

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO
E SISTEMAS

MODELO ADAPTATIVO PARA PREVISÃO DE CARGA ATIVA DE
CURTO PRAZO

Cláudio Magalhães de Oliveira

Tese apresentada para a obtenção do grau de Doutor em Engenharia de Produção

Orientador: Raul Sidnei Wazlawick

Florianópolis

Novembro de 2004

Modelo Adaptativo para Previsão de Carga Ativa de Curto Prazo

Cláudio Magalhães de Oliveira

Esta Tese foi julgada adequada para a obtenção do título de Doutor em Engenharia, especialidade em Engenharia de Produção e Área de Concentração Inteligência Aplicada e aprovada em sua forma final pelo curso de Pós-Graduação em Engenharia de Produção e Sistemas da Universidade Federal de Santa Catarina.

Edson Pacheco Paladini, Dr.

Banca Examinadora

Raul Sidnei Wazlawick, Dr. Eng. (Orientador)

Arlan Luiz Bettioli, DSA

Carlos Claumann, Dr. Eng.

Nestor Roqueiro, Dr. Sc.

Rogério Cid Bastos, Dr.

O valor de um objetivo não tem a ver com sua acessibilidade, mas com a atração magnética da direção que ele impõe. Mais do que o ponto de chegada, é a própria viagