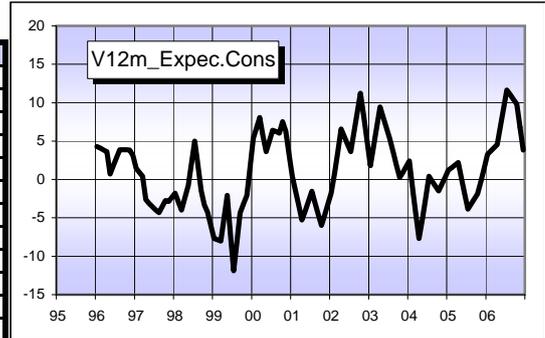
Expec_Cons - Índice Nacional de Expectativa do Consumidor - CNI

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	97	97	97	97	98	98	98	98	99	99	99	100
1996	101	101	101	101	98	100	101	102	103	103	103	103
1997	102	102	101	98	95	96	97	98	99	100	100	100
1998	100	99	97	96	95	98	102	100	97	97	96	94
1999	93	91	89	91	93	91	90	91	93	94	94	96
2000	98	97	97	96	96	96	95	97	99	101	100	99
2001	98	96	93	91	92	93	94	94	94	95	95	96
2002	96	97	97	97	97	97	97	100	103	105	103	100
2003	98	101	104	106	105	104	103	104	104	105	104	102
2004	100	100	99	98	100	101	103	103	104	104	103	102
2005	102	101	101	100	100	99	99	100	101	102	103	104
2006	105	105	105	105	107	109	111	111	111	112	110	108



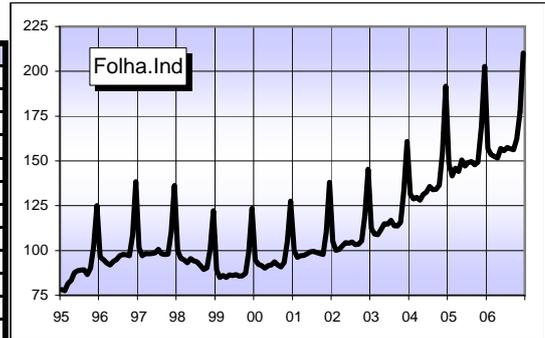
V12m_Expec.Cons - Variação do Índice Nacional de Expectativa do Consumidor em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	4.29	4.06	3.84	3.62	0.73	1.79	2.84	3.89	3.88	3.86	3.85	3.11
1997	1.46	0.94	0.42	-2.60	-3.11	-3.53	-3.94	-4.33	-3.52	-2.72	-2.87	-2.33
1998	-1.79	-2.88	-3.99	-2.43	-0.77	2.14	4.99	1.87	-1.44	-3.34	-4.27	-5.98
1999	-7.68	-7.84	-8.00	-5.08	-2.07	-7.16	-11.87	-8.20	-4.37	-3.24	-2.09	1.58
2000	5.38	6.70	8.08	5.67	3.61	4.99	6.41	6.22	6.05	7.52	6.28	3.31
2001	0.45	-1.43	-3.34	-5.26	-4.02	-2.77	-1.52	-3.06	-4.55	-5.99	-4.61	-3.20
2002	-1.77	0.88	3.66	6.59	5.58	4.59	3.62	6.17	8.71	11.24	8.05	4.89
2003	1.78	4.34	6.90	9.43	8.06	6.69	5.32	3.54	1.85	0.24	0.93	1.66
2004	2.42	-1.13	-4.50	-7.69	-5.05	-2.35	0.41	-0.24	-0.87	-1.50	-0.63	0.27
2005	1.20	1.53	1.86	2.20	0.12	-1.89	-3.84	-3.18	-2.52	-1.86	-0.17	1.54
2006	3.28	3.70	4.12	4.55	6.89	9.26	11.64	11.01	10.40	9.80	6.79	3.84



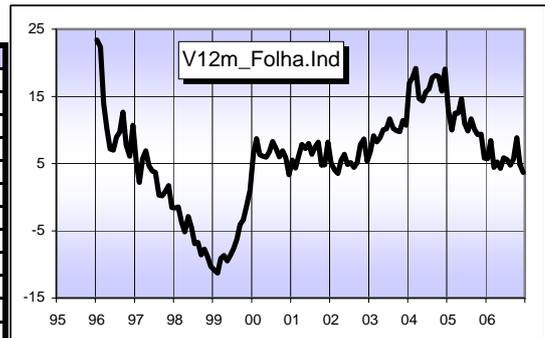
Folha.Ind - Folha de Pagamento da Indústria (Núm. Índice janeiro/2001=100) - IBGE

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	78	78	82	83	88	89	89	89	87	90	102	125
1996	96	95	93	92	94	95	97	98	98	97	109	138
1997	102	97	98	98	98	99	101	98	98	98	110	136
1998	100	96	95	93	95	94	94	91	89	90	101	122
1999	89	85	86	85	86	86	87	86	86	87	99	123
2000	95	92	92	90	91	92	94	92	91	93	105	128
2001	100	96	97	97	98	99	100	99	98	98	110	138
2002	105	100	101	103	104	104	105	103	103	105	120	145
2003	112	109	109	112	115	115	117	114	114	116	134	161
2004	131	129	130	128	131	133	136	134	134	137	155	192
2005	148	142	146	144	151	147	149	150	148	149	169	203
2006	157	154	152	152	157	156	158	157	156	162	177	210



V12m_Folha.Ind - Variação da Folha de Pagamento da Indústria em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	23.4	22.3	13.9	10.2	7.2	7.0	8.9	9.7	12.6	7.8	6.1	10.7
1997	5.4	2.2	5.7	6.9	4.7	3.9	3.6	0.3	0.2	0.9	1.7	-1.6
1998	-1.6	-1.5	-3.7	-5.2	-2.9	-4.5	-6.9	-6.7	-8.6	-7.8	-8.9	-10.3
1999	-10.8	-11.3	-9.1	-8.7	-9.5	-8.6	-7.6	-6.3	-4.1	-3.4	-1.1	1.1
2000	6.3	8.7	6.3	6.1	6.0	6.8	8.3	7.2	6.0	6.9	5.9	3.4
2001	5.5	4.3	6.1	7.8	7.2	8.0	6.4	7.5	8.2	4.8	4.8	8.2
2002	5.0	4.0	3.5	5.5	6.4	4.8	5.1	4.5	5.1	7.8	8.7	5.3
2003	6.8	9.1	8.2	8.8	10.1	10.2	11.6	10.2	9.9	9.8	11.4	10.7
2004	17.0	17.8	19.2	14.7	14.3	15.7	16.1	17.8	18.1	18.0	15.8	19.1
2005	13.0	10.0	12.5	12.5	14.6	10.9	9.9	11.7	10.1	9.3	9.4	5.8
2006	5.7	8.4	4.4	5.2	4.3	5.8	5.6	4.7	5.7	8.8	4.8	3.7



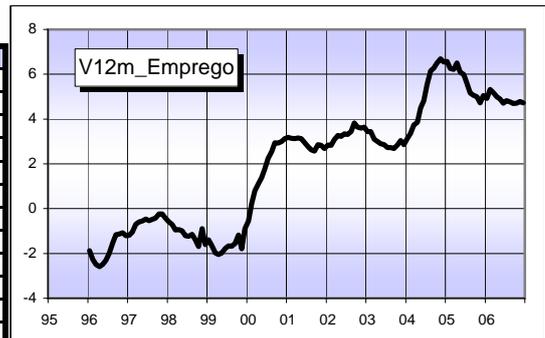
Emprego - Índice Mensal do Emprego Formal no Brasil (Núm. Índice dezembro/2005=100) - Ministério do Trabalho

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	84	84	84	84	85	85	84	84	84	84	83	83
1996	82	82	82	82	83	83	83	83	83	83	82	82
1997	81	81	81	82	82	82	82	82	82	82	82	81
1998	81	81	81	81	81	81	81	81	81	81	82	80
1999	80	79	79	79	80	80	80	80	80	80	80	79
2000	79	80	80	80	81	81	82	82	82	82	82	82
2001	82	82	82	83	83	84	84	84	85	85	85	84
2002	84	84	85	85	86	87	87	87	88	88	88	87
2003	87	87	87	88	89	89	89	89	90	90	90	89
2004	90	90	91	91	93	93	94	95	96	96	97	95
2005	96	96	96	97	98	99	99	100	101	101	101	100
2006	100	101	101	102	103	104	104	105	105	106	106	105



V12m_Emprego - Variação do Índice Mensal do Emprego Formal no Brasil em Relação ao Mesmo Período do Ano Anterior (%)

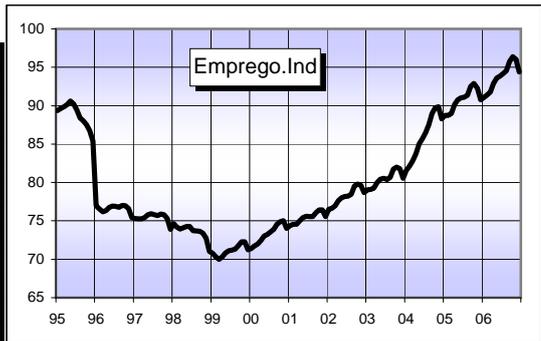
	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-1.87	-2.26	-2.50	-2.58	-2.49	-2.30	-2.00	-1.54	-1.17	-1.14	-1.08	-1.20
1997	-1.19	-1.05	-0.69	-0.60	-0.56	-0.46	-0.53	-0.42	-0.24	-0.24	-0.24	-0.43
1998	-0.59	-0.70	-0.95	-0.93	-0.99	-1.20	-1.24	-1.15	-1.39	-1.70	-0.90	-1.60
1999	-1.39	-1.65	-1.97	-2.05	-1.98	-1.78	-1.66	-1.68	-1.56	-1.18	-1.79	-0.89
2000	-0.55	0.24	0.80	1.11	1.39	1.79	2.24	2.54	2.94	2.92	3.00	3.12
2001	3.18	3.14	3.12	3.15	3.13	2.94	2.76	2.63	2.57	2.85	2.83	2.68
2002	2.84	2.83	3.09	3.26	3.23	3.34	3.31	3.43	3.82	3.63	3.60	3.64
2003	3.44	3.44	3.10	3.00	2.89	2.85	2.73	2.73	2.69	2.83	3.04	2.86
2004	3.14	3.37	3.74	3.85	4.50	4.82	5.53	6.15	6.27	6.51	6.69	6.55
2005	6.58	6.26	6.22	6.50	6.10	5.99	5.59	5.16	5.07	5.00	4.72	5.05
2006	4.91	5.32	5.18	4.99	4.89	4.70	4.82	4.77	4.69	4.71	4.78	4.72



Emprego.Ind - Índice Mensal do Emprego Formal na Indústria Brasileira
Índice dezembro/2005=100) - Ministério do Trabalho

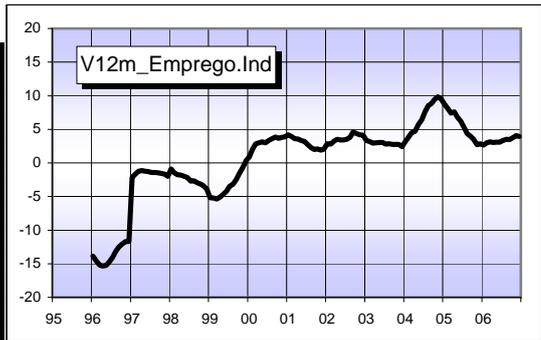
(Núm.

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	89	90	90	90	91	90	89	88	88	88	87	85
1996	77	77	76	76	77	77	77	77	77	77	77	75
1997	75	75	75	75	76	76	76	76	76	76	75	74
1998	75	74	74	74	74	74	74	74	74	73	73	71
1999	71	70	70	70	71	71	71	71	72	72	72	71
2000	71	72	72	72	73	73	74	74	75	75	75	74
2001	74	75	75	75	75	76	76	76	76	76	76	76
2002	77	77	77	78	78	78	78	78	80	80	80	79
2003	79	79	79	80	80	81	80	81	82	82	82	81
2004	82	82	83	84	85	86	87	88	89	90	90	88
2005	89	89	89	90	91	91	91	91	93	93	92	91
2006	91	91	92	93	94	94	94	95	96	96	96	94



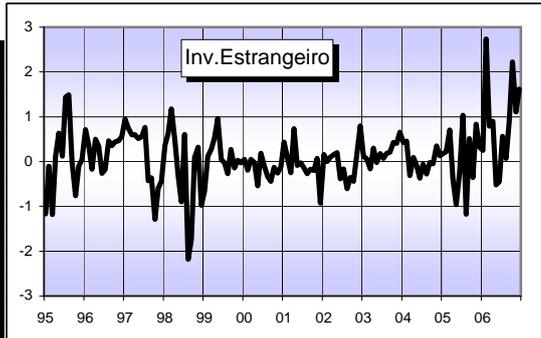
V12m_Emprego.Ind - Variação do Índice Mensal do Emprego Formal na Indústria Brasileira em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-13.9	-14.6	-15.2	-15.3	-15.3	-14.7	-14.0	-13.1	-12.5	-12.0	-11.7	-11.7
1997	-2.1	-1.7	-1.2	-1.2	-1.3	-1.3	-1.4	-1.4	-1.5	-1.5	-1.7	-2.0
1998	-0.9	-1.5	-1.8	-1.8	-2.0	-2.2	-2.7	-2.6	-3.0	-3.1	-3.4	-3.9
1999	-5.2	-5.2	-5.4	-5.1	-4.7	-4.2	-3.5	-3.2	-2.5	-1.6	-0.7	0.3
2000	0.9	2.1	2.9	3.0	3.1	3.0	3.3	3.6	3.9	3.6	3.8	3.9
2001	4.2	3.9	3.6	3.5	3.3	3.2	2.7	2.3	2.0	2.1	1.9	2.1
2002	2.8	2.8	3.2	3.5	3.4	3.4	3.5	3.8	4.6	4.4	4.2	4.1
2003	3.3	3.2	3.0	3.0	3.1	3.0	2.8	2.8	2.8	2.8	2.7	2.4
2004	3.2	3.8	4.5	4.7	5.7	6.4	7.6	8.5	8.8	9.4	9.8	9.6
2005	8.8	8.1	7.4	7.6	6.8	6.2	5.3	4.4	4.0	3.5	2.7	2.9
2006	2.6	3.0	3.1	3.1	3.1	3.1	3.3	3.5	3.5	3.8	4.1	3.9



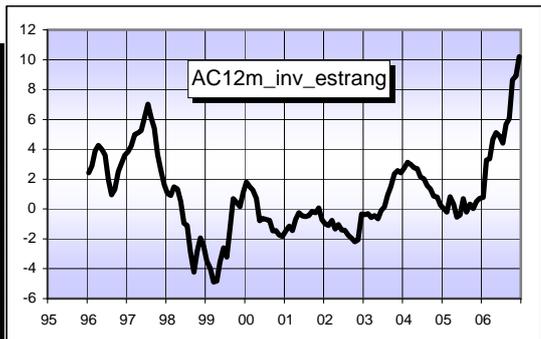
Inv.Estrangeiro - Saldo Mensal do Investimento Estrangeiro em Carteira (US\$ bilhões) - CVM

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	-1.17	-0.11	-1.18	0.13	0.63	0.12	1.44	1.49	0.00	-0.76	-0.10	0.04
1996	0.72	0.37	-0.17	0.50	0.34	-0.26	-0.18	0.47	0.36	0.44	0.46	0.56
1997	0.95	0.75	0.60	0.60	0.51	0.56	0.76	-0.43	-0.36	-1.29	-0.59	-0.44
1998	0.37	0.62	1.18	0.46	-0.32	-0.90	0.61	-2.18	-1.74	0.09	0.32	-0.97
1999	-0.66	0.11	0.28	0.53	0.96	0.04	-0.03	-0.27	0.27	-0.15	0.03	-0.03
2000	0.05	-0.19	0.05	-0.02	-0.54	0.18	-0.09	-0.33	-0.44	-0.13	-0.26	-0.12
2001	0.43	0.10	-0.25	0.73	-0.09	-0.03	-0.14	-0.27	-0.17	-0.20	0.07	-0.93
2002	0.16	0.00	0.10	0.16	0.20	-0.38	-0.17	-0.61	-0.35	-0.44	0.20	0.80
2003	0.11	0.06	-0.16	0.30	-0.02	0.17	0.07	0.18	0.21	0.43	0.41	0.65
2004	0.42	0.46	-0.31	0.09	-0.08	-0.37	-0.06	-0.28	-0.02	-0.05	0.35	0.13
2005	0.18	0.22	0.71	-0.40	-0.96	-0.21	1.03	-1.18	0.52	-0.36	0.83	0.33
2006	0.25	2.73	0.79	0.90	-0.52	-0.45	0.56	0.07	0.90	2.22	1.11	1.62



AC12m_Inv.Estrangeiro - Investimento Estrangeiro em Carteira Acumulado nos Últimos 12 Meses (US\$ bilhões)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	2.4	2.9	3.9	4.3	4.0	3.6	2.0	1.0	1.3	2.5	3.1	3.6
1997	3.8	4.2	5.0	5.1	5.3	6.1	7.0	6.1	5.4	3.7	2.6	1.6
1998	1.0	0.9	1.5	1.3	0.5	-0.9	-1.1	-2.9	-4.2	-2.8	-1.9	-2.5
1999	-3.5	-4.0	-4.9	-4.8	-3.5	-2.6	-3.2	-1.3	0.7	0.4	0.2	1.1
2000	1.8	1.5	1.3	0.7	-0.8	-0.6	-0.7	-0.8	-1.5	-1.5	-1.7	-1.8
2001	-1.5	-1.2	-1.5	-0.7	-0.3	-0.5	-0.5	-0.4	-0.2	-0.2	0.1	-0.7
2002	-1.0	-1.1	-0.8	-1.3	-1.0	-1.4	-1.4	-1.8	-2.0	-2.2	-2.1	-0.3
2003	-0.4	-0.3	-0.6	-0.4	-0.7	-0.1	0.1	0.9	1.5	2.4	2.6	2.4
2004	2.7	3.1	3.0	2.8	2.7	2.2	2.0	1.6	1.3	0.9	0.8	0.3
2005	0.0	-0.2	0.8	0.3	-0.6	-0.4	0.7	-0.2	0.3	0.0	0.5	0.7
2006	0.8	3.3	3.4	4.7	5.1	4.9	4.4	5.7	6.1	8.6	8.9	10.2



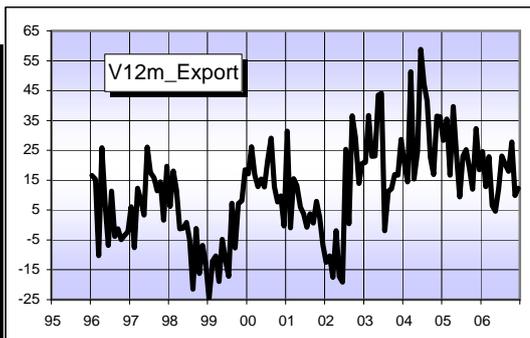
Export - Exportações Mensais da Balança Comercial Brasileira (US\$ bilhões) - SECEX

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	3.0	3.0	3.8	3.4	4.2	4.1	4.0	4.6	4.2	4.4	4.0	3.9
1996	3.5	3.4	3.4	4.3	4.5	3.8	4.5	4.4	4.1	4.2	3.9	3.8
1997	3.7	3.1	3.8	4.6	4.7	4.8	5.2	5.1	4.6	4.8	4.0	4.5
1998	3.9	3.7	4.3	4.6	4.6	4.9	5.0	4.0	4.5	4.0	3.7	3.9
1999	2.9	3.3	3.8	3.7	4.4	4.3	4.1	4.3	4.2	4.3	4.0	4.7
2000	3.5	4.1	4.5	4.2	5.1	4.9	5.0	5.5	4.7	4.6	4.4	4.7
2001	4.5	4.1	5.2	4.7	5.4	5.0	5.0	5.7	4.8	5.0	4.5	4.3
2002	4.0	3.7	4.3	4.6	4.4	4.1	6.2	5.8	6.5	6.5	5.1	5.2
2003	4.8	5.0	5.2	5.7	6.4	5.9	6.1	6.4	7.3	7.6	6.0	6.7
2004	5.8	5.7	7.9	6.6	7.9	9.3	9.0	9.1	8.9	8.8	8.2	9.2
2005	7.4	7.8	9.3	9.2	9.8	10.2	11.1	11.3	10.6	9.9	10.8	10.9
2006	9.3	8.8	11.4	9.8	10.3	11.4	13.6	13.6	12.5	12.7	11.9	12.2



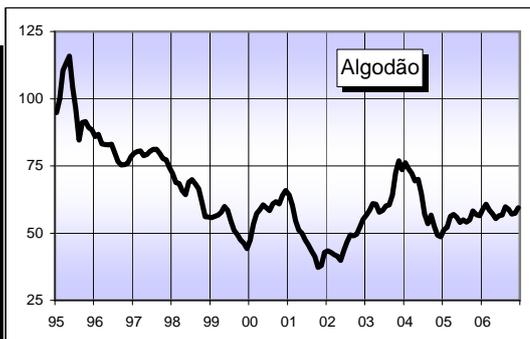
V12m_Export - Variação das Exportações Mensais da Balança Comercial Brasileira em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	16.5	15.3	-10.3	25.8	7.2	-6.8	11.4	-3.9	-1.2	-4.9	-3.4	-2.2
1997	6.1	-7.6	12.3	8.4	3.4	26.1	17.5	15.8	11.5	14.4	1.6	19.7
1998	6.2	18.1	11.7	-1.2	-1.1	0.9	-5.1	-21.5	-1.1	-16.3	-6.8	-13.0
1999	-24.7	-12.0	-10.4	-18.9	-4.8	-11.7	-17.2	7.3	-7.7	7.2	8.1	18.5
2000	17.1	26.2	16.8	12.8	15.4	12.7	21.5	29.0	12.8	7.8	9.7	-0.3
2001	31.4	-1.0	15.5	13.1	6.0	3.7	-0.8	3.8	0.7	7.9	2.5	-6.7
2002	-12.5	-10.4	-17.5	-1.9	-17.3	-19.1	25.3	0.4	36.5	29.4	13.9	20.6
2003	21.0	36.7	23.0	23.1	43.5	44.0	-1.9	11.3	12.1	16.9	16.6	28.7
2004	20.7	14.4	51.3	15.4	24.6	58.8	47.3	41.4	22.6	16.9	36.4	36.2
2005	28.4	35.5	16.7	39.6	23.6	9.4	23.0	25.3	19.2	12.0	32.2	18.5
2006	24.5	12.8	22.9	6.5	4.7	12.0	23.1	20.2	18.0	27.8	10.0	12.3



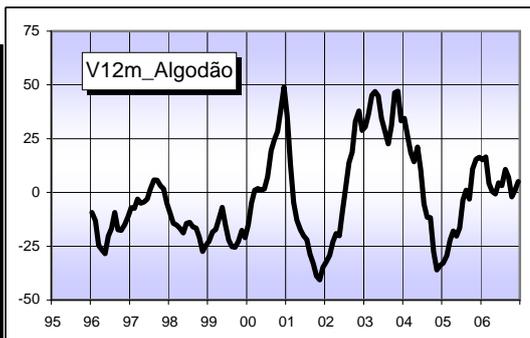
Algodão - Preço Médio Mensal do Algodão na Bolsa de Mercadorias e Valores de Liverpool (US\$) - IPEA

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	94.8	100.0	110.5	113.2	115.9	104.4	96.0	84.7	91.1	91.5	89.3	88.4
1996	85.9	86.8	83.2	83.0	82.9	83.1	79.8	76.7	75.4	75.4	75.9	78.3
1997	79.8	80.4	80.6	78.8	79.3	80.5	81.2	81.2	79.6	77.8	77.2	74.4
1998	72.1	68.8	68.4	65.7	64.4	68.9	69.9	68.2	66.4	61.5	56.1	56.0
1999	55.8	56.2	56.7	57.7	59.9	58.5	54.4	51.0	49.5	47.4	46.2	44.2
2000	47.4	53.4	57.3	58.8	60.5	59.5	58.4	60.9	61.6	60.9	64.0	65.9
2001	64.2	60.4	54.6	51.2	50.0	47.5	45.6	43.3	41.3	37.2	38.0	42.9
2002	43.4	42.8	42.0	41.4	39.9	43.5	46.7	49.3	49.0	49.6	52.3	55.2
2003	56.7	58.6	61.0	60.8	57.8	58.5	60.2	60.5	64.2	72.6	76.9	73.6
2004	76.2	73.9	72.3	69.4	70.0	64.6	57.0	53.5	56.7	52.5	49.2	48.6
2005	51.3	52.2	56.2	57.0	55.8	54.0	55.0	54.1	55.0	58.2	56.8	56.5
2006	59.0	60.8	58.6	57.2	55.4	56.4	56.7	59.9	58.8	57.0	57.4	59.4



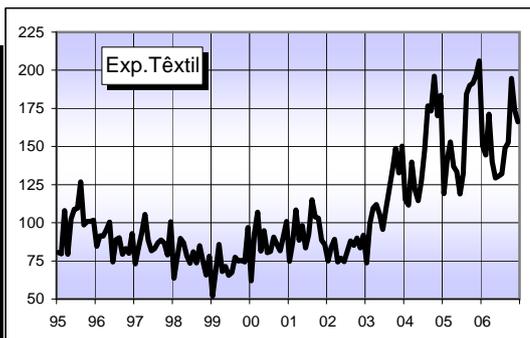
V12m_Algodão - Variação do Preço Médio Mensal do Algodão na Bolsa de Mercadorias e Valores de Liverpool em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-9.4	-13.2	-24.7	-26.7	-28.5	-20.3	-16.8	-9.4	-17.3	-17.6	-15.0	-11.5
1997	-7.1	-7.4	-3.1	-5.0	-4.4	-3.2	1.7	5.9	5.7	3.1	1.7	-5.0
1998	-9.6	-14.4	-15.1	-16.6	-18.8	-14.4	-13.9	-16.0	-16.6	-21.0	-27.4	-24.7
1999	-22.7	-18.4	-17.1	-12.1	-6.9	-15.1	-22.1	-25.2	-25.5	-22.8	-17.6	-21.1
2000	-15.0	-4.9	1.0	1.8	1.0	1.7	7.3	19.4	24.6	28.4	38.5	49.0
2001	35.3	13.1	-4.8	-12.9	-17.4	-20.2	-22.0	-28.8	-33.1	-38.9	-40.7	-34.9
2002	-32.3	-29.2	-22.9	-19.1	-20.2	-8.4	2.5	13.8	18.7	33.2	37.9	28.8
2003	30.6	36.8	45.1	46.9	44.9	34.5	28.9	22.7	31.0	46.4	47.0	33.3
2004	34.4	26.3	18.5	14.2	21.2	10.5	-5.3	-11.6	-11.7	-27.6	-36.0	-34.0
2005	-32.8	-29.4	-22.2	-18.0	-20.3	-16.5	-3.6	1.1	-3.1	10.9	15.4	16.3
2006	15.1	16.4	4.2	0.4	-0.8	4.5	3.2	10.7	7.0	-2.1	1.0	5.1



Exp.Têxtil - Valor Financeiro das Exportações do Setor Têxtil Brasileiro (US\$ milhões) - FUNCEX

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	81	80	108	79	102	109	109	127	99	101	101	102
1996	85	91	91	96	100	74	89	90	79	83	80	93
1997	73	84	94	105	89	82	83	87	89	87	79	101
1998	64	77	90	87	78	73	81	74	85	75	66	78
1999	52	69	86	68	71	66	67	77	75	75	74	97
2000	62	93	107	81	95	80	81	91	86	82	91	101
2001	75	87	108	89	98	83	93	115	104	103	89	86
2002	75	84	89	74	77	75	81	88	85	90	83	92
2003	74	100	110	112	106	96	109	122	135	149	133	150
2004	115	112	140	122	115	128	148	177	173	196	170	184
2005	119	141	153	137	134	119	132	184	190	192	197	206
2006	151	144	171	140	129	131	132	149	153	195	174	166



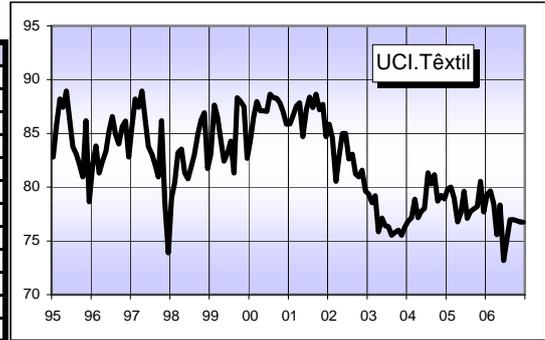
V12m_Exp.Têxtil - Variação do Valor Financeiro das Exportações do Setor Têxtil Brasileiro em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	5.0	14.7	-15.4	20.4	-2.0	-31.9	-18.7	-29.0	-19.5	-17.7	-20.7	-8.6
1997	-13.5	-8.5	2.4	10.4	-11.9	10.1	-6.5	-3.7	11.9	4.3	-1.3	8.3
1998	-13.0	-7.9	-4.0	-17.6	-11.5	-10.2	-2.5	-15.1	-4.2	-13.5	-16.7	-22.4
1999	-18.4	-10.9	-4.3	-21.7	-8.9	-10.8	-16.9	5.0	-11.8	0.5	12.9	24.1
2000	19.3	35.4	24.6	19.7	33.0	22.6	20.5	17.2	14.3	8.4	22.6	4.0
2001	20.8	-6.1	1.3	8.7	3.5	3.9	14.1	27.0	21.1	26.2	-2.7	-15.2
2002	0.3	-3.4	-17.8	-16.0	-21.7	-10.7	-12.1	-23.5	-17.9	-12.7	-5.8	7.5
2003	-1.9	18.4	23.0	50.6	37.5	28.3	34.4	38.1	58.0	65.4	59.1	63.5
2004	56.3	11.9	27.5	8.7	8.4	33.4	35.0	45.1	28.8	31.9	28.3	22.1
2005	3.6	26.3	9.4	12.5	16.7	-6.7	-10.4	4.4	9.6	-2.3	15.7	12.4
2006	26.4	2.4	12.0	2.3	-3.1	9.8	-0.1	-19.1	-19.7	1.6	-11.7	-19.4



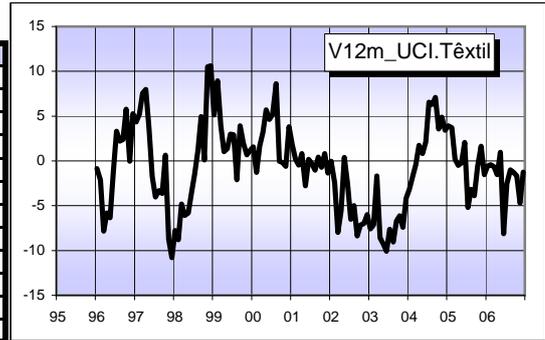
UCI.Têxtil - Utilização da Capacidade Instalada da Indústria Têxtil de SC (%) - FIESC

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	82.8	85.7	88.2	87.4	89.0	86.3	83.8	83.1	82.1	81.0	86.2	78.6
1996	82.1	83.8	81.3	82.4	83.3	85.3	86.6	84.9	84.0	85.6	86.2	82.8
1997	85.7	88.2	87.4	89.0	86.3	83.8	83.1	82.1	81.0	86.2	78.6	73.9
1998	79.0	80.4	83.2	83.5	81.3	80.8	81.9	83.0	85.0	86.3	86.9	81.7
1999	83.1	87.6	86.5	84.4	82.4	83.2	84.3	81.3	88.3	88.0	87.5	82.7
2000	84.4	86.5	88.0	87.1	87.1	87.0	88.7	88.3	88.3	87.8	87.0	85.8
2001	85.9	86.7	87.5	87.8	84.7	87.2	88.4	87.4	88.7	87.2	87.7	84.7
2002	85.8	84.6	80.5	83.0	85.0	85.0	82.6	83.1	81.2	81.0	81.6	79.6
2003	79.3	78.6	79.2	75.8	77.1	76.4	76.3	75.5	75.8	76.0	75.5	76.3
2004	76.8	77.1	78.9	77.2	77.8	78.0	81.3	80.3	81.2	78.7	79.2	78.9
2005	79.8	80.0	79.0	76.8	77.6	79.6	77.1	77.8	78.0	78.2	80.5	77.7
2006	79.4	79.7	78.5	75.6	78.4	73.2	75.1	77.0	77.0	76.9	76.8	76.7



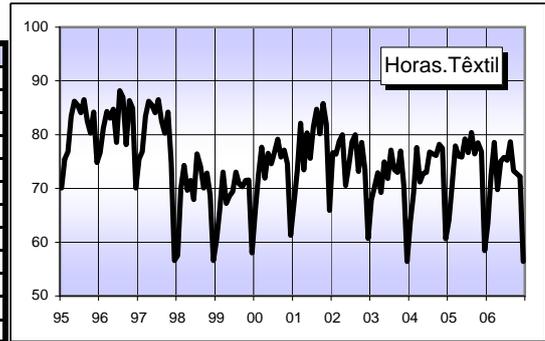
V12m_UCI.Têxtil - Variação da Utilização da Capacidade Instalada da Indústria Têxtil de SC em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-0.9	-2.1	-7.8	-5.8	-6.3	-1.2	3.3	2.2	2.4	5.8	0.0	5.3
1997	4.3	5.2	7.5	8.0	3.6	-1.7	-4.0	-3.3	-3.6	0.6	-8.7	-10.8
1998	-7.8	-8.8	-4.8	-6.1	-5.8	-3.6	-1.4	1.2	4.9	0.1	10.5	10.6
1999	5.1	8.9	4.0	1.0	1.3	3.0	2.9	-2.1	3.9	2.0	0.7	1.2
2000	1.6	-1.3	1.7	3.2	5.7	4.6	5.2	8.6	0.0	-0.2	-0.6	3.8
2001	1.8	0.2	-0.5	0.8	-2.8	0.2	-0.3	-1.0	0.4	-0.7	0.8	-1.3
2002	-0.1	-2.4	-8.0	-5.5	0.4	-2.5	-6.5	-5.0	-8.4	-7.2	-7.0	-6.0
2003	-7.6	-7.1	-1.7	-8.6	-9.3	-10.1	-7.6	-9.0	-6.7	-6.1	-7.4	-4.2
2004	-3.2	-1.8	-0.4	1.7	0.8	2.1	6.6	6.3	7.1	3.6	4.9	3.4
2005	3.9	3.7	0.2	-0.5	-0.2	2.1	-5.2	-3.2	-3.9	-0.7	1.6	-1.5
2006	-0.6	-0.4	-0.7	-1.5	1.0	-8.1	-2.6	-1.0	-1.3	-1.7	-4.7	-1.2



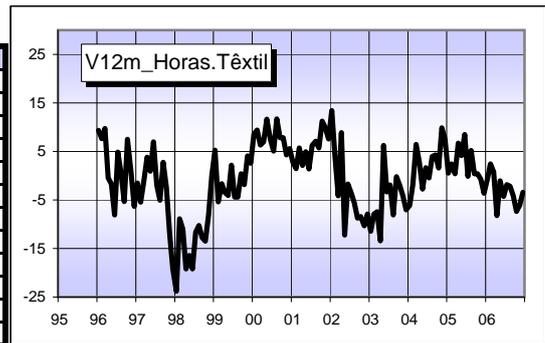
Horas.Têxtil - Total de Horas Trabalhadas na Indústria Têxtil de SC (h) - FIESC

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	70.1	75.5	76.8	83.5	86.2	85.5	84.1	86.5	82.6	80.3	84.2	74.8
1996	76.7	81.2	84.3	83.1	84.7	78.6	88.2	87.0	78.1	86.3	84.9	70.1
1997	75.5	76.8	83.5	86.2	85.5	84.1	86.5	82.6	80.3	84.2	74.8	56.6
1998	57.5	70.0	74.3	69.6	71.5	67.9	76.4	74.1	70.1	72.8	68.7	56.6
1999	60.5	66.2	73.1	67.2	68.6	69.4	73.0	70.8	70.3	71.5	71.5	58.0
2000	65.7	72.5	77.7	71.9	76.5	74.6	76.8	79.1	75.8	77.1	74.6	61.3
2001	67.6	73.5	82.1	73.5	80.3	75.6	81.6	84.7	80.2	85.8	82.0	65.9
2002	76.6	76.4	78.8	80.0	70.5	74.3	78.7	80.0	73.2	78.5	73.5	60.7
2003	67.9	70.3	72.9	69.3	74.9	71.8	77.2	73.5	73.0	77.0	70.4	56.4
2004	63.7	69.1	77.6	71.2	72.8	73.0	76.8	76.4	76.2	78.2	77.4	60.6
2005	64.1	70.8	77.9	76.0	75.9	79.2	76.7	80.4	76.4	78.5	76.8	58.4
2006	63.5	72.5	78.6	69.8	75.1	75.8	75.3	78.7	73.3	72.7	72.2	56.4



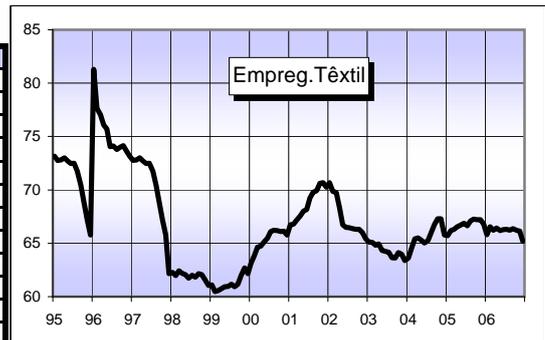
V12m_Horas.Têxtil - Variação do Total de Horas Trabalhadas na Indústria Têxtil de SC em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	9.4	7.6	9.8	-0.5	-1.7	-8.1	4.9	0.5	-5.4	7.5	0.8	-6.3
1997	-1.5	-5.4	-1.0	3.8	0.9	7.0	-1.9	-5.1	2.8	-2.5	-11.9	-19.3
1998	-23.8	-8.9	-11.0	-19.2	-16.4	-19.2	-11.7	-10.2	-12.8	-13.5	-8.1	0.0
1999	5.2	-5.4	-1.7	-3.5	-4.1	2.2	-4.4	-4.4	0.4	-1.8	4.1	2.6
2000	8.6	9.4	6.3	7.0	11.7	7.5	5.1	11.7	7.8	7.9	4.3	5.6
2001	2.8	1.4	5.7	2.1	4.9	1.4	6.2	7.1	5.8	11.2	9.9	7.6
2002	13.4	3.9	-4.1	8.9	-12.2	-1.7	-3.5	-5.6	-8.8	-8.4	-10.3	-7.9
2003	-11.4	-7.9	-7.4	-13.4	6.2	-3.3	-1.9	-8.1	-0.2	-2.0	-4.1	-7.1
2004	-6.1	-1.8	6.5	2.8	-2.8	1.6	-0.5	3.9	4.3	1.6	9.9	7.4
2005	0.5	2.4	0.4	6.7	4.2	8.5	-0.1	5.2	0.4	0.4	-0.7	-3.6
2006	-0.8	2.4	0.8	-8.2	-1.0	-4.3	-1.9	-2.1	-4.2	-7.4	-6.1	-3.4



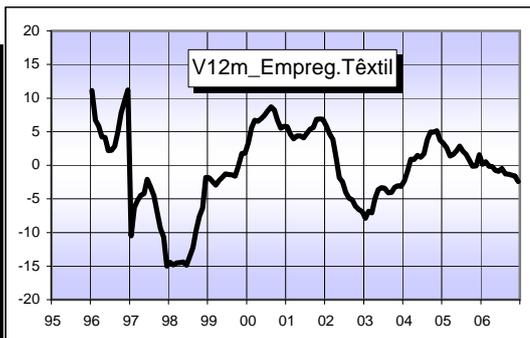
Empreg.Têxtil - Pessoal Empregado na Indústria Têxtil de SC - FIESC

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	73.2	72.8	72.8	73.0	72.7	72.5	72.5	71.7	70.4	68.8	67.2	65.8
1996	81.3	77.6	77.1	76.1	75.7	74.1	74.1	73.8	74.0	74.1	73.6	73.2
1997	72.8	72.8	73.0	72.7	72.5	72.5	71.7	70.4	68.8	67.2	65.8	62.2
1998	62.3	62.0	62.4	62.2	62.1	61.7	62.0	61.8	62.2	62.1	61.6	61.0
1999	61.1	60.5	60.6	60.8	60.9	61.0	61.2	60.9	61.2	62.0	62.7	62.1
2000	63.1	63.8	64.6	64.7	65.1	65.5	66.1	66.2	66.2	66.1	66.1	65.8
2001	66.7	66.8	67.2	67.6	68.0	68.2	69.2	69.8	69.9	70.6	70.7	70.3
2002	70.7	69.9	69.7	68.3	66.7	66.5	66.4	66.4	66.3	66.3	66.0	65.4
2003	65.1	65.1	64.8	64.9	64.3	64.3	64.2	63.6	63.6	64.1	64.0	63.4
2004	63.6	64.5	65.4	65.5	65.3	65.0	65.3	66.0	66.8	67.3	67.3	65.8
2005	65.7	66.2	66.3	66.6	66.7	66.9	66.6	67.1	67.3	67.2	67.2	66.8
2006	65.8	66.6	66.2	66.4	66.2	66.3	66.3	66.2	66.4	66.2	66.1	65.2



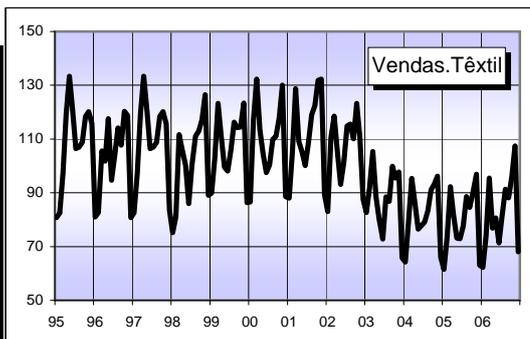
V12m_Empreg.Têxtil - Variação do Pessoal Empregado na Indústria Têxtil de SC em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	11.1	6.7	5.9	4.2	4.1	2.2	2.2	2.9	5.1	7.8	9.6	11.2
1997	-10.5	-6.3	-5.2	-4.5	-4.3	-2.1	-3.2	-4.5	-7.0	-9.4	-10.7	-15.0
1998	-14.4	-14.8	-14.5	-14.5	-14.4	-14.9	-13.6	-12.2	-9.6	-7.6	-6.4	-1.8
1999	-1.9	-2.4	-3.0	-2.3	-1.8	-1.3	-1.4	-1.4	-1.6	-0.1	1.8	1.8
2000	3.3	5.6	6.7	6.6	6.9	7.4	8.1	8.7	8.2	6.6	5.5	5.8
2001	5.7	4.6	3.9	4.4	4.4	4.1	4.7	5.4	5.6	6.8	6.9	6.9
2002	5.9	4.6	3.8	1.1	-1.9	-2.5	-4.0	-4.9	-5.1	-6.1	-6.6	-6.9
2003	-7.9	-6.8	-7.1	-5.0	-3.6	-3.3	-3.4	-4.1	-4.1	-3.3	-3.1	-3.1
2004	-2.3	-0.8	0.9	0.9	1.5	1.2	1.7	3.7	4.9	4.9	5.2	3.8
2005	3.3	2.6	1.4	1.6	2.2	2.8	2.1	1.6	0.8	-0.1	-0.1	1.6
2006	0.1	0.5	-0.1	-0.2	-0.8	-0.9	-0.5	-1.3	-1.3	-1.5	-1.6	-2.4



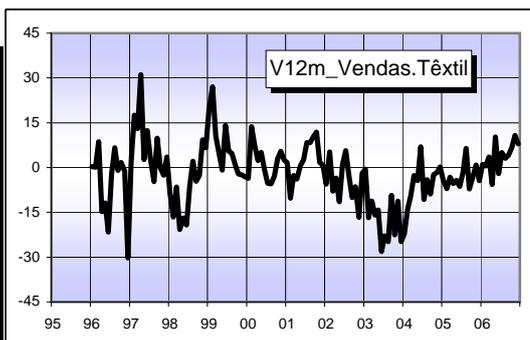
Vendas.Têxtil - Vendas Totais da Indústria Têxtil de SC (R\$ milhões) - FIESC

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	81	83	97	119	133	121	106	107	109	118	120	116
1996	81	83	106	102	118	95	104	114	108	120	119	81
1997	83	97	119	133	121	106	107	109	118	120	116	84
1998	75	81	112	106	100	86	100	111	113	117	126	89
1999	90	103	123	111	99	98	106	116	114	115	123	86
2000	87	117	132	113	105	98	100	110	111	118	130	89
2001	88	105	129	109	105	100	109	119	122	132	132	89
2002	83	111	119	105	93	101	115	116	110	123	110	88
2003	83	92	105	88	80	73	89	87	100	96	98	66
2004	64	79	95	86	76	78	79	83	91	93	96	66
2005	62	74	92	82	73	73	78	89	85	90	97	63
2006	62	74	96	77	81	71	82	91	88	96	107	68



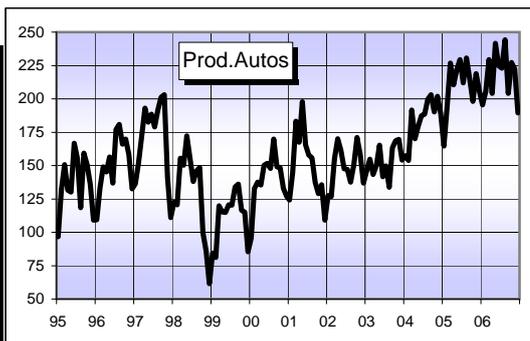
V12m_Vendas.Têxtil - Variação das Vendas Totais da Indústria Têxtil de SC em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.4	0.1	8.6	-14.8	-11.9	-21.6	-2.4	6.7	-0.9	1.7	-1.2	-30.2
1997	1.9	17.6	13.1	31.1	2.7	12.4	3.0	-4.7	9.9	-0.1	-2.6	3.5
1998	-8.9	-16.6	-6.5	-20.7	-16.9	-19.2	-6.2	2.1	-4.6	-2.7	9.3	6.7
1999	19.5	27.0	10.5	4.8	-0.9	14.1	5.5	4.7	1.1	-2.2	-2.4	-3.1
2000	-3.6	13.7	7.3	2.4	5.1	-0.5	-5.3	-5.5	-2.8	2.9	5.4	2.6
2001	1.6	-10.2	-2.7	-3.8	0.6	2.7	8.4	8.3	10.3	11.8	1.7	0.8
2002	-5.6	5.2	-7.9	-3.6	-11.5	1.1	5.6	-2.9	-10.1	-6.4	-16.7	-1.9
2003	-0.5	-16.8	-11.2	-15.9	-14.2	-28.1	-22.9	-24.8	-9.3	-22.5	-11.3	-24.8
2004	-22.2	-14.0	-9.4	-2.7	-4.4	6.9	-10.7	-4.1	-8.8	-2.4	-1.7	0.3
2005	-4.3	-7.1	-3.2	-5.3	-4.3	-6.3	-1.8	6.4	-7.2	-3.5	0.8	-4.4
2006	1.1	0.5	3.6	-5.7	10.2	-2.0	5.1	3.1	4.2	6.7	10.7	7.9



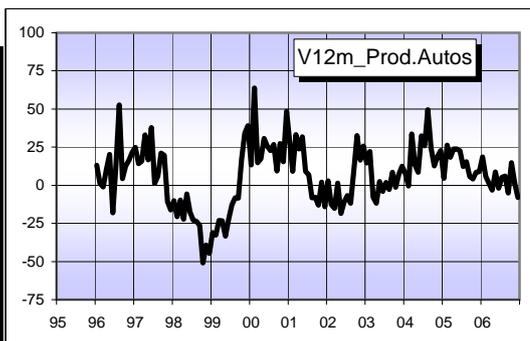
Prod.Autos - Produção Total de Autoveículos Nacionais (mil unidades) - ANFAVEA

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	97	132	151	132	130	167	155	118	159	151	136	109
1996	109	133	149	145	156	137	177	181	166	170	158	132
1997	136	152	172	193	183	189	179	192	201	203	141	111
1998	123	121	156	150	172	155	138	146	149	100	86	61
1999	84	81	120	115	115	121	120	134	136	117	115	85
2000	96	133	138	135	150	152	148	170	149	148	133	127
2001	124	145	183	168	198	166	158	156	137	129	136	109
2002	128	127	155	170	161	148	147	138	150	171	158	137
2003	146	155	143	150	165	142	150	134	163	169	170	154
2004	157	154	192	170	179	187	189	200	203	190	202	189
2005	165	194	227	211	222	229	212	231	215	198	219	206
2006	195	206	229	204	242	225	223	244	204	227	222	189



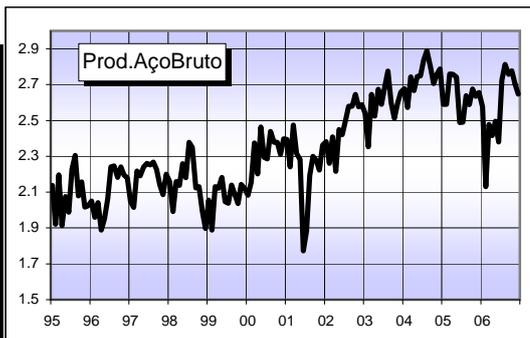
V12m_Prod.Autos - Variação da Produção Total de Autoveículos Nacionais em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	13.0	1.2	-1.1	10.3	20.2	-18.0	14.0	52.6	4.3	12.8	16.3	21.4
1997	24.8	14.2	15.7	33.0	16.8	37.8	1.1	6.0	21.1	19.5	-10.7	-16.3
1998	-10.2	-20.6	-9.8	-22.2	-5.7	-17.7	-22.8	-23.8	-26.2	-50.9	-39.2	-44.6
1999	-31.1	-32.8	-23.0	-23.2	-33.3	-22.3	-12.9	-8.3	-8.4	16.8	34.1	39.0
2000	13.2	63.8	14.8	17.3	30.8	25.7	22.8	26.8	9.4	27.4	15.5	48.6
2001	29.8	9.1	33.3	23.7	31.7	9.2	6.8	-8.2	-7.8	-13.1	2.0	-14.1
2002	2.8	-12.6	-15.2	1.5	-18.5	-10.9	-6.8	-11.7	9.6	32.7	16.5	25.6
2003	14.6	22.1	-7.7	-11.9	2.5	-4.1	1.9	-2.9	8.6	-1.4	7.3	12.5
2004	7.7	-0.6	33.6	13.4	8.6	32.3	25.9	49.5	24.4	12.8	19.1	22.7
2005	4.6	26.3	18.4	23.9	23.7	22.5	12.3	15.4	5.9	4.1	8.4	9.0
2006	18.7	5.8	1.2	-3.1	8.8	-2.0	5.2	5.9	-5.1	14.7	1.5	-8.0



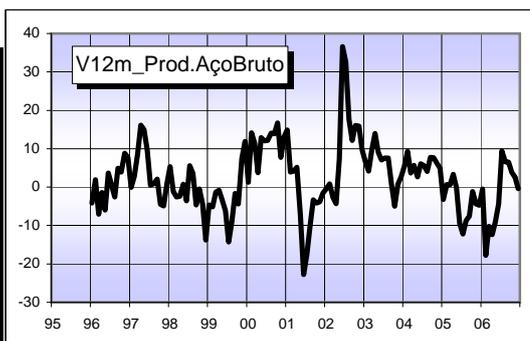
Prod. Aço Bruto - Produção Siderúrgica de Aço Bruto (mil toneladas) - IBS

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	2.1	1.9	2.2	1.9	2.1	2.0	2.2	2.3	2.1	2.2	2.0	2.0
1996	2.1	2.0	2.0	1.9	2.0	2.1	2.2	2.2	2.2	2.2	2.2	2.2
1997	2.0	2.0	2.2	2.2	2.2	2.3	2.3	2.3	2.2	2.1	2.1	2.2
1998	2.2	2.0	2.2	2.1	2.3	2.2	2.4	2.3	2.1	2.1	2.0	1.9
1999	2.1	1.9	2.1	2.1	2.2	2.0	2.0	2.1	2.1	2.0	2.1	2.1
2000	2.1	2.2	2.4	2.2	2.5	2.3	2.3	2.4	2.4	2.4	2.3	2.4
2001	2.4	2.2	2.5	2.3	2.3	1.8	1.9	2.2	2.3	2.3	2.2	2.4
2002	2.4	2.3	2.4	2.2	2.5	2.4	2.5	2.6	2.6	2.6	2.6	2.6
2003	2.5	2.4	2.6	2.5	2.7	2.6	2.7	2.8	2.6	2.5	2.6	2.7
2004	2.7	2.6	2.7	2.7	2.7	2.7	2.8	2.9	2.8	2.7	2.8	2.8
2005	2.6	2.6	2.8	2.8	2.7	2.5	2.5	2.6	2.6	2.7	2.6	2.7
2006	2.6	2.1	2.5	2.4	2.5	2.4	2.7	2.8	2.8	2.8	2.7	2.6



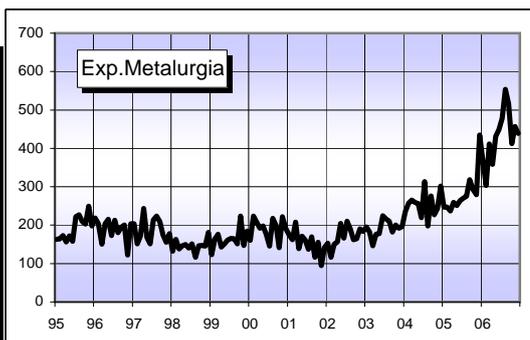
V12m_Prod. Aço Bruto - Variação da Produção Siderúrgica de Aço Bruto em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-4.1	1.9	-7.0	-1.4	-6.0	3.7	0.6	-2.5	4.9	3.9	8.8	7.8
1997	-0.1	2.9	8.6	16.1	14.9	9.7	0.5	0.9	2.1	-4.4	-4.9	0.9
1998	5.3	-1.2	-2.6	-2.4	0.8	-3.6	5.6	3.6	-4.6	-0.5	-4.4	-13.8
1999	-4.7	-5.2	-1.3	-0.8	-3.4	-6.2	-14.3	-9.0	-1.7	-4.4	7.5	11.9
2000	1.3	14.2	11.4	3.8	12.9	12.1	12.1	14.1	13.9	16.8	7.8	13.0
2001	14.9	3.9	4.2	5.2	-7.4	-22.8	-17.6	-10.1	-3.3	-4.2	-3.8	-1.5
2002	-0.5	0.9	-2.6	-4.3	7.3	36.6	32.6	17.7	12.2	16.1	15.9	9.6
2003	6.6	4.2	9.8	14.0	9.1	7.1	7.6	7.6	0.8	-5.0	0.8	2.7
2004	5.4	9.3	3.7	5.6	2.7	6.1	5.6	4.1	7.8	7.7	6.2	4.9
2005	-3.3	0.7	0.6	3.4	-0.1	-9.5	-12.2	-8.7	-7.6	-1.1	-4.4	-4.7
2006	-0.5	-17.7	-10.2	-12.4	-9.0	-4.4	9.4	6.6	6.5	3.8	2.6	-0.4



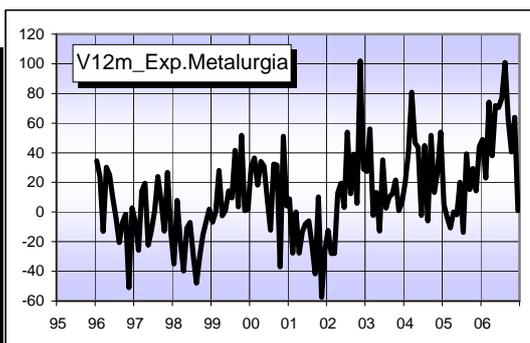
Exp. Metalurgia - Valor Financeiro das Exportações do Setor Metalúrgico Brasileiro (US\$ milhões) - FUNCEX

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	162.7	164.6	172.9	156.6	172.5	158.3	221.7	227.2	209.3	202.9	249.3	197.7
1996	218.7	204.0	150.5	203.9	215.7	173.1	212.7	180.4	194.7	200.1	122.4	203.3
1997	203.5	151.6	171.8	243.7	167.6	151.6	214.0	223.5	209.8	174.3	155.1	177.7
1998	132.1	163.3	137.6	146.7	149.3	140.8	151.3	116.3	146.5	147.5	145.3	181.4
1999	123.0	163.6	176.1	143.0	151.1	160.9	165.7	164.6	151.6	223.8	146.8	184.5
2000	160.7	223.4	208.1	191.8	197.8	175.2	145.6	218.0	199.8	141.1	221.7	192.0
2001	175.0	161.7	208.2	138.8	171.4	161.2	136.9	169.9	116.7	155.6	94.4	141.9
2002	153.1	116.4	150.1	156.1	204.7	166.2	210.6	190.7	162.2	164.8	190.6	183.4
2003	195.0	181.7	146.5	176.6	178.3	224.6	216.1	210.3	182.2	200.5	192.3	195.9
2004	235.1	256.7	264.9	259.2	256.1	219.4	313.1	197.8	276.3	226.9	244.0	301.6
2005	246.7	247.3	236.6	259.6	251.4	263.3	270.2	275.4	318.2	293.5	279.0	435.0
2006	367.5	303.8	411.8	358.2	431.6	449.0	478.3	553.3	516.0	412.2	456.8	438.7



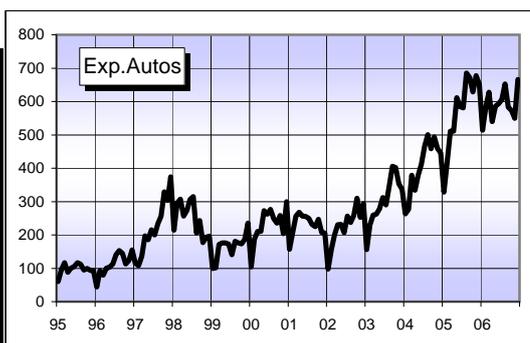
V12m_Exp. Metalurgia - Variação do Valor Financeiro das Exportações do Setor Metalúrgico Brasileiro em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	34.4	23.9	-13.0	30.2	25.0	9.3	-4.1	-20.6	-7.0	-1.4	-50.9	2.8
1997	-7.0	-25.7	14.2	19.5	-22.3	-12.4	0.6	23.9	7.8	-12.9	26.7	-12.6
1998	-35.1	7.7	-19.9	-39.8	-10.9	-7.1	-29.3	-48.0	-30.2	-15.4	-6.3	2.1
1999	-6.9	0.2	28.0	-2.5	1.2	14.3	9.5	41.5	3.5	51.7	1.0	1.7
2000	30.7	36.6	18.2	34.1	30.9	8.9	-12.1	32.4	31.8	-37.0	51.0	4.1
2001	8.9	-27.6	0.0	-27.6	-13.3	-8.0	-6.0	-22.1	-41.6	10.3	-57.4	-26.1
2002	-12.5	-28.0	-27.9	12.5	19.4	3.1	53.8	12.2	39.0	5.9	101.9	29.2
2003	27.4	56.1	-2.4	13.1	-12.9	35.1	2.6	10.3	12.3	21.7	0.9	6.8
2004	20.6	41.3	80.8	46.8	43.6	-2.3	44.9	-5.9	51.6	13.2	26.9	54.0
2005	4.9	-3.7	-10.7	0.2	-1.8	20.0	-13.7	39.2	15.2	29.4	14.3	44.2
2006	49.0	22.8	74.0	38.0	71.7	70.5	77.0	100.9	62.2	40.4	63.7	0.9



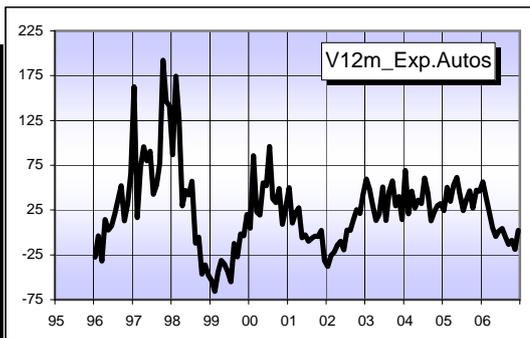
Exp. Autos - Valor Financeiro das Exportações Brasileiras de Veículos Automotores (US\$ milhões) - FUNCEX

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	60.6	96.1	116.5	88.0	100.3	105.3	116.3	112.2	94.9	99.7	93.7	93.3
1996	43.8	92.5	79.2	100.8	103.1	113.1	140.2	152.9	144.4	112.7	123.3	155.0
1997	115.1	107.9	136.3	197.3	185.4	215.7	200.0	233.7	256.1	329.4	303.3	374.6
1998	214.8	295.9	307.5	256.1	272.3	306.2	314.4	205.9	242.8	176.6	193.4	196.3
1999	99.5	101.2	170.9	176.1	175.6	172.4	141.0	180.9	176.5	173.6	186.4	235.7
2000	104.4	188.0	210.3	210.1	273.2	262.6	276.4	248.7	235.0	258.7	203.6	299.4
2001	156.6	208.0	256.6	268.3	256.9	255.7	249.3	232.0	225.2	247.1	208.1	205.5
2002	97.4	154.6	200.0	230.8	231.6	206.5	256.1	237.0	258.0	309.7	252.3	294.0
2003	155.7	229.3	259.5	261.9	278.7	311.5	290.4	346.2	406.2	401.7	353.0	336.9
2004	263.4	277.0	379.0	333.6	379.0	412.1	466.4	500.3	458.6	493.7	459.7	445.9
2005	328.0	417.0	511.0	510.6	611.6	584.6	581.0	685.2	672.0	628.7	677.1	652.1
2006	513.5	581.6	627.4	539.5	585.4	593.7	606.2	652.7	583.2	573.4	550.5	666.2



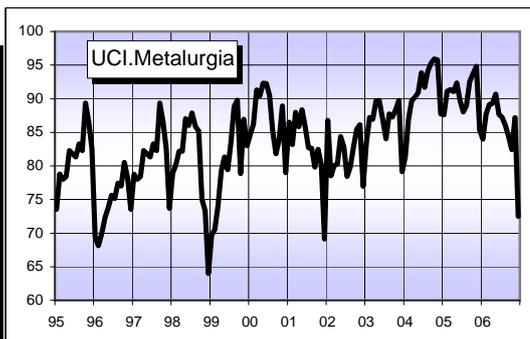
V12m_Exp.Autos - Variação do Valor Financeiro das Exportações Brasileiras de Veículos Automotores em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-27.7	-3.7	-32.0	14.5	2.8	7.4	20.6	36.3	52.2	13.0	31.6	66.1
1997	162.8	16.6	72.1	95.7	79.8	90.7	42.7	52.8	77.4	192.3	146.0	141.7
1998	86.6	174.2	125.6	29.8	46.9	42.0	57.2	-11.9	-5.2	-46.4	-36.2	-47.6
1999	-53.7	-65.8	-44.4	-31.2	-35.5	-43.7	-55.2	-12.1	-27.3	-1.7	-3.6	20.1
2000	4.9	85.8	23.1	19.3	55.6	52.3	96.0	37.5	33.1	49.0	9.2	27.0
2001	50.0	10.6	22.0	27.7	-6.0	-2.6	-9.8	-6.7	-4.2	-4.5	2.2	-31.4
2002	-37.8	-25.7	-22.1	-14.0	-9.8	-19.2	2.7	2.2	14.6	25.3	21.2	43.1
2003	59.9	48.3	29.8	13.5	20.3	50.8	13.4	46.1	57.4	29.7	39.9	14.6
2004	69.2	20.8	46.1	27.4	36.0	32.3	60.6	44.5	12.9	22.9	30.2	32.4
2005	24.5	50.5	34.8	53.1	61.4	41.9	24.6	37.0	46.5	27.3	47.3	46.2
2006	56.6	39.5	22.8	5.7	-4.3	1.6	4.3	-4.7	-13.2	-8.8	-18.7	2.2



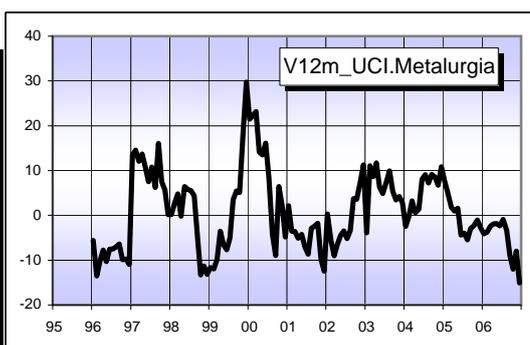
UCI.Metalurgia - Utilização da Capacidade Instalada da Indústria Metalúrgica de SC (%) - FIESC

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	73.6	78.8	78.0	78.4	82.3	81.8	81.3	83.3	82.3	89.4	86.6	82.6
1996	69.4	68.1	70.0	72.4	73.8	75.6	75.2	77.5	77.0	80.5	78.2	73.6
1997	78.8	78.0	78.4	82.3	81.8	81.3	83.3	82.3	89.4	86.6	82.6	73.7
1998	78.9	80.1	82.2	82.2	87.0	86.0	87.9	85.9	85.2	75.1	73.3	64.0
1999	69.7	70.5	74.1	79.2	81.3	79.4	83.5	88.9	89.8	78.9	86.9	83.0
2000	84.6	86.2	91.3	90.4	92.3	92.3	90.5	85.1	81.8	83.9	88.9	79.0
2001	86.5	83.2	88.0	85.8	88.4	85.8	82.7	82.6	79.8	82.5	80.2	69.1
2002	86.8	78.5	80.0	80.3	84.4	82.8	78.4	79.8	82.8	85.4	86.1	77.0
2003	83.4	87.2	86.9	89.7	89.7	86.9	84.1	87.8	87.3	88.4	89.8	79.2
2004	81.3	87.0	89.7	90.2	90.9	93.9	91.7	94.1	95.3	95.9	95.8	87.7
2005	87.6	91.1	91.3	91.1	92.4	89.7	88.0	89.0	92.6	93.7	94.8	85.3
2006	84.0	87.7	89.1	89.3	90.7	87.6	87.2	86.0	84.4	82.4	87.2	72.5



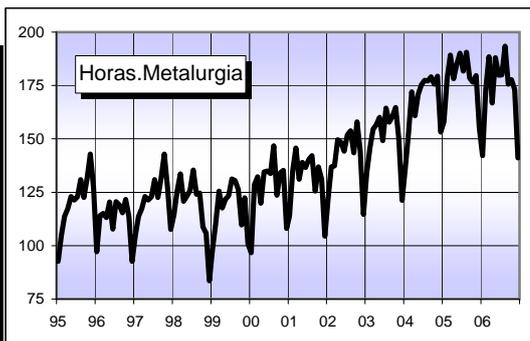
V12m_UCI.Metalurgia - Variação da Utilização da Capacidade Instalada da Indústria Metalúrgica de SC em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-5.6	-13.5	-10.3	-7.7	-10.3	-7.5	-7.5	-7.0	-6.4	-9.9	-9.8	-11.0
1997	13.5	14.5	12.0	13.7	10.8	7.5	10.8	6.2	16.0	7.5	5.7	0.2
1998	0.2	2.7	4.8	-0.2	6.4	5.8	5.5	4.4	-4.7	-13.3	-11.3	-13.2
1999	-11.7	-12.0	-9.8	-3.6	-6.6	-7.7	-5.0	3.5	5.5	5.1	18.6	29.7
2000	21.5	22.3	23.2	14.1	13.5	16.2	8.4	-4.3	-8.9	6.4	2.3	-4.8
2001	2.2	-3.5	-3.6	-5.1	-4.3	-7.0	-8.7	-2.9	-2.4	-1.8	-9.8	-12.5
2002	0.3	-5.6	-9.1	-6.5	-4.5	-3.4	-5.2	-3.4	3.8	3.6	7.4	11.3
2003	-3.9	11.0	8.6	11.7	6.3	4.9	7.2	9.9	5.4	3.4	4.2	2.9
2004	-2.5	-0.2	3.2	0.6	1.4	8.0	9.1	7.2	9.2	8.5	6.7	10.8
2005	7.7	4.7	1.8	0.9	1.6	-4.4	-4.0	-5.4	-2.9	-2.3	-1.0	-2.7
2006	-4.1	-3.8	-2.5	-1.9	-1.8	-2.3	-0.9	-3.3	-8.9	-12.0	-8.1	-15.1



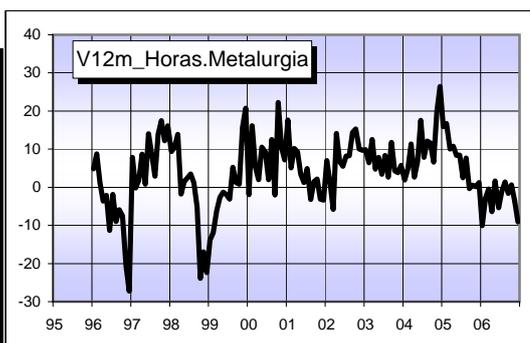
Horas.Metalurgia - Total de Horas Trabalhadas na Indústria Metalúrgica de SC (h) - FIESC

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	92.7	104.8	113.8	117.4	123.0	121.4	122.8	130.9	122.6	131.5	142.9	127.3
1996	97.1	114.0	115.1	113.1	120.4	107.7	120.5	119.1	115.4	121.7	113.5	92.7
1997	104.8	113.8	117.4	123.0	121.4	122.8	130.9	122.6	131.5	142.9	127.3	107.6
1998	114.5	125.7	133.7	120.8	123.2	125.9	135.4	124.0	124.7	108.8	105.7	83.5
1999	98.6	110.7	125.6	117.6	121.7	123.5	131.2	130.5	126.2	109.7	122.3	100.9
2000	96.7	128.6	132.3	119.9	134.5	134.9	133.8	146.8	123.6	134.1	135.2	108.1
2001	113.8	135.1	145.7	131.1	139.0	136.6	140.3	142.1	125.5	137.0	131.0	104.5
2002	121.8	136.9	137.3	149.6	148.5	144.2	151.8	153.8	143.5	157.9	144.2	114.6
2003	133.9	145.8	154.5	156.6	160.1	149.1	164.5	157.9	160.5	164.7	149.7	121.2
2004	136.4	152.8	172.0	160.8	170.8	175.3	177.4	177.1	179.1	175.6	179.4	153.2
2005	158.0	178.4	189.2	178.1	185.0	190.1	181.8	190.6	178.4	176.5	179.6	155.1
2006	142.1	173.3	188.4	166.8	188.0	179.9	179.9	193.4	175.6	177.7	173.1	141.1



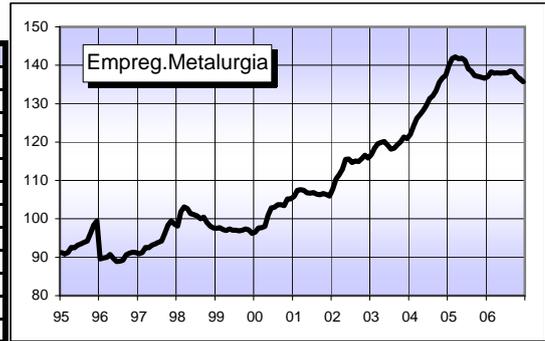
V12m_Horas.Metalurgia - Variação do Total de Horas Trabalhadas na Indústria Metalúrgica de SC em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	4.8	8.8	1.2	-3.6	-2.1	-11.3	-1.9	-9.0	-5.9	-7.5	-20.6	-27.2
1997	7.9	-0.2	1.9	8.7	0.8	14.0	8.6	2.9	13.9	17.5	12.2	16.2
1998	9.3	10.5	13.9	-1.8	1.5	2.5	3.5	1.2	-5.2	-23.9	-17.0	-22.4
1999	-13.9	-11.9	-6.0	-2.6	-1.3	-1.9	-3.1	5.2	1.2	0.8	15.7	20.8
2000	-1.9	16.1	5.3	2.0	10.5	9.3	2.0	12.5	-2.0	22.3	10.5	7.2
2001	17.7	5.1	10.2	9.3	3.4	1.3	4.9	-3.2	1.5	2.1	-3.1	-3.4
2002	7.0	1.3	-5.8	14.1	6.8	5.5	8.2	8.3	14.4	15.3	10.0	9.7
2003	9.9	6.5	12.6	4.7	7.8	3.4	8.3	2.7	11.8	4.3	3.9	5.8
2004	1.9	4.8	11.3	2.7	6.7	17.6	7.9	12.1	11.6	6.6	19.8	26.4
2005	15.9	16.7	10.0	10.8	8.3	8.5	2.5	7.7	-0.4	0.6	0.2	1.2
2006	-10.1	-2.9	-0.4	-6.4	1.6	-5.4	-1.1	1.4	-1.6	0.6	-3.6	-9.1



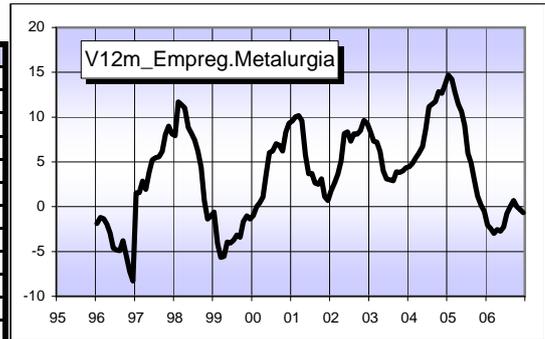
Empreg.Metalurgia - Pessoal Empregado na Indústria Metalúrgica de SC - FIESC

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	91.2	90.9	91.2	92.6	92.5	93.1	93.5	93.8	94.2	96.2	98.4	99.5
1996	89.5	89.8	90.0	90.7	89.8	88.9	89.0	89.3	90.6	91.0	91.3	91.2
1997	90.9	91.2	92.6	92.5	93.1	93.5	93.8	94.2	96.2	98.4	99.5	98.6
1998	98.1	101.9	103.1	102.7	101.4	101.1	100.8	100.1	100.5	99.0	98.1	97.6
1999	97.5	97.7	97.2	97.0	97.4	97.0	97.0	96.9	97.0	97.4	97.1	96.2
2000	96.6	97.7	97.7	98.0	101.0	102.9	103.1	103.7	103.7	103.4	105.2	105.2
2001	105.8	107.4	107.6	107.5	106.8	106.7	106.9	106.5	106.3	106.6	106.4	106.0
2002	107.7	110.3	111.5	112.9	115.5	115.6	114.7	115.1	114.9	115.7	116.6	115.8
2003	116.8	118.4	119.6	119.9	120.1	119.2	118.1	118.4	119.4	120.1	121.3	120.9
2004	122.0	124.2	126.1	127.1	128.2	129.5	131.3	132.0	133.4	135.5	136.7	137.3
2005	139.9	141.8	142.2	141.7	141.8	141.2	139.1	138.4	137.3	137.1	136.9	136.6
2006	137.1	138.3	138.0	138.1	138.0	138.0	138.0	138.5	138.2	137.1	136.5	135.7



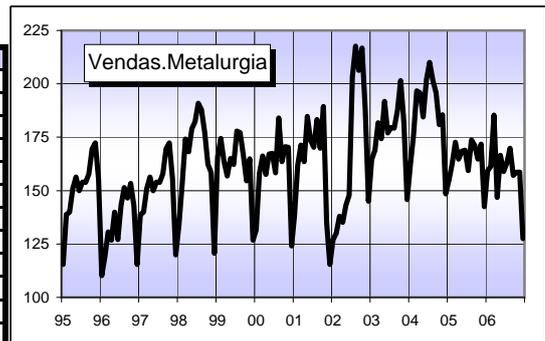
V12m_Empreg.Metalurgia - Variação do Pessoal Empregado na Indústria Metalúrgica de SC em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-1.9	-1.2	-1.3	-2.0	-3.0	-4.6	-4.8	-4.9	-3.8	-5.4	-7.2	-8.3
1997	1.5	1.6	2.8	1.9	3.8	5.2	5.5	5.6	6.2	8.0	9.0	8.1
1998	7.9	11.7	11.4	11.0	8.9	8.2	7.4	6.2	4.4	0.7	-1.4	-1.1
1999	-0.6	-4.1	-5.7	-5.5	-3.9	-4.0	-3.7	-3.2	-3.4	-1.7	-1.0	-1.4
2000	-1.0	0.0	0.4	1.1	3.6	6.0	6.2	7.0	6.8	6.2	8.3	9.3
2001	9.6	10.0	10.2	9.6	5.8	3.7	3.7	2.6	2.5	3.1	1.1	0.7
2002	1.8	2.7	3.7	5.1	8.2	8.4	7.3	8.1	8.1	8.5	9.6	9.3
2003	8.4	7.3	7.2	6.2	4.0	3.1	3.0	2.9	3.9	3.8	4.0	4.4
2004	4.5	4.9	5.5	6.0	6.7	8.7	11.1	11.5	11.7	12.8	12.7	13.6
2005	14.7	14.2	12.7	11.5	10.6	9.1	6.0	4.9	3.0	1.2	0.2	-0.5
2006	-2.1	-2.5	-3.0	-2.6	-2.7	-2.3	-0.8	0.1	0.7	0.0	-0.3	-0.7



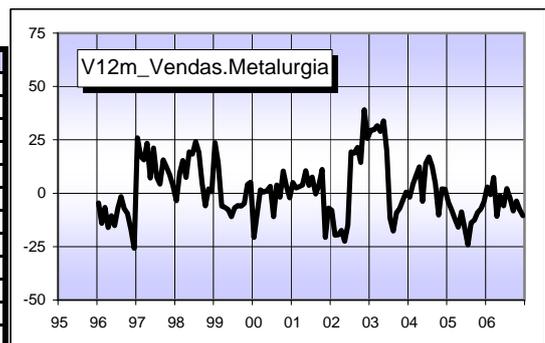
Vendas.Metalurgia - Vendas Totais da Indústria Metalúrgica de SC (R\$ milhões) - FIESC

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	115	139	140	151	156	150	154	154	158	170	172	155
1996	110	119	131	127	140	127	143	151	147	153	143	115
1997	139	140	151	156	150	154	154	158	170	172	155	120
1998	134	153	174	168	179	182	191	188	177	162	158	121
1999	166	174	164	157	165	162	178	177	167	155	165	127
2000	132	158	166	158	167	167	158	184	164	171	170	124
2001	138	162	171	164	185	174	170	183	170	189	135	115
2002	127	130	138	135	143	148	203	218	206	217	188	145
2003	165	169	182	174	192	177	180	179	187	202	182	146
2004	162	176	197	196	184	202	210	202	196	181	186	148
2005	155	163	173	165	168	169	159	174	171	165	172	142
2006	159	161	185	147	167	159	163	170	157	159	159	127



V12m_Vendas.Metalurgia - Variação das Vendas Totais da Indústria Metalúrgica de SC em Relação ao Mesmo Período do Ano Anterior (%)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	-4.6	-14.0	-6.6	-16.0	-10.5	-15.2	-7.1	-1.6	-7.2	-9.5	-17.2	-25.7
1997	26.0	17.3	15.6	23.4	7.1	21.1	7.6	4.2	15.7	12.4	8.8	3.8
1998	-3.5	9.3	15.3	7.5	19.3	18.3	24.1	19.0	4.6	-5.8	2.0	0.6
1999	23.8	14.1	-6.1	-6.7	-7.7	-10.9	-6.8	-5.7	-6.0	-4.8	4.1	5.1
2000	-20.7	-9.4	1.6	0.5	1.2	3.2	-11.0	3.9	-1.9	10.4	3.2	-2.2
2001	5.0	2.5	3.1	3.8	10.6	3.7	7.5	-0.4	3.8	11.1	-20.7	-7.0
2002	-8.0	-19.7	-19.5	-17.3	-22.5	-14.8	19.4	18.8	21.5	14.4	39.1	25.7
2003	29.5	29.7	31.7	28.9	33.9	19.7	-11.7	-17.7	-9.1	-7.0	-3.2	0.5
2004	-1.8	4.2	8.2	12.4	-3.8	14.0	17.0	12.5	4.5	-10.2	2.0	1.8
2005	-4.2	-7.6	-12.2	-15.9	-8.7	-16.3	-24.1	-13.8	-12.6	-9.0	-7.4	-4.0
2006	2.9	-0.7	7.4	-10.8	-1.1	-5.9	2.2	-2.3	-8.2	-3.6	-7.6	-10.5



- ANEXO E -

BDP3 – Base de Dados Primária 3 Séries Históricas das Variáveis Climáticas

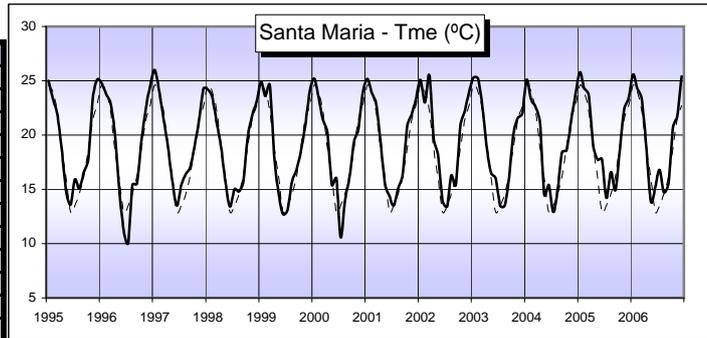
<< Dados de 15 Estações Climatológicas do Sul e Sudeste >>
<< Anomalias Climáticas das Temperaturas para o Sul/Sudeste >>
<< Indicadores de Severidade Climática para o Sul/Sudeste >>

Legenda:

- Valores Mensais de janeiro/1995 a dezembro/2006
- - - Valores Esperados ou Normais de janeiro/1995 a dezembro/2006

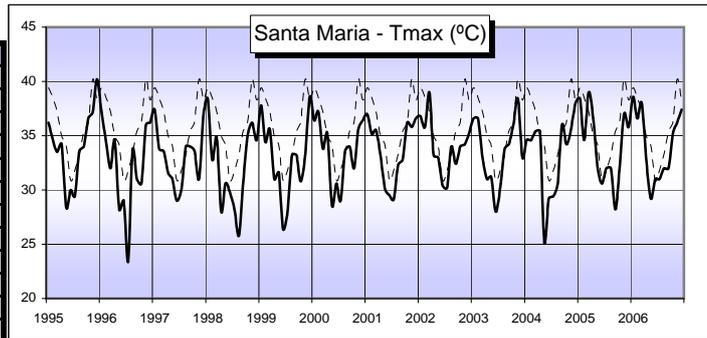
Estação Climatológica Principal de Santa Maria/RS
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	25.0	23.3	22.0	18.8	14.8	13.6	15.9	15.1	16.6	17.8	23.4	25.1
1996	24.8	23.8	22.9	20.3	15.1	11.2	10.1	15.4	15.5	19.5	22.5	24.5
1997	26.0	24.1	21.4	18.8	15.8	13.5	15.4	16.4	17.0	18.9	21.4	24.3
1998	24.2	23.5	21.1	18.8	15.7	13.4	15.0	14.8	15.6	19.7	21.8	23.1
1999	24.9	23.6	24.6	17.9	14.5	12.7	13.1	15.7	16.8	18.4	20.8	24.0
2000	25.2	23.6	21.4	20.2	15.4	16.0	10.6	14.0	16.2	19.4	20.5	23.9
2001	25.2	23.9	22.9	19.5	15.5	14.4	13.5	15.1	16.4	20.8	21.9	23.3
2002	25.1	23.0	25.5	19.8	18.1	13.9	13.4	16.3	15.4	20.8	22.2	23.9
2003	25.3	25.2	22.5	18.7	16.5	16.0	13.5	13.5	15.9	20.1	21.6	22.0
2004	25.1	23.3	22.6	21.1	14.5	15.4	12.9	15.1	18.4	18.6	21.2	23.8
2005	25.8	24.3	23.7	19.1	17.7	17.8	14.2	16.6	14.9	18.4	22.3	23.4
2006	25.6	24.3	23.3	18.9	13.9	15.2	16.8	14.7	15.5	20.7	21.7	25.4



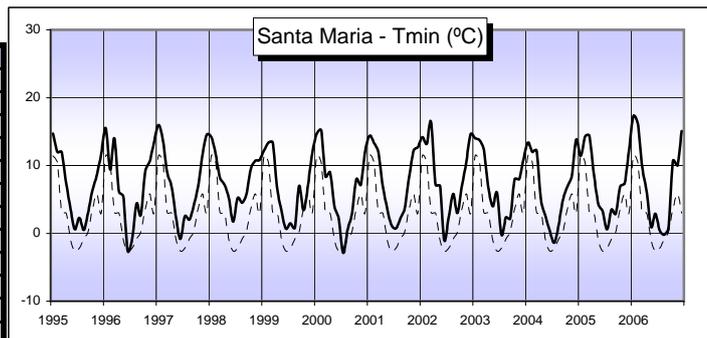
Estação Climatológica Principal de Santa Maria/RS
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	36.2	34.6	33.5	34.2	28.4	30.0	29.4	33.6	34.0	36.6	37.2	40.2
1996	37.2	34.4	32.0	34.6	28.2	29.0	23.4	33.6	31.0	30.6	36.0	36.2
1997	37.4	33.8	33.6	31.6	31.0	29.0	30.0	34.0	34.0	33.6	31.0	37.0
1998	38.4	32.8	34.8	28.0	30.6	29.8	28.2	25.8	30.6	35.0	36.2	34.6
1999	37.8	34.4	35.6	31.0	31.6	26.4	28.0	33.2	33.2	30.8	33.2	38.6
2000	36.4	37.2	33.8	35.2	28.6	30.6	29.0	33.6	34.0	32.0	35.6	36.4
2001	37.0	35.2	35.5	33.2	30.1	29.5	29.1	32.3	32.8	36.2	35.8	36.6
2002	36.8	35.8	39.0	33.2	33.0	30.4	30.2	34.0	32.4	34.0	34.2	35.2
2003	36.6	36.6	33.0	31.0	31.2	28.0	30.2	33.8	34.2	36.0	38.4	33.0
2004	34.6	34.6	35.4	35.4	25.2	29.2	29.4	30.6	36.0	34.2	35.6	38.0
2005	38.4	34.6	39.0	36.6	32.0	30.6	32.0	32.0	28.2	32.0	37.0	35.8
2006	38.6	36.6	38.0	32.8	29.2	31.0	31.0	32.0	32.0	35.2	36.2	37.4



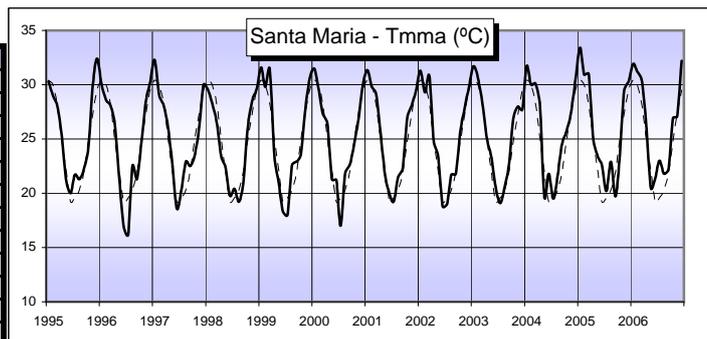
Estação Climatológica Principal de Santa Maria/RS
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	14.7	12.0	12.0	7.4	3.5	0.6	2.3	0.5	3.0	6.4	8.7	11.7
1996	15.5	9.4	14.0	6.2	5.4	-2.5	-0.8	4.4	2.7	9.1	10.6	13.4
1997	16.0	13.6	9.0	6.8	2.2	-0.8	2.5	2.0	4.0	6.9	11.6	14.5
1998	14.2	11.6	8.2	7.2	5.1	1.7	5.2	4.5	5.7	9.5	10.7	10.8
1999	12.2	13.4	13.4	6.6	3.2	0.7	1.5	0.8	7.0	3.4	7.2	11.8
2000	14.7	15.2	8.4	9.0	4.0	2.2	-2.9	0.6	2.8	8.0	7.2	12.0
2001	14.4	13.3	12.1	7.0	3.6	1.3	0.7	2.2	3.7	8.3	12.2	12.7
2002	14.2	13.2	16.4	7.2	7.0	-1.0	2.4	5.8	3.0	7.0	10.6	14.6
2003	14.0	13.7	12.4	6.8	4.0	6.0	-0.2	2.4	2.2	8.0	8.0	10.8
2004	13.4	12.0	12.2	4.9	2.5	0.4	-1.4	1.3	4.9	6.9	8.6	13.8
2005	11.4	14.3	14.4	8.8	4.3	3.3	0.6	3.5	2.9	6.9	7.4	12.1
2006	17.3	16.1	9.9	6.2	0.9	2.9	0.4	-0.2	0.8	10.7	10.0	15.1



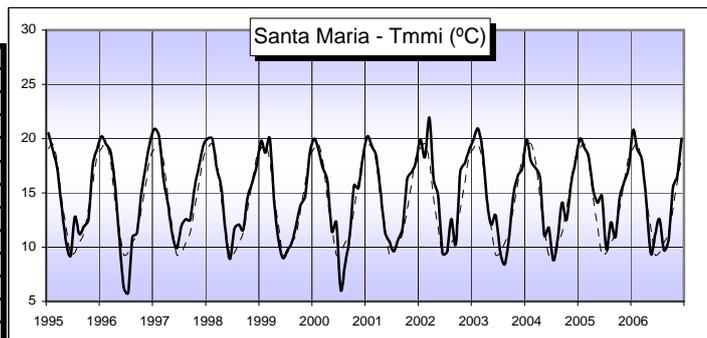
Estação Climatológica Principal de Santa Maria/RS
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	30.3	29.0	28.1	25.4	21.2	20.0	21.7	21.3	22.2	24.2	30.0	32.4
1996	30.1	28.6	28.1	26.4	21.4	16.9	16.2	22.5	21.3	24.7	28.5	30.2
1997	32.3	29.1	28.1	26.0	22.7	18.6	20.3	22.9	22.5	23.4	26.0	30.0
1998	29.6	28.3	26.5	23.4	22.4	19.8	20.4	19.2	20.8	25.9	28.5	29.6
1999	31.6	29.8	31.4	23.6	20.9	18.3	18.0	22.6	22.9	23.5	27.6	30.6
2000	31.5	29.7	27.3	26.4	21.3	21.2	17.0	21.8	22.6	24.5	26.7	29.9
2001	31.4	29.8	29.2	25.7	21.7	19.9	19.3	21.5	22.3	26.9	28.1	29.4
2002	31.3	29.3	30.8	24.9	23.4	18.8	19.0	21.7	21.8	25.7	27.9	29.8
2003	31.7	30.6	28.2	25.0	23.4	20.6	19.1	20.6	22.6	26.9	28.0	27.7
2004	31.7	30.0	30.1	28.0	19.7	21.8	19.5	21.7	24.5	25.7	27.4	30.5
2005	33.4	30.9	31.0	25.1	23.4	22.6	20.2	22.9	19.7	23.2	29.4	30.3
2006	31.9	31.2	30.4	26.2	20.5	21.4	23.0	21.8	22.2	26.9	27.1	32.2



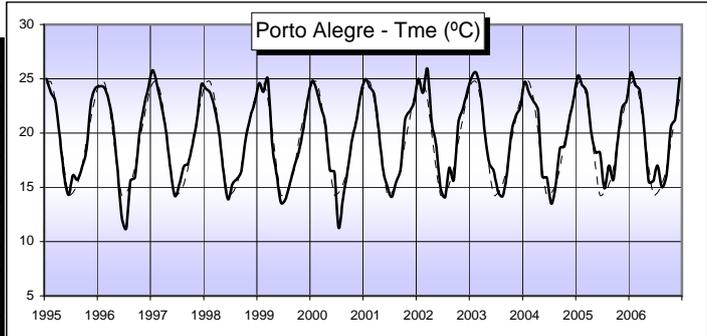
Estação Climatológica Principal de Santa Maria/RS
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	20.5	18.9	17.3	13.8	10.4	9.2	12.8	11.2	11.9	12.5	17.6	19.0
1996	20.2	19.5	18.8	16.0	11.0	6.3	5.8	10.9	11.3	15.0	17.6	19.7
1997	20.9	20.2	16.2	13.9	11.2	9.9	11.9	12.6	12.5	15.4	17.5	19.4
1998	20.0	20.0	17.3	15.5	11.6	8.9	11.7	12.1	11.6	14.6	15.9	17.5
1999	19.8	18.7	20.0	14.0	10.5	9.0	9.7	10.5	12.2	13.9	14.7	18.6
2000	20.0	19.0	17.3	16.1	11.4	12.3	6.1	8.4	11.0	15.7	15.4	18.2
2001	20.2	19.3	18.5	15.2	11.4	10.5	9.6	10.7	11.8	16.3	16.9	17.8
2002	19.9	18.3	21.9	16.3	14.7	9.4	9.6	12.6	10.3	17.0	17.7	18.9
2003	19.9	20.9	18.9	14.3	12.1	12.9	9.6	8.4	10.8	14.8	16.6	17.3
2004	19.9	17.9	17.3	16.4	11.1	11.8	8.8	10.8	14.1	12.5	15.8	17.9
2005	20.0	19.2	18.3	15.3	14.1	14.7	9.8	12.3	10.9	14.5	16.0	17.3
2006	20.8	19.0	18.1	14.2	9.4	11.2	12.6	9.7	10.6	15.5	16.5	20.0



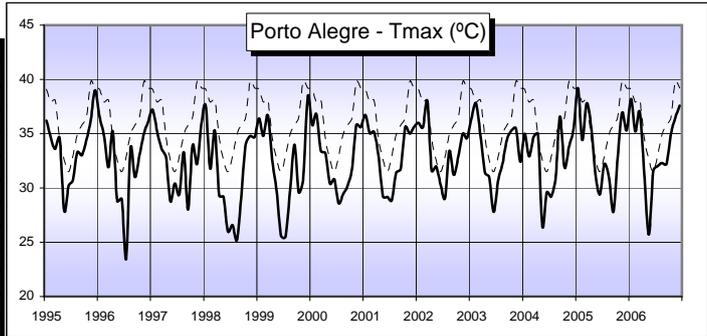
Estação Climatológica Principal de Porto Alegre/RS
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	25.0	23.7	23.0	19.8	16.1	14.3	16.1	15.7	16.8	18.4	22.7	24.1
1996	24.3	24.2	23.1	21.0	17.0	12.3	11.2	15.6	15.9	19.9	22.4	24.1
1997	25.8	24.4	22.4	20.1	16.8	14.2	15.3	16.9	17.2	18.9	21.3	24.5
1998	24.1	23.7	22.2	19.9	16.5	13.9	15.3	15.8	16.4	19.4	21.4	22.8
1999	24.6	23.8	25.0	18.9	16.1	13.6	13.9	15.4	17.0	18.2	20.3	23.1
2000	24.8	24.0	22.4	20.8	16.6	16.4	11.3	14.0	16.6	19.4	21.1	23.6
2001	25.0	24.2	23.6	20.5	16.7	15.0	14.1	15.5	16.8	21.3	22.0	22.8
2002	25.0	23.7	25.9	21.1	18.9	14.9	14.1	16.8	15.7	20.9	22.2	23.7
2003	25.1	25.6	23.9	19.9	17.3	16.5	14.6	14.2	16.2	20.0	21.6	22.4
2004	24.7	23.7	22.9	22.1	16.0	15.9	13.5	15.3	18.6	18.8	21.1	23.1
2005	25.3	24.4	23.8	20.1	18.2	18.2	14.9	17.0	15.7	19.2	22.3	23.0
2006	25.6	24.4	23.9	20.2	15.5	15.6	17.0	15.0	16.1	20.6	21.3	25.1



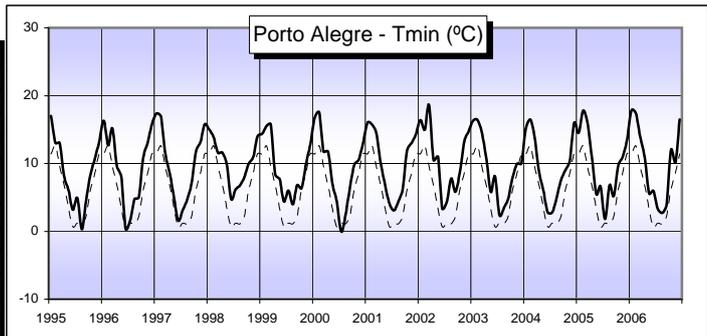
Estação Climatológica Principal de Porto Alegre/RS
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	36.2	34.6	33.6	34.6	27.9	30.2	30.7	33.3	33.0	34.4	36.3	39.0
1996	36.6	34.8	31.9	35.2	28.8	29.0	23.5	33.6	31.0	33.0	35.0	36.1
1997	37.2	35.2	33.6	32.8	28.8	30.4	29.4	33.3	28.0	33.9	32.2	36.0
1998	37.6	31.8	35.3	29.3	29.2	26.0	26.6	25.2	29.0	34.0	34.8	34.7
1999	36.4	34.8	36.7	32.5	29.6	25.6	25.5	29.7	34.0	29.6	30.8	38.4
2000	35.8	36.8	33.4	33.2	30.4	30.8	28.6	29.4	30.2	31.8	35.8	35.6
2001	36.8	35.0	35.2	33.0	29.2	29.2	28.9	31.4	31.8	35.6	35.0	35.6
2002	36.0	35.6	38.0	31.6	32.0	30.3	29.1	33.4	31.2	32.9	35.0	34.6
2003	36.4	37.8	34.8	31.4	31.0	27.8	30.7	32.3	34.4	35.3	35.5	32.4
2004	35.0	32.9	34.7	35.0	26.5	29.6	29.2	31.1	36.6	31.9	33.8	35.4
2005	39.2	34.4	37.8	35.6	31.1	29.4	32.2	31.0	27.8	32.7	36.9	35.3
2006	38.2	35.2	37.0	31.3	25.7	31.6	32.0	32.3	32.2	35.0	36.4	37.6



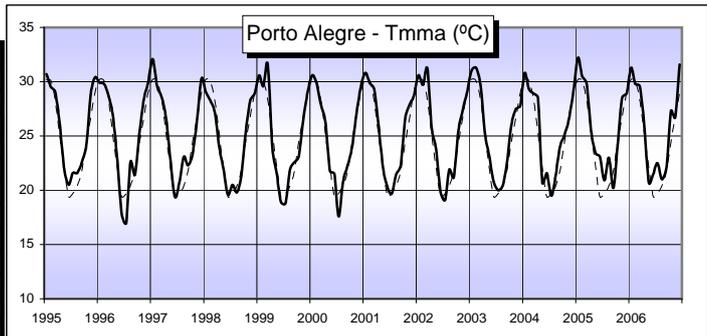
Estação Climatológica Principal de Porto Alegre/RS
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	17.0	13.0	13.0	8.1	6.0	3.2	4.9	0.3	4.4	8.4	10.8	13.2
1996	16.3	12.7	15.2	9.6	8.0	0.4	1.6	4.8	5.0	10.9	13.1	15.8
1997	17.4	16.9	11.6	8.6	4.8	1.6	3.2	4.8	7.1	11.8	13.2	15.8
1998	15.0	13.8	11.6	11.6	9.7	4.8	6.2	6.8	8.0	10.0	11.0	14.0
1999	14.4	15.5	15.8	8.4	7.7	4.4	6.0	4.0	6.8	6.4	10.0	12.8
2000	16.8	17.5	11.8	11.8	7.0	4.5	0.0	2.5	6.4	9.8	10.6	13.0
2001	16.0	15.8	14.5	10.0	6.7	4.1	3.1	4.4	6.2	12.0	13.0	14.3
2002	16.4	15.0	18.6	10.5	11.0	3.4	4.3	7.8	5.8	8.8	13.3	14.7
2003	16.3	16.4	14.6	10.8	5.8	8.1	2.4	3.5	4.8	8.0	10.0	10.0
2004	15.2	16.5	13.9	8.8	5.9	2.8	2.8	5.0	7.5	9.0	10.5	16.0
2005	14.5	17.8	16.1	11.0	5.5	6.6	1.8	6.8	5.2	9.6	11.0	13.4
2006	17.8	17.4	14.0	11.0	5.6	6.0	3.3	2.7	3.8	12.0	10.2	16.5



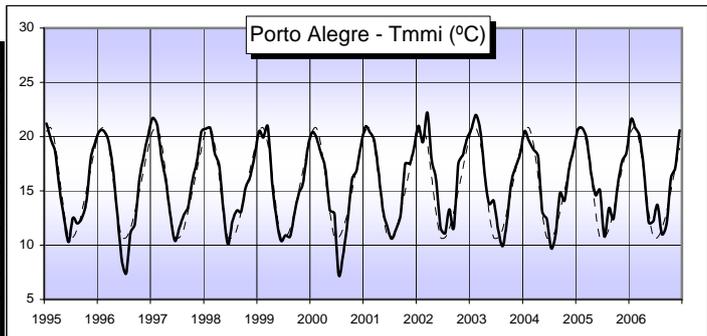
Estação Climatológica Principal de Porto Alegre/RS
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	30.7	29.5	29.1	26.2	22.0	20.5	21.6	21.6	22.6	24.2	28.9	30.4
1996	29.9	29.8	28.7	27.0	22.9	17.8	17.0	22.6	21.4	25.3	28.4	29.9
1997	32.1	29.6	28.6	26.6	22.9	19.4	20.7	23.1	22.3	23.3	26.5	30.3
1998	29.1	28.3	27.2	24.0	22.0	19.6	20.5	19.8	21.2	25.2	28.2	28.9
1999	30.6	29.6	31.6	24.0	21.5	18.9	18.8	21.9	22.6	23.1	26.4	29.1
2000	30.6	29.9	27.9	26.3	21.8	21.5	17.6	20.8	22.3	24.0	26.9	29.5
2001	30.8	29.8	29.4	26.1	22.1	20.3	19.7	21.5	22.3	26.6	27.9	28.7
2002	30.6	29.7	31.2	25.8	23.8	19.8	19.1	21.9	21.2	25.4	27.4	29.0
2003	31.0	31.3	29.7	25.2	23.2	20.8	20.0	20.4	22.5	26.0	27.5	27.8
2004	30.8	29.3	28.9	28.5	20.7	21.6	19.5	21.4	24.0	25.1	26.6	29.2
2005	32.2	30.5	29.8	25.4	23.4	23.1	20.9	23.0	20.2	24.1	28.5	28.9
2006	31.3	29.8	29.6	25.9	20.7	21.5	22.5	21.0	22.1	27.3	26.7	31.6



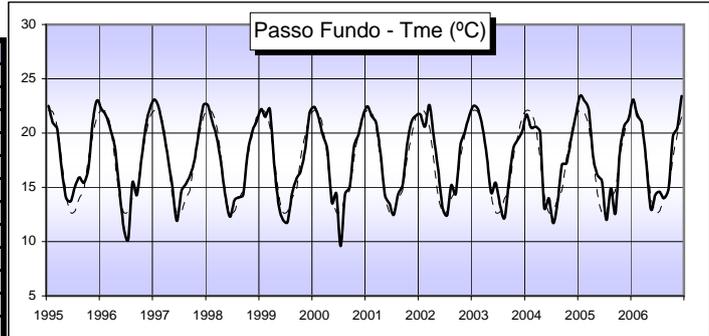
Estação Climatológica Principal de Porto Alegre/RS
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	21.2	19.7	18.6	15.2	12.4	10.3	12.5	12.0	12.5	14.0	18.0	19.4
1996	20.5	20.5	19.6	17.2	13.0	8.7	7.4	11.1	12.0	16.1	18.3	20.1
1997	21.7	21.1	18.0	15.8	12.8	10.4	11.6	12.8	13.5	16.0	17.8	20.5
1998	20.7	20.8	18.5	17.3	13.3	10.1	12.2	13.2	13.1	15.3	16.3	18.3
1999	20.5	19.9	20.9	15.6	12.3	10.4	10.9	10.8	12.9	14.7	15.8	18.9
2000	20.4	19.9	18.5	17.0	13.2	12.9	7.3	9.1	12.3	16.1	16.8	19.1
2001	20.9	20.4	19.7	16.8	13.2	11.6	10.6	11.5	12.9	17.5	17.5	18.9
2002	21.0	19.5	22.2	17.9	16.0	11.6	11.1	13.3	11.6	17.5	18.3	19.8
2003	20.7	22.0	20.4	16.3	13.8	14.1	11.4	9.9	12.2	15.8	17.3	18.5
2004	20.5	19.6	18.8	18.2	13.1	12.4	9.7	11.1	14.8	14.1	17.0	18.8
2005	20.7	20.8	19.8	16.6	14.6	15.1	10.8	13.4	12.4	15.4	17.7	18.6
2006	21.6	20.8	20.0	16.5	12.1	12.2	13.7	11.0	11.9	16.2	17.1	20.6



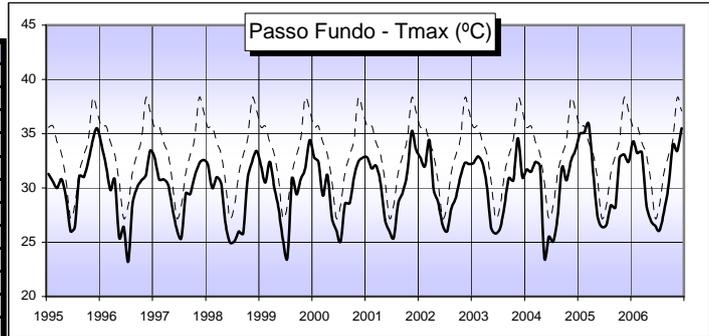
Estação Climatológica Principal de Passo Fundo/RS
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	22.5	20.9	20.4	16.8	14.0	13.7	15.0	15.9	15.4	16.7	21.1	23.0
1996	22.2	21.6	20.3	18.8	15.0	11.3	10.2	15.4	14.3	17.6	20.7	22.3
1997	23.1	22.2	20.1	17.6	15.1	11.9	14.6	15.3	16.1	17.5	20.3	22.6
1998	22.6	21.1	19.6	17.1	14.2	12.3	13.8	14.1	14.3	18.1	20.1	21.1
1999	22.2	21.5	22.2	17.0	13.3	12.0	11.8	14.4	15.8	16.5	18.5	21.9
2000	22.4	21.5	19.8	18.4	13.6	14.4	9.6	14.4	15.0	18.8	19.8	21.5
2001	22.5	21.5	21.0	18.2	14.3	13.5	12.5	14.4	15.3	19.0	21.1	21.6
2002	21.7	20.6	22.6	19.8	16.7	13.1	12.4	15.2	14.4	18.8	20.1	21.5
2003	22.5	22.2	20.5	17.7	14.5	15.4	13.3	12.2	15.5	18.6	19.4	20.2
2004	21.7	20.5	20.6	20.1	13.1	14.0	11.7	13.8	17.1	17.2	19.4	21.5
2005	23.4	23.0	22.2	17.8	16.1	15.6	12.0	14.9	12.6	18.0	20.6	21.3
2006	23.1	21.6	20.9	17.3	13.0	14.3	14.6	14.0	14.8	19.7	20.4	23.4



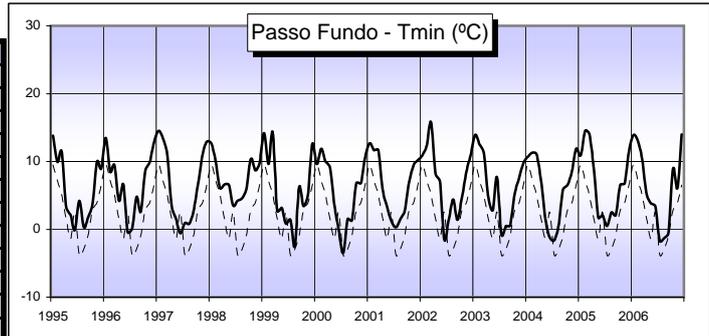
Estação Climatológica Principal de Passo Fundo/RS
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	31.3	30.6	30.0	30.8	29.0	26.0	26.4	31.1	31.0	32.5	34.4	35.5
1996	34.0	32.0	29.8	30.8	25.4	26.4	23.2	28.4	30.0	30.7	31.2	33.4
1997	32.8	30.8	30.8	30.3	28.2	26.2	25.4	29.5	29.4	31.0	32.2	32.6
1998	32.2	30.0	31.0	30.4	26.8	25.0	25.1	26.0	25.8	30.8	32.4	33.4
1999	32.0	30.5	32.4	30.0	28.0	25.2	23.6	30.8	29.4	30.8	31.8	34.4
2000	32.8	32.4	29.3	31.2	27.3	26.1	25.1	28.6	28.6	31.0	32.4	32.8
2001	32.8	31.8	32.1	30.5	27.1	26.0	25.4	28.6	29.6	31.4	35.2	33.6
2002	32.8	32.0	34.4	29.9	28.7	26.6	26.0	28.1	29.1	31.0	32.3	32.2
2003	32.3	32.9	32.3	30.1	26.3	25.8	26.3	28.5	30.9	30.7	34.6	31.0
2004	31.7	31.5	32.4	32.0	23.6	25.5	25.1	27.5	31.9	30.7	32.5	33.5
2005	35.0	35.1	35.9	31.4	27.3	26.4	26.6	28.4	28.2	32.8	33.1	32.4
2006	34.3	33.2	33.3	28.6	27.0	26.5	26.1	27.8	30.2	34.0	33.4	35.5



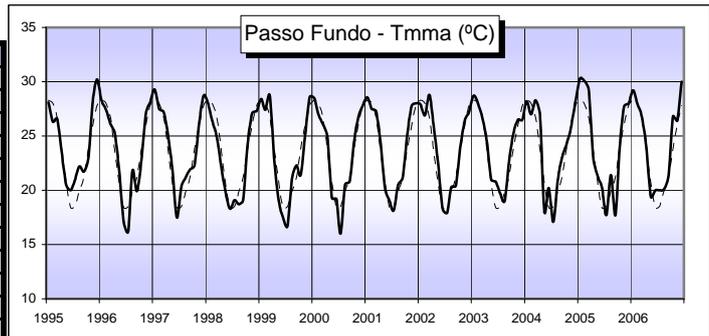
Estação Climatológica Principal de Passo Fundo/RS
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	13.8	9.9	11.5	3.3	2.1	-0.1	4.2	0.3	1.7	3.8	10.0	8.9
1996	13.5	8.5	9.5	4.2	6.6	-0.4	0.1	4.8	2.6	8.6	9.9	12.8
1997	14.5	13.4	11.1	3.5	1.5	-0.6	0.9	0.8	2.7	6.7	11.0	12.9
1998	12.7	9.9	6.1	6.6	6.5	3.5	4.2	4.6	5.9	10.4	8.7	9.7
1999	14.2	9.6	14.3	2.7	3.2	0.8	1.4	-2.5	6.2	3.4	5.2	12.6
2000	9.6	11.9	10.0	9.1	3.5	0.0	-3.5	1.5	1.3	6.8	6.8	10.5
2001	12.7	11.7	11.7	5.8	3.2	1.2	0.3	1.5	2.7	7.0	9.5	10.2
2002	10.9	12.4	15.8	8.2	7.0	-1.5	1.4	4.4	1.4	4.7	8.5	10.9
2003	13.9	12.5	11.3	4.8	2.8	7.7	-0.8	0.5	0.6	5.2	7.6	9.7
2004	10.7	11.3	11.1	7.2	1.4	-1.2	-1.6	0.7	5.8	6.5	8.6	11.9
2005	10.9	14.5	14.1	8.9	1.7	2.1	0.5	2.5	2.1	6.5	6.8	11.4
2006	13.9	13.0	10.4	5.2	3.8	3.4	-1.7	-1.3	-0.5	8.9	6.1	14.0



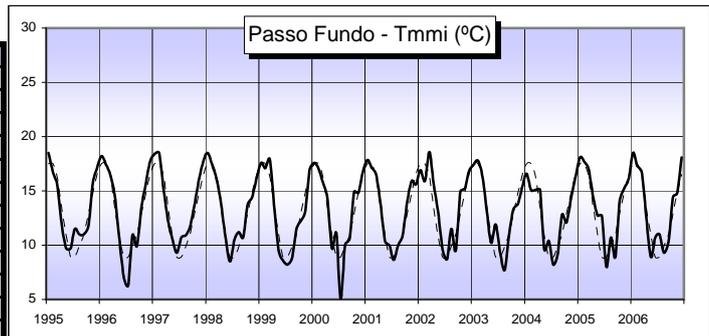
Estação Climatológica Principal de Passo Fundo/RS
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	28.1	26.3	26.6	23.6	20.5	20.0	20.9	22.2	21.7	22.9	28.2	30.2
1996	28.3	27.4	26.1	25.3	21.8	17.1	16.2	21.8	19.9	22.8	27.1	28.1
1997	29.3	27.5	27.2	25.0	22.0	17.5	20.3	21.2	21.9	22.3	26.1	28.7
1998	28.1	26.4	24.9	22.2	19.9	18.3	19.1	18.7	19.1	24.2	27.1	27.3
1999	28.4	27.4	28.7	22.7	19.0	17.5	16.7	21.1	22.3	21.4	25.1	28.6
2000	28.5	27.0	26.1	24.9	19.3	19.2	16.0	20.5	20.8	24.5	26.7	27.8
2001	28.6	27.5	27.3	24.5	20.2	19.0	18.2	20.5	21.2	25.1	27.8	28.0
2002	27.9	26.9	28.8	26.0	22.5	18.3	17.9	20.3	20.4	24.0	26.4	27.2
2003	28.7	28.0	26.6	24.4	21.0	20.8	19.7	19.0	22.5	25.2	26.5	26.5
2004	28.2	27.0	28.3	26.9	18.1	20.2	17.1	20.9	23.0	24.2	25.8	28.2
2005	30.3	30.1	29.3	23.1	21.3	20.3	17.7	21.4	17.7	23.8	27.7	28.0
2006	29.2	28.0	26.8	24.0	19.4	20.0	20.0	20.1	21.3	26.8	26.4	30.0



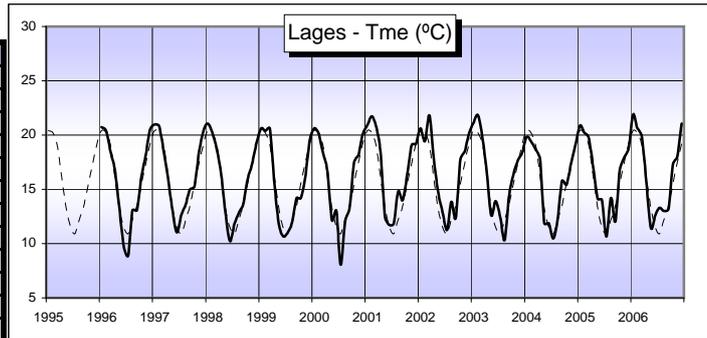
Estação Climatológica Principal de Passo Fundo/RS
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	18.5	16.7	15.6	12.0	9.7	9.7	11.5	11.0	11.0	11.7	15.7	17.1
1996	18.2	17.4	16.4	14.6	10.7	7.1	6.3	10.9	9.9	13.5	15.7	17.7
1997	18.4	18.5	15.1	12.2	10.6	9.3	10.7	10.9	11.7	13.7	16.1	17.8
1998	18.5	17.4	16.0	13.7	10.8	8.5	10.5	11.2	10.7	13.7	14.4	16.2
1999	17.6	17.1	17.9	13.4	9.4	8.6	8.2	8.8	11.5	12.2	13.1	17.0
2000	17.6	17.1	15.8	14.3	9.7	11.1	5.1	10.0	10.6	14.9	14.8	16.7
2001	17.9	17.1	16.6	13.9	10.4	10.0	8.7	10.0	10.9	14.0	15.9	15.6
2002	16.9	15.9	18.6	15.7	13.1	9.6	8.7	11.5	9.5	14.9	15.2	16.8
2003	17.4	17.8	16.3	13.0	10.2	11.9	9.3	7.7	10.8	13.3	13.8	15.4
2004	16.6	15.1	15.1	15.1	9.6	10.4	8.2	9.2	12.8	12.1	14.3	16.3
2005	18.1	17.7	17.0	14.4	12.7	12.7	8.0	10.7	8.9	14.0	15.2	16.1
2006	18.5	17.3	16.7	12.6	8.9	10.7	11.0	9.3	10.3	14.4	14.8	18.1



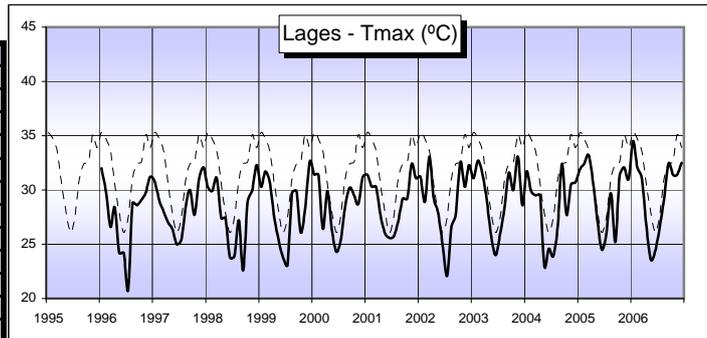
Estação Climatológica Principal de Lages/SC
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	20.7	20.4	18.5	16.9	13.4	9.8	8.9	13.1	13.1	16.2	18.2	20.5
1997	21.0	20.8	18.5	16.0	13.2	11.0	12.6	13.6	15.0	15.3	18.5	20.4
1998	21.1	20.3	18.7	16.3	12.9	10.3	11.8	12.8	13.6	15.9	17.4	19.3
1999	20.6	20.4	20.6	15.6	11.8	10.7	11.0	11.9	14.2	14.2	16.1	19.5
2000	20.6	20.2	18.4	16.7	12.2	13.0	8.1	12.0	13.4	17.5	18.1	20.1
2001	20.9	21.8	20.8	18.5	12.4	11.7	11.8	14.8	14.0	16.4	19.1	19.2
2002	20.6	19.4	21.8	18.0	14.8	12.8	11.3	13.9	12.4	17.7	18.5	20.1
2003	21.1	21.8	19.7	16.4	12.6	13.9	12.4	10.3	14.3	16.3	17.7	18.4
2004	19.8	19.4	18.7	17.8	11.9	11.9	10.5	12.4	15.8	15.4	17.4	19.1
2005	20.9	20.2	19.8	17.0	14.1	14.0	10.7	14.2	12.0	16.7	17.9	18.8
2006	21.9	20.7	19.9	15.7	11.5	12.6	13.3	13.0	13.2	17.3	18.0	21.1



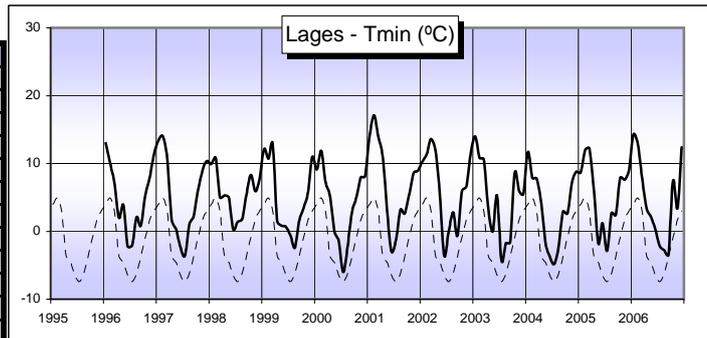
Estação Climatológica Principal de Lages/SC
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	32.0	29.8	26.6	28.4	24.2	20.8	28.8	28.6	29.1	29.8	31.2	
1997	30.8	29.1	28.0	27.0	26.4	25.0	25.4	28.5	30.0	27.7	31.0	32.1
1998	30.3	29.9	31.1	27.4	27.4	23.8	23.9	27.2	22.6	28.9	29.9	32.3
1999	30.3	31.7	30.7	27.4	25.3	23.8	23.1	29.7	29.9	26.1	28.3	32.6
2000	31.4	31.4	26.4	29.9	26.3	24.3	25.3	28.4	30.2	29.5	28.7	31.2
2001	31.4	30.3	30.3	27.7	26.0	25.6	25.7	27.1	29.2	29.2	32.4	31.1
2002	31.2	28.9	33.1	29.3	27.9	24.9	22.1	26.5	27.8	32.6	30.3	32.3
2003	31.1	32.7	31.4	28.9	25.8	24.0	26.0	28.5	31.6	30.0	33.1	28.6
2004	31.7	29.9	29.5	29.5	23.0	24.6	23.9	26.7	32.4	27.7	30.5	30.7
2005	31.9	32.4	33.2	30.6	27.0	24.5	26.0	29.7	25.2	31.3	32.1	31.0
2006	34.5	32.1	31.1	26.8	23.6	24.4	26.4	29.1	32.4	31.4	31.4	32.5



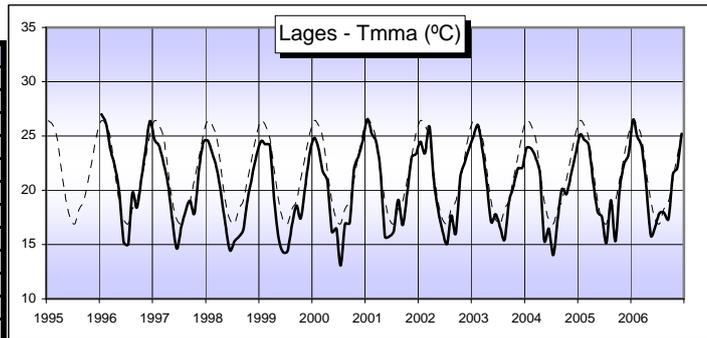
Estação Climatológica Principal de Lages/SC
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	13.0	10.0	7.2	2.0	3.9	-2.2	-2.1	2.1	0.8	5.3	8.0	11.3
1997	13.4	14.0	10.8	1.7	0.3	-2.3	-3.6	1.0	2.2	6.1	9.0	10.4
1998	9.9	10.8	5.0	5.3	4.9	0.3	1.4	1.8	5.3	8.3	5.9	7.7
1999	12.1	10.7	12.9	1.5	0.8	0.7	-0.6	-2.4	1.5	3.4	5.8	11.0
2000	9.1	11.9	7.3	5.2	0.0	-1.4	-6.0	-2.2	2.7	5.0	8.0	8.1
2001	14.0	17.1	14.0	11.0	2.8	-3.0	-1.3	3.2	2.6	5.4	8.6	8.9
2002	10.3	11.4	13.6	11.9	5.0	-3.6	0.0	2.8	-0.7	5.9	6.6	11.3
2003	14.0	10.8	10.6	3.4	0.0	5.3	-4.3	-1.7	-1.6	8.6	5.9	5.5
2004	11.7	7.9	7.8	4.4	-1.7	-3.7	-4.8	-2.1	2.9	2.6	7.2	8.8
2005	8.7	12.0	12.2	6.2	-1.8	1.2	-2.9	2.7	2.4	7.9	7.6	8.9
2006	14.3	12.8	7.9	3.4	2.1	0.3	-2.2	-2.8	-3.5	7.4	3.4	12.4



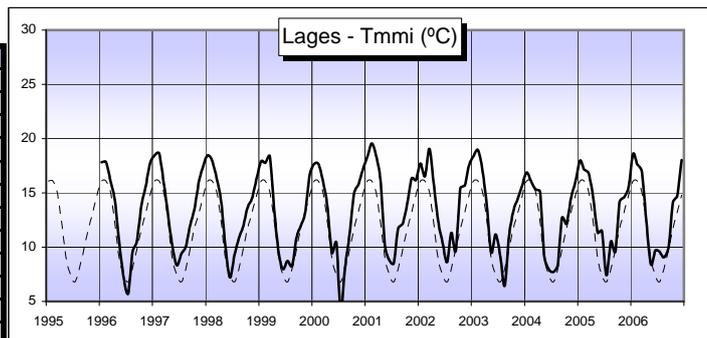
Estação Climatológica Principal de Lages/SC
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	27.0	26.1	23.7	22.3	19.9	15.2	15.0	19.7	18.4	21.1	24.0	26.4
1997	24.6	24.1	22.4	20.5	17.3	14.6	16.7	18.2	19.0	17.9	22.0	24.5
1998	24.6	23.4	22.0	19.6	16.9	14.5	15.3	15.7	16.3	19.1	21.3	23.3
1999	24.5	24.2	24.2	19.0	15.5	14.3	14.4	16.8	18.6	17.4	20.3	23.4
2000	24.8	23.9	21.7	20.9	16.2	16.5	13.1	16.9	17.0	22.0	23.1	24.6
2001	26.6	25.2	24.5	21.7	15.7	15.8	16.2	19.1	16.8	19.8	23.1	23.3
2002	24.5	23.4	25.9	21.1	18.2	16.2	15.1	17.7	16.0	21.2	22.6	23.8
2003	25.0	26.0	23.7	20.5	17.1	17.8	16.6	15.5	18.9	20.3	22.0	22.1
2004	23.9	23.9	23.0	21.4	15.4	16.5	14.0	17.4	20.1	19.7	21.4	23.3
2005	25.1	24.6	24.2	20.7	18.0	17.6	15.1	19.1	15.3	20.0	22.4	23.4
2006	26.5	25.0	24.0	20.3	15.8	16.7	17.9	17.9	17.3	21.5	22.0	25.2



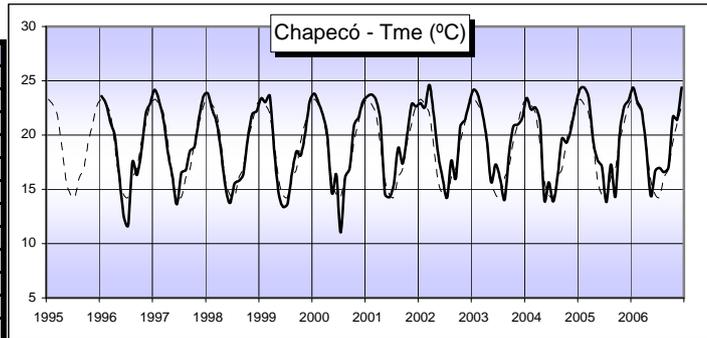
Estação Climatológica Principal de Lages/SC
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	17.8	17.8	16.1	14.4	10.5	7.2	5.8	9.5	10.6	13.8	15.7	17.7
1997	18.5	18.7	16.0	12.9	10.2	8.3	9.4	10.1	12.0	13.5	16.1	17.6
1998	18.5	17.9	16.3	14.2	10.1	7.2	9.3	10.8	11.9	13.7	14.5	16.4
1999	17.9	17.8	18.4	13.3	9.4	8.0	8.8	8.3	10.9	11.9	13.2	16.7
2000	17.7	17.7	16.2	13.7	9.5	10.4	4.3	8.1	11.2	15.0	15.7	17.1
2001	18.3	19.6	18.4	16.2	10.1	8.8	8.5	11.7	12.2	14.0	16.4	16.2
2002	17.7	16.5	19.1	16.0	12.5	10.4	8.6	11.3	9.7	15.4	15.7	17.5
2003	18.4	18.9	17.0	13.6	9.5	11.2	9.2	6.4	10.9	13.3	14.5	15.7
2004	16.9	16.1	15.3	15.1	9.2	8.0	7.7	8.4	12.7	12.2	14.5	16.1
2005	18.0	17.1	16.8	14.5	11.3	11.5	7.4	10.5	9.6	14.2	14.6	15.6
2006	18.6	17.6	17.0	12.5	8.4	9.7	9.6	9.1	9.9	14.1	14.7	18.0



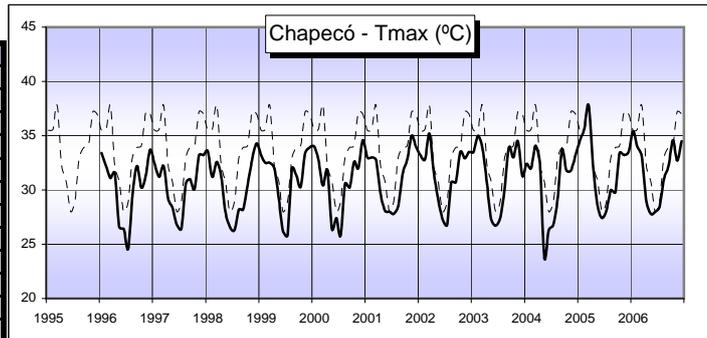
Estação Climatológica Principal de Chapecó/SC
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	23.6	22.9	21.2	19.9	16.4	12.5	11.7	17.5	16.3	18.6	22.0	22.9
1997	24.2	23.1	21.3	18.3	16.3	13.6	16.5	16.8	18.5	18.9	21.6	23.6
1998	23.9	22.3	21.1	18.4	15.3	13.8	15.5	15.8	16.3	19.5	21.9	22.2
1999	23.4	23.0	23.6	18.5	14.5	13.4	13.6	16.5	18.5	18.1	20.2	23.1
2000	23.8	23.0	21.9	19.9	14.6	16.3	11.0	16.1	16.9	20.9	21.6	23.1
2001	23.6	23.7	23.3	21.2	14.6	14.3	15.4	18.8	17.4	20.1	22.9	22.6
2002	22.9	22.6	24.6	22.0	18.3	16.0	14.3	17.7	16.0	20.8	21.4	22.9
2003	24.2	23.7	22.0	19.4	15.7	17.3	15.9	14.1	18.1	20.8	21.0	21.6
2004	23.4	22.4	22.5	21.3	14.0	15.6	13.9	16.4	19.7	19.3	20.6	22.7
2005	24.3	24.4	23.5	19.5	17.7	17.1	13.8	17.3	14.3	20.0	22.6	23.2
2006	24.4	23.1	22.2	18.7	14.4	16.7	17.0	16.6	17.0	21.7	21.4	24.4



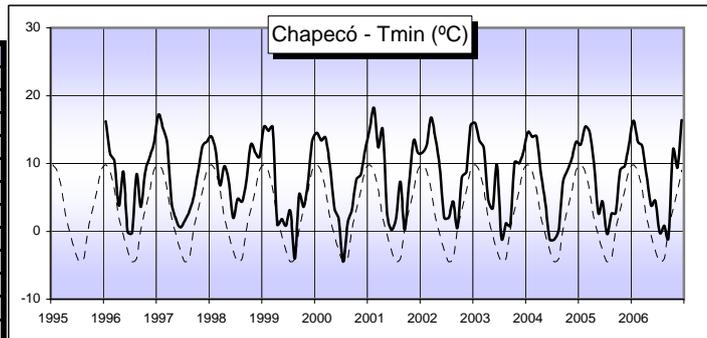
Estação Climatológica Principal de Chapecó/SC
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	33.4	32.2	31.1	31.6	26.6	26.4	24.6	29.4	32.2	30.2	31.4	33.7
1997	32.4	31.2	32.2	29.2	28.4	26.8	26.4	30.6	31.0	30.1	33.2	33.2
1998	33.6	31.2	32.6	31.2	28.0	26.6	26.3	28.2	28.2	30.4	32.8	34.3
1999	33.2	32.5	32.5	32.0	29.2	26.2	25.8	32.0	31.3	30.3	33.4	33.9
2000	34.0	32.8	30.4	31.8	26.4	27.4	25.8	30.6	30.2	32.6	32.0	34.6
2001	33.0	33.0	32.8	29.7	28.1	28.0	27.8	28.5	31.5	32.8	35.0	34.0
2002	33.2	32.8	35.2	31.8	29.2	27.3	26.8	30.7	30.7	33.5	32.9	33.5
2003	33.5	35.0	33.8	30.6	27.3	26.7	27.4	30.2	33.9	33.0	34.5	31.3
2004	32.4	32.0	34.1	32.3	23.8	26.3	26.8	29.3	33.7	31.8	31.8	33.2
2005	34.6	35.6	37.8	32.1	28.5	27.4	28.1	30.0	29.8	33.4	33.2	33.5
2006	35.4	34.0	33.1	29.0	27.8	28.0	28.4	31.0	32.2	34.6	32.7	34.5



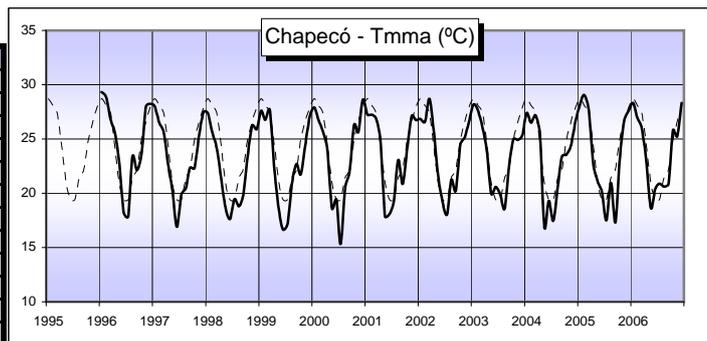
Estação Climatológica Principal de Chapecó/SC
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	16.2	11.4	10.4	3.8	8.8	0.0	-0.2	8.4	3.6	8.8	11.0	13.0
1997	17.2	15.2	13.0	4.2	1.7	0.6	1.6	3.0	5.0	8.8	12.6	13.2
1998	14.0	11.8	6.8	9.6	7.2	2.0	4.8	4.4	7.4	12.8	11.6	11.0
1999	15.4	14.8	15.4	1.0	1.8	0.8	3.0	-4.0	5.4	3.6	7.4	13.4
2000	14.5	13.4	13.8	9.6	3.4	1.8	-4.5	1.2	3.2	7.6	8.4	11.9
2001	15.0	18.2	12.4	15.0	2.4	0.2	1.8	7.3	0.2	7.2	13.4	11.6
2002	11.6	12.8	16.8	13.6	9.0	2.0	2.0	4.4	0.5	8.0	8.8	15.6
2003	16.0	13.3	12.3	4.6	3.4	9.8	-1.0	1.2	0.8	10.2	10.0	11.7
2004	14.6	13.9	14.0	8.4	4.0	-1.2	-1.2	0.2	7.2	9.0	10.8	13.2
2005	12.8	15.4	14.8	10.2	2.7	4.4	-0.4	2.6	2.7	9.0	9.6	12.8
2006	16.3	13.2	12.6	8.2	3.8	4.5	-0.2	0.8	-1.0	12.0	9.4	16.4



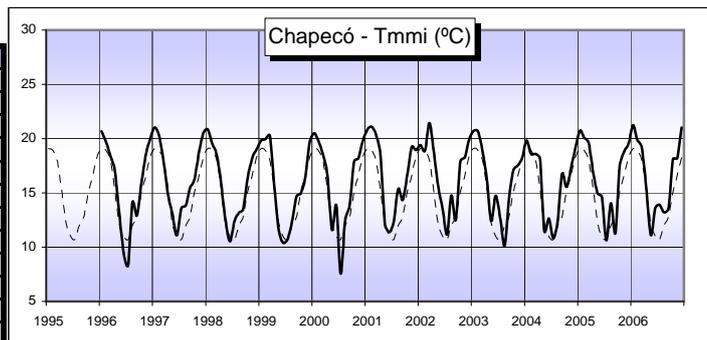
Estação Climatológica Principal de Chapecó/SC
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	29.3	28.9	26.8	25.6	22.9	18.2	17.8	23.4	22.1	23.6	28.0	28.3
1997	28.0	26.5	25.6	22.7	20.3	16.9	19.8	20.5	22.3	22.3	25.3	27.5
1998	27.4	25.7	24.2	21.4	18.8	17.6	19.4	18.8	19.8	23.3	26.3	25.9
1999	27.6	26.8	27.7	22.3	18.5	16.7	17.2	20.9	22.7	21.7	24.4	27.1
2000	27.9	26.8	25.7	24.0	18.6	19.5	15.3	20.4	22.1	26.3	25.6	28.6
2001	27.3	27.2	26.9	24.8	17.8	18.1	19.2	23.1	20.8	24.2	27.1	26.7
2002	26.9	26.6	28.7	25.9	21.7	19.2	18.1	21.2	20.3	24.5	25.2	26.6
2003	28.2	27.6	26.0	23.8	20.0	20.6	19.9	18.6	22.3	25.0	24.9	25.4
2004	27.4	26.5	27.2	25.3	16.9	19.3	17.5	20.6	23.4	23.6	24.4	26.7
2005	28.2	29.1	27.7	22.8	21.1	20.1	17.5	21.0	17.3	22.9	26.6	27.6
2006	28.3	27.0	26.0	23.0	18.6	20.4	20.9	20.6	20.9	25.8	25.3	28.3



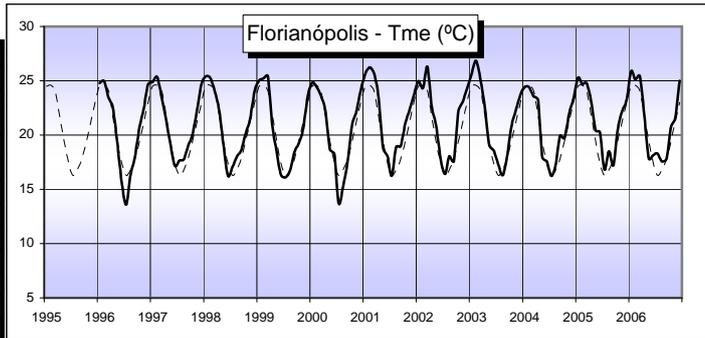
Estação Climatológica Principal de Chapecó/SC
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	20.7	19.7	18.4	17.1	13.2	9.4	8.4	14.1	12.9	16.0	18.6	19.9
1997	21.0	20.3	17.8	14.8	13.1	11.1	13.6	13.9	15.4	16.3	18.8	20.6
1998	20.8	19.6	18.5	15.8	12.6	10.5	12.4	13.2	13.5	16.3	18.2	19.0
1999	19.8	20.0	20.3	15.6	11.5	10.4	10.7	12.4	14.7	14.9	16.4	19.7
2000	20.5	19.8	18.6	16.7	11.6	13.8	7.6	12.4	13.9	17.9	18.2	19.8
2001	20.8	21.1	20.4	18.4	12.1	11.4	12.3	15.4	14.3	16.7	19.2	18.9
2002	19.4	18.9	21.4	19.0	15.7	13.5	11.2	14.8	12.5	17.9	18.3	19.9
2003	20.7	20.7	18.8	16.1	12.4	14.7	12.7	10.2	14.3	17.1	17.5	18.3
2004	19.8	18.6	18.6	18.1	11.5	12.7	10.8	12.5	16.8	15.6	17.3	19.2
2005	20.8	20.1	19.6	16.9	14.9	14.6	10.6	14.1	11.3	17.4	18.8	19.6
2006	21.2	19.9	19.2	15.4	11.1	13.6	13.9	13.2	13.6	18.1	18.2	21.0



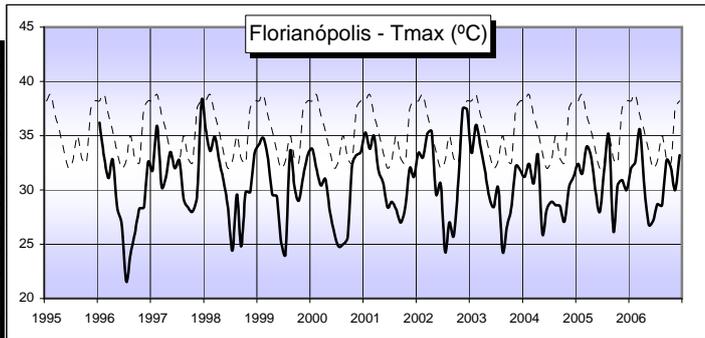
Estação Climatológica Principal de São José/SC - (Grande Florianópolis)
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	24.8	25.0	23.5	22.6	19.4	15.6	13.6	16.3	18.0	20.7	22.5	24.7
1997	24.9	25.4	23.5	21.4	19.3	17.2	17.7	17.8	19.0	20.1	22.3	24.7
1998	25.4	25.3	24.0	22.2	19.1	16.3	17.1	18.0	18.6	20.1	21.5	24.1
1999	25.0	25.2	25.4	20.9	18.4	16.3	16.1	16.7	18.5	19.2	20.6	23.6
2000	24.8	24.5	23.6	22.2	18.7	18.3	13.7	15.2	17.6	20.9	22.2	24.1
2001	25.7	26.2	25.7	23.5	18.9	18.1	16.3	18.9	19.0	21.1	22.4	23.7
2002	25.0	24.3	26.3	22.7	20.9	17.8	16.4	18.1	17.6	22.1	23.1	24.3
2003	25.6	26.9	25.1	22.4	19.1	18.6	17.3	16.3	17.9	20.7	22.3	23.7
2004	24.4	24.4	23.6	23.2	18.0	17.6	16.2	17.3	19.9	19.7	21.9	23.4
2005	25.3	24.7	24.8	23.1	20.4	20.3	16.8	18.5	17.2	20.4	22.2	23.2
2006	25.9	25.1	25.4	21.8	17.8	18.1	18.3	17.6	17.8	20.8	21.6	25.0



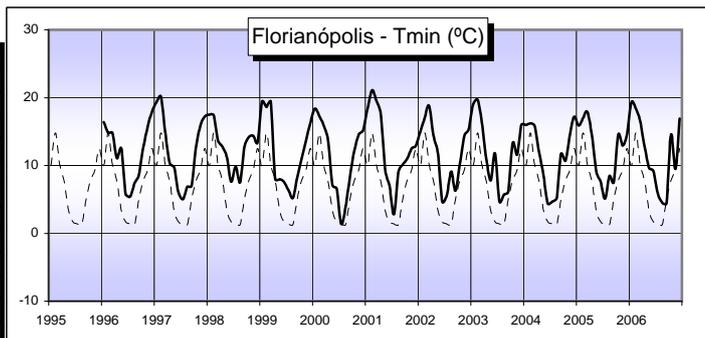
Estação Climatológica Principal de São José/SC - (Grande Florianópolis)
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	36.2	33.1	31.1	32.8	28.4	26.8	21.6	24.0	26.0	28.3	28.4	32.6
1997	31.8	35.9	30.3	31.3	33.5	32.0	32.7	29.1	28.4	28.0	29.4	38.2
1998	35.6	33.6	34.9	32.7	30.9	28.4	24.4	29.6	24.8	29.8	29.8	33.4
1999	34.2	34.8	33.0	29.6	29.4	25.3	24.1	33.5	30.3	29.0	31.2	33.2
2000	33.8	32.0	30.4	31.0	28.0	26.0	24.8	25.0	25.6	32.3	33.2	33.5
2001	35.3	33.8	35.0	31.8	30.7	28.4	28.9	28.2	27.0	28.4	32.0	31.2
2002	33.4	33.0	35.2	35.4	29.6	30.6	24.3	27.0	25.8	30.8	37.5	37.4
2003	33.4	36.0	34.0	31.8	29.4	28.4	30.2	24.3	26.6	28.4	32.2	31.8
2004	31.2	32.4	30.6	33.2	26.0	28.2	28.9	28.6	28.5	27.1	30.2	31.2
2005	32.4	31.5	34.0	33.0	29.8	28.0	32.0	35.0	26.2	30.4	30.9	30.0
2006	32.0	32.6	35.6	30.4	26.8	27.2	28.7	28.6	32.7	32.0	30.0	33.2



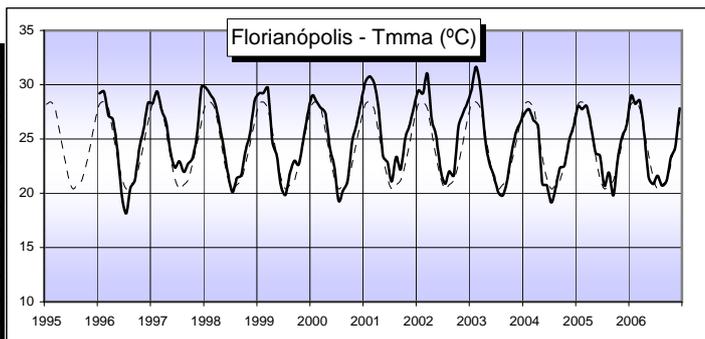
Estação Climatológica Principal de São José/SC - (Grande Florianópolis)
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	16.4	14.8	14.8	11.1	12.5	5.8	5.4	7.4	8.6	12.7	15.8	17.9
1997	19.3	20.1	15.0	10.4	9.7	6.1	5.0	6.9	7.0	12.8	16.0	17.2
1998	17.5	17.4	13.7	12.8	11.2	7.6	9.8	7.5	12.7	14.2	14.4	13.4
1999	19.4	18.6	19.4	8.0	8.0	7.6	6.4	5.2	8.1	11.0	13.7	16.2
2000	18.4	17.3	16.0	13.7	7.1	6.6	1.4	4.0	8.2	12.2	14.6	15.2
2001	18.4	21.1	19.6	17.6	9.3	7.1	2.8	9.1	10.1	11.0	12.5	12.9
2002	15.0	17.1	18.8	14.4	11.7	4.7	5.6	9.1	6.3	10.3	14.4	15.3
2003	19.0	19.7	16.4	11.0	7.8	11.8	4.7	5.7	6.1	13.3	11.6	16.0
2004	16.0	16.2	15.9	12.0	8.5	4.4	4.7	5.2	11.7	10.7	14.5	17.2
2005	15.9	17.0	17.9	14.5	9.1	7.7	5.1	8.5	7.5	14.5	12.9	14.5
2006	19.3	18.4	16.6	12.8	9.6	9.2	5.9	4.5	4.4	14.5	9.5	16.9



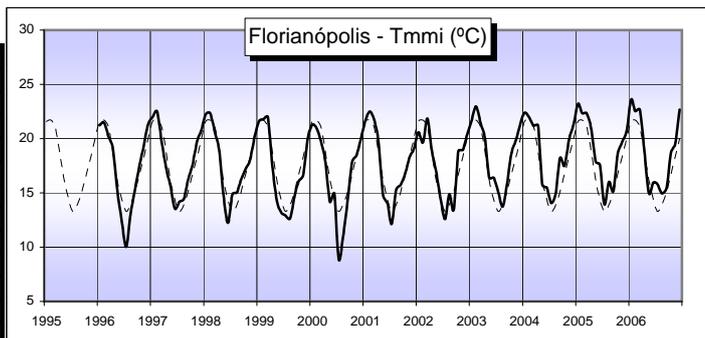
Estação Climatológica Principal de São José/SC - (Grande Florianópolis)
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	29.2	29.4	27.1	26.8	24.1	19.9	18.2	20.5	21.2	24.2	26.0	28.3
1997	28.3	29.4	27.7	26.5	24.0	22.4	22.9	22.7	23.3	25.5	29.8	
1998	29.8	29.1	28.4	26.5	24.3	21.8	20.1	21.4	21.7	23.9	25.6	28.5
1999	29.2	29.3	29.7	24.8	23.4	20.7	19.9	21.9	23.0	22.7	24.8	27.3
2000	29.0	28.5	27.8	27.4	24.2	22.4	19.3	20.3	21.2	24.8	26.2	28.2
2001	30.2	30.8	30.2	27.9	23.5	22.9	21.1	23.3	22.2	25.0	26.3	27.9
2002	29.5	29.2	31.0	26.9	25.3	22.2	20.9	22.0	21.6	26.0	27.3	28.3
2003	29.5	31.7	29.5	25.1	22.9	21.7	20.1	19.8	21.1	23.6	25.6	26.5
2004	27.4	27.7	26.7	26.2	20.9	20.8	19.1	20.5	22.3	22.6	24.8	26.2
2005	28.0	27.8	28.0	26.0	23.7	23.5	20.7	21.9	19.8	23.0	25.2	26.3
2006	29.0	28.3	28.5	25.4	21.4	20.9	21.6	20.7	21.1	23.3	24.2	27.8



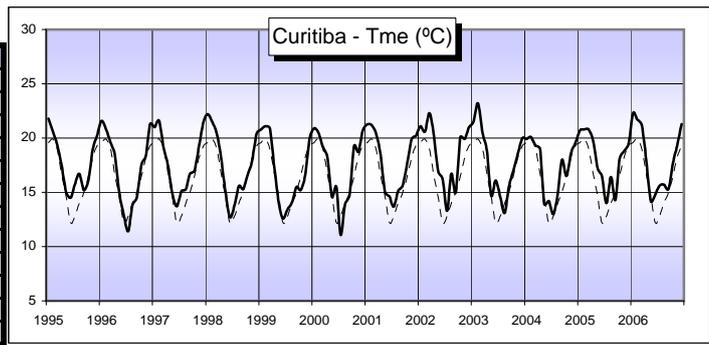
Estação Climatológica Principal de São José/SC - (Grande Florianópolis)
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	21.2	21.5	20.2	19.2	15.4	12.4	10.0	13.0	15.2	17.5	19.4	21.3
1997	22.0	22.5	19.7	17.3	15.7	13.6	14.2	14.4	16.2	17.6	19.7	20.8
1998	22.2	22.3	20.6	18.9	14.9	12.2	14.9	15.0	16.3	17.2	18.1	20.2
1999	21.6	21.8	22.0	17.5	14.3	13.2	12.9	12.6	14.7	16.1	16.7	20.0
2000	21.3	21.0	19.8	17.9	14.2	14.9	8.9	11.0	14.3	17.9	18.4	19.9
2001	21.7	22.5	21.8	19.7	14.8	14.0	12.1	15.3	15.7	16.8	18.3	19.1
2002	20.6	19.7	21.9	19.0	17.0	14.5	12.6	14.9	13.5	18.8	18.9	20.3
2003	21.6	23.0	21.5	20.0	16.4	16.4	15.1	13.7	15.8	18.6	19.9	21.4
2004	22.4	22.0	21.2	21.2	15.8	15.5	14.1	15.0	18.2	17.5	19.9	21.3
2005	23.2	22.4	22.3	20.9	17.9	17.6	14.0	16.0	15.2	18.5	19.7	20.7
2006	23.6	22.5	22.7	19.0	15.0	15.9	15.8	15.0	15.4	18.7	19.5	22.7



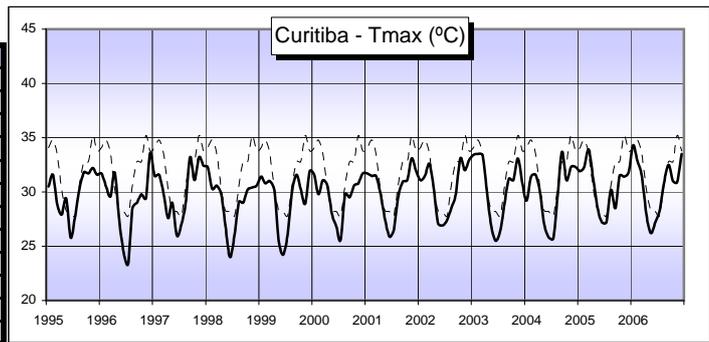
Estação Climatológica Principal de Curitiba/PR
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	21.8	20.6	19.4	17.5	15.0	14.5	15.7	16.7	15.2	16.1	19.0	20.2
1996	21.6	20.8	19.6	18.5	15.0	12.9	11.4	13.8	14.6	17.5	18.4	21.3
1997	21.0	21.6	19.1	17.4	14.9	13.7	15.1	15.3	16.7	17.0	19.3	21.5
1998	22.2	21.5	20.4	18.1	15.1	12.7	13.8	15.6	15.3	16.6	17.9	20.4
1999	20.8	21.1	20.9	17.3	14.0	12.6	13.4	14.1	15.5	15.2	16.6	20.0
2000	20.9	20.5	19.2	18.2	14.6	15.5	11.1	13.9	14.8	19.3	18.7	20.7
2001	21.3	21.2	20.4	18.5	15.0	14.6	13.7	15.1	15.7	17.7	19.9	20.2
2002	21.1	20.6	22.3	20.4	17.0	16.2	13.3	16.7	15.0	20.1	19.9	21.0
2003	21.5	23.2	20.5	18.8	14.7	16.1	14.6	13.1	15.5	17.0	18.6	20.0
2004	19.9	20.1	19.3	19.0	13.9	14.2	13.0	14.9	18.0	16.5	18.6	19.6
2005	20.7	20.8	20.8	19.7	17.2	16.5	14.0	16.4	14.3	18.1	18.8	19.5
2006	22.3	21.7	21.2	17.9	14.2	14.8	15.6	15.7	15.3	17.7	19.3	21.3



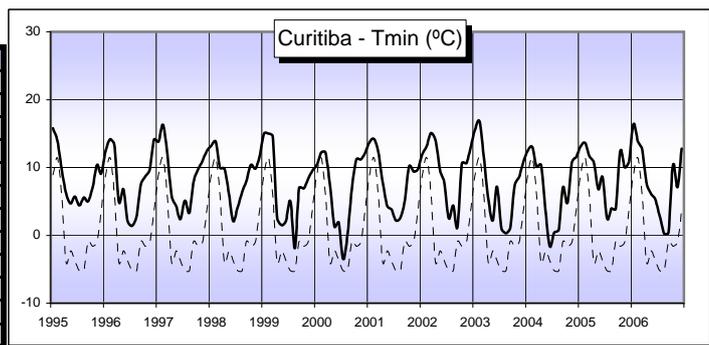
Estação Climatológica Principal de Curitiba/PR
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	30.5	31.6	28.9	27.9	29.4	25.8	27.6	30.2	31.8	31.7	32.2	31.6
1996	31.7	30.5	29.6	31.8	27.5	24.4	23.4	28.5	29.0	29.8	29.4	33.6
1997	31.5	31.6	29.8	27.6	29.0	26.0	27.0	29.1	33.2	31.1	33.2	32.4
1998	32.3	30.3	30.6	29.8	26.9	24.0	26.0	29.1	29.0	30.2	30.4	30.6
1999	31.4	30.8	31.0	30.2	25.4	24.2	26.0	30.0	31.6	30.3	28.9	31.9
2000	31.6	29.8	31.1	30.6	28.0	25.8	25.6	29.8	29.5	30.6	30.8	31.7
2001	31.7	31.5	31.5	29.9	27.5	26.9	26.4	29.5	31.0	31.1	33.1	32.0
2002	31.1	31.5	32.6	30.4	27.1	26.9	27.4	28.5	29.8	33.1	32.0	32.9
2003	33.4	33.5	33.4	30.0	26.9	25.5	26.4	29.0	31.2	31.1	33.1	30.8
2004	29.2	31.4	31.6	29.9	27.0	25.8	25.7	29.8	33.7	31.1	32.3	32.3
2005	31.9	32.3	33.9	31.2	28.5	27.2	27.2	30.2	28.5	31.5	31.4	31.8
2006	34.3	32.9	31.5	28.0	26.2	27.2	28.2	30.8	32.5	31.0	30.9	33.5



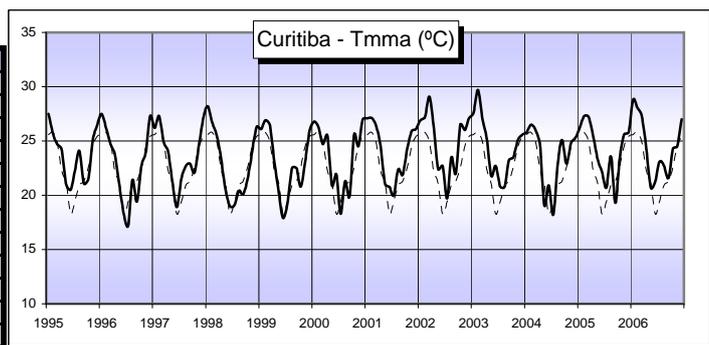
Estação Climatológica Principal de Curitiba/PR
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	15.8	13.9	9.8	6.2	4.7	5.7	4.4	5.6	5.0	7.0	10.4	9.1
1996	12.5	14.2	13.3	4.9	6.8	2.1	1.4	2.8	7.4	8.7	9.7	14.1
1997	13.8	16.3	12.2	5.8	4.3	2.4	5.1	3.3	7.9	9.7	11.0	12.4
1998	13.2	13.8	10.0	9.8	6.1	2.1	4.1	6.4	8.0	10.4	9.8	11.6
1999	15.0	15.0	14.6	2.5	1.5	2.1	5.0	-1.9	7.0	6.9	8.3	9.5
2000	10.4	10.2	12.2	7.4	1.3	1.9	-3.5	0.3	6.8	11.2	11.2	12.1
2001	13.7	14.2	12.3	7.8	4.3	3.8	2.2	2.6	5.0	10.2	9.4	9.7
2002	12.0	13.2	15.1	14.0	9.6	7.8	2.5	4.4	1.2	10.6	10.6	12.9
2003	15.6	16.8	11.6	5.4	2.2	7.2	1.0	0.3	1.0	7.3	8.6	10.8
2004	12.5	13.0	10.1	10.4	3.6	-1.6	0.4	0.8	7.1	4.8	10.8	11.5
2005	13.1	13.6	11.7	10.7	6.8	8.6	2.5	4.0	3.9	12.4	10.0	10.8
2006	16.4	13.8	12.7	7.7	6.1	5.3	2.8	0.2	0.4	10.4	7.1	12.8



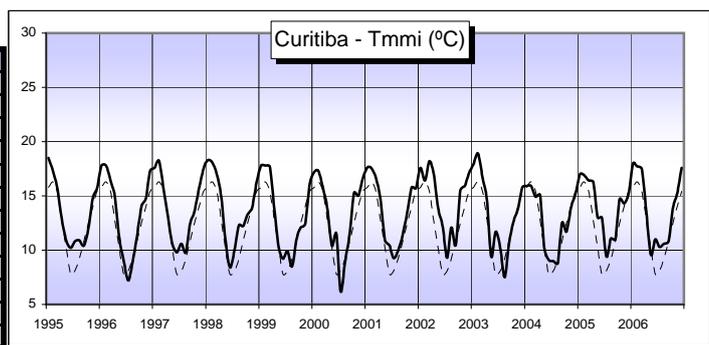
Estação Climatológica Principal de Curitiba/PR
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	27.5	25.7	24.7	24.2	21.0	20.5	22.2	24.1	21.1	21.5	25.1	26.4
1996	27.5	26.2	24.7	23.8	21.1	18.3	17.2	21.4	19.4	22.7	24.0	27.3
1997	26.2	27.3	24.9	24.0	21.3	18.9	21.5	22.7	22.9	22.1	24.7	27.2
1998	28.2	26.7	25.5	23.3	20.6	19.0	19.1	20.4	20.1	21.5	24.0	26.3
1999	26.1	26.9	26.5	23.1	20.2	17.9	19.3	22.5	22.5	20.8	23.1	26.0
2000	26.8	26.3	24.7	25.5	20.9	21.9	18.3	21.3	19.9	25.6	24.5	27.0
2001	27.1	27.1	26.4	24.6	21.1	20.8	20.0	22.4	21.9	24.3	25.9	26.1
2002	26.9	27.2	29.1	26.4	22.4	22.7	19.7	23.5	22.0	26.5	26.0	27.1
2003	27.6	29.7	27.0	25.1	21.8	22.7	20.8	20.8	23.2	23.5	25.1	25.6
2004	25.8	26.5	26.0	24.6	19.1	20.9	18.2	22.9	25.1	22.9	24.8	25.3
2005	26.3	27.3	27.2	25.4	23.3	22.2	20.7	23.6	19.3	23.3	25.6	25.8
2006	28.8	28.1	27.3	24.3	20.7	21.3	23.1	22.7	21.6	24.3	24.5	27.0



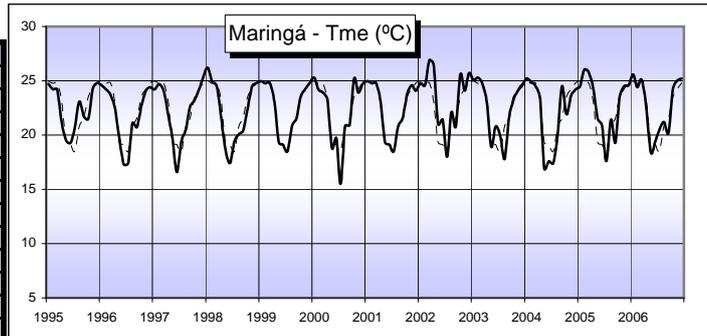
Estação Climatológica Principal de Curitiba/PR
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	18.5	17.3	15.8	13.0	10.9	10.2	10.8	10.9	10.4	12.0	14.8	15.7
1996	17.8	17.8	16.4	15.0	11.2	9.0	7.2	8.8	11.2	14.0	14.8	17.3
1997	17.6	18.2	15.6	13.0	10.6	9.8	10.6	9.8	12.4	13.6	15.7	17.5
1998	18.3	18.1	17.0	14.9	11.0	8.4	10.0	12.3	12.2	13.3	13.9	16.3
1999	17.8	17.8	17.7	13.8	10.2	9.2	9.9	8.5	11.0	12.1	12.4	16.1
2000	17.2	17.3	15.8	13.8	10.4	11.5	6.2	8.9	11.5	15.3	15.0	16.6
2001	17.6	17.5	16.7	14.7	10.9	10.5	9.3	10.0	11.4	13.5	15.8	15.7
2002	17.6	16.4	18.2	17.1	13.9	12.2	9.3	12.1	10.5	15.5	15.9	17.1
2003	17.9	18.9	16.7	14.6	9.4	11.7	10.2	7.5	10.5	12.6	13.8	15.8
2004	15.9	15.9	14.9	15.1	10.2	9.1	9.0	8.8	12.5	11.7	13.9	15.2
2005	17.0	16.9	16.4	16.3	13.0	13.0	9.4	11.1	11.0	14.7	14.3	15.2
2006	18.0	17.7	17.5	13.6	9.6	11.0	10.3	10.6	10.8	13.9	15.2	17.6



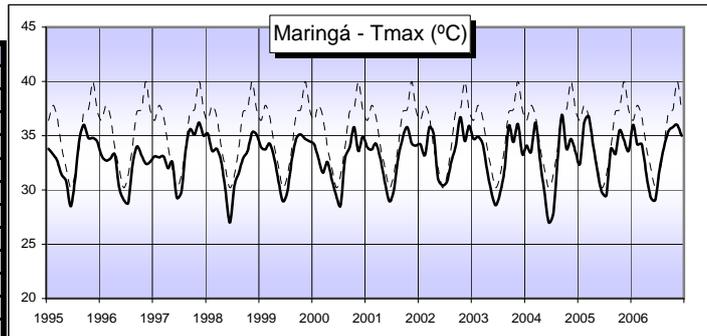
Estação Climatológica Principal de Maringá/PR
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	24.7	24.2	24.2	21.2	19.5	19.3	20.7	23.1	21.7	21.5	24.3	24.8
1996	24.6	24.2	23.7	22.6	19.8	17.3	17.4	21.1	20.7	22.7	24.1	24.4
1997	24.2	24.7	24.1	21.9	19.8	16.6	19.4	20.5	22.6	23.2	24.2	25.4
1998	26.2	24.9	24.5	21.6	18.7	17.4	19.4	20.1	20.4	22.4	24.5	24.8
1999	25.0	24.8	24.8	23.1	19.3	19.1	18.5	20.8	21.6	23.5	24.2	24.8
2000	25.3	24.2	23.9	23.3	18.8	19.7	15.5	20.8	20.9	25.2	23.9	24.7
2001	25.0	24.8	24.8	23.1	19.3	19.1	18.5	20.8	21.6	23.8	24.6	24.1
2002	24.8	24.6	26.9	26.5	21.0	21.4	18.0	22.1	20.8	25.6	24.1	25.7
2003	25.1	25.3	24.7	22.9	18.9	20.8	19.9	17.8	21.5	23.2	24.1	24.6
2004	25.2	24.9	24.5	23.4	16.9	17.6	17.4	20.2	24.5	21.9	23.6	24.2
2005	24.5	26.0	25.8	24.3	21.5	20.9	17.6	21.4	19.3	23.5	24.5	24.6
2006	25.6	24.4	25.1	22.5	18.4	19.4	20.5	21.2	20.2	24.3	25.0	25.2



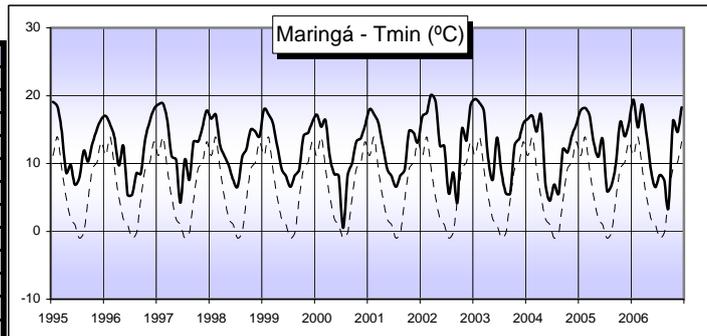
Estação Climatológica Principal de Maringá/PR
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	33.8	33.3	32.7	31.4	30.8	28.5	30.8	34.6	36.0	34.8	34.8	34.5
1996	33.2	32.7	32.9	33.3	30.2	29.1	28.8	32.2	34.0	33.2	32.4	32.6
1997	33.1	33.0	33.1	32.0	32.6	29.3	29.8	33.8	35.6	35.1	36.2	35.0
1998	35.2	33.6	33.8	32.6	30.0	27.0	30.4	31.6	32.9	33.6	35.3	35.1
1999	33.9	33.7	34.3	32.9	30.7	28.9	29.9	32.9	34.8	35.1	34.7	34.5
2000	34.2	32.9	31.6	32.6	30.9	29.4	28.6	32.9	33.9	35.8	33.6	34.9
2001	33.9	33.7	34.3	32.9	30.7	28.9	29.9	32.9	34.8	35.8	34.3	34.1
2002	34.2	33.2	35.8	35.2	31.0	30.4	30.8	32.6	34.1	36.7	34.5	35.9
2003	34.7	34.9	34.3	31.9	29.9	28.6	29.8	32.0	35.9	34.4	36.1	33.3
2004	34.1	33.5	36.2	32.7	29.9	27.0	27.8	33.0	36.9	33.8	34.7	33.5
2005	32.4	36.2	36.8	34.1	31.6	29.8	29.5	33.8	33.3	35.5	34.6	33.6
2006	36.0	34.2	34.2	31.5	29.3	29.1	31.8	33.9	35.4	35.8	36.0	35.0



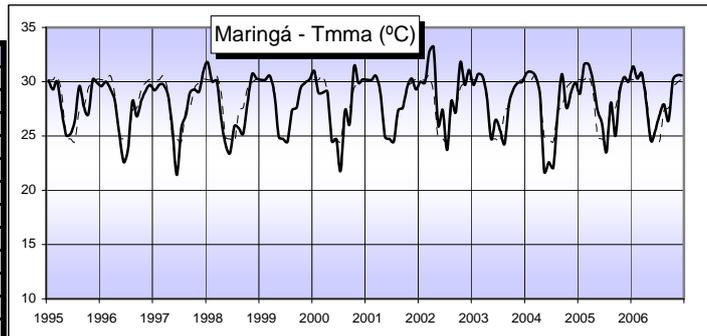
Estação Climatológica Principal de Maringá/PR
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	19.1	18.4	14.9	8.7	9.8	6.9	7.9	11.9	10.3	13.0	15.1	16.5
1996	17.0	15.7	13.9	9.7	12.6	5.4	5.4	8.6	8.5	13.6	16.2	18.0
1997	18.7	18.8	16.5	11.1	10.5	4.2	10.6	7.6	13.2	13.2	15.4	17.8
1998	16.6	17.2	12.8	11.1	9.6	7.6	6.6	10.9	12.1	15.0	14.7	14.0
1999	18.0	17.2	16.0	12.6	9.2	8.2	6.5	8.3	9.0	14.1	14.5	16.1
2000	17.2	15.4	16.4	10.9	8.4	8.2	0.5	8.3	9.9	13.2	13.7	15.6
2001	18.0	17.2	16.0	12.6	9.2	8.2	6.5	8.3	9.0	14.8	14.5	13.1
2002	16.9	17.5	20.1	19.2	12.6	12.6	5.6	8.7	4.3	15.1	13.4	18.6
2003	19.5	18.9	17.8	10.6	7.6	13.8	8.7	5.6	5.6	12.7	13.6	15.9
2004	16.6	17.0	14.7	17.1	6.8	4.5	6.9	5.6	12.1	11.6	14.1	15.7
2005	17.8	18.2	17.2	13.0	11.0	13.6	6.0	6.8	9.8	16.1	14.0	16.0
2006	19.4	15.3	18.7	14.2	8.9	6.5	8.3	7.5	3.5	16.2	14.6	18.3



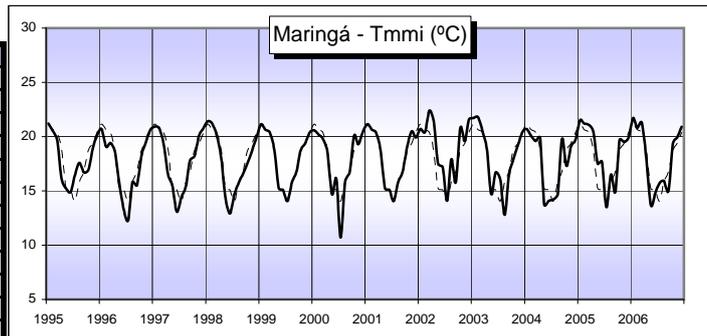
Estação Climatológica Principal de Maringá/PR
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	30.1	29.3	30.0	27.4	25.1	25.2	26.4	29.6	27.7	27.0	30.2	29.9
1996	29.6	30.0	29.3	28.3	25.3	22.6	23.9	28.2	26.8	28.3	29.2	29.7
1997	29.2	29.7	29.7	28.7	25.7	21.4	25.7	26.9	29.0	29.3	29.1	31.0
1998	31.8	30.0	30.1	26.6	24.3	23.4	25.9	25.7	25.2	28.1	30.7	30.3
1999	30.2	30.2	30.5	28.9	24.9	24.7	24.5	27.4	27.6	29.4	29.9	30.2
2000	31.0	29.0	29.0	29.1	24.5	24.7	21.8	27.4	26.1	31.4	29.9	30.2
2001	30.2	30.2	30.5	28.9	24.9	24.7	24.5	27.4	27.6	29.5	30.3	29.3
2002	30.0	29.9	32.8	33.2	26.0	27.4	23.7	28.2	27.2	31.8	29.7	31.1
2003	29.7	30.7	30.5	28.5	24.7	26.5	25.5	24.3	27.9	29.3	29.9	30.0
2004	30.8	30.9	30.5	28.7	21.7	22.6	22.1	27.2	30.7	27.6	29.0	29.9
2005	28.9	31.6	31.6	29.9	27.3	26.2	23.5	28.1	25.0	29.0	30.4	30.0
2006	31.4	30.3	30.8	28.1	24.6	25.5	26.9	27.9	26.4	30.2	30.6	30.6



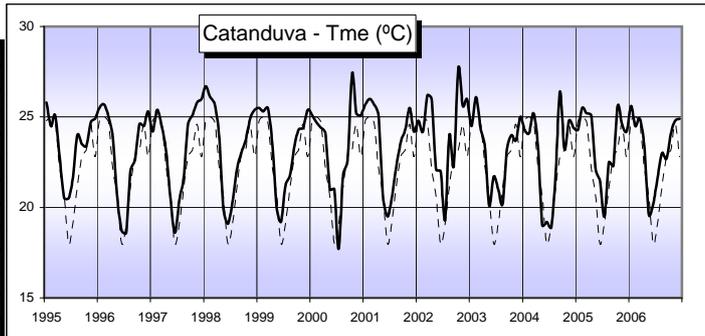
Estação Climatológica Principal de Maringá/PR
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	21.2	20.5	19.7	16.1	15.2	14.9	16.4	17.6	16.7	16.9	18.9	20.1
1996	20.7	19.1	19.4	18.7	15.8	13.3	12.3	15.8	15.5	18.2	19.5	20.6
1997	20.9	20.8	19.3	16.5	15.5	13.1	14.4	15.4	17.8	18.2	20.1	20.8
1998	21.4	21.2	20.1	18.0	14.4	12.9	14.7	15.8	16.6	17.6	18.7	20.0
1999	21.1	20.6	20.4	18.8	15.2	15.1	14.1	15.8	16.8	18.8	19.4	20.4
2000	20.6	20.2	19.8	18.6	14.7	16.1	10.7	15.8	16.7	20.1	19.3	20.4
2001	21.1	20.6	20.4	18.8	15.2	15.1	14.1	15.8	16.8	19.1	20.5	19.9
2002	20.7	20.4	22.4	21.5	17.5	17.2	14.1	17.9	15.8	20.8	19.6	21.6
2003	21.7	21.8	20.5	18.8	14.7	16.7	16.1	12.8	16.4	17.9	19.2	20.4
2004	20.7	20.1	19.6	19.9	13.7	14.1	14.2	14.7	19.8	17.3	19.1	19.7
2005	21.5	21.2	21.1	20.5	17.5	17.7	13.5	16.5	14.9	19.7	19.5	19.9
2006	21.7	20.8	21.3	18.0	13.7	14.8	15.7	15.9	15.0	19.4	19.9	20.9



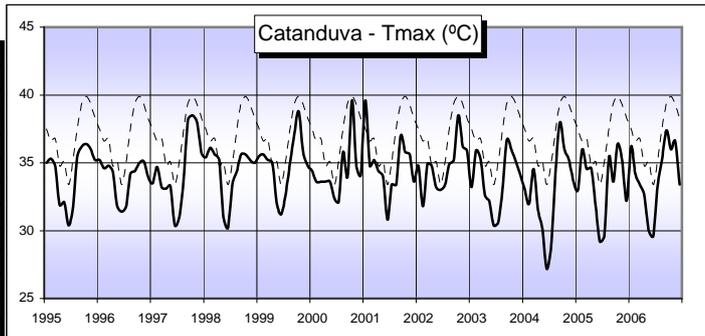
Estação Climatológica Principal de Catanduva/SP
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	25.8	24.5	25.1	22.8	20.5	20.5	21.6	24.0	23.5	23.4	24.7	24.9
1996	25.5	25.7	25.0	23.9	20.6	18.7	18.6	22.0	22.6	24.6	24.5	25.3
1997	24.2	25.4	24.5	23.1	20.6	18.6	20.4	21.7	24.6	25.1	25.8	26.0
1998	26.7	26.1	25.7	23.9	19.9	19.1	20.3	22.1	23.0	23.7	24.9	25.4
1999	25.5	25.3	25.5	23.5	19.9	19.2	21.2	21.8	23.4	24.3	24.4	25.4
2000	25.1	24.7	24.4	24.1	21.0	21.0	17.7	21.8	22.6	27.4	25.2	25.1
2001	25.7	26.0	25.7	25.1	20.6	19.5	20.5	22.2	23.6	24.3	25.5	24.2
2002	24.8	24.2	26.2	26.0	22.1	22.0	19.3	24.0	22.3	27.7	25.6	26.0
2003	24.5	26.1	24.4	23.3	20.1	21.7	21.0	20.2	23.2	24.0	23.7	25.0
2004	24.3	24.1	25.2	23.3	19.0	19.2	18.9	22.0	26.4	23.2	24.8	24.4
2005	24.3	25.5	25.2	25.1	22.1	21.5	19.5	22.5	22.3	25.6	24.6	24.2
2006	25.6	24.5	24.9	23.4	19.6	20.2	21.6	23.0	22.7	24.1	24.8	24.9



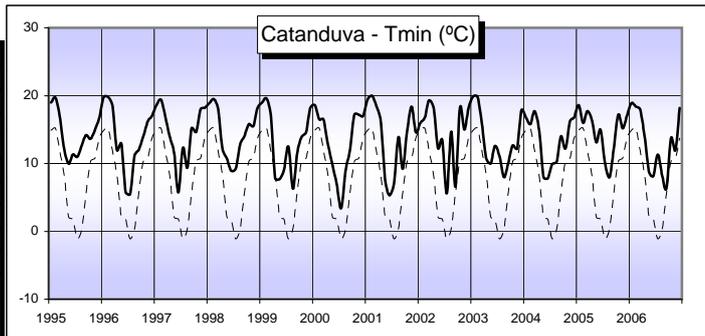
Estação Climatológica Principal de Catanduva/SP
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	35.0	35.3	34.8	31.9	32.1	30.4	31.6	35.5	36.2	36.4	36.0	35.2
1996	35.2	34.6	34.8	34.4	31.8	31.4	31.8	34.2	34.4	35.0	35.1	34.0
1997	33.5	34.7	33.2	33.1	33.3	30.4	31.0	34.0	38.2	38.5	38.0	35.7
1998	35.4	36.1	35.6	35.2	31.0	30.2	33.4	34.4	35.6	35.6	35.2	35.0
1999	35.5	35.6	35.2	35.0	32.0	31.2	32.6	35.0	37.2	38.8	35.8	34.8
2000	34.4	33.6	33.6	33.6	33.6	32.4	32.1	35.8	34.0	39.6	34.8	34.1
2001	39.6	34.8	35.2	34.4	34.0	30.8	33.4	33.4	37.0	35.8	35.6	33.6
2002	34.8	31.8	34.9	34.8	33.2	33.0	33.4	34.9	35.2	38.5	36.2	35.9
2003	33.2	35.9	35.3	32.6	32.2	30.4	30.6	33.2	36.7	36.0	35.1	34.1
2004	33.1	32.0	34.5	31.5	30.2	27.2	29.0	34.6	38.0	36.0	35.2	33.6
2005	33.0	36.0	34.5	34.6	31.8	29.2	29.6	35.4	33.6	36.4	35.2	32.2
2006	36.2	34.2	33.4	32.6	30.0	29.6	33.2	35.2	37.4	36.0	36.6	33.4



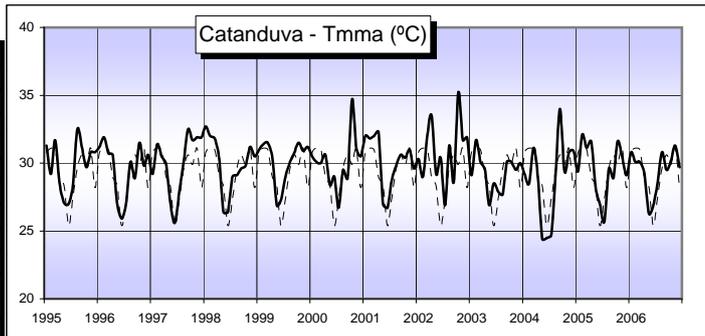
Estação Climatológica Principal de Catanduva/SP
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	19.0	19.7	17.0	12.2	10.0	11.3	11.0	12.7	14.2	13.6	15.0	16.7
1996	19.8	19.8	18.6	12.0	12.9	5.8	5.5	11.2	12.0	14.0	16.2	17.0
1997	18.6	19.4	17.0	14.0	11.5	5.7	12.3	9.4	15.2	14.6	18.0	18.2
1998	18.9	19.5	18.2	12.2	10.7	8.9	9.2	12.8	14.0	15.8	15.5	18.2
1999	19.0	19.6	17.3	7.8	7.7	9.0	12.5	6.3	11.4	13.9	14.6	18.2
2000	18.6	16.5	16.5	12.8	9.8	7.0	3.4	9.0	11.9	17.2	17.2	17.0
2001	19.4	20.0	18.5	16.2	7.4	5.3	7.0	13.9	9.2	14.8	18.4	14.6
2002	16.0	16.8	19.3	18.3	12.2	13.5	5.6	14.7	6.6	18.2	15.0	18.2
2003	19.9	19.8	16.0	10.7	10.0	12.6	11.1	8.0	10.0	12.7	12.2	17.8
2004	16.8	15.8	17.7	15.0	8.0	7.8	9.9	10.3	14.0	12.2	16.2	16.8
2005	18.6	16.0	17.7	16.4	13.1	15.0	10.1	8.0	12.1	17.2	15.2	17.0
2006	18.9	18.4	18.0	14.0	8.7	8.1	11.3	8.1	6.4	13.7	12.0	18.2



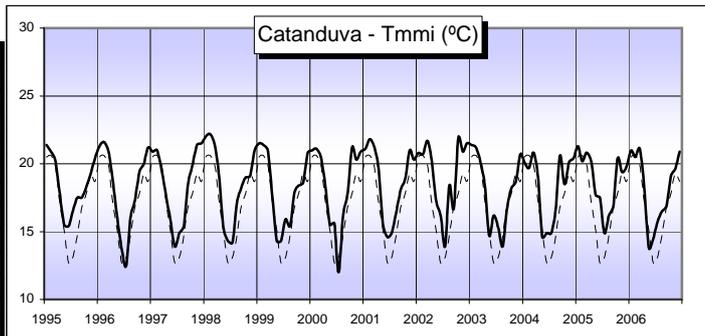
Estação Climatológica Principal de Catanduva/SP
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	31.3	29.2	31.7	28.5	27.1	27.0	28.3	32.5	31.2	29.7	30.8	30.8
1996	31.2	31.9	30.7	30.6	27.0	25.9	27.1	30.1	28.9	31.5	29.8	30.6
1997	29.2	31.4	30.5	29.9	27.1	25.6	27.9	30.2	32.5	31.7	31.9	31.9
1998	32.7	32.0	31.8	30.3	26.4	26.4	29.0	29.1	29.6	29.8	31.2	30.5
1999	31.0	31.4	31.5	30.4	26.9	27.3	29.0	30.1	30.8	31.5	30.9	31.2
2000	30.5	30.1	30.0	30.6	28.4	29.0	26.7	29.5	28.9	34.7	31.1	30.5
2001	32.0	31.8	32.0	32.3	27.0	26.7	28.7	29.8	30.6	30.4	31.0	29.6
2002	30.3	29.0	32.1	33.5	29.2	30.4	26.9	31.3	28.6	35.2	31.7	31.9
2003	29.1	31.7	30.1	29.5	26.9	28.5	27.9	27.7	30.1	30.1	29.5	30.0
2004	29.2	28.5	31.1	28.8	24.4	24.5	24.7	29.4	34.0	29.4	30.8	30.9
2005	29.4	32.1	31.1	31.6	28.2	27.0	25.7	29.6	28.9	31.6	30.5	29.1
2006	30.8	30.1	30.1	29.3	26.3	26.9	28.5	30.8	29.5	30.2	31.3	29.7



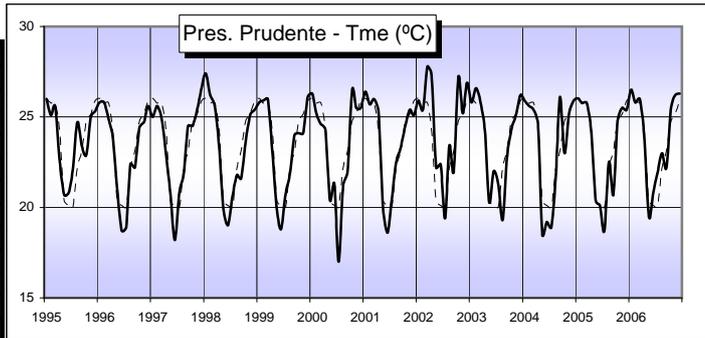
Estação Climatológica Principal de Catanduva/SP
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	21.4	20.9	20.3	17.9	15.5	15.4	16.5	17.5	17.5	18.3	19.3	20.4
1996	21.3	21.6	20.9	18.8	16.1	13.7	12.5	16.0	17.3	19.4	20.0	21.2
1997	20.9	21.0	19.5	17.6	15.9	13.9	14.9	15.4	18.5	19.9	21.4	21.5
1998	22.0	22.2	21.4	19.0	15.3	14.3	14.2	17.1	18.2	19.0	19.1	21.0
1999	21.5	21.4	21.0	17.6	14.3	14.3	15.9	15.4	17.9	18.4	18.6	20.8
2000	21.0	21.1	20.5	18.3	15.5	15.6	12.0	16.2	17.8	21.2	20.3	20.9
2001	21.1	21.8	21.3	19.7	15.5	14.6	14.9	16.4	18.1	18.9	21.0	20.3
2002	20.8	20.7	21.7	20.3	17.3	16.2	13.9	18.4	16.7	21.9	20.9	21.5
2003	21.4	21.2	20.1	18.3	14.7	16.2	15.3	13.9	16.6	18.2	18.7	20.7
2004	20.1	19.7	20.8	19.0	14.6	14.9	14.9	16.7	20.6	18.5	20.1	20.4
2005	21.3	20.2	20.8	20.2	17.7	17.5	14.9	16.2	16.9	20.4	19.4	19.8
2006	21.0	20.5	21.1	18.2	13.8	14.5	15.7	16.5	16.9	19.1	19.6	20.9



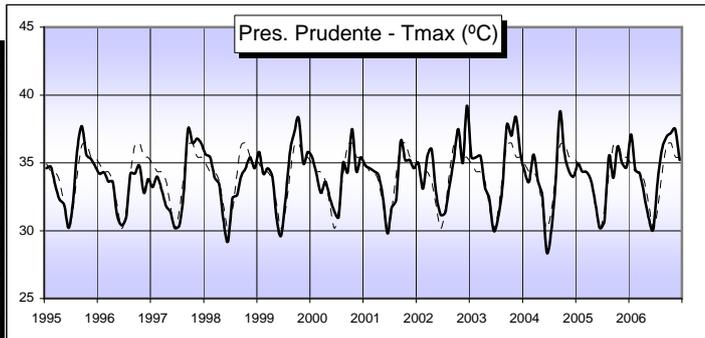
Estação Climatológica Principal de Presidente Prudente/SP
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	26.0	25.1	25.6	22.6	20.7	20.8	22.1	24.7	23.4	22.9	25.0	25.3
1996	25.8	25.8	24.9	23.9	21.0	18.7	18.9	22.4	22.2	24.4	24.7	25.6
1997	25.0	25.6	24.9	22.9	20.8	18.2	20.8	21.9	24.5	24.5	25.4	26.6
1998	27.4	26.2	25.6	23.3	19.9	19.0	20.6	21.8	21.6	23.6	25.1	25.4
1999	25.8	25.9	26.0	23.1	19.9	18.8	20.7	21.9	24.0	24.1	24.1	26.1
2000	26.3	25.2	24.6	24.3	20.4	21.3	17.0	21.2	22.0	26.5	25.5	25.5
2001	26.4	25.7	26.0	25.3	20.0	18.6	20.4	22.5	23.3	24.5	25.4	25.1
2002	25.9	25.4	27.8	27.3	22.2	22.4	19.4	23.4	22.0	27.2	25.2	26.9
2003	25.8	26.6	25.8	24.2	20.3	22.0	21.3	19.3	22.7	24.3	25.1	26.2
2004	25.9	25.6	25.4	24.6	18.5	19.2	18.9	21.7	26.1	23.0	25.2	25.9
2005	26.0	25.8	25.8	24.2	20.4	20.1	18.7	22.5	20.7	24.8	25.5	25.4
2006	26.5	25.8	26.0	23.9	19.5	20.8	21.9	23.0	22.2	25.5	26.2	26.3



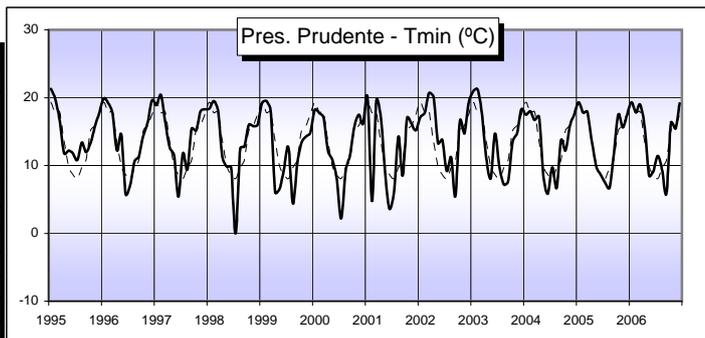
Estação Climatológica Principal de Presidente Prudente/SP
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	34.6	34.7	33.4	32.3	31.9	30.2	32.0	36.0	37.7	35.6	35.3	34.8
1996	34.2	34.3	33.6	33.6	31.1	30.4	31.0	34.2	34.2	34.8	32.8	33.8
1997	33.2	34.0	33.0	31.8	31.4	30.2	30.4	32.9	37.5	36.5	36.8	36.4
1998	35.6	35.4	33.9	33.4	30.8	29.2	32.4	32.6	34.0	34.6	35.4	34.6
1999	35.8	34.2	34.6	34.0	30.8	29.6	32.3	35.8	37.3	38.3	35.0	35.8
2000	35.4	34.2	32.8	33.6	32.4	31.4	31.0	35.0	34.3	37.5	34.4	35.4
2001	34.8	34.6	34.4	34.1	32.4	29.8	31.7	32.3	36.6	35.2	35.2	34.6
2002	35.0	33.1	35.5	36.0	32.8	31.2	31.3	33.2	35.2	37.5	35.0	39.2
2003	35.4	35.4	35.5	33.2	32.4	30.0	31.0	33.4	37.8	37.0	38.4	35.7
2004	34.4	33.6	35.6	33.6	32.6	28.4	30.0	33.8	38.8	35.7	34.4	34.0
2005	34.9	34.4	34.3	33.6	31.9	30.2	30.7	35.5	33.9	36.2	35.0	34.7
2006	37.1	34.5	34.2	32.6	30.9	30.1	33.5	36.0	36.9	37.2	37.5	35.2



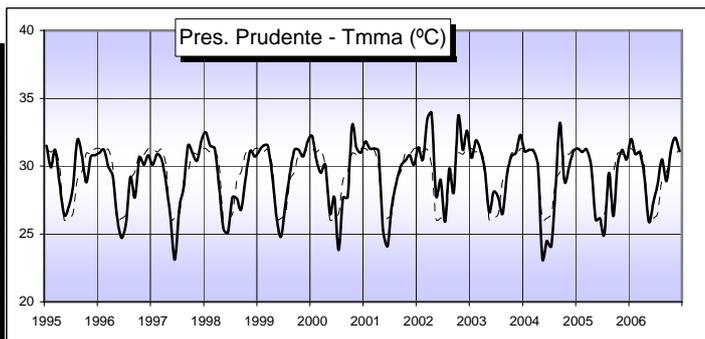
Estação Climatológica Principal de Presidente Prudente/SP
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	21.3	19.7	16.7	11.8	12.2	11.8	10.8	13.4	12.0	13.3	15.8	17.7
1996	19.9	19.2	17.8	12.2	14.5	5.8	7.1	10.6	11.3	14.4	16.4	19.6
1997	18.9	20.4	16.5	12.7	11.4	5.4	11.8	9.4	15.4	15.2	18.0	18.3
1998	18.4	19.5	18.2	11.2	9.8	9.7	0.0	12.5	12.8	16.0	15.8	16.0
1999	19.2	19.5	18.0	6.0	6.6	9.4	12.7	4.4	10.0	13.4	14.3	14.8
2000	18.2	17.7	17.1	12.2	10.8	8.1	2.2	9.2	11.4	15.7	17.5	16.1
2001	20.0	4.8	19.5	17.2	8.8	3.6	6.0	14.3	8.5	17.0	16.1	15.2
2002	17.1	17.8	20.7	20.1	13.3	13.8	9.2	11.2	5.5	16.6	14.7	19.2
2003	20.9	21.2	17.8	11.1	8.1	14.7	9.7	7.2	7.7	13.5	14.8	18.3
2004	17.5	18.0	16.7	17.2	8.2	5.8	9.7	6.7	13.7	12.2	15.9	17.5
2005	19.3	17.8	17.9	13.6	9.9	8.7	7.5	6.7	11.5	17.5	15.6	17.4
2006	19.3	17.8	19.0	15.7	8.5	9.1	11.4	9.2	5.9	16.3	15.4	19.2



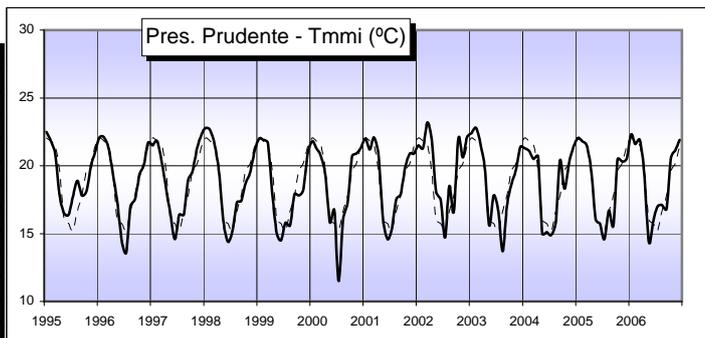
Estação Climatológica Principal de Presidente Prudente/SP
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	31.5	29.9	31.2	28.7	26.4	27.0	28.4	31.9	30.8	28.8	30.7	30.8
1996	31.0	31.2	29.9	29.3	26.2	24.7	25.9	29.2	27.7	30.6	30.1	30.8
1997	30.1	30.9	30.5	28.7	26.3	23.1	26.9	28.5	31.5	30.9	30.4	31.9
1998	32.5	31.5	31.3	28.4	25.4	25.1	27.7	27.6	26.8	29.1	31.1	30.7
1999	31.1	31.5	31.5	29.2	26.1	24.8	27.2	29.5	31.2	31.2	30.7	31.8
2000	32.2	30.5	29.5	30.1	26.5	27.7	23.8	27.7	27.7	33.0	31.4	31.0
2001	31.8	31.3	31.3	31.1	25.3	24.1	27.0	28.7	30.0	30.4	30.8	30.1
2002	31.4	30.5	33.5	33.9	27.8	29.0	25.9	29.8	28.1	33.7	31.2	32.6
2003	30.6	31.9	31.1	29.6	26.6	28.1	27.7	26.5	29.3	30.7	31.0	32.3
2004	31.1	31.2	31.1	30.0	23.2	24.5	24.1	28.6	33.2	28.9	29.9	31.1
2005	31.3	31.0	31.2	29.9	26.1	26.2	25.0	29.5	26.3	30.1	31.2	30.5
2006	32.0	30.9	31.0	29.3	25.9	27.3	28.6	30.5	28.9	31.2	32.1	31.1



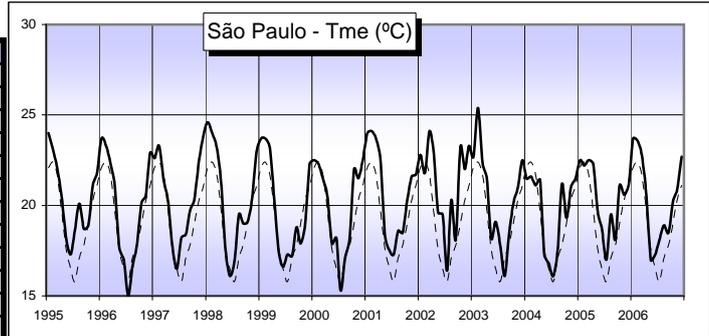
Estação Climatológica Principal de Presidente Prudente/SP
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	22.5	21.8	20.9	17.8	16.5	16.4	17.7	18.9	17.8	18.1	19.9	21.0
1996	22.1	22.1	21.3	19.5	17.4	14.5	13.6	17.0	17.5	19.3	20.1	21.7
1997	21.5	21.8	20.3	18.3	16.5	14.6	16.4	16.4	18.9	19.6	21.3	22.3
1998	22.8	22.6	21.5	19.4	15.9	14.4	15.2	17.3	17.4	18.7	19.5	21.1
1999	22.0	21.9	21.7	17.9	15.0	14.5	15.8	15.6	17.9	17.8	18.2	20.9
2000	21.8	21.3	20.7	19.3	15.8	16.7	11.5	16.0	17.3	20.7	20.9	21.3
2001	22.0	21.2	22.1	20.8	16.1	14.6	15.3	17.5	17.9	19.9	20.9	20.9
2002	21.5	21.3	23.2	22.0	18.1	17.5	14.7	18.5	16.6	22.0	20.6	22.1
2003	22.4	22.8	21.6	19.7	15.6	17.8	16.7	13.7	17.0	18.6	19.7	21.4
2004	21.3	21.1	20.5	20.7	15.0	15.1	14.9	15.8	20.4	18.3	20.2	21.4
2005	22.1	21.8	21.5	19.6	16.1	15.7	14.6	16.7	15.6	20.5	20.3	20.5
2006	22.3	21.6	21.9	19.4	14.4	15.9	17.0	17.1	16.8	20.6	21.1	21.9



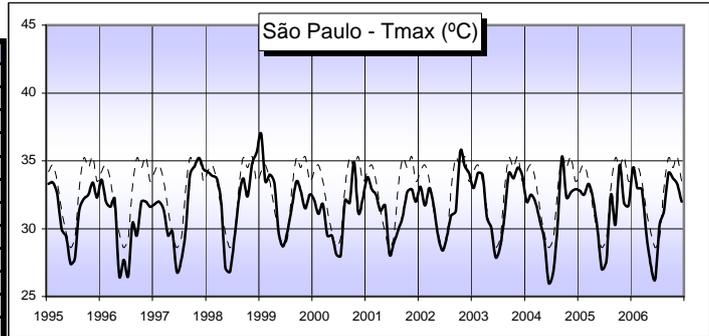
Estação Climatológica Principal de Mirante Santana/SP - (São Paulo)
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	24.0	23.1	22.1	20.5	18.2	17.3	18.6	20.1	18.7	18.9	21.1	21.8
1996	23.7	23.3	22.3	21.1	17.7	17.0	15.0	16.6	17.8	20.1	20.6	22.9
1997	22.6	23.3	21.4	20.2	17.8	16.5	18.2	18.4	19.7	20.4	22.5	23.9
1998	24.6	24.0	23.2	21.2	17.6	16.1	16.9	19.5	19.0	19.1	20.4	23.0
1999	23.7	23.7	23.2	20.3	17.4	16.6	17.3	17.2	18.8	17.9	19.0	22.3
2000	22.5	22.3	21.5	20.5	17.9	18.2	15.3	17.1	18.2	22.0	21.5	22.5
2001	24.0	24.1	23.7	22.5	18.3	17.5	17.3	18.6	18.5	20.3	21.6	21.7
2002	22.8	21.8	24.1	23.0	19.6	19.5	16.4	20.3	18.1	23.2	22.0	23.3
2003	22.7	25.4	22.4	21.4	18.2	19.1	17.8	16.1	18.3	20.1	21.0	22.5
2004	21.5	21.6	21.1	21.4	17.3	16.8	16.1	17.6	21.2	19.3	21.0	21.5
2005	22.5	22.2	22.5	22.3	19.7	18.7	17.0	19.5	18.1	21.1	20.6	21.1
2006	23.7	23.6	22.8	20.6	17.0	17.3	18.1	18.9	18.5	20.2	20.9	22.7



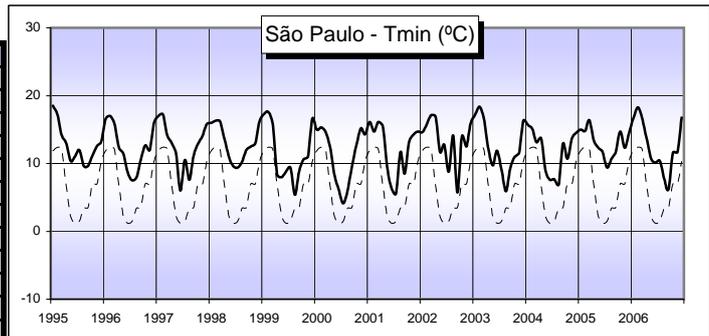
Estação Climatológica Principal de Mirante Santana/SP - (São Paulo)
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	33.3	33.4	32.6	30.0	29.4	27.4	27.8	31.4	32.2	32.5	33.4	32.3
1996	33.6	32.0	31.6	32.2	26.5	27.7	26.5	30.4	29.5	32.0	32.0	31.6
1997	31.8	32.0	31.4	29.5	29.8	26.8	27.7	30.0	34.0	34.6	35.2	34.4
1998	34.2	33.9	33.7	31.9	27.1	26.8	29.3	32.2	33.7	32.4	34.8	35.6
1999	37.0	33.5	34.0	33.4	29.6	28.7	29.8	31.7	33.5	32.8	31.5	32.5
2000	32.1	31.1	31.8	29.5	29.1	28.1	28.0	32.1	31.9	34.9	31.2	32.2
2001	33.8	32.9	32.5	31.3	31.7	28.1	28.9	29.9	30.9	32.7	32.9	32.0
2002	33.1	31.7	33.0	31.7	29.5	28.4	29.5	31.0	31.3	35.7	34.6	34.1
2003	33.0	34.1	34.0	30.8	30.1	27.9	28.7	31.1	34.1	33.7	34.5	33.9
2004	32.0	32.5	31.9	30.5	29.2	26.0	26.8	30.5	35.3	32.3	32.7	32.9
2005	32.8	32.5	33.3	32.1	29.8	27.0	27.6	32.5	30.3	34.7	31.9	31.7
2006	34.5	33.0	32.9	29.7	27.3	26.3	30.2	31.3	34.1	33.7	33.3	32.0



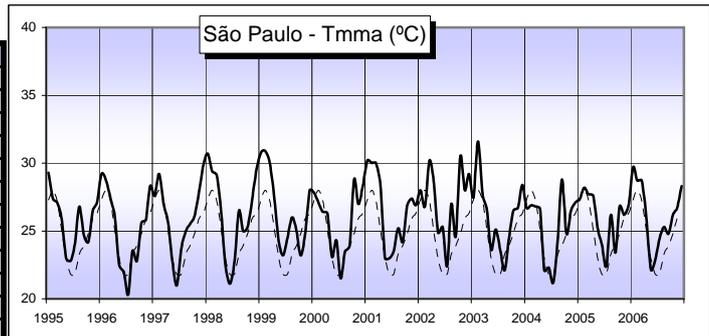
Estação Climatológica Principal de Mirante Santana/SP - (São Paulo)
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	18.5	17.2	14.2	13.0	10.4	11.0	12.0	9.6	9.6	11.2	12.6	13.2
1996	16.6	17.0	15.9	12.4	11.4	8.8	7.5	8.0	10.5	12.7	12.0	16.0
1997	17.0	17.2	14.2	13.0	11.3	6.0	10.5	7.6	11.1	12.9	14.1	15.8
1998	16.0	16.3	16.2	13.6	11.0	9.6	9.4	10.3	12.0	12.5	13.0	16.2
1999	17.3	17.6	15.9	8.3	8.0	8.8	9.4	5.4	8.8	10.6	11.1	16.6
2000	15.0	15.3	14.7	12.5	8.3	6.2	4.1	6.1	9.5	12.7	15.2	14.3
2001	16.1	14.7	16.1	15.5	9.4	6.4	5.6	11.7	8.5	13.2	14.3	14.7
2002	14.6	15.8	17.1	16.9	11.7	12.8	8.8	14.1	5.7	14.0	12.5	15.9
2003	17.2	18.4	16.7	12.2	9.7	11.9	9.1	5.9	9.2	11.0	11.6	16.3
2004	15.7	15.1	13.1	13.7	8.9	7.6	7.7	6.9	12.9	10.7	13.7	14.5
2005	15.0	14.8	16.4	13.4	12.3	11.7	9.4	10.7	11.7	14.7	12.3	14.4
2006	16.7	18.3	16.7	13.7	10.7	10.1	10.4	7.7	6.2	11.6	11.7	16.8



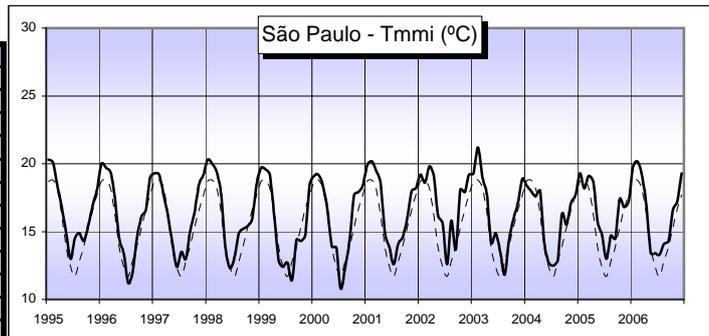
Estação Climatológica Principal de Mirante Santana/SP - (São Paulo)
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	29.3	27.4	27.1	25.9	23.0	22.8	24.0	26.8	24.7	24.2	26.5	27.1
1996	29.2	28.7	27.4	26.1	22.5	22.0	20.3	23.5	22.8	25.6	25.8	28.3
1997	27.6	29.2	27.0	25.6	22.8	21.0	23.7	25.0	25.5	26.1	27.9	29.9
1998	30.7	29.4	29.1	26.3	22.5	21.1	22.7	26.5	25.0	25.3	27.3	29.6
1999	30.8	30.9	30.0	27.4	24.2	23.2	24.5	26.0	25.0	23.2	24.8	28.0
2000	27.8	27.1	26.4	26.3	23.1	24.3	21.5	23.5	23.9	28.8	27.0	28.3
2001	30.2	30.0	30.0	28.3	23.0	23.0	23.5	25.2	24.2	26.9	27.4	26.9
2002	28.0	26.8	30.2	28.7	24.9	25.3	22.4	27.0	24.6	30.5	28.0	29.2
2003	27.5	31.6	27.8	26.5	23.6	25.1	23.6	22.1	24.4	26.5	26.7	28.4
2004	26.7	26.9	26.8	26.6	22.1	22.3	21.2	24.4	28.8	24.8	26.5	27.1
2005	27.4	28.2	27.7	27.6	25.2	24.0	22.4	26.2	23.4	26.8	26.2	26.9
2006	29.7	28.7	28.7	26.0	22.2	22.9	24.4	25.3	24.8	26.2	26.7	28.3



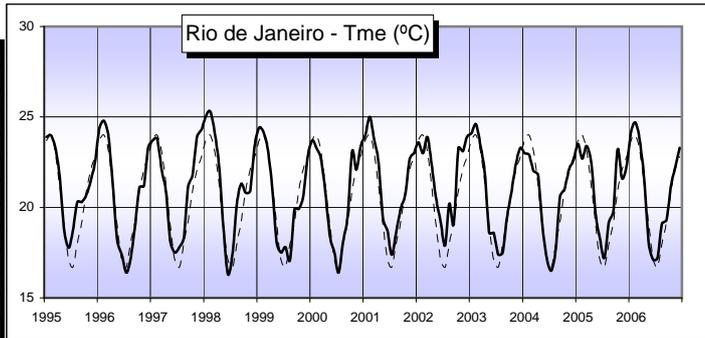
Estação Climatológica Principal de Mirante Santana/SP - (São Paulo)
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	20.3	20.1	18.5	16.9	14.9	13.0	14.5	14.9	14.3	15.5	17.0	18.1
1996	20.0	19.7	19.4	17.6	14.5	13.4	11.2	11.9	14.5	16.1	16.6	19.0
1997	19.3	19.2	17.7	16.1	14.2	12.4	13.5	13.0	15.0	16.4	18.5	19.2
1998	20.3	20.0	19.4	17.7	13.8	12.3	13.1	14.9	15.2	15.4	15.9	18.5
1999	19.7	19.6	19.2	16.1	12.8	12.4	12.7	11.4	14.4	14.3	14.7	18.5
2000	19.1	19.2	18.4	16.6	13.9	13.8	10.8	12.3	14.4	17.7	17.9	18.4
2001	19.9	20.2	19.5	18.6	14.9	13.8	12.6	14.1	14.6	16.0	18.0	18.2
2002	19.2	18.6	19.8	19.2	16.2	15.6	12.6	15.8	13.7	18.1	17.9	19.2
2003	19.3	21.2	19.0	17.7	14.2	14.9	13.5	11.8	14.3	15.9	17.1	18.9
2004	18.4	18.0	17.6	18.0	14.2	12.7	12.5	12.9	16.3	15.5	17.1	17.7
2005	19.3	18.2	19.1	18.7	15.7	14.8	13.0	14.7	14.5	17.4	16.8	17.2
2006	19.8	20.2	19.2	17.0	13.4	13.4	13.3	14.1	14.3	16.6	17.2	19.3



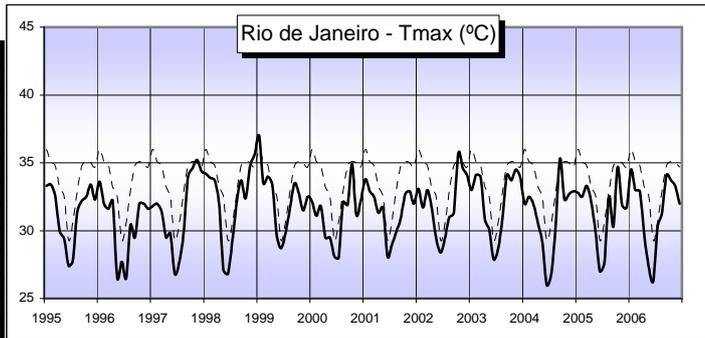
Estação Climatológica Principal de Cordeiro/RJ
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	23.9	24.0	23.4	21.7	18.8	17.8	18.7	20.3	20.3	20.7	21.5	22.5
1996	24.4	24.8	23.9	21.3	18.2	17.4	16.4	17.1	18.9	21.1	21.2	23.3
1997	23.7	23.8	22.1	20.8	18.1	17.5	17.8	18.3	21.1	21.8	23.9	24.3
1998	25.0	25.3	24.1	22.2	18.9	16.3	17.4	20.2	21.3	20.8	20.9	23.4
1999	24.4	24.2	23.2	21.0	18.0	17.5	17.8	17.1	19.9	19.9	20.6	22.8
2000	23.7	23.3	22.7	20.8	18.4	17.5	16.4	18.1	19.5	23.1	22.1	23.4
2001	24.0	25.0	23.8	22.5	19.4	18.7	17.4	18.6	20.0	20.7	22.7	23.0
2002	23.6	23.0	23.9	22.4	20.5	19.2	17.9	20.2	19.1	23.3	23.1	23.9
2003	24.1	24.6	23.4	21.8	18.6	18.6	17.4	17.5	19.4	20.8	22.4	23.3
2004	23.0	22.9	22.0	21.8	19.1	17.2	16.5	17.7	20.6	21.0	22.1	22.6
2005	23.5	22.7	23.4	22.5	19.6	18.3	17.2	19.2	19.8	23.2	21.6	22.3
2006	24.2	24.7	23.7	21.5	18.0	17.1	17.2	19.1	19.3	21.2	22.2	23.3



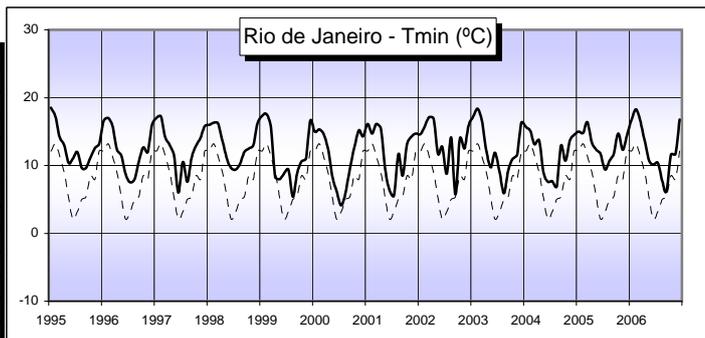
Estação Climatológica Principal de Cordeiro/RJ
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	33.3	33.4	32.6	30.0	29.4	27.4	27.8	31.4	32.2	32.5	33.4	32.3
1996	33.6	32.0	31.6	32.2	26.5	27.7	26.5	30.4	29.5	32.0	32.0	31.6
1997	31.8	32.0	31.4	29.5	29.8	26.8	27.7	30.0	34.0	34.6	35.2	34.4
1998	34.2	33.9	33.7	31.9	27.1	26.8	29.3	32.2	33.7	32.4	34.8	35.6
1999	37.0	33.5	34.0	33.4	29.6	28.7	29.8	31.7	33.5	32.8	31.5	32.5
2000	32.1	31.1	31.8	29.5	28.1	28.0	32.1	31.9	34.9	31.2	32.2	32.2
2001	33.8	32.9	32.5	31.3	31.7	28.1	28.9	29.9	30.9	32.7	32.9	32.0
2002	33.1	31.7	33.0	31.7	29.5	28.4	29.5	31.0	31.3	35.7	34.6	34.1
2003	33.0	34.1	34.0	30.8	30.1	27.9	28.7	31.1	34.1	33.7	34.5	33.9
2004	32.0	32.5	31.9	30.5	29.2	26.0	26.8	30.5	35.3	32.3	32.7	32.9
2005	32.8	32.5	33.3	32.1	29.8	27.0	27.6	32.5	30.3	34.7	31.9	31.7
2006	34.5	33.0	32.9	29.7	27.3	26.3	30.2	31.3	34.1	33.7	33.3	32.0



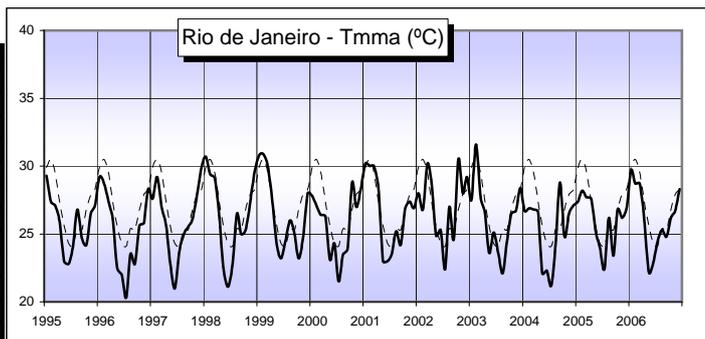
Estação Climatológica Principal de Cordeiro/RJ
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	18.5	17.2	14.2	13.0	10.4	11.0	12.0	9.6	9.6	11.2	12.6	13.2
1996	16.6	17.0	15.9	12.4	11.4	8.8	7.5	8.0	10.5	12.7	12.0	16.0
1997	17.0	17.2	14.2	13.0	11.3	6.0	10.5	7.6	11.1	12.9	14.1	15.8
1998	16.0	16.3	16.2	13.6	11.0	9.6	9.4	10.3	12.0	12.5	13.0	16.2
1999	17.3	17.6	15.9	8.3	8.0	8.8	9.4	5.4	8.8	10.6	11.1	16.6
2000	15.0	15.3	14.7	12.5	8.3	6.2	4.1	6.1	9.5	12.7	15.2	14.3
2001	16.1	14.7	16.1	15.5	9.4	6.4	5.6	11.7	8.5	13.2	14.3	14.7
2002	14.6	15.8	17.1	16.9	11.7	12.8	8.8	14.1	5.7	14.0	12.5	15.9
2003	17.2	18.4	16.7	12.2	9.7	11.9	9.1	5.9	9.2	11.0	11.6	16.3
2004	15.7	15.1	13.1	13.7	8.9	7.6	7.7	6.9	12.9	10.7	13.7	14.5
2005	15.0	14.8	16.4	13.4	12.3	11.7	9.4	10.7	11.7	14.7	12.3	14.4
2006	16.7	18.3	16.7	13.7	10.7	10.1	10.4	7.7	6.2	11.6	11.7	16.8



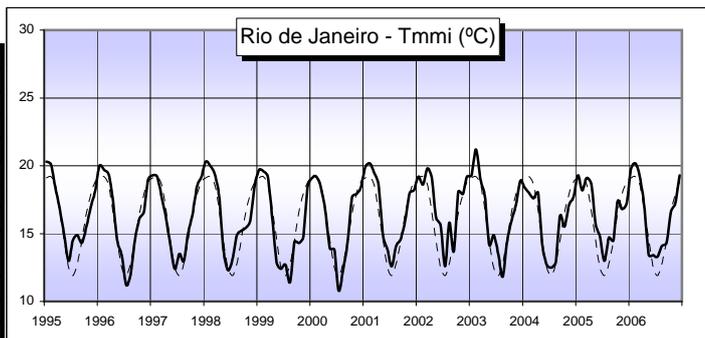
Estação Climatológica Principal de Cordeiro/RJ
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	29.3	27.4	27.1	25.9	23.0	22.8	24.0	26.8	24.7	24.2	26.5	27.1
1996	29.2	28.7	27.4	26.1	22.5	22.0	20.3	23.5	22.8	25.6	25.8	28.3
1997	27.6	29.2	27.0	25.6	22.8	21.0	23.7	25.0	25.5	26.1	27.9	29.9
1998	30.7	29.4	29.1	26.3	22.5	21.1	22.7	26.5	25.0	25.3	27.3	29.6
1999	30.8	30.9	30.0	27.4	24.2	23.2	24.5	26.0	25.0	23.2	24.8	28.0
2000	27.8	27.1	26.4	26.3	23.1	24.3	21.5	23.5	23.9	28.8	27.0	28.3
2001	30.2	30.0	30.0	28.3	23.0	23.0	23.5	25.2	24.2	26.9	27.4	26.9
2002	28.0	26.8	30.2	28.7	24.9	25.3	22.4	27.0	24.6	30.5	28.0	29.2
2003	27.5	31.6	27.8	26.5	23.6	25.1	23.6	22.1	24.4	26.5	26.7	28.4
2004	26.7	26.9	26.8	26.6	22.1	22.3	21.2	24.4	28.8	24.8	26.5	27.1
2005	27.4	28.2	27.7	27.6	25.2	24.0	22.4	26.2	23.4	26.8	26.2	26.9
2006	29.7	28.7	28.7	26.0	22.2	22.9	24.4	25.3	24.8	26.2	26.7	28.3



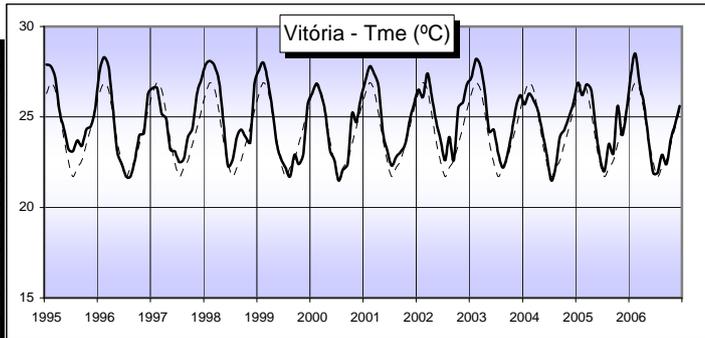
Estação Climatológica Principal de Cordeiro/RJ
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	20.3	20.1	18.5	16.9	14.9	13.0	14.5	14.9	14.3	15.5	17.0	18.1
1996	20.0	19.7	19.4	17.6	14.5	13.4	11.2	11.9	14.5	16.1	16.6	19.0
1997	19.3	19.2	17.7	16.1	14.2	12.4	13.5	13.0	15.0	16.4	18.5	19.2
1998	20.3	20.0	19.4	17.7	13.8	12.3	13.1	14.9	15.2	15.4	15.9	18.5
1999	19.7	19.6	19.2	16.1	12.8	12.4	12.7	11.4	14.4	14.3	14.7	18.5
2000	19.1	19.2	18.4	16.6	13.9	13.8	10.8	12.3	14.4	17.7	17.9	18.4
2001	19.9	20.2	19.5	18.6	14.9	13.8	12.6	14.1	14.6	16.0	18.0	18.2
2002	19.2	18.6	19.8	19.2	16.2	15.6	12.6	15.8	13.7	18.1	17.9	19.2
2003	19.3	21.2	19.0	17.7	14.2	14.9	13.5	11.8	14.3	15.9	17.1	18.9
2004	18.4	18.0	17.6	18.0	14.2	12.7	12.5	12.9	16.3	15.5	17.1	17.7
2005	19.3	18.2	19.1	18.7	15.7	14.8	13.0	14.7	14.5	17.4	16.8	17.2
2006	19.8	20.2	19.2	17.0	13.4	13.4	13.3	14.1	14.3	16.6	17.2	19.3



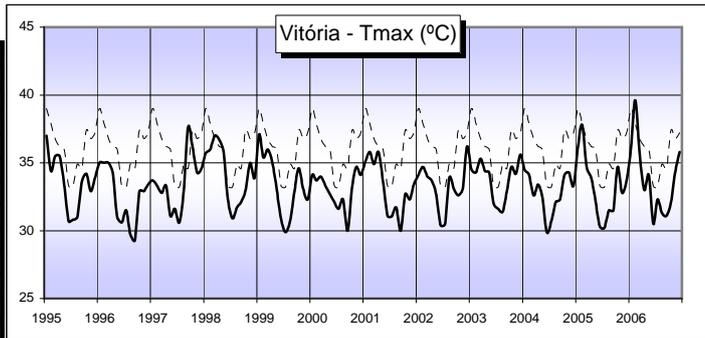
Estação Climatológica Principal de Vitória/ES
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	27.9	27.8	27.2	25.3	24.3	23.2	23.1	23.7	23.4	24.3	24.5	25.4
1996	27.5	28.3	27.8	25.6	23.1	22.4	21.7	21.7	22.6	24.0	24.1	26.3
1997	26.6	26.6	25.2	24.9	23.2	23.1	22.5	22.7	23.9	24.4	26.3	27.1
1998	27.9	28.1	27.8	26.9	24.7	22.3	22.6	23.9	24.3	23.9	23.6	26.9
1999	27.6	28.0	27.0	25.4	23.5	22.7	22.2	21.7	22.9	22.4	22.9	25.7
2000	26.3	26.8	26.3	25.2	23.2	22.6	21.5	22.1	22.4	25.2	24.7	26.0
2001	27.0	27.8	27.4	26.7	24.1	23.1	22.3	22.8	23.1	23.5	24.8	25.7
2002	26.5	26.1	27.4	26.2	24.8	23.7	22.6	23.9	22.6	25.5	25.8	26.8
2003	27.2	28.2	27.8	26.3	24.2	24.3	23.0	22.2	22.8	24.0	25.5	26.2
2004	25.7	26.3	25.9	25.3	24.2	22.9	21.5	22.3	23.9	24.3	25.0	25.8
2005	26.9	26.2	26.8	26.5	24.4	22.8	22.0	23.5	23.0	25.6	24.0	25.4
2006	27.4	28.5	26.8	25.6	23.6	21.9	21.9	22.9	22.4	23.8	24.6	25.6



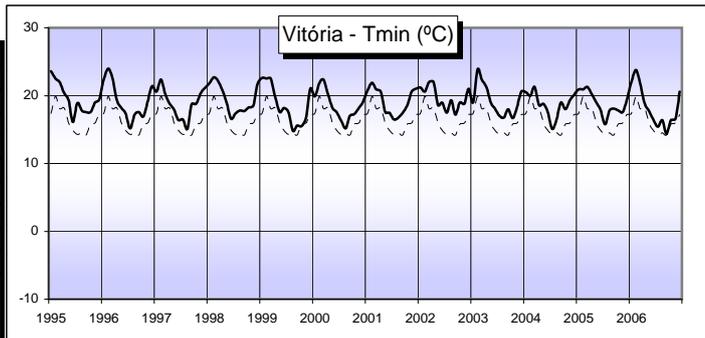
Estação Climatológica Principal de Vitória/ES
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	37.0	34.4	35.5	35.5	33.4	30.7	30.8	31.0	33.6	34.2	32.9	33.9
1996	35.0	35.0	35.0	34.3	31.0	30.6	31.5	29.7	29.3	32.9	32.9	33.4
1997	33.7	33.3	32.8	33.3	31.1	31.6	30.6	33.0	37.6	36.2	34.3	34.6
1998	35.7	36.0	37.0	36.7	35.9	32.3	30.9	31.7	32.1	33.0	35.0	33.9
1999	37.1	35.4	36.0	35.0	33.0	30.9	29.9	30.7	32.9	34.6	33.1	32.3
2000	34.1	33.7	34.0	33.3	32.7	32.1	31.6	32.3	30.0	33.2	34.7	34.1
2001	35.1	35.8	34.9	35.8	33.6	31.1	31.1	31.7	30.0	32.7	32.3	33.4
2002	34.1	34.7	34.0	33.7	32.7	30.4	30.5	33.9	33.1	32.6	33.1	36.2
2003	34.5	34.3	35.3	34.4	34.3	32.0	31.6	31.4	32.9	34.7	34.2	35.6
2004	34.5	34.1	32.6	33.4	32.5	29.9	30.7	32.1	32.3	34.1	34.3	33.3
2005	36.2	37.8	34.7	33.9	32.1	30.3	30.2	31.5	31.5	34.7	32.8	33.7
2006	36.2	39.6	35.6	33.0	34.1	30.5	32.3	31.3	31.1	32.1	34.3	35.8



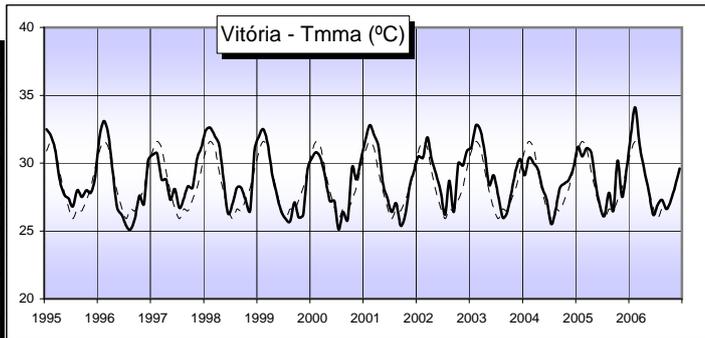
Estação Climatológica Principal de Vitória/ES
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	23.6	22.5	22.0	20.4	19.3	16.1	18.9	17.8	17.6	17.6	19.0	19.4
1996	22.4	24.0	22.6	19.3	18.2	17.4	15.2	17.2	17.6	16.9	19.2	21.4
1997	20.6	22.4	20.3	18.8	17.9	16.4	16.5	15.1	18.7	18.8	20.3	21.1
1998	21.8	22.7	22.2	20.8	18.8	16.6	17.4	17.8	17.7	18.3	18.5	21.7
1999	22.6	22.5	22.5	19.8	17.6	18.2	17.6	14.8	15.6	15.5	16.8	21.0
2000	19.9	21.8	22.4	20.2	18.2	17.6	16.3	15.2	17.0	17.3	18.2	19.1
2001	20.8	21.9	20.9	20.6	17.6	17.5	16.5	16.8	17.4	18.5	20.6	21.0
2002	21.2	20.6	22.0	22.0	18.6	19.0	17.5	19.3	17.2	19.0	18.8	21.0
2003	19.0	23.9	22.4	21.3	19.0	18.1	17.0	16.8	18.0	16.7	18.4	20.6
2004	20.5	20.0	21.3	18.6	18.8	17.6	15.1	16.6	19.0	18.0	19.3	20.1
2005	20.9	20.9	21.3	20.2	19.0	17.9	15.8	17.8	18.1	17.8	17.6	19.4
2006	22.0	23.8	21.8	18.9	17.7	16.5	15.4	16.4	14.4	16.4	16.6	20.6



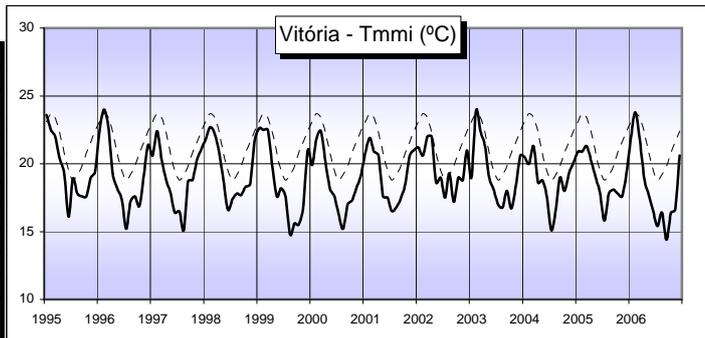
Estação Climatológica Principal de Vitória/ES
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	32.5	32.0	31.0	28.8	27.7	27.4	26.8	28.0	27.5	28.0	27.8	28.9
1996	31.9	33.1	32.0	29.4	26.7	26.2	25.4	25.1	25.9	27.6	27.0	30.2
1997	30.6	30.7	28.8	28.8	27.3	28.1	26.7	27.4	28.3	28.2	30.3	31.2
1998	32.4	32.6	32.0	31.3	28.9	26.3	27.0	28.2	28.2	27.3	26.5	31.0
1999	32.0	32.5	31.4	29.1	27.7	26.5	25.9	25.7	27.1	26.0	26.2	29.6
2000	30.4	30.8	30.3	28.9	27.2	27.2	25.1	26.4	25.8	29.7	28.8	30.2
2001	31.7	32.8	32.1	31.2	28.5	27.4	26.4	27.0	25.4	26.2	28.3	29.4
2002	30.5	30.4	31.9	30.3	29.2	27.9	26.2	28.7	26.4	30.0	29.8	30.9
2003	31.2	32.8	32.4	30.6	28.4	29.1	27.6	26.0	26.3	27.8	29.5	30.3
2004	29.1	30.4	30.0	29.5	28.2	27.3	25.5	26.6	28.2	28.5	28.8	29.7
2005	31.2	30.5	31.1	30.8	28.5	26.9	26.1	27.8	26.5	30.2	27.5	29.6
2006	32.2	34.1	31.3	29.5	27.9	26.2	26.9	27.3	26.6	27.3	28.3	29.6



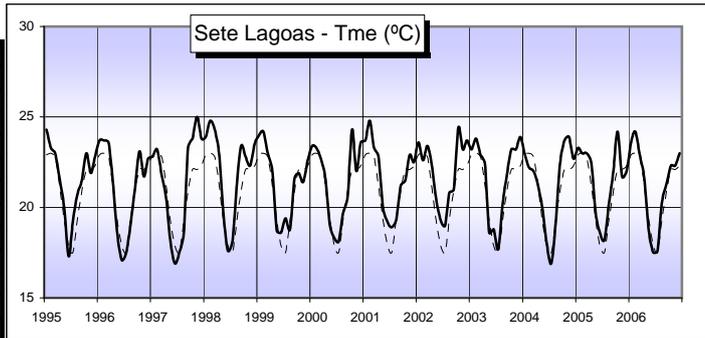
Estação Climatológica Principal de Vitória/ES
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	23.6	22.5	22.0	20.4	19.3	16.1	18.9	17.8	17.6	17.6	19.0	19.4
1996	22.4	24.0	22.6	19.3	18.2	17.4	15.2	17.2	17.6	16.9	19.2	21.4
1997	20.6	22.4	20.3	18.8	17.9	16.4	16.5	15.1	18.7	18.8	20.3	21.1
1998	21.8	22.7	22.2	20.8	18.8	16.6	17.4	17.8	17.7	18.3	18.5	21.7
1999	22.6	22.5	22.5	19.8	17.6	18.2	17.6	14.8	15.6	15.5	16.8	21.0
2000	19.9	21.8	22.4	20.2	18.2	17.6	16.3	15.2	17.0	17.3	18.2	19.1
2001	20.8	21.9	20.9	20.6	17.6	17.5	16.5	16.8	17.4	18.5	20.6	21.0
2002	21.2	20.6	22.0	22.0	18.6	19.0	17.5	19.3	17.2	19.0	18.8	21.0
2003	19.0	23.9	22.4	21.3	19.0	18.1	17.0	16.8	18.0	16.7	18.4	20.6
2004	20.5	20.0	21.3	18.6	18.8	17.6	15.1	16.6	19.0	18.0	19.3	20.1
2005	20.9	20.9	21.3	20.2	19.0	17.9	15.8	17.8	18.1	17.8	17.6	19.4
2006	22.0	23.8	21.8	18.9	17.7	16.5	15.4	16.4	14.4	16.4	16.6	20.6



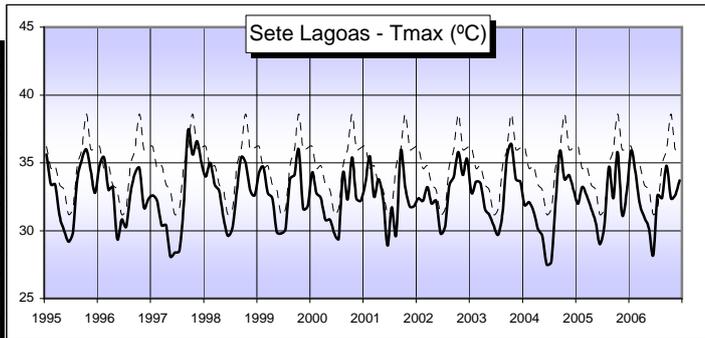
Estação Climatológica Principal de Sete Lagoas/MG
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	24.3	23.3	23.0	21.6	20.0	17.3	19.2	20.7	21.5	23.0	21.9	22.8
1996	23.7	23.7	23.6	21.5	18.6	17.1	17.5	19.0	21.0	23.1	21.7	22.7
1997	22.8	23.2	21.8	20.5	18.2	16.9	17.5	18.6	23.3	23.8	25.0	23.8
1998	23.9	24.8	24.3	22.9	19.7	17.6	18.1	21.3	23.4	22.8	22.3	23.5
1999	24.0	24.2	23.0	22.0	18.7	18.6	19.4	18.8	21.6	21.9	21.4	22.6
2000	23.4	23.3	22.7	21.6	19.0	18.3	18.1	19.7	20.6	24.3	22.0	23.6
2001	23.7	24.8	23.3	22.8	20.0	19.2	18.9	19.3	21.2	21.5	22.9	22.5
2002	23.6	22.6	23.4	22.4	20.5	19.3	19.0	20.8	21.0	24.4	23.2	23.7
2003	23.2	23.8	22.9	22.4	18.6	18.8	17.7	20.2	21.8	23.2	23.2	23.9
2004	23.0	22.2	22.0	21.2	20.0	18.0	16.9	19.2	22.4	23.7	23.9	22.7
2005	23.3	23.0	23.0	22.5	19.7	18.6	18.2	20.2	22.0	24.2	21.7	22.0
2006	23.6	24.2	22.9	21.6	18.7	17.5	17.6	20.3	21.3	22.3	22.3	23.0



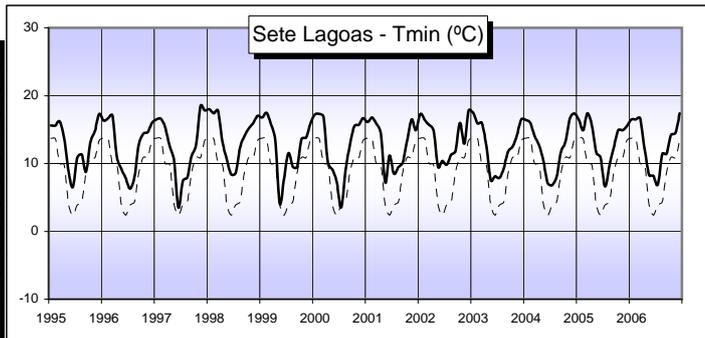
Estação Climatológica Principal de Sete Lagoas/MG
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	35.6	33.4	33.4	31.1	30.0	29.2	29.8	33.8	35.2	36.0	34.4	32.8
1996	34.8	35.4	33.0	33.2	29.4	30.8	30.3	32.7	34.2	34.6	31.7	32.3
1997	32.6	32.2	30.4	30.4	28.1	28.4	28.5	32.0	37.4	35.6	36.6	35.0
1998	34.0	35.0	33.4	32.9	31.0	29.6	30.2	33.0	35.4	35.0	33.0	32.6
1999	34.3	34.7	32.8	32.4	29.9	29.8	30.1	33.8	34.1	36.0	31.6	31.8
2000	34.3	32.8	32.4	30.8	30.8	29.8	29.4	34.3	32.3	35.4	32.4	32.2
2001	33.5	35.5	32.5	33.8	32.4	28.9	31.7	29.7	35.9	33.2	31.8	31.8
2002	32.4	32.2	33.2	32.0	32.2	29.8	30.3	33.3	34.0	35.8	34.1	35.3
2003	32.8	33.6	33.5	31.6	31.2	30.4	29.7	31.4	35.4	36.4	33.8	33.6
2004	31.9	32.1	31.4	30.1	29.6	27.5	27.7	32.3	35.9	33.8	34.1	33.0
2005	32.0	33.2	32.6	31.6	30.6	29.0	30.4	34.7	32.4	35.8	31.2	32.8
2006	35.9	34.4	32.0	31.0	30.2	28.2	32.6	32.4	34.8	32.4	32.6	33.7



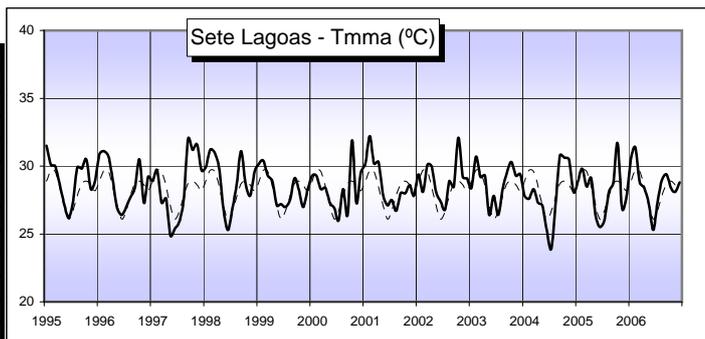
Estação Climatológica Principal de Sete Lagoas/MG
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	15.6	15.6	16.2	13.7	8.8	6.5	10.9	11.3	8.8	13.2	14.8	17.3
1996	16.3	16.7	17.1	11.0	9.2	7.9	6.3	8.1	12.8	14.4	14.6	16.0
1997	16.5	16.6	15.3	12.6	10.3	3.5	7.4	8.0	11.1	12.8	18.5	17.8
1998	18.0	17.4	17.8	13.2	10.5	8.4	8.6	12.4	14.0	15.2	16.0	17.0
1999	16.8	17.5	15.9	13.5	4.1	7.6	11.5	9.5	9.5	13.6	13.8	15.8
2000	17.2	17.3	16.9	10.1	9.1	7.3	3.5	9.1	12.7	15.5	15.7	16.7
2001	16.1	16.8	15.9	14.5	7.2	11.2	8.5	9.5	10.1	13.4	16.5	14.9
2002	17.3	16.4	15.7	14.9	9.5	10.4	9.8	11.3	11.8	16.0	12.9	17.8
2003	17.5	15.9	16.0	12.7	7.5	8.1	7.9	9.4	11.8	12.5	14.3	16.5
2004	16.4	16.0	14.1	12.7	10.3	7.1	6.8	8.1	11.7	13.2	16.7	17.4
2005	16.5	14.9	17.4	15.6	11.6	10.9	6.6	9.7	12.3	14.9	14.9	15.5
2006	16.5	16.5	16.7	12.1	8.3	8.2	6.9	11.4	11.4	14.2	14.5	17.4



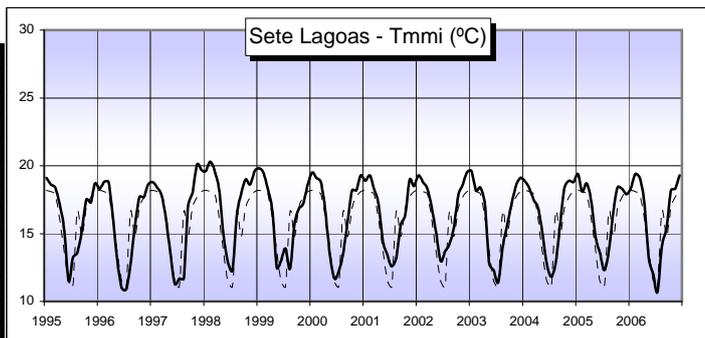
Estação Climatológica Principal de Sete Lagoas/MG
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	31.5	30.1	30.0	28.7	27.2	26.2	27.3	29.9	29.8	30.5	28.3	28.9
1996	30.9	31.1	30.7	29.0	26.9	26.4	27.0	27.7	28.4	30.5	27.3	29.2
1997	28.9	29.7	27.3	27.6	24.9	25.4	25.9	27.6	32.0	31.2	31.6	29.7
1998	29.9	31.2	31.0	29.8	26.9	25.3	26.9	28.8	31.1	28.7	27.8	29.6
1999	30.2	30.4	29.3	28.9	27.1	27.2	27.0	27.5	29.1	28.3	27.0	28.3
2000	29.3	29.3	28.3	28.4	27.3	26.9	26.0	28.3	26.4	31.9	27.3	29.5
2001	30.2	32.2	30.2	30.3	27.9	27.1	27.5	26.7	28.0	28.0	28.6	27.8
2002	29.4	28.1	30.1	30.0	28.1	27.4	26.8	28.9	28.5	32.1	29.2	29.1
2003	28.4	30.7	29.2	29.3	26.4	27.8	26.4	28.3	29.5	30.3	29.3	29.4
2004	27.8	27.6	28.3	27.3	27.1	25.3	23.9	27.4	30.8	30.6	30.5	28.1
2005	28.9	29.8	28.5	29.1	26.3	25.5	26.0	28.1	28.8	31.7	26.9	27.8
2006	30.6	31.4	28.8	28.4	27.2	25.3	27.3	29.0	29.4	28.4	28.1	28.8



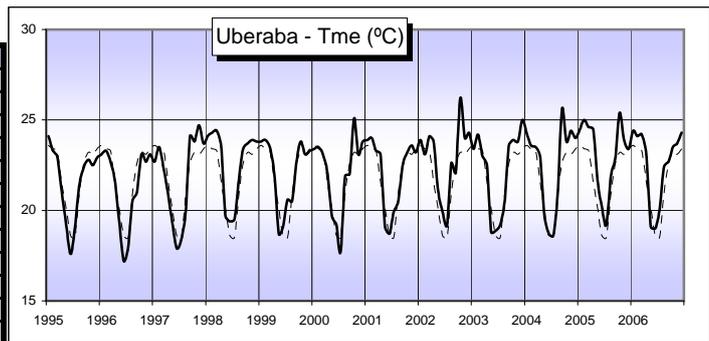
Estação Climatológica Principal de Sete Lagoas/MG
Temperatura Mínima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	19.1	18.6	18.4	17.2	15.3	11.5	13.2	13.6	15.2	17.5	17.3	18.7
1996	18.3	18.8	18.8	16.3	13.1	11.0	10.9	12.7	15.5	17.7	17.7	18.6
1997	18.8	18.4	17.8	16.0	13.6	11.3	11.7	11.7	17.0	18.0	20.1	19.7
1998	19.6	20.3	19.6	18.2	15.0	12.9	12.3	16.4	17.9	19.0	18.6	19.6
1999	19.8	19.5	18.3	16.7	12.5	13.0	13.9	12.4	15.7	16.8	17.2	18.6
2000	19.5	19.1	18.8	16.6	13.4	11.7	12.2	13.5	15.9	18.2	18.2	19.3
2001	18.9	19.3	18.3	17.2	14.4	13.4	12.6	13.2	15.6	16.4	19.0	18.5
2002	19.3	18.8	18.3	17.0	15.1	13.0	13.7	14.2	15.4	17.8	18.6	19.5
2003	19.6	18.2	18.4	17.1	12.8	12.3	11.4	14.0	15.5	17.1	18.5	19.1
2004	18.9	18.4	17.5	16.9	15.1	12.8	11.8	12.9	15.6	18.4	18.9	18.8
2005	19.4	18.1	18.7	17.4	14.7	13.6	12.3	13.8	16.6	18.4	18.3	17.9
2006	18.4	19.4	19.1	17.3	13.2	12.0	10.7	14.1	15.4	18.2	18.3	19.3



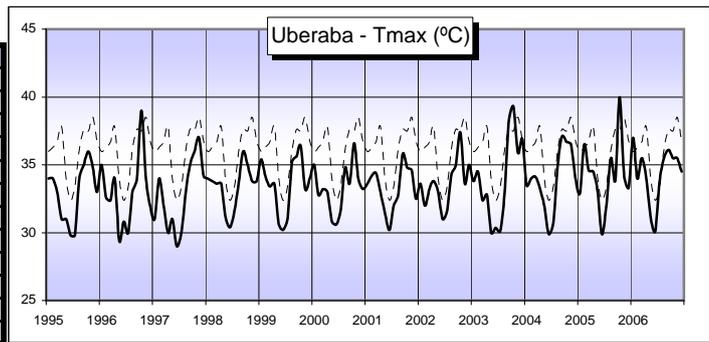
Estação Climatológica Principal de Uberaba/MG
Temperatura Média, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	24.1	23.3	23.0	21.1	19.2	17.6	19.0	21.4	22.4	22.8	22.5	22.9
1996	23.1	23.3	22.7	21.7	19.4	17.2	18.0	20.5	21.0	23.1	22.7	23.1
1997	22.7	23.5	22.3	20.9	19.3	17.9	18.4	20.0	24.1	23.8	24.7	23.7
1998	24.1	24.3	24.4	23.5	19.7	19.4	19.5	21.7	23.4	23.7	23.9	23.8
1999	23.8	23.9	23.5	22.0	18.7	19.1	20.6	20.5	22.7	23.8	23.1	23.3
2000	23.4	23.5	23.1	22.1	19.7	19.2	17.7	21.9	22.0	25.1	23.1	23.8
2001	23.9	24.0	23.3	23.1	19.1	18.7	19.9	20.5	22.5	23.2	23.6	23.2
2002	23.9	23.1	24.1	23.8	21.1	19.9	19.2	22.6	22.1	26.2	24.0	24.3
2003	23.4	24.2	23.0	22.5	18.8	18.9	19.2	20.5	23.6	23.9	23.8	25.0
2004	24.3	23.6	23.5	23.0	18.7	18.6	21.0	25.6	23.8	24.4	24.0	
2005	24.5	25.0	24.6	24.5	21.6	20.2	19.2	21.9	22.9	25.4	23.9	23.4
2006	24.4	24.1	24.2	23.1	19.1	19.0	20.0	22.4	22.7	23.5	23.7	24.3



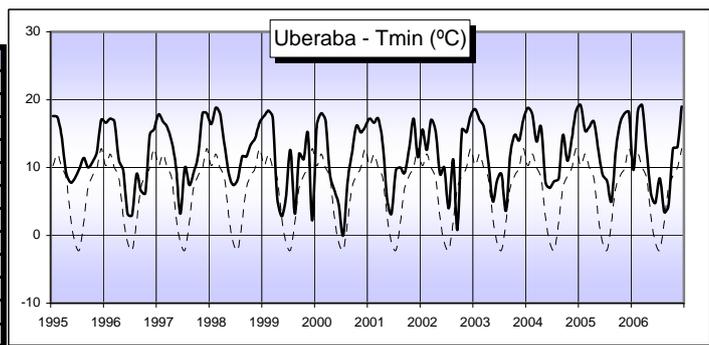
Estação Climatológica Principal de Uberaba/MG
Temperatura Máxima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	34.0	34.0	33.0	31.0	31.0	29.8	29.8	34.0	35.0	36.0	34.8	33.0
1996	35.0	32.6	32.4	34.0	29.4	30.8	30.0	33.0	34.0	39.0	34.0	32.0
1997	31.0	34.0	32.0	30.0	31.0	29.0	30.0	33.0	35.0	36.0	37.0	34.2
1998	34.0	33.8	33.6	33.6	31.2	30.4	31.6	33.8	36.0	35.0	33.8	33.8
1999	35.4	34.2	33.4	33.6	30.6	30.2	31.0	35.2	35.6	36.4	33.2	34.0
2000	35.0	32.8	33.2	33.0	30.8	30.6	31.6	34.8	33.6	36.6	34.0	33.2
2001	33.6	34.2	34.4	33.0	31.4	30.2	32.0	32.8	35.8	34.8	34.6	32.5
2002	33.6	32.0	33.2	33.8	33.0	31.0	31.6	34.2	35.0	37.4	33.6	35.0
2003	33.8	34.5	32.4	32.8	30.0	30.4	30.1	33.0	38.3	39.3	35.9	36.9
2004	33.5	34.0	34.1	33.2	32.0	29.9	30.7	35.0	37.1	36.7	36.5	34.0
2005	32.9	36.5	34.6	34.5	33.0	29.9	32.0	35.5	33.9	40.0	34.2	33.3
2006	37.0	34.0	35.5	34.0	31.1	30.1	33.7	35.5	36.1	35.5	35.5	34.5



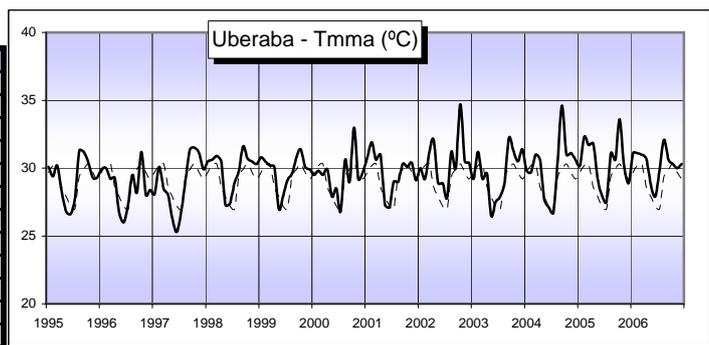
Estação Climatológica Principal de Uberaba/MG
Temperatura Mínima Absoluta, Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	17.6	17.4	14.6	9.2	7.8	8.4	9.8	11.4	10.0	10.8	12.4	17.0
1996	16.6	17.2	16.8	11.2	9.4	3.2	3.0	9.0	6.6	6.2	14.8	15.6
1997	17.8	16.8	16.0	13.8	9.8	3.2	10.0	7.4	9.2	11.8	18.0	18.0
1998	16.4	18.8	18.0	13.4	9.0	7.4	8.2	11.6	11.6	13.4	14.4	16.6
1999	17.6	18.4	17.4	5.6	2.8	5.6	12.6	3.2	12.0	11.2	15.0	2.2
2000	16.2	18.0	17.0	9.0	6.6	4.6	0.0	8.0	12.0	16.1	15.2	16.0
2001	17.2	16.6	17.2	13.4	5.2	3.2	9.6	10.0	9.2	12.8	17.2	11.5
2002	15.6	12.6	17.0	15.4	9.0	10.0	4.0	11.2	0.8	15.6	15.2	17.6
2003	18.6	17.0	16.0	10.9	5.0	8.0	9.0	3.6	11.8	14.8	14.0	17.0
2004	18.8	17.8	13.8	16.0	7.8	7.0	8.0	8.4	14.8	11.0	14.4	18.4
2005	19.2	15.4	16.0	16.8	12.6	9.0	8.0	5.0	12.4	16.6	18.0	18.2
2006	9.6	18.4	19.2	12.6	6.0	4.8	8.4	3.4	4.4	12.8	13.0	19.0



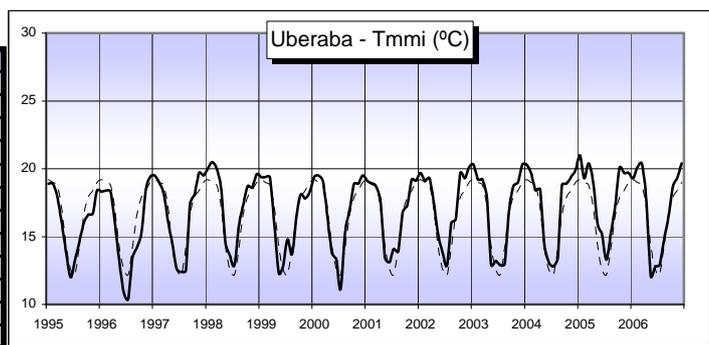
Estação Climatológica Principal de Uberaba/MG
Temperatura Máxima, Média Mensal (°C)

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	30.1	29.4	30.2	28.3	26.8	26.6	27.7	31.3	31.2	30.4	29.3	29.3
1996	29.9	30.0	29.2	29.3	26.7	26.0	27.4	29.5	28.2	31.2	28.0	28.4
1997	28.1	30.1	28.5	28.0	26.3	25.3	26.9	29.3	31.4	31.5	31.1	29.9
1998	30.5	30.6	30.9	30.5	27.3	27.4	28.9	29.8	31.6	30.7	30.5	30.3
1999	30.8	30.5	30.2	30.1	27.0	27.9	29.1	29.6	30.8	31.4	30.1	29.9
2000	29.5	29.8	29.5	29.9	27.9	28.5	26.8	30.6	29.0	33.0	29.2	29.7
2001	30.8	31.9	30.6	31.0	27.3	27.1	29.0	29.0	30.3	30.1	30.4	29.1
2002	30.0	29.2	31.2	32.1	28.9	28.9	27.8	31.2	30.0	34.7	30.5	30.4
2003	29.2	31.2	29.2	29.6	26.5	27.5	27.9	29.0	32.2	31.3	30.5	31.4
2004	29.8	29.7	31.0	30.6	27.7	27.1	26.7	30.6	34.6	31.0	31.1	30.6
2005	30.2	32.3	31.7	31.8	29.2	28.0	27.5	31.1	30.6	33.6	30.2	28.9
2006	31.1	31.1	31.0	30.7	28.8	27.9	29.8	32.1	30.6	30.3	30.0	30.3



Estação Climatológica Principal de Uberaba/MG
Temperatura Mínima, Média Mensal (°C)

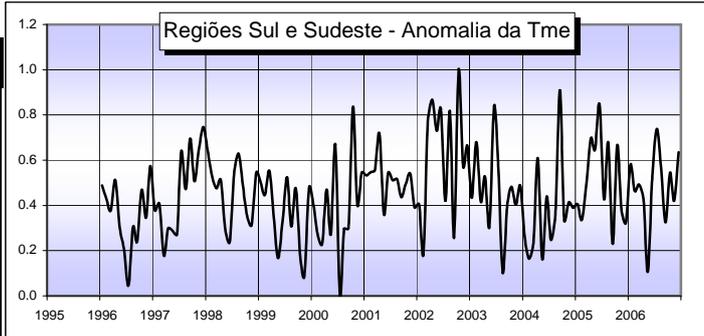
	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995	18.9	18.9	18.0	16.1	13.8	12.0	13.2	14.6	16.0	16.6	16.7	18.4
1996	18.3	18.4	18.3	16.1	13.3	10.9	10.4	13.4	14.2	15.3	18.5	19.4
1997	19.5	19.0	18.2	16.1	14.5	12.6	12.4	12.5	17.4	18.1	19.7	19.5
1998	20.0	20.5	20.0	18.5	14.6	13.6	12.9	15.8	17.3	18.7	18.6	19.6
1999	19.4	19.4	19.4	15.9	12.3	12.8	14.8	13.7	16.5	18.1	17.8	18.3
2000	19.4	19.5	19.1	16.5	13.8	13.3	11.1	15.3	17.0	18.9	18.9	19.5
2001	19.1	18.9	18.7	17.6	13.4	13.1	14.1	13.9	16.8	17.3	19.2	19.1
2002	19.7	19.1	19.3	17.6	15.2	13.8	12.9	16.0	16.3	19.7	19.3	20.1
2003	20.3	19.2	19.2	17.8	12.9	13.2	12.9	13.0	16.8	18.7	19.0	20.3
2004	20.3	19.7	18.4	18.5	14.5	13.1	12.8	13.4	18.8	18.9	19.4	19.9
2005	21.0	19.3	20.4	19.0	15.9	15.2	13.3	15.3	17.4	20.1	19.7	19.7
2006	19.3	20.1	20.4	17.7	12.1	12.8	12.9	14.7	16.5	18.7	19.3	20.4



Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste

Temperatura Média (valores normalizados de -1,4°C a 2,9°C).

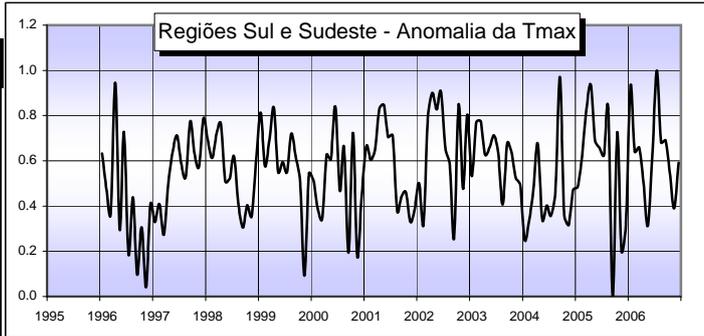
	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.49	0.43	0.38	0.51	0.30	0.21	0.04	0.30	0.24	0.47	0.35	0.57
1997	0.38	0.41	0.18	0.30	0.29	0.27	0.64	0.47	0.70	0.51	0.65	0.75
1998	0.64	0.53	0.48	0.51	0.29	0.24	0.53	0.63	0.49	0.35	0.32	0.54
1999	0.50	0.45	0.55	0.34	0.17	0.33	0.52	0.31	0.48	0.17	0.09	0.48
2000	0.40	0.27	0.23	0.47	0.27	0.67	0.00	0.30	0.30	0.84	0.41	0.54
2001	0.53	0.55	0.56	0.72	0.36	0.54	0.51	0.52	0.44	0.50	0.54	0.39
2002	0.40	0.19	0.77	0.87	0.73	0.82	0.42	0.82	0.26	1.00	0.57	0.66
2003	0.43	0.68	0.42	0.53	0.31	0.84	0.59	0.10	0.40	0.48	0.40	0.49
2004	0.27	0.16	0.24	0.61	0.16	0.44	0.25	0.36	0.91	0.34	0.41	0.39
2005	0.40	0.34	0.49	0.70	0.65	0.85	0.43	0.68	0.23	0.67	0.38	0.32
2006	0.58	0.46	0.49	0.43	0.11	0.53	0.74	0.57	0.33	0.55	0.42	0.64



Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste

Temperatura Máxima Absoluta (valores normalizados de -4,8°C a 0°C).

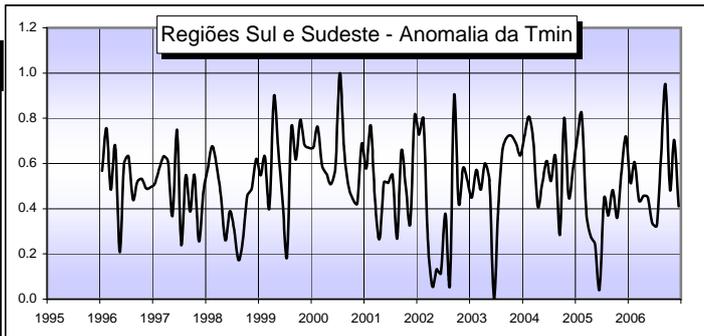
	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.63	0.47	0.37	0.95	0.29	0.73	0.19	0.44	0.10	0.31	0.04	0.41
1997	0.33	0.41	0.27	0.49	0.64	0.71	0.59	0.53	0.78	0.63	0.57	0.79
1998	0.70	0.61	0.72	0.77	0.51	0.52	0.62	0.40	0.30	0.40	0.36	0.61
1999	0.81	0.58	0.69	0.84	0.55	0.59	0.55	0.72	0.62	0.50	0.09	0.54
2000	0.51	0.39	0.34	0.63	0.61	0.84	0.47	0.66	0.19	0.72	0.18	0.44
2001	0.66	0.60	0.65	0.83	0.85	0.71	0.71	0.38	0.44	0.46	0.33	0.38
2002	0.50	0.32	0.78	0.90	0.83	0.91	0.66	0.58	0.26	0.85	0.48	0.81
2003	0.53	0.77	0.78	0.63	0.66	0.71	0.64	0.41	0.68	0.64	0.52	0.49
2004	0.25	0.33	0.48	0.68	0.34	0.40	0.36	0.46	0.97	0.36	0.31	0.47
2005	0.48	0.61	0.82	0.94	0.69	0.66	0.63	0.83	0.00	0.73	0.20	0.32
2006	0.93	0.64	0.66	0.50	0.31	0.62	1.00	0.68	0.69	0.54	0.39	0.59



Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste

Temperatura Mínima Absoluta (valores normalizados de 1°C a 9°C).

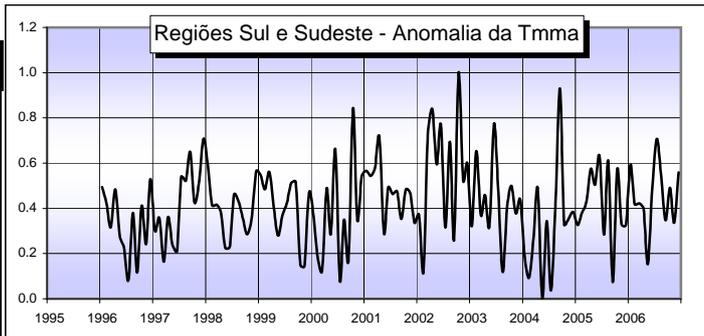
	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.57	0.76	0.48	0.68	0.21	0.60	0.63	0.44	0.52	0.53	0.49	0.49
1997	0.51	0.58	0.63	0.61	0.37	0.75	0.24	0.55	0.39	0.55	0.25	0.48
1998	0.57	0.68	0.59	0.46	0.26	0.39	0.31	0.17	0.27	0.45	0.49	0.62
1999	0.55	0.63	0.40	0.89	0.68	0.43	0.19	0.76	0.62	0.79	0.68	0.67
2000	0.67	0.76	0.59	0.55	0.51	0.58	1.00	0.67	0.50	0.44	0.42	0.69
2001	0.58	0.77	0.44	0.27	0.52	0.51	0.55	0.27	0.65	0.49	0.34	0.81
2002	0.73	0.80	0.27	0.06	0.13	0.11	0.38	0.07	0.90	0.43	0.58	0.53
2003	0.45	0.57	0.48	0.60	0.53	0.00	0.40	0.67	0.72	0.72	0.69	0.64
2004	0.72	0.81	0.69	0.41	0.51	0.61	0.52	0.63	0.28	0.80	0.45	0.58
2005	0.72	0.82	0.38	0.28	0.24	0.04	0.45	0.37	0.48	0.36	0.56	0.72
2006	0.51	0.61	0.43	0.46	0.45	0.34	0.32	0.62	0.95	0.48	0.71	0.41



Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste

Temperatura Máxima, Média Mensal (valores norm. de -1,6°C a 3,5°C).

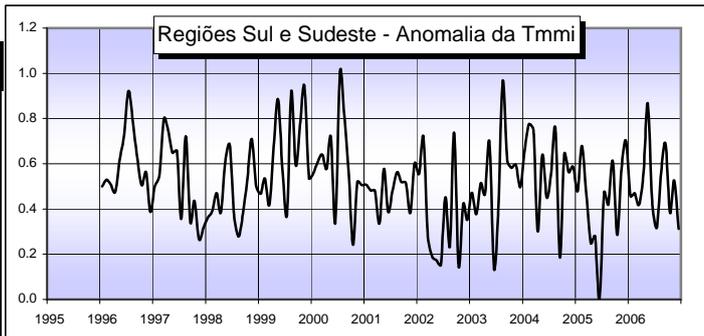
	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.49	0.42	0.32	0.48	0.28	0.23	0.08	0.38	0.12	0.41	0.24	0.53
1997	0.30	0.36	0.16	0.36	0.24	0.21	0.54	0.52	0.65	0.43	0.51	0.71
1998	0.60	0.41	0.42	0.38	0.22	0.23	0.46	0.43	0.35	0.29	0.36	0.57
1999	0.55	0.48	0.56	0.40	0.28	0.37	0.43	0.51	0.52	0.15	0.14	0.47
2000	0.37	0.18	0.12	0.49	0.29	0.66	0.08	0.35	0.17	0.84	0.35	0.54
2001	0.57	0.54	0.58	0.71	0.29	0.49	0.46	0.47	0.35	0.48	0.47	0.34
2002	0.37	0.12	0.72	0.84	0.59	0.77	0.31	0.69	0.26	1.00	0.52	0.60
2003	0.32	0.65	0.37	0.46	0.32	0.77	0.49	0.12	0.41	0.50	0.38	0.44
2004	0.19	0.09	0.27	0.49	0.00	0.34	0.04	0.41	0.93	0.33	0.35	0.38
2005	0.33	0.38	0.43	0.57	0.50	0.63	0.29	0.61	0.07	0.57	0.33	0.33
2006	0.59	0.42	0.42	0.40	0.15	0.49	0.71	0.55	0.35	0.49	0.34	0.56



Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste

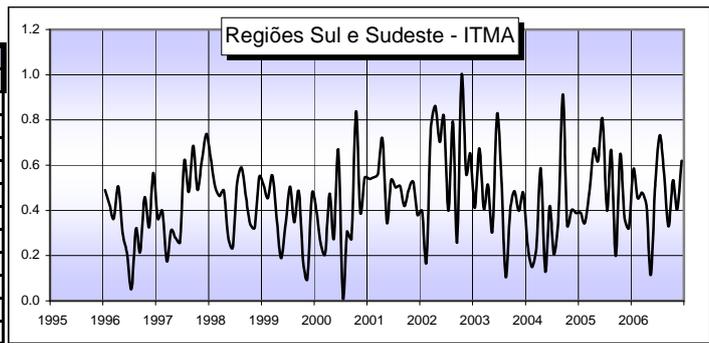
Temperatura Mínima, Média Mensal (valores norm. de -1,6°C a 2,9°C).

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.50	0.53	0.51	0.48	0.62	0.72	0.92	0.78	0.63	0.51	0.56	0.39
1997	0.50	0.55	0.80	0.75	0.65	0.66	0.36	0.72	0.34	0.44	0.27	0.32
1998	0.36	0.39	0.47	0.38	0.61	0.68	0.38	0.28	0.38	0.53	0.71	0.50
1999	0.47	0.54	0.42	0.69	0.89	0.57	0.38	0.92	0.59	0.78	0.94	0.54
2000	0.56	0.61	0.64	0.58	0.72	0.34	1.00	0.83	0.57	0.24	0.52	0.50
2001	0.51	0.48	0.48	0.34	0.58	0.39	0.48	0.56	0.52	0.52	0.38	0.60
2002	0.55	0.72	0.28	0.19	0.17	0.15	0.45	0.24	0.74	0.15	0.42	0.35
2003	0.47	0.38	0.51	0.47	0.70	0.14	0.37	0.97	0.62	0.58	0.59	0.50
2004	0.65	0.78	0.75	0.30	0.64	0.45	0.55	0.75	0.18	0.64	0.56	0.59
2005	0.48	0.68	0.47	0.25	0.28	0.00	0.47	0.42	0.61	0.29	0.57	0.70
2006	0.46	0.47	0.42	0.56	0.87	0.42	0.32	0.55	0.69	0.38	0.53	0.31



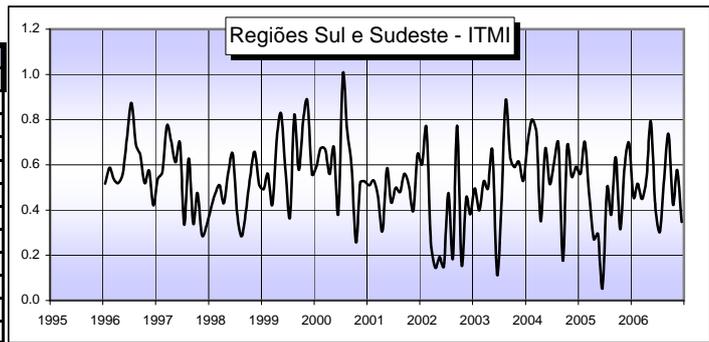
Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
ITMA - Intensidade Térmica das Temperaturas Máximas.

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.49	0.43	0.36	0.51	0.30	0.21	0.05	0.32	0.22	0.46	0.33	0.57
1997	0.36	0.40	0.17	0.31	0.28	0.26	0.62	0.48	0.69	0.49	0.62	0.74
1998	0.63	0.51	0.46	0.49	0.28	0.24	0.52	0.59	0.46	0.34	0.32	0.55
1999	0.51	0.45	0.56	0.35	0.19	0.34	0.51	0.35	0.48	0.17	0.10	0.47
2000	0.40	0.26	0.21	0.47	0.27	0.67	0.02	0.31	0.27	0.84	0.39	0.54
2001	0.54	0.55	0.56	0.72	0.35	0.53	0.50	0.51	0.42	0.49	0.53	0.38
2002	0.40	0.17	0.76	0.86	0.70	0.81	0.40	0.79	0.26	1.00	0.56	0.65
2003	0.41	0.68	0.41	0.51	0.31	0.82	0.57	0.11	0.40	0.49	0.40	0.48
2004	0.25	0.15	0.24	0.59	0.13	0.42	0.20	0.37	0.91	0.34	0.40	0.39
2005	0.39	0.34	0.48	0.67	0.62	0.80	0.40	0.66	0.20	0.65	0.37	0.32
2006	0.58	0.45	0.48	0.42	0.11	0.52	0.73	0.57	0.33	0.53	0.40	0.62



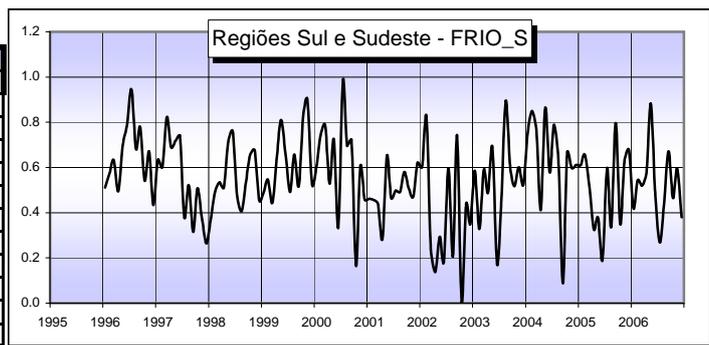
Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
ITMI - Intensidade Térmica das Temperaturas Mínimas.

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.52	0.59	0.54	0.52	0.56	0.72	0.87	0.69	0.65	0.52	0.57	0.42
1997	0.54	0.57	0.77	0.71	0.61	0.70	0.33	0.63	0.34	0.48	0.29	0.33
1998	0.40	0.47	0.51	0.43	0.57	0.65	0.39	0.28	0.40	0.55	0.66	0.51
1999	0.49	0.56	0.42	0.72	0.83	0.57	0.37	0.82	0.58	0.80	0.88	0.56
2000	0.59	0.67	0.67	0.56	0.68	0.38	1.00	0.76	0.59	0.26	0.52	0.53
2001	0.51	0.53	0.46	0.31	0.58	0.43	0.50	0.48	0.56	0.51	0.40	0.65
2002	0.60	0.76	0.27	0.15	0.19	0.15	0.48	0.19	0.77	0.16	0.45	0.38
2003	0.50	0.40	0.53	0.49	0.66	0.12	0.39	0.88	0.63	0.59	0.61	0.53
2004	0.69	0.80	0.74	0.35	0.67	0.52	0.61	0.69	0.18	0.68	0.55	0.59
2005	0.56	0.70	0.46	0.27	0.29	0.05	0.50	0.38	0.63	0.31	0.58	0.70
2006	0.46	0.52	0.45	0.55	0.79	0.42	0.30	0.53	0.74	0.43	0.58	0.35



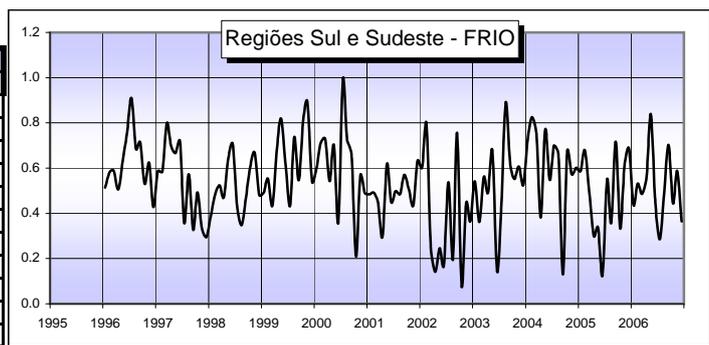
Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
FRIO_S - Severidade Climática Sazonal do Frio.

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.51	0.58	0.63	0.49	0.70	0.78	0.95	0.68	0.78	0.54	0.67	0.43
1997	0.63	0.60	0.82	0.69	0.72	0.74	0.38	0.52	0.31	0.51	0.38	0.26
1998	0.37	0.49	0.54	0.51	0.71	0.76	0.48	0.41	0.54	0.66	0.68	0.45
1999	0.49	0.55	0.44	0.65	0.81	0.66	0.49	0.66	0.52	0.83	0.90	0.53
2000	0.60	0.74	0.79	0.53	0.72	0.33	0.98	0.70	0.72	0.16	0.60	0.46
2001	0.46	0.46	0.44	0.28	0.65	0.47	0.50	0.49	0.58	0.51	0.47	0.62
2002	0.60	0.82	0.24	0.14	0.29	0.19	0.60	0.21	0.74	0.01	0.44	0.35
2003	0.59	0.33	0.59	0.49	0.69	0.17	0.43	0.89	0.60	0.52	0.60	0.52
2004	0.75	0.85	0.76	0.41	0.86	0.58	0.79	0.63	0.09	0.67	0.60	0.61
2005	0.61	0.66	0.52	0.33	0.38	0.19	0.60	0.34	0.80	0.35	0.63	0.68
2006	0.42	0.54	0.52	0.58	0.88	0.48	0.27	0.44	0.67	0.46	0.60	0.38



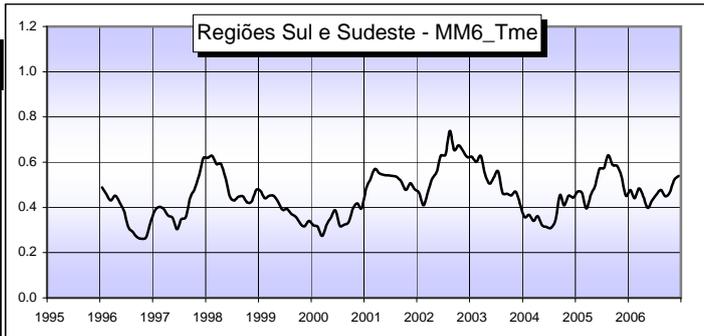
Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
FRIO - Severidade Climática do Frio.

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.51	0.58	0.59	0.51	0.63	0.75	0.91	0.69	0.72	0.53	0.62	0.43
1997	0.59	0.58	0.80	0.70	0.67	0.72	0.36	0.57	0.33	0.49	0.33	0.30
1998	0.38	0.48	0.52	0.47	0.64	0.70	0.44	0.35	0.47	0.60	0.67	0.48
1999	0.49	0.55	0.43	0.68	0.82	0.62	0.43	0.74	0.55	0.81	0.89	0.54
2000	0.60	0.71	0.73	0.54	0.70	0.36	0.99	0.73	0.66	0.21	0.56	0.49
2001	0.48	0.49	0.45	0.29	0.62	0.45	0.50	0.49	0.57	0.51	0.44	0.63
2002	0.60	0.79	0.25	0.14	0.25	0.17	0.54	0.20	0.76	0.08	0.44	0.36
2003	0.54	0.36	0.56	0.49	0.68	0.15	0.41	0.89	0.62	0.55	0.61	0.53
2004	0.72	0.83	0.75	0.38	0.77	0.55	0.70	0.66	0.13	0.67	0.57	0.60
2005	0.59	0.68	0.49	0.30	0.34	0.13	0.55	0.36	0.72	0.33	0.61	0.69
2006	0.44	0.53	0.49	0.56	0.84	0.45	0.28	0.48	0.70	0.45	0.59	0.36



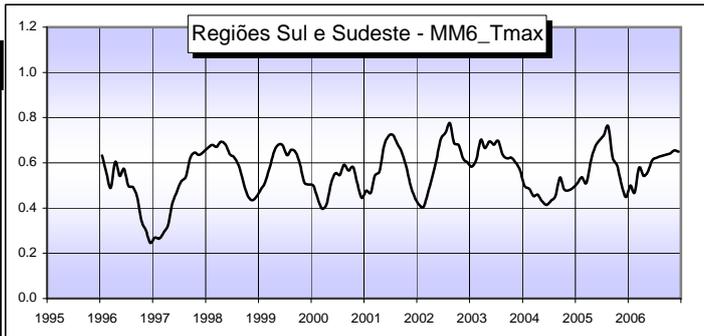
Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
Temperatura Média (média móvel de 6 meses).

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.49	0.46	0.43	0.45	0.42	0.39	0.31	0.29	0.27	0.26	0.27	0.33
1997	0.39	0.40	0.39	0.36	0.35	0.30	0.35	0.36	0.44	0.48	0.54	0.62
1998	0.62	0.63	0.59	0.59	0.53	0.45	0.43	0.45	0.45	0.42	0.43	0.48
1999	0.47	0.44	0.45	0.45	0.43	0.39	0.39	0.37	0.36	0.33	0.32	0.34
2000	0.32	0.31	0.27	0.32	0.35	0.39	0.32	0.32	0.33	0.40	0.42	0.40
2001	0.49	0.53	0.57	0.55	0.54	0.54	0.54	0.53	0.51	0.48	0.51	0.48
2002	0.46	0.41	0.46	0.53	0.56	0.63	0.63	0.74	0.65	0.68	0.65	0.62
2003	0.62	0.60	0.63	0.55	0.50	0.53	0.56	0.46	0.46	0.45	0.47	0.41
2004	0.36	0.37	0.34	0.36	0.32	0.31	0.31	0.34	0.46	0.41	0.45	0.44
2005	0.47	0.47	0.40	0.46	0.49	0.57	0.57	0.63	0.59	0.58	0.54	0.45
2006	0.48	0.44	0.48	0.44	0.40	0.43	0.46	0.48	0.45	0.47	0.52	0.54



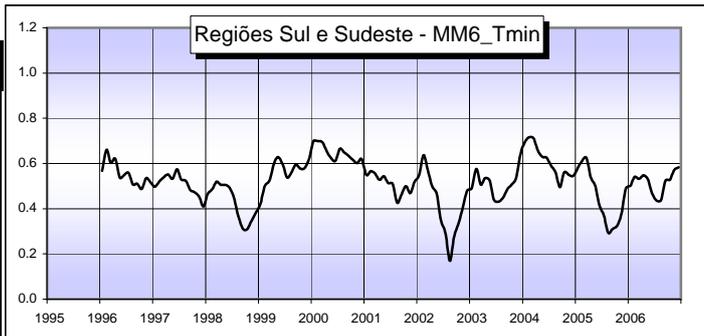
Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
Temperatura Máxima Absoluta (média móvel de 6 meses).

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.63	0.55	0.49	0.60	0.54	0.57	0.50	0.49	0.45	0.34	0.30	0.25
1997	0.27	0.26	0.29	0.32	0.42	0.47	0.52	0.54	0.62	0.65	0.64	0.65
1998	0.67	0.68	0.67	0.69	0.68	0.64	0.63	0.59	0.52	0.46	0.44	0.45
1999	0.48	0.51	0.58	0.65	0.68	0.68	0.63	0.66	0.65	0.59	0.51	0.50
2000	0.50	0.44	0.40	0.42	0.50	0.55	0.55	0.59	0.57	0.58	0.51	0.44
2001	0.48	0.47	0.54	0.56	0.67	0.72	0.72	0.69	0.65	0.59	0.50	0.45
2002	0.42	0.41	0.46	0.54	0.62	0.71	0.73	0.78	0.69	0.68	0.62	0.60
2003	0.58	0.61	0.70	0.66	0.70	0.68	0.70	0.64	0.62	0.62	0.60	0.56
2004	0.50	0.49	0.45	0.46	0.43	0.41	0.43	0.45	0.54	0.48	0.48	0.49
2005	0.51	0.54	0.51	0.61	0.67	0.70	0.72	0.76	0.62	0.59	0.51	0.45
2006	0.50	0.47	0.58	0.54	0.56	0.61	0.62	0.63	0.63	0.64	0.65	0.65



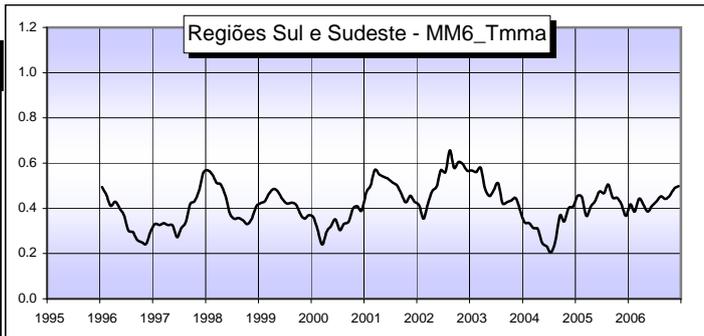
Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
Temperatura Mínima Absoluta (média móvel de 6 meses).

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.57	0.66	0.60	0.62	0.54	0.55	0.56	0.51	0.51	0.49	0.53	0.52
1997	0.50	0.52	0.54	0.55	0.53	0.57	0.53	0.52	0.48	0.47	0.45	0.41
1998	0.46	0.49	0.52	0.51	0.51	0.49	0.45	0.36	0.31	0.31	0.35	0.39
1999	0.43	0.50	0.52	0.60	0.63	0.60	0.54	0.56	0.59	0.58	0.58	0.62
2000	0.70	0.70	0.69	0.66	0.63	0.61	0.67	0.65	0.63	0.62	0.60	0.62
2001	0.55	0.57	0.56	0.53	0.54	0.51	0.51	0.43	0.46	0.50	0.47	0.52
2002	0.55	0.64	0.57	0.50	0.47	0.35	0.29	0.17	0.27	0.34	0.41	0.48
2003	0.49	0.58	0.51	0.54	0.53	0.44	0.43	0.45	0.48	0.50	0.53	0.64
2004	0.69	0.72	0.71	0.66	0.63	0.63	0.59	0.56	0.50	0.56	0.55	0.55
2005	0.58	0.61	0.63	0.54	0.50	0.41	0.37	0.29	0.31	0.32	0.38	0.49
2006	0.50	0.54	0.53	0.55	0.53	0.47	0.43	0.44	0.52	0.53	0.57	0.58



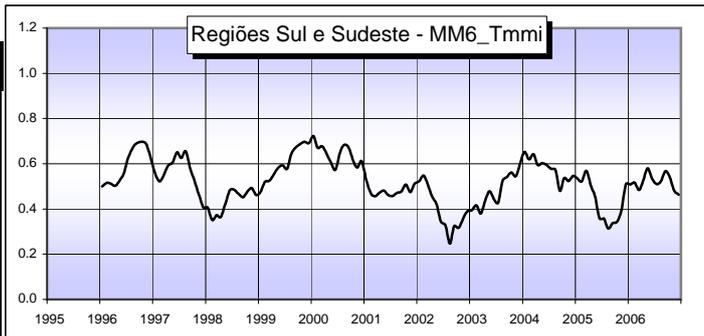
Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
Temperatura Máxima, Média Mensal (média móvel de 6 meses).

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.49	0.46	0.41	0.43	0.40	0.37	0.30	0.29	0.26	0.25	0.24	0.29
1997	0.33	0.33	0.33	0.33	0.33	0.27	0.31	0.34	0.42	0.43	0.48	0.56
1998	0.57	0.55	0.51	0.51	0.46	0.38	0.35	0.36	0.35	0.33	0.35	0.41
1999	0.42	0.43	0.47	0.49	0.47	0.44	0.42	0.43	0.42	0.38	0.35	0.37
2000	0.36	0.31	0.24	0.30	0.32	0.35	0.30	0.33	0.34	0.40	0.41	0.39
2001	0.47	0.50	0.57	0.55	0.54	0.53	0.51	0.50	0.46	0.43	0.46	0.43
2002	0.41	0.35	0.42	0.48	0.50	0.57	0.56	0.66	0.58	0.61	0.59	0.57
2003	0.57	0.56	0.58	0.49	0.45	0.48	0.51	0.42	0.43	0.44	0.44	0.39
2004	0.34	0.33	0.31	0.31	0.25	0.23	0.21	0.26	0.37	0.34	0.40	0.41
2005	0.46	0.45	0.37	0.41	0.43	0.47	0.47	0.51	0.45	0.45	0.42	0.37
2006	0.42	0.39	0.44	0.41	0.38	0.41	0.43	0.45	0.44	0.46	0.49	0.50



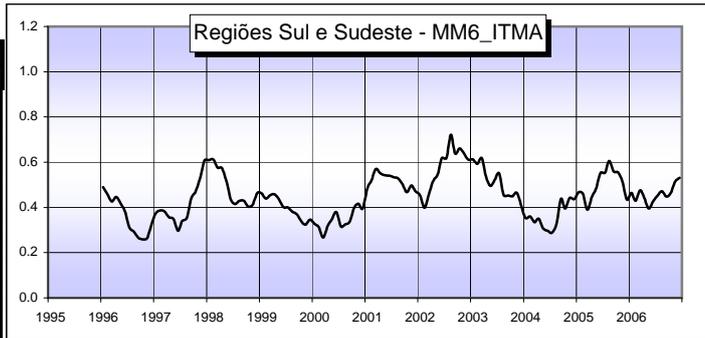
Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
Temperatura Mínima, Média Mensal (média móvel de 6 meses).

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
1995												
1996	0.50	0.51	0.51	0.50	0.53	0.56	0.63	0.67	0.69	0.70	0.69	0.63
1997	0.56	0.52	0.55	0.59	0.61	0.65	0.63	0.65	0.58	0.53	0.46	0.41
1998	0.41	0.35	0.37	0.36	0.42	0.48	0.49	0.47	0.45	0.48	0.49	0.46
1999	0.48	0.52	0.53	0.55	0.58	0.59	0.58	0.64	0.67	0.69	0.70	0.69
2000	0.72	0.67	0.68	0.64	0.61	0.57	0.65	0.68	0.67	0.62	0.58	0.61
2001	0.53	0.47	0.46	0.47	0.48	0.46	0.46	0.47	0.48	0.51	0.47	0.51
2002	0.52	0.55	0.51	0.45	0.42	0.34	0.33	0.25	0.32	0.32	0.36	0.39
2003	0.39	0.42	0.38	0.43	0.48	0.44	0.43	0.53	0.54	0.56	0.54	0.60
2004	0.65	0.62	0.64	0.59	0.60	0.59	0.58	0.57	0.48	0.54	0.52	0.55
2005	0.53	0.52	0.57	0.50	0.46	0.36	0.36	0.31	0.34	0.34	0.39	0.51
2006	0.51	0.52	0.48	0.53	0.58	0.53	0.51	0.52	0.57	0.54	0.48	0.46



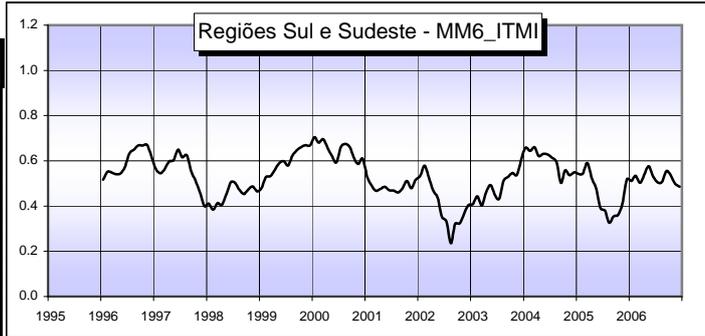
Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
Média móvel de 6 meses do indicador climático ITMA

	jan	fev	mar	abr	maí	jun	jul	ago	set	out	nov	dez
1995												
1996	0.49	0.46	0.43	0.45	0.42	0.38	0.31	0.29	0.27	0.26	0.26	0.32
1997	0.37	0.39	0.38	0.36	0.35	0.30	0.34	0.35	0.44	0.47	0.53	0.61
1998	0.61	0.61	0.58	0.58	0.52	0.43	0.42	0.43	0.43	0.40	0.41	0.46
1999	0.46	0.44	0.45	0.46	0.44	0.40	0.40	0.38	0.37	0.34	0.32	0.35
2000	0.33	0.31	0.27	0.32	0.35	0.38	0.32	0.32	0.34	0.40	0.42	0.40
2001	0.48	0.52	0.57	0.55	0.54	0.54	0.53	0.53	0.50	0.47	0.50	0.47
2002	0.45	0.40	0.45	0.52	0.55	0.62	0.62	0.72	0.64	0.66	0.64	0.61
2003	0.61	0.59	0.62	0.54	0.49	0.52	0.55	0.46	0.45	0.45	0.46	0.41
2004	0.35	0.36	0.33	0.35	0.31	0.30	0.29	0.33	0.44	0.40	0.44	0.44
2005	0.47	0.46	0.39	0.45	0.48	0.55	0.55	0.61	0.56	0.56	0.51	0.43
2006	0.46	0.43	0.48	0.44	0.40	0.43	0.45	0.47	0.45	0.47	0.51	0.53



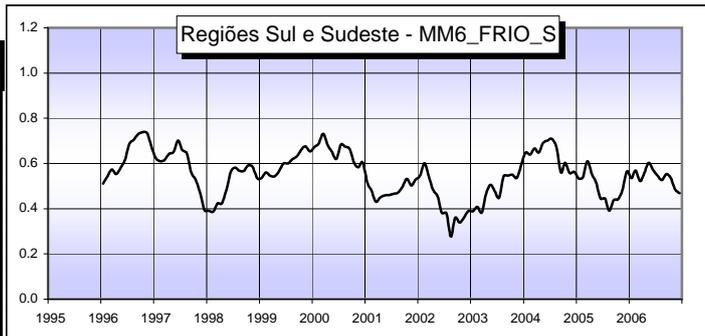
Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
Média móvel de 6 meses do indicador climático ITMI

	jan	fev	mar	abr	maí	jun	jul	ago	set	out	nov	dez
1995												
1996	0.52	0.55	0.55	0.54	0.54	0.57	0.63	0.65	0.67	0.67	0.67	0.62
1997	0.56	0.54	0.57	0.60	0.60	0.65	0.61	0.62	0.55	0.51	0.46	0.40
1998	0.41	0.38	0.41	0.41	0.45	0.50	0.50	0.47	0.45	0.47	0.49	0.47
1999	0.48	0.53	0.53	0.56	0.59	0.60	0.58	0.62	0.65	0.66	0.67	0.67
2000	0.70	0.68	0.70	0.66	0.62	0.59	0.66	0.67	0.66	0.61	0.59	0.61
2001	0.53	0.49	0.47	0.48	0.49	0.47	0.47	0.46	0.48	0.51	0.48	0.51
2002	0.53	0.58	0.53	0.47	0.44	0.35	0.33	0.24	0.32	0.32	0.37	0.40
2003	0.41	0.44	0.40	0.46	0.49	0.45	0.43	0.51	0.53	0.55	0.54	0.61
2004	0.66	0.64	0.66	0.62	0.63	0.63	0.61	0.60	0.50	0.56	0.54	0.55
2005	0.54	0.54	0.59	0.52	0.48	0.39	0.38	0.33	0.35	0.36	0.41	0.52
2006	0.51	0.53	0.50	0.54	0.58	0.53	0.50	0.51	0.55	0.53	0.50	0.49



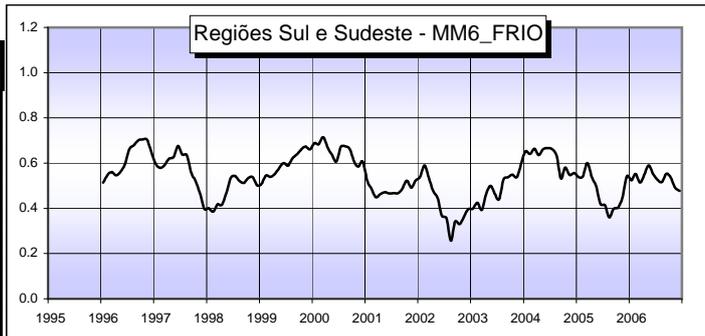
Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
Média móvel de 6 meses do indicador climático FRIO_S

	jan	fev	mar	abr	maí	jun	jul	ago	set	out	nov	dez
1995												
1996	0.51	0.54	0.57	0.55	0.58	0.62	0.69	0.71	0.73	0.74	0.73	0.68
1997	0.62	0.61	0.62	0.64	0.65	0.70	0.66	0.65	0.56	0.53	0.47	0.39
1998	0.39	0.39	0.42	0.42	0.48	0.56	0.58	0.57	0.57	0.59	0.59	0.53
1999	0.54	0.56	0.54	0.54	0.57	0.60	0.60	0.62	0.63	0.66	0.68	0.65
2000	0.67	0.69	0.73	0.68	0.65	0.62	0.68	0.68	0.66	0.60	0.58	0.60
2001	0.52	0.48	0.43	0.45	0.46	0.46	0.47	0.47	0.50	0.53	0.50	0.53
2002	0.55	0.60	0.55	0.48	0.45	0.38	0.38	0.28	0.36	0.34	0.36	0.39
2003	0.39	0.41	0.38	0.46	0.50	0.48	0.45	0.54	0.55	0.55	0.54	0.59
2004	0.65	0.64	0.67	0.65	0.69	0.70	0.71	0.67	0.56	0.60	0.56	0.56
2005	0.53	0.54	0.61	0.55	0.52	0.45	0.44	0.39	0.44	0.44	0.48	0.56
2006	0.53	0.57	0.52	0.56	0.60	0.57	0.55	0.53	0.55	0.53	0.49	0.47



Anomalias Climáticas das Temperaturas - Regiões Sul e Sudeste
Média móvel de 6 meses do indicador climático FRIO

	jan	fev	mar	abr	maí	jun	jul	ago	set	out	nov	dez
1995												
1996	0.51	0.55	0.56	0.55	0.56	0.60	0.66	0.68	0.70	0.70	0.70	0.65
1997	0.60	0.58	0.59	0.62	0.63	0.68	0.64	0.64	0.56	0.52	0.47	0.40
1998	0.40	0.39	0.42	0.42	0.47	0.53	0.54	0.52	0.51	0.53	0.54	0.50
1999	0.51	0.54	0.54	0.55	0.58	0.60	0.59	0.62	0.64	0.66	0.67	0.66
2000	0.69	0.68	0.71	0.67	0.64	0.61	0.67	0.68	0.66	0.61	0.58	0.61
2001	0.52	0.48	0.45	0.46	0.47	0.47	0.47	0.47	0.49	0.52	0.49	0.52
2002	0.54	0.59	0.54	0.48	0.44	0.37	0.36	0.26	0.34	0.33	0.36	0.40
2003	0.40	0.42	0.39	0.46	0.50	0.46	0.44	0.53	0.54	0.55	0.54	0.60
2004	0.65	0.64	0.66	0.64	0.66	0.67	0.66	0.64	0.53	0.58	0.55	0.56
2005	0.54	0.54	0.60	0.54	0.50	0.42	0.41	0.36	0.40	0.40	0.45	0.54
2006	0.52	0.55	0.51	0.55	0.59	0.55	0.53	0.52	0.55	0.53	0.49	0.48



- ANEXO F -

**Processo de Pré-Seleção e Análise Individual das
Variáveis Econômicas e Climáticas Candidatas
aos Modelos Econométricos Têxtil e Metalúrgico**

<< análise detalhada quanto ao nível de correlação
linear com a demanda e a correspondência às
expectativas de influência >>

Taxas de Crescimento Econômico				- Têxtil -
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
V12m_PIB.BR	0,457	0	0,676	0
V12m_PIB.EUA*	Insignificante	-	0,282	3
Resultado: V12m_PIB.BR foi selecionada para o modelo descritivo do consumo de energia elétrica.				
As variações dos PIBs confirmaram as expectativas quanto ao sentido da correlação com o consumo de energia elétrica, ou seja, o aumento do consumo estaria associado ao crescimento do PIB. O indicador americano não passou no teste de estacionariedade e apresentou fraca correlação com a tendência de consumo, talvez pelo descolamento do ritmo de crescimento da economia entre esses países no final da década de 90. Nesse sentido, o indicador de crescimento da economia brasileira apresenta-se como a melhor variável deste tema devido correlação moderada tanto com a série histórica consumo quanto com sua tendência.				
Taxas de Câmbio				- Têxtil -
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
TCER*	0,247	12	0,327	12
TCRD*	Insignificante	-	0,271	12
V12m_TCER	0,278	12	0,290	12
V12m_TCRD	Insignificante	-	Insignificante	-
Volat_TCER	0,408	11	0,548	12
Volat_TCRD	0,429	11	0,566	12
Resultado: Nenhuma variável deste tema foi selecionada.				
Todas as hipóteses iniciais para o efeito das taxas de câmbio sobre o consumo de energia elétrica foram refutadas, pois a depreciação do real, em valores mensais e na comparação com mesmo mês do ano anterior, e o aumento da volatilidade do câmbio “favoreceria” o crescimento do consumo de energia elétrica. Além disso, o AMMC de 12 meses não se justifica na dinâmica da economia, apesar da correlação obtida para a volatilidade.				
Taxas de Juros e o Crédito à Indústria				- Têxtil -
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
V12m_Credito	-0,390	0	-0,471	2
V12m_TR	-0,384	1	-0,491	2
V12m_Selic	-0,529	0	-0,695	2
V12m_TJLP	-0,372	0	-0,590	0
Resultado: V12m_Selic foi selecionada para o modelo descritivo do consumo de energia elétrica.				
A hipótese do crescimento do crédito correlacionar-se positivamente com o consumo não foi confirmada para os anos considerados. As taxas de juros apresentaram as correlações nas direções esperadas, ou seja, a redução das mesmas favoreceria o crescimento do consumo de energia elétrica. Apenas a taxa Selic foi selecionada devido a sua maior intensidade de sua correlação (quase forte).				
Indicadores de Inflação				- Têxtil -
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
AC12m_IPCA	0,252	10	0,349	11
AC12m_IPA	0,272	12	0,400	12
AC12m_IGPM	0,282	12	0,425	12
AC12m_INCC	0,269	9	0,393	9
Resultado: Nenhuma variável deste tema foi selecionada.				

Todos os indicadores de preços apresentaram correlações positivas com o consumo de energia elétrica, confirmando a hipótese de que o estreitamento entre a oferta e a demanda poderia estimular o crescimento na produção do setor têxtil ainda que 9 ou 12 meses depois. Porém, a menor correlação obtida com a tendência de consumo, mesmo no caso do IGPM, em comparação com outras variáveis testadas inviabilizou a seleção de qualquer indicador de inflação para o modelo descritivo.

Arrecadação de Impostos - Têxtil -

Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
V12m_ICMS.BR	0,390	0	0,471	0
V12m_ICMS.SC	0,327	0	0,320	1
V12m_PISPP	0,423	12	0,446	12

Resultado: Nenhuma variável deste tema foi selecionada.

As correlações positivas confirmaram o comportamento esperado, com o aumento de arrecadação associado ao aumento do consumo de energia elétrica. A melhor aderência à série histórica de consumo foi com a arrecadação nacional do ICMS, porém ela foi preterida por outras variáveis econômicas terem obtido correlações superiores e pela suspeita de que tal indicador seja mais consequente do que antecedente em relação à produção do setor.

Indicadores de Confiança - Têxtil -

Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
Confiança_Indústria	0,595	0	0,810	0
Exp_Cons	Insignificante	-	Insignificante	-
V12m_Conf.Ind	0,559	0	0,777	1
V12m_Expc.Cons	Insignificante	-	Insignificante	-

Resultado: Confiança_Indústria foi selecionada para o modelo descritivo do consumo de energia elétrica.

Apesar da apuração trimestral, a medida do grau de confiança da indústria brasileira na economia apresenta-se como uma ótima variável explicativa da variação do consumo de energia elétrica do setor têxtil nos anos analisados. A variação da confiança em relação ao mesmo mês do ano anterior também apresentou correlação forte, mas foi preterida pela medida original da confiança da indústria.

Emprego e Renda - Têxtil -

Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
V12m_Folha Ind.	0,366	0	0,569	0
V12m_Emprego*	Insignificante	-	0,304	0
V12m_Emp.Ind.*	0,345	0	0,492	0

Resultado: V12m_Folha_Ind foi selecionada para o modelo descritivo do consumo de energia elétrica.

Os resultados obtidos confirmaram a hipótese de que o crescimento do emprego formal e da renda (estimada pela folha de pagamento das indústrias) favoreceriam o aumento do consumo de energia elétrica do setor têxtil. Devido à correlação mais significativa e a não estacionariedade das séries de emprego, apenas a variação da folha de pagamento das indústrias em relação ao mesmo mês do ano anterior foi a escolhida.

Comércio Exterior - Têxtil -

Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
V12m_Export	0,317	0	0,416	0
V12m_Exp. Têxtil	0,410	6	0,483	6

Resultado: V12m_Exp. Têxtil foi selecionada para o modelo descritivo do consumo de energia elétrica.

A variação das exportações brasileiras, principalmente do produto têxtil, mostrou-se correlacionada positivamente com o consumo de energia elétrica, como esperado. Porém, ainda não se pode afirmar qual a direção da causalidade desta relação. A escolha da série referente às exportações têxteis deveu-se a correlação moderada obtida e a identificação do AMMC de seis meses, compatível com a dinâmica do setor.

Indicadores Setoriais - Têxtil -				
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
V12m_UCI.Têxtil	0,351	0	0,424	1
V12m_Horas.Têxtil	0,476	0	0,549	0
V12m_Empreg.Têxtil	0,427	1	0,592	1
V12m_Vendas.Têxtil	-0,243	10	-0,294	12
Resultado: Nenhuma variável deste tema foi selecionada.				
Apesar das moderadas correlações obtidas na associação entre os indicadores setoriais, exceção feita às vendas do setor têxtil, e o consumo de energia elétrica, optou-se por não utilizar nenhuma dessas variáveis por terem comportamentos muito próximos à dinâmica das indústrias têxteis (endógenas). Nesse caso a análise estatística serviu apenas para confirmar ou não as hipóteses preliminares de correlação.				
Outros Indicadores Conjunturais - Têxtil -				
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
V12m_Algodão	0,256	12	0,337	12
AC12m_ Inv.Estrangeiro*	0,278	1	0,330	1
Resultado: Nenhuma variável deste tema foi selecionada.				
A cotação internacional do algodão e o saldo acumulado do investimento estrangeiro apresentaram correlações fracas em relação ao consumo de energia elétrica e pouco poderiam contribuir para o modelo descritivo.				
Indicadores Climáticos - Têxtil -				
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
MM6-Tme	-0,542	4	-0,731	3
MM6-Tmax	-0,356	1	-0,490	2
MM6-Tmin	0,475	1	0,661	2
MM6-Tmma	-0,481	4	-0,644	2
MM6-Tmmi	0,537	4	0,739	3
MM6-ITMA	-0,529	4	-0,711	3
MM6-ITMI	0,548	4	0,762	3
MM6 FRIO_S	0,531	4	0,714	3
MM6 FRIO	0,548	4	0,751	3
Resultado: MM6_ITMI foi selecionada para o modelo descritivo do consumo de energia elétrica				
Das hipóteses apresentadas anteriormente sobre a influência do clima no consumo de energia elétrica do segmento têxtil, apenas as séries históricas de temperaturas máxima absoluta e média das máximas não se confirmaram. Assim ficou demonstrado, estatisticamente, que o crescimento do consumo de energia deste segmento está fortemente correlacionado com o abaixamento das temperaturas nas regiões Sul e Sudeste em relação aos valores historicamente esperados. A escolha de ITMI deveu-se a forte correlação obtida e ao AMMC de três meses, compatível com a dinâmica existente entre o consumo do produto têxtil (demanda) e a produção do mesmo.				
RESUMO DAS VARIÁVEIS SELECIONADAS - Têxtil -				
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
Confiança_Indústria [23]	0,595	0	0,810 (forte)	0
MM6-ITMI [44]	0,548	4	0,762 (forte)	3
V12m_Selic [14]	-0,529	0	-0,695 (forte)	2
V12m_PIB.BR [4]	0,457	0	0,676 (moderada)	0
V12m_Folha Ind. [26]	0,366	0	0,569 (moderada)	0
V12m_Exp. Têxtil [31]	0,410	6	0,483 (moderada)	6

Taxas de Crescimento Econômico				- Metalúrgico -	
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC	
V12m_PIB.BR	0,548	0	0,661	0	
V12m_PIB.EUA*	0,250	2	0,306	2	
Resultado: V12m_PIB.BR foi selecionada para o modelo descritivo do consumo de energia elétrica.					
As variações dos PIBs confirmaram as expectativas quanto ao sentido da correlação com o consumo de energia elétrica, ou seja, o aumento do consumo estaria associado ao seu crescimento. O desempenho da economia americana apresentou fraca correlação com a tendência de consumo do segmento metalúrgico, evidenciando uma função de menor relevância sobre a demanda do produto catarinense em relação a força do mercado interno. Nesse sentido, o indicador do crescimento da economia brasileira apresenta-se como a melhor variável deste tema dada sua correlação quase-forte com a série histórica de tendência de consumo.					
Taxas de Câmbio				- Metalúrgico -	
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC	
TCER*	0,235	12	0,312	12	
TCRD*	Insignificante	-	0,300	12	
V12m_TCER	-0,240	0	-0,343	0	
V12m_TCRD	Insignificante	-	-0,368	0	
Volat_TCER	0,370	11	0,486	12	
Volat_TCRD	0,378	11	0,477	12	
Resultado: Nenhuma variável deste tema foi selecionada.					
Todas as hipóteses iniciais para o efeito das taxas de câmbio sobre o consumo de energia elétrica foram refutadas, com exceção dos valores mensais comparados com mesmo mês do ano anterior (V12m). Nesse caso, a apreciação do real aumentaria a competitividade das empresas metalúrgicas no mercado externo com o respectivo aumento do consumo de energia elétrica para produção. Porém, devido a fraca correlação obtida para V12m_TCRD optou-se pela escolha de indicadores diretos de exportação ao invés de considerar as taxas de câmbio. Outro agravante para utilização dessas séries históricas foi a mudança do regime de banda cambial para câmbio flutuante, que permitiu uma super-desvalorização do real frente as demais moedas no final de 1998. Talvez para períodos de estudos iniciados a partir de 1999 tais séries ofereçam maior contribuição ao problema da demanda.					
Taxas de Juros e o Crédito à Indústria				- Metalúrgico -	
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC	
V12m_Credito	-0,415	2	-0,549	2	
V12m_TR	-0,242	3	-0,256	2	
V12m_Selic	-0,479	3	-0,481	5	
V12m_TJLP	-0,528	0	-0,565	0	
Resultado: V12m_TJLP foi selecionada para o modelo descritivo do consumo de energia elétrica.					
A hipótese do crescimento do crédito correlacionar-se positivamente com o consumo também não se confirmou para a metalurgia. As taxas de juros apresentaram as correlações nas direções esperadas. Apenas a taxa de juros de longo prazo (TJLP) foi selecionada devido a sua maior correlação com o consumo.					
Indicadores de Inflação				- Metalúrgico -	
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC	
AC12m_IPCA	0,530	10	0,735	11	
AC12m_IPA	0,317	10	0,451	12	
AC12m_IGPM	0,411	12	0,589	12	
AC12m_INCC	0,495	9	0,662	8	

Resultado: AC12m_IPCA foi selecionada para o modelo descritivo do consumo de energia elétrica.				
<p>Todos os indicadores de preços apresentaram correlações positivas com o consumo de energia elétrica, confirmando a hipótese de que o estreitamento entre a oferta e a demanda poderia estimular o crescimento na produção do setor metalúrgico. Porém, a maior correlação com o consumo de energia elétrica foi obtida para o IPCA (indicador oficial do governo brasileiro para o regime de metas do Banco Central) com um AMMC bastante longo de 11 meses. Essa relação no médio-prazo não foi cogitada previamente na pesquisa e não é evidenciada no contexto da macroeconomia. <u>Ainda assim, devido à forte correlação e à possibilidade de descoberta de conhecimento novo e útil no contexto da mineração de dados, optou-se pela escolha desta variável para compor o modelo descritivo da demanda.</u></p>				
Arrecadação de Impostos				- Metalúrgico -
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
V12m_ICMS.BR	0,388	0	0,340	2
V12m_ICMS.SC	0,328	8	0,369	6
V12m_PISPP	0,347	12	0,506	12
Resultado: Nenhuma variável deste tema foi selecionada.				
<p>As correlações positivas confirmaram o comportamento esperado, com o aumento de arrecadação associado ao aumento do consumo de energia elétrica. Das variáveis testadas, a de melhor aderência à série histórica de consumo foi a arrecadação nacional do PIS/Pasep, porém ela foi preterida em razão de outras variáveis econômicas terem obtido correlações superiores e pela suspeita de que tal indicador seja mais conseqüente do que antecedente em relação à produção do setor.</p>				
Indicadores de Confiança				- Metalúrgico -
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
Confiança_Indústria	0,565	1	0,660	0
Exp_Cons	Insignificante	-	0,280	4
V12m_Conf.Ind	0,577	2	0,665	3
V12m_Expc.Cons	Insignificante	-	0,327	12
Resultado: V12m_Conf.Ind foi selecionada para o modelo descritivo do consumo de energia elétrica.				
<p>Apesar da apuração trimestral, a medida do grau de confiança da indústria brasileira na economia apresenta-se também como uma ótima variável explicativa da variação do consumo de energia elétrica do setor metalúrgico nos anos considerados. A variação da confiança da indústria em relação ao mesmo mês do ano anterior foi preferida em relação à medição mensal da confiança em razão dos três meses de antecedência do seu impacto sobre a tendência de consumo de energia elétrica (AMMC), haja visto que ambas as variáveis apresentavam correlações muito próximas.</p>				
Emprego e Renda				- Metalúrgico -
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC
V12m_Folha Ind.	0,478	1	0,634	0
V12m_Emprego*	Insignificante	-	Insignificante	-
V12m_Emp.Ind.*	-0,270	12	-0,355	12
Resultado: V12m_Folha Ind. foi selecionada para o modelo descritivo do consumo de energia elétrica.				
<p>Os resultados obtidos não confirmaram a hipótese de que o crescimento do emprego formal favoreceria o aumento do consumo de energia elétrica do setor metalúrgico. Apenas a renda da população, estimada pela folha de pagamento da indústria confirmou as expectativas de promotora do crescimento do consumo e da produção deste segmento, em especial na indústria automobilística. Assim, apenas a variação da folha de pagamento das indústrias em relação ao mesmo mês do ano anterior foi escolhida para compor o modelo descritivo da demanda.</p>				

Cadeia Produtiva e Exportações				- Metalúrgico -	
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC	
V12m_Prod.Autoveículos	0,550	0	0,604	0	
V12m_Prod.AçoBruto	0,341	1	0,400	1	
V12m_Export	0,442	1	0,556	0	
V12m_Exp. Metalurgia	0,247	10	0,241	7	
V12m_Exp. Autoveículos	0,486	0	0,568	0	
Resultado: V12m_Prod.Autoveículos foi selecionada para o modelo descritivo.					
A variação das exportações brasileiras compradas ao mesmo mês do ano anterior, principalmente da metalurgia e de autoveículos, confirmou a hipótese de correlacionamento positivo em relação ao consumo de energia elétrica. Porém, a variação na produção de autoveículos apresentou melhores níveis de correlação tanto com a série de consumo efetivo quanto com a tendência de consumo do segmento. Caso seja necessário, a série histórica V12m_Exp.Autoveículos ainda poderá ser incluída no modelo descritivo da demanda.					
Indicadores Setoriais				- Metalúrgico -	
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC	
V12m_UCI.Metalurgia	0,556	0	0,603	0	
V12m_Horas.Metalurgia	0,649	0	0,580	0	
V12m_Empreg.Metalurgia	-0,424	10	-0,524	11	
V12m_Vendas.Metalurgia	Insignificante	-	Insignificante	-	
Resultado: Nenhuma variável deste tema foi selecionada.					
Apesar das moderadas correlações obtidas na associação entre os indicadores setoriais e o consumo de energia elétrica, exceção feita à variação do emprego formal do setor, optou-se por não utilizar nenhuma dessas variáveis por terem comportamentos muito próximos à dinâmica das indústrias metalúrgicas (endógenas). Nesse caso a análise estatística serviu apenas para confirmar ou não as hipóteses preliminares de correlacionamento.					
Investimentos				- Metalúrgico -	
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC	
AC12m_Inv.Estrangeiro*	0,479	3	0,545	3	
Resultado: AC12m_Inv.Estrangeiro foi selecionada para o modelo descritivo.					
A moderada correlação obtida entre o saldo de investimento estrangeiro nos últimos 12 meses e o consumo de energia elétrica da metalurgia em Santa Catarina possibilitou não só a confirmação das hipóteses preliminares, mas também sua inclusão no modelo descritivo. Além de se tratar de uma variável importantíssima no cenário macroeconômico, com AMMC da ordem de três meses, sua baixa correlação com as demais variáveis explicativas pode contribuir sobremaneira para explicação do comportamento da demanda.					
RESUMO DAS VARIÁVEIS SELECIONADAS				- Metalúrgico -	
Variável Explicativa	Coef. de correlação (r) com o consumo efetivo	AMMC	Coef. de correlação (r) com a tendência de consumo	AMMC	
AC12m_IPCA [16]	0,530	10	0,735 (forte)	11	
V12m_Conf.Ind [23]	0,577	2	0,665 (moderada)	3	
V12m_PIB.BR [4]	0,548	0	0,661 (moderada)	0	
V12m_Folha Ind. [26]	0,478	1	0,634 (moderada)	0	
V12m_Prod.Autos [29]	0,550	0	0,604 (moderada)	0	
V12m_TJLP [15]	-0,528	0	-0,565 (moderada)	0	
AC12m_Inv.Estrang.* [39]	0,479	3	0,545 (moderada)	3	

- ANEXO G -

**Exemplo de Resultado Gerado pelo Programa desenvolvido
em *Matlab* para o Desenvolvimento dos Modelos de
Descrição da Demanda de cada Segmento Industrial**

<< inclui todos os procedimentos previstos na metodologia >>

REGRESSÃO MÚLTIPLA DO CONSUMO - SEGMENTO METALÚRGICO DE SC

```
<< Regressores Selecionados: 1 2 6 7
<< Dados com valores medidos ORIGINAIS.
<< REGRESSANDO: V12m da Curva de Tendência do Consumo de Energia Elétrica

>> Coeficientes de Pearson (r) para cada regressor:
+0.7354;    +0.6648;    +0.6338;    +0.5680;

>> Matriz de Correlações Cruzadas:
+1.0000    ; +0.2124    ; +0.4388    ; +0.4612    ;
+0.2124    ; +1.0000    ; +0.4385    ; +0.2908    ;
+0.4388    ; +0.4385    ; +1.0000    ; +0.2694    ;
+0.4612    ; +0.2908    ; +0.2694    ; +1.0000    ;

  >> Matriz de Covariâncias:
+17.1312   ; +12.4946   ; +12.9375   ; +87.6233   ;
+12.4946   ; +202.0055   ;           ; +44.3999   ; +189.7341   ;
+12.9375   ; +44.3999   ; +50.7439   ; +88.0850   ;
+87.6233   ; +189.7341   ;           ; +88.0850   ; +2107.2441   ;

  >> Resultado para Estimação dos Parâmetros da Regressão Múltipla (coeficien-
te de confiança de 95%)
Beta_estimado = -0.084    +0.764    +0.198    +0.171    +0.024
Beta_superior = +0.930    +0.898    +0.235    +0.249    +0.036
Beta_inferior = -1.097    +0.630    +0.162    +0.094    +0.013
Coeficiente de Determinação Múltipla - R2    = 0.857
Coeficiente de Determinação Ajustado - R2AJ = 0.852
Critério de Informação de Akaike    - CIA    = 6.588
Critério de Informação de Schwarz   - CIS    = 7.399

  >> Testes de Significância:
>> 1 - Regressores apresentam significância geral para explicar o consumo!
>> 2 - Todos os regressores são individualmente significativos!
>> 3 - Estatística F das contribuições marginais dos regressores:
Fmarginais = 0.000    59.933    57.050    16.277    14.841

  >> Testes de Multicolineariedade
>> 1 - As correlações cruzadas não indicam multicolineariedade!
>> 2 - (IC = 3.32), é menor que 10 - Multicolineariedade FRACA!

  >> Testes de Causalidade dos Regressores na Direção do Consumo de Energia
Elétrica
(99%) <1> REJEITAR a hipótese do Regressor (1) não preceder temporalmente o
COEE do segmento (defasagem = 4 | F = 6.02).
(90%) <2> REJEITAR a hipótese do Regressor (2) não preceder temporalmente o
COEE do segmento (defasagem = 2 | F = 2.82).
(90%) <6> ACEITAR a hipótese do Regressor (6) não preceder temporalmente o
COEE do segmento (defasagem = 2 | F = 0.85).
(90%) <7> ACEITAR a hipótese do Regressor (7) não preceder temporalmente o
COEE do segmento (defasagem = 2 | F = 1.75).

  >> Testes de Causalidade do Consumo de Energia Elétrica na Direção dos Re-
gressores
(90%) <1> ACEITAR a hipótese do COEE do segmento não preceder temporalmente o
Regressor (1) (defasagem = 2 | F = 0.56).
(99%) <2> REJEITAR a hipótese do COEE do segmento não preceder temporalmente
o Regressor (2) (defasagem = 8 | F = 4.56).
(99%) <6> REJEITAR a hipótese do COEE do segmento não preceder temporalmente
o Regressor (6) (defasagem = 2 | F = 5.80).
(99%) <7> REJEITAR a hipótese do COEE do segmento não preceder temporalmente
o Regressor (7) (defasagem = 12 | F = 2.83).
```

```

>> Testes de Causalidade entre os Regressores:
(90%) ACEITAR a hipótese do Regressor (1) não preceder temporalmente o Re-
gressor (2) - (defasagem = 2 | F = 0.84).
(90%) ACEITAR a hipótese do Regressor (1) não preceder temporalmente o Re-
gressor (6) - (defasagem = 1 | F = 1.55).
(99%) REJEITAR a hipótese do Regressor (1) não preceder temporalmente o Re-
gressor (7) - (defasagem = 12 | F = 2.79).
(90%) ACEITAR a hipótese do Regressor (2) não preceder temporalmente o Re-
gressor (1) - (defasagem = 2 | F = 0.11).
(99%) REJEITAR a hipótese do Regressor (2) não preceder temporalmente o Re-
gressor (6) - (defasagem = 3 | F = 5.89).
(95%) REJEITAR a hipótese do Regressor (2) não preceder temporalmente o Re-
gressor (7) - (defasagem = 2 | F = 4.46).
(90%) ACEITAR a hipótese do Regressor (6) não preceder temporalmente o Re-
gressor (1) - (defasagem = 2 | F = 1.07).
(90%) ACEITAR a hipótese do Regressor (6) não preceder temporalmente o Re-
gressor (2) - (defasagem = 2 | F = 0.27).
(95%) REJEITAR a hipótese do Regressor (6) não preceder temporalmente o Re-
gressor (7) - (defasagem = 2 | F = 3.36).
(90%) ACEITAR a hipótese do Regressor (7) não preceder temporalmente o Re-
gressor (1) - (defasagem = 2 | F = 0.52).
(95%) REJEITAR a hipótese do Regressor (7) não preceder temporalmente o Re-
gressor (2) - (defasagem = 5 | F = 3.14).
(90%) ACEITAR a hipótese do Regressor (7) não preceder temporalmente o Re-
gressor (6) - (defasagem = 1 | F = 0.26).

```

```

>> Matriz das Causalidades dos Regressores (Significância):
0.00      ; 10.00      ; 10.00      ; 99.00      ;
10.00     ; 0.00      ; 99.00     ; 95.00     ;
10.00     ; 10.00     ; 0.00     ; 95.00     ;
10.00     ; 95.00     ; 10.00     ; 0.00     ;

```

```

>> Matriz das Causalidades dos Regressores (Defasagens):
0.00      ; 2.00      ; 1.00      ; 12.00     ;
2.00      ; 0.00      ; 3.00      ; 2.00     ;
2.00      ; 2.00      ; 0.00      ; 2.00     ;
2.00      ; 5.00      ; 1.00      ; 0.00     ;

```

```

>> Matriz das Causalidades dos Regressores (Teste F):
0.00      ; 0.84      ; 1.55      ; 2.79      ;
0.11      ; 0.00      ; 5.89      ; 4.46      ;
1.07      ; 0.27      ; 0.00      ; 3.36      ;
0.52      ; 3.14      ; 0.26      ; 0.00      ;

```


REFERÊNCIAS BIBLIOGRÁFICAS

- AGNOLUCCI, P. The energy demand in the British and German industrial sectors: Heterogeneity and common factors. *Energy Economics*, vol. 31, n. 1, p. 175-187, Jan. 2009. {24}
- ALCÁNTARA, V.; PADILLA, E. “Key” Sectors in Final Energy Consumption: An Input-Output Application to the Spanish Case. *Energy Policy*, v. 31, n. 15, p. 1673-1678, Dec. 2003. {23}
- ANDRADE, Fabiano Ferreira; 2003. *Formação de Agrupamentos de Consumidores de Energia Elétrica com Base nos Perfis de Carga Individuais*. Florianópolis. Dissertação (Mestrado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal de Santa Catarina. {30}
- ANDRADE, Fabiano Ferreira; 2006. *Demanda de Energia Elétrica dos Consumidores Industriais: Uma Abordagem via Mineração de Dados*. Florianópolis. Qualificação (Doutorado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal de Santa Catarina.
- ANDRADE, F. F.; CAMARGO, C. C. de B.; CATARINA, R. S.; et al. Estimativa da Relação Preço-Demanda para o Gás Natural com Base na Estatística Multivariada. In: CONGRESSO BRASILEIRO DE ENERGIA (10. : Out. : 2004 : Rio de Janeiro, Brasil). *Anais*. Rio de Janeiro, 2004a. {27}
- ANDRADE, F. F.; VALTER, E. M.; CAMARGO, C. C. de B. Brazilian Electrical Sectors Tariff Design Outlook in Competitive Framework. In: IEEE/PES LATIN AMERICA TRANSMISSION AND DISTRIBUTION (Oct. 2004 : São Paulo, Brazil). *Proceedings* São Paulo, 2004b. {31}

- ANDRADE, T. A.; LOBÃO, W. J. A. Elasticidade Renda e Preço da Demanda Residencial de Energia Elétrica no Brasil. *IPEA - Textos para Discussão*, Rio de Janeiro, n. 489, Jun. 1997. {50}
- ANDRADE, T. B. de; MOREIRA, J. L. B.; REIS, R. J. dos; et al. Influência da Climatologia na Previsão de Carga. In: SNPTEE – SEMINÁRIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA (17. : Out. : 2003 : Uberlândia, Brasil). *Anais*. Uberlândia, 2003. GOP-28. {72}
- ANG, B. W. Multilevel Decomposition of Industrial Energy Consumption. *Energy Economics*, vol. 17, n. 1, p. 39-51, Jan. 1995. {18}
- AZADEH, M. A.; SOHRABKHANI, S.; Annual Electricity Consumption Forecasting with Neural Network in High Energy Consuming Industrial Sectors of Iran. In: IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY (Dec. 2006). *Proceedings*. 2006. p. 2166-2171. {66}
- BAO, J. *Short-term Load Forecasting based on Neural network and Moving Average*. Technical Report. Iowa State University, 2002. http://www.public.iastate.edu/~baojie/pub/2002-05-08_stlf.pdf. {38}
- BARDELIN, Cesar Endrigo Alves; 2004. *Os Efeitos do Racionamento de Energia Elétrica ocorrido no Brasil em 2001 e 2002 com Ênfase no Consumo de Energia Elétrica*. São Paulo. Dissertação (Mestrado em Engenharia de Energia e Automação Elétricas) – Escola Politécnica, Universidade de São Paulo. {51}
- BESSEC, M.; FOUQUAU, J. The non-linear link between electricity consumption and temperature in Europe: A threshold panel approach. *Energy Economics*, vol. 30, n. 5, p. 2705-2721, Sep. 2008. {12}
- BIRCH, A. P.; ÖZVEREN C. Z.; SAPELUK, A. T. A. Generic Load Profiling Technique Using Fuzzy Classification. In: IEE, METERING AND TARIFFS FOR ENERGY SUPPLY (July 1996). *Conference Publication*. 1996. n. 426. p. 203-207. {29}

- BORLEA, I.; BUTA, A.; LUSTREA, B. Some Aspects Concerning Mid Term Monthly Load Forecasting Using ANN. In: IEEE / EUROCON – THE INTERNATIONAL CONFERENCE ON “COMPUTER AS A TOOL” (Nov. 2005 : Serbia & Montenegro, Belgrade). *Proceedings*. Serbia & Montenegro, 2005. vol. 1. p. 253-256.
- BRANCO, A. C. C.; SCHUCH, G. B.; PINHO, R.; et al. Metodologia de Projeção de Demanda Adequada ao Novo Contexto do Setor Elétrico Brasileiro. In: CITENEL – CONGRESSO DE INOVAÇÃO TECNOLÓGICA EM ENERGIA ELÉTRICA (2. : Nov. : 2003 : Salvador, Brasil). *Anais*. Salvador, 2003. p. 688-692. {42 e 55}
- CAMARGO, C. C. de B.; TEIVE, R. C. G.; 2006. *Gerenciamento pelo lado da demanda: aspectos técnicos, econômicos, ambientais e políticos de conservação de energia*. 1. ed. Itajaí : Univali.
- CARPINTEIRO, O. A. S.; REIS, A. J. R.; SILVA, A. P. A. da. A Hierarchical Neural Model in Short-term Load Forecasting. *Applied Soft Computing*, vol. 4, n. 4, p. 405-412, Sep. 2004. {77}
- CAVALLARO, F. Electric Load Analysis Using an Artificial Neural Network. *International Journal of Energy Research*, n. 29, p. 377-392, Feb., 2005. {37, 39 e 69}
- CHANG, H. S.. CHERN W. S. Specification, Estimation, and Forecasts of Industrial Demand and Price Elasticity. *Energy Systems and Policy*, London, vol. 5, p. 219-242, 1981. {2}
- CHANG, R. F.; LU, C. N. Load Profile assignment of Low Voltage Customers for Power Retail market applications. *IEE Proceedings – Generation Transmission Distribution*, v. 150, n. 3, p. 263-267, May. 2003. {34}
- CHEN, H. ; DU, Y.; JIANG, J. N. Weather Sensitive Short-Term Load Forecast Using Knowledge-Based ARX Models. In: IEEE POWER ENGINEERING SOCIETY GENERAL MEETING (June : 2005 : San Francisco, USA). *Proceedings*. San Francisco, 2005. vol. 1. p. 190-196. {60}

- CHONTANAWAT, J.; HUNT, L. C.; PIERSE, R. Causality Between Energy Consumption and GDP: Evidence from 30 OECD and 78 Non-OECD Countries. *SEEDS - Surrey Energy Economics Discussion paper Series*, Guildford, UK, n. 113, June 2006. {16}
- CHOW, L. C. A Study of Sectoral Energy Consumption in Hong Kong (1984-97) with Special Emphasis on the Household Sector. *Energy Policy*, vol. 29, n. 13, p. 1099-1110, Nov. 2001. {13}
- CRISTIFARO, M.; FROSINI, L.; ANGLANI, N. Free electricity market: how industrial customers and ESCOs can make the most from load forecasting techniques. In: IEEE INTERNATIONAL WORKSHOP ON SOFT COMPUTING IN INDUSTRIAL APPLICATIONS (Jun. 2003 : Binghamton, New York). *Proceedings*. Binghamton, 2003. {61}
- DAMRONGKULKAMJORN, P.; CHURUEANG, P.; Monthly Energy Forecasting Using Decomposition Method with Application of Seasonal ARIMA. In: IEEE\IPEC INTERNATIONAL POWER ENGINEERING CONFERENCE (Nov. 2005). *Proceedings*. 2005. {57}
- DA-PENG, L.; DONG-HAI, M. The Forecasting of China's Energy Consumption. In: INTERNATIONAL CONFERENCE ON MANAGEMENT SCIENCE & ENGINEERING (15. : Sep. 2008 : Long Beach, USA). *Proceedings*. Long Beach, 2008. p. 1557-1562. {45}
- DERGIADES, T.; TSOULFIDIS, L. Estimating residential demand for electricity in the United States, 1965-2006. *Energy Economics*, vol. 30, n. 5, p. 2722-2730, Sep. 2008. {6}
- DOUGLAS, A. P.; BREIPOHL, A. M.; LEE, F. N.; et al. The Impacts of Temperature Forecast Uncertainty on Bayesian Load Forecasting.. *IEEE Transactions on Power Systems*, v. 13, n. 4, p. 1507-1513, Nov. 1998. {62}
- DORTOLINA, C. A.; NADIRA, R. Estimating Future Demand - A Top Down / Bottom Up Approach for Forecasting Annual Growths. In: IEEE POWER ENGINEERING SOCIETY GENERAL MEETING (June 2005 : San Francisco, USA). *Proceedings*. San Francisco, 2005. vol. 1. p. 400-405. {56}

- DRAPER, N. R.; SMITH, H.; 1981. *Applied Regression Analysis*. 3. ed. John Wiley.
- ENDERS, W. *Applied Econometric Time Series*. 1. ed. New York : Wiley, 2004. {63}
- EPE – EMPRESA DE PESQUISA ENERGÉTICA; 2006. *Plano Decenal de Expansão de Energia Elétrica 2006-2015*. Brasília. {41}
- EPE – EMPRESA DE PESQUISA ENERGÉTICA; 2009. *Boletins Anuais de Consolidação do Mercado de Energia Elétrica e da Economia*. <http://www.epe.gov.br/mercado/Paginas/default.aspx>
- FARAHAT, M. A. Long-term Industrial Load Forecasting and Planning using Neural Networks Technique and Fuzzy Inference Method. In: IEEE – UPEC - UNIVERSITIES POWER ENGINEERING CONFERENCE (39. : Sep. 2004 : Bristol, UK). *Proceedings*. Bristol, 2004. vol. 1. p. 368-372. {65}
- FARIA, A. F. de; CARVALHO, W.; TORRES, G. L.; et al. Desenvolvimento de Aplicativo para Previsão de Cargas Elétricas da CEB. In: CITENEL - CONGRESSO DE INOVAÇÃO TECNOLÓGICA EM ENERGIA ELÉTRICA (3. : Dez. : 2005 : Florianópolis, Brasil). *Anais*. Florianópolis, 2005. {68}
- FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. The KDD Process for Extracting Useful Knowledge from Volumes of Data. *Communications of the Association for Computing Machinery*, v. 39, n. 11, p. 27-34, Nov. 1996. {1}
- FERREIRA, V. H.; SILVA, A. P. A. da. Toward Estimating Autonomous Neural Network-Based Electric Load Forecasters. *IEEE Transactions on Power Systems*, v. 22, n. 4, p. 1554-1562, Nov. 2007.
- FIGUEIREDO, V.; RODRIGUES, F.; VALE, Z.; et al. An Electric Energy Consumer Characterization Framework Based on Data Mining Techniques. *IEEE Transactions on Power Systems*, v. 20, n. 2, p. 596-602, May. 2005. {33}

- FORESEE, F. D.; HAGAN, M. T. Gauss-Newton Approximation to Bayesian Learning. In: IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS (3. : Jun. 1997). *Proceedings*. 1997. p. 1930-1935.
- GARCEZ, E. W.; GHIRARDI, A. G. Elasticidade da Demanda Residencial de Energia Elétrica. In: ENCONTRO NACIONAL DE ECONOMIA DA ANPEC (29. : 2003). *Anais*. 2003. d34. {7}
- GHALI, K. H.; EL-SAKKA, M. I. T. Energy Use and Output Growth in Canada: A Multivariate Cointegration Analysis. *Energy Economics*, vol. 26, n. 2, p. 225-238, Mar. 2004. {14}
- GHODS, L.; KALANTAR, M.; Methods For Long-Term Electric Load Demand Forecasting: A Comprehensive Investigation. In: IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY (Apr. 2008). *Proceedings*. 2008. p. 1-4. {67}
- GOLDSCHMIDT, R.; PASSOS, E.; 2005. *Data Mining: Conceitos, Técnicas, Orientações e Aplicações*. 1. ed. Rio de Janeiro : Elsevier.
- GONZÁLEZ-ROMERA, E.; JARAMILLO-MORÁN, M. Á.; CARMONA-FERNÁNDEZ, D. Montly Electric Energy Demand Forecasting Based on Trend Extraction. *IEEE Transactions on Power Systems*, v. 21, n. 4, p. 1946-1953, Nov. 2006. {70}
- GUIRELLI, C. R.; JARDINI, J. A.; MAGRINI, L. C.; et al. Desenvolvimento de um Sistema Computacional de Previsão de Carga Baseado em Redes Neurais e Inteligência Artificial através de Sensores Implantados no Sistema de Transmissão de Energia. In: CITENEL - CONGRESSO DE INOVAÇÃO TECNOLÓGICA EM ENERGIA ELÉTRICA (3. : Dez. : 2005 : Florianópolis, Brasil). *Anais*. Florianópolis, 2005. {79}
- GUJARATI, D. N.; PASSOS, E.; 2006. *Economia Básica*. 1. ed. Rio de Janeiro : Elsevier.
- HAINOUM, A.; SEIF-ELDIN, M. K.; ALMOUSTAFA, S. Analysis of the Syrian Long-term Energy and Electricity Demand Projection Using the End-use Methodology. *Energy Policy*, vol. 34, n. 14, p. 1958-1970, Sep. 2006. {44}

- HAYKIN, S.; 2001. *Redes Neurais: princípios e prática*. 2. ed. Porto Alegre : Bookman.
- HILL, R. C.; GRIFFITHS, W. E.; JUDGE, G. G.; 2003. *Econometria*. 2. ed. São Paulo : Saraiva.
- HOUAISS, A. *Dicionário Houaiss da Língua Portuguesa*. Editora Objetiva. 2006. URL <http://houaiss.uol.com.br/busca.jhtm>. {40}
- IAEA – INTERNATIONAL ATOMIC ENERGY AGENCY; 2006. *Model for Analysis of Energy Demand 2 : User's Manual*. Vienna, Austria. {43}
- IBGE. Instituto Brasileiro de Geografia e Estatística. *Densidade Demográfica e Rede Coletora de Esgoto*. 2000.
- KAMERSCHEN, D. R.; PORTER, D. V. The Demand for Residential, Industrial and Total Electricity, 1973-1998. *Energy Economics*, vol. 26, n. 1, p. 87-100, Jan. 2004. {25}
- KHOTANZAD, A.; ZHOU, E.; ELRAGAL, H. A Neuro-Fuzzy Approach to Short-Term Load Forecasting in a Price-Sensitive Environment. *IEEE Transactions on Power Systems*, v. 17, n. 4, p. 1273-1282, Nov. 2002. {36 e 82}
- KIRSCHEN, D. S; STRBAC, G.; CUMPERAYOT, P.; MENDES, D. P. Factoring the Elasticity of Demand in Electricity Prices. *IEEE Transactions on Power Systems*, v. 15, n. 2, p. 612-617, May. 2000. {8}
- KITAYAMA, M.; MATSUBARA, R.; IZUI, Y. Application of Data Mining to Customer Profile Analysis in the Power Electric Industry. In: POWER ENGINEERING SOCIETY WINTER MEETING (Jan. 2002 : New York, USA). *Proceedings*. New York, 2002. vol. 1. p. 632-634. {32}
- KOOP, G.; 2000. *Analysis Economic Data*. 1 ed. West Sussex, England : John Wiley.
- LEITE, K.T.F.; VELLASCO, M.; PACHECO, M. A.; et al. Modeling Neural Nets and Fuzzy Logic to Very Short-Term Load Forecasting. In: SEPOPE - SYMPOSIUM OF SPECIALISTS IN ELECTRIC OPERATIONAL AND EXPANSION PLANNING (7. : May. 2000 : Curitiba, Brazil). *Proceedings*. Curitiba, 2000. {78}

- LINDEROTH, H. Forecast Errors in IEA-countries' energy consumption. *Energy Policy*, vol. 30, n.1, p. 53-61, Jan. 2002. {52}
- LIRA, J. Pontos de Dicotomização para a Obtenção do Coeficiente de Correlação Tetracórico. *Revista Ciências Exatas e Naturais*, vol. 7, n. 2, p. 195-208, Jul. / Dez. 2005.
- LIU, X. Q.; ANG, B. W.; GOH, T. N. Forecasting of Electricity Consumption: A Comparison Between an Econometric Model and Neural Network Model. In: IEEE INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (Nov. 1991). *Proceedings*. 1991. vol. 2. p. 1254-1259. {64}
- LOPES, M. L. M.; LOTUFO, A. D. P.; MINUSSI, C. R. A Fast Electric Load Forecasting Using Adaptive Neural Networks. In: IEEE BOLOGNA POWERTECH CONFERENCE (June 2003 : Bologna, Italy). *Proceedings*. Bologna, 2003. {81}
- MAIA, M. R.; VELOSO, K.de O. G.; OKAMOTO, M. T. Mercado de Energia Elétrica: Desenvolvimento de uma Ferramenta Computacional para Predição Decenal. In: SNPTEE – SEMINÁRIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA (Out. : 2007 : Rio de Janeiro, Brasil). *Anais*. Rio de Janeiro, 2007. GPL-01. {47}
- MANDAL, P.; SENJYU, T.; UEZATO, K.; et al. Several-Hours-Ahead Electricity Price and Load Forecasting Using Neural Networks. In: IEEE POWER ENGINEERING SOCIETY GENERAL MEETING (June 2005 : San Francisco, USA). *Proceedings*. San Francisco, 2005. vol. 3. p. 2146-2153. {71}
- MC CAFFEIRTY, P.; BEATTIE, W. C. The Influence of Disaggregation Applied to Time Series Modelling of Electricity Demand in The Industrial Sector. In: IEEE INTERNATIONAL CONFERENCE ON EC3-ENERGY, COMPUTER, COMMUNICATION AND CONTROL SYSTEMS (10. : Aug. : 1991 : New Delhi, Indian). *Proceedings*. New Delhi, 1991. vol. 1. p. 213-216. {3, 39 e 59}
- MACKAY, David J. C.; 1992a. *Bayesian Methods for Adaptive Models*. California. Thesis California Institute of Technology Pasadena.

- MACKAY, David J. C.; 1992b. A Practical Bayesian Framework for Backpropagation networks. *Neural Computation*, vol. 4, n. 3, p. 448-472.
- MATLAB; 2006. *Neural Network Toolbox: for use with Matlab*. Version 5.0. Natick, MA : The MathWorks, Inc.
- MELANDA, Edson Augusto; 2004. *Pós-processamento de Regras de Associação*. São Carlos. Tese (Doutorado em Ciências da Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e Computação, Universidade de São Paulo.
- METHAPRAYOON, K.; LEE, W.; RASMIDDATTA, S.; et al. Multistage Artificial Neural Short-Term Load Forecasting Engine With Front-End Weather Forecast. *IEEE Transactions on Industry Applications*, v. 43, n. 6, p. 1410-1416, Nov./Dec. 2007. {74}
- MIKETA, A.; MULDER, P. Energy Productivity Across Developed and Developing Countries in 10 Manufacturing Sectors: Patterns of Growth and Convergence. *Energy Economics*, vol. 27, n. 3, p. 429-453, May. 2005. {21}
- MORAL-CARCEDO, J.; VICÉNS-OTERO, J. Modelling the Non-linear Response of Spanish Electricity Demand to Temperature Variations. *Energy Economics*, vol. 27, n. 3, p. 477-494, May. 2005. {11}
- MORETTIN, P. A.; TOLOI, C. M. C.; 2004. *Análise de séries temporais*. 1. ed. São Paulo : Edgar Blücher.
- MURTISHAW, S.; SHIPPER, L. Disaggregated Analysis of US Energy Consumption in the 1990s: Evidence of the Effects of the Internet and Rapid Economic Growth. *Energy Policy*, vol. 29, n. 15, p. 1335-1356, Dec. 2001. {19}
- OKAMOTO, M. T.; EVSUKOFF, A.; CALÔBA, L. P. Previsão Decenal de Carga Utilizando Técnicas Computacionais Inteligentes. In: SNPTEE – SEMINÁRIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA (Out. : 2007 : Rio de Janeiro, Brasil). *Anais*. Rio de Janeiro, 2007. GPL-03. {48}

- OLIVEIRA, Cláudio Magalhães; 2004. *Modelo Adaptativo para Previsão da Carga Ativa de Curto Prazo*. Florianópolis. Tese (Doutorado em Engenharia de Produção) – Centro Tecnológico, Universidade Federal de Santa Catarina. {75}
- OLIVEIRA, C. M.; WAZLAWICK, R. S. Modelo Adaptativo para Previsão de Carga Ativa de Curto Prazo - Parte II. In: CELESC – Relatório de Acompanhamento de Projetos de Pesquisa. Florianópolis, 2004. {35 e 76}
- PAUL, S.; BHATTACHARYA, R. N. Causality between Energy Consumption and Economic Growth in India: A Note on Conflicting Results. *Energy Economics*, vol. 26, n. 6, p. 977-983, Nov. 2004. {15}
- PINTO, L. M. V. G.; SZEZUPAK, J.; MACEDO, L. H. G. de; et al. A New Approach to Load Forecast: Incorporating Climate, Economic and Social Behavior Predictions. *IEEE Russia Power Tech.* p. 1-6, Jun. 2005. {49}
- PITT, B.D.; KIRSCHEN, D.S. Application of Data Mining Techniques to Load Profiling. In: IEEE INTERNATIONAL CONFERENCE OF POWER INDUSTRY COMPUTER APPLICATIONS (21. : May. 1999). *Proceedings*. 1999. p. 131-136. {28}
- RAFAEL, Manuel Camela; 2004. *Potencial de Conservação de Energia no Segmento Industrial para o Desenvolvimento Sustentado*. Florianópolis. Tese (Doutorado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal de Santa Catarina. {22}
- SANDERS, D. R.; MANFREDO, M. R.; BORIS, K. Accuracy and efficiency in the U.S. Department of Energy's short-term supply casts. *Energy Economics*, vol. 30, n. 3, p. 1192-1207, May. 2008. {53}
- SCHUCH, Gladis Bordin; 2000. *Um Modelo para Estudos da Demanda de Energia Elétrica em Ambiente Competitivo*. Florianópolis. Tese (Doutorado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal de Santa Catarina. {54}
- SILVA, A. P. A. da; MOULIN, L. S. Confidence Intervals for Neural Network Based Short-Term Load Forecasting. *IEEE Transactions on Power Systems*, v. 15, n. 4, p. 1191-1196, Nov. 2000.

- SILVA, A. P. A. da; FERREIRA, V. H.; VELASQUEZ, R. M. G. Input Space to Neural Network Based Load Forecasters. *International Journal of Forecasting*, vol. 24, 2008. {83}
- SILVA, A. P. A. da; RODRIGUES, U. de P.; LAGE, W. F.; et al. Previsão de Carga On-Line. In: SNPTTE – SEMINÁRIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA (17. : Out. : 2003 : Uberlândia, Brasil). *Anais*. Uberlândia, 2003. {73}
- SILVA, M. A. H. G. Comportamento de Carga Sensível à Temperatura Ambiente. In: SENDI - SEMINÁRIO NACIONAL DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA (15. : Nov. 2002 : Salvador, Brasil). *Anais*. Salvador, 2002. {10}
- SISWORAHARDJO, N. S.; ALAM, M. S.; EL-KEIB, A. A. An Improved Stochastic Load Model for Industrial Power Market. In: IEEE/IAS ANNUAL MEETING (3. : Oct. 2006). *Proceedings*. 2006. p. 1352-1359. {9}
- SOUZA, G. P.; SAMOBYL, R. W.; MEURER, R.; et al. Combinação de Modelos de Séries Temporais para Previsões do Consumo Industrial de Energia Elétrica em Santa Catarina. In: ESCOLA DE MODELOS DE REGRESSÃO (9. : Fev. : 2005 : São Pedro, Brasil). *Anais*. São Pedro, 2005. p. 49-49. {58}
- STEENHOF, P. A. Decomposition of Electricity Demand in China's Industrial Sector. *Energy Economics*, vol. 28, n. 3, p. 370-384, May. 2006. {20}
- TINTNER, G.; 1968. *Methodology of mathematical economics and econometrics*. 1. ed. Chicago : University of Chicago Press.
- TONSIG, S. L.; 2006. *MySQL - Aprendendo na Prática*. 1. ed. Rio de Janeiro : Editora Ciência Moderna.
- TOLMASQUIM, M. T.; SZKLO, A. S.; 2000. *A Matriz Energética Brasileira na Virada do Milênio*. 1. ed. Rio de Janeiro : COPPE / UFRJ / ENERGE. {46}

- ÚBEDA, E. F. S.; BERZOSA, A. Modeling and forecasting industrial and-use natural gas consumption. *Energy Economics*, vol. 29, n. 4, p. 710-742, Jul. 2007. {26}
- WANG, P. Y.; WANG, G. S. Power System Load Forecasting with ANN and Fuzzy Logic Control. In: IEEE/REGION 10 – CONFERENCE ON COMPUTER, COMUNICATION, CONTROL AND POWER ENGINEERING (1. : Oct 1993 : Beijing, China). *Proceedings*. Beijing, 1993. vol. 5. p. 359-362. {80}
- WANKE, P. Previsão Top-down ou botton-up? Impacto nos níveis de erros e de estoques de segurança. *GEST. PROD.*, São Carlos, v. 15, n. 2, p. 231-245, Mai. / Ago. 2008. {5}
- ZARNIKAU, J. Functional Forms in Energy Demand Modelling. *Energy Economics*, vol. 25, n. 6, p. 603-613, Nov. 2003. {17}
- ZOTTERI, G.; KALCHSCHMIDT, M.; CANIATO, F. The Impact of Aggregation Level on Forecasting Performance. *International Journal of Production Economics*, vol. 93-94, p. 479-491, Jan. 2005. {4}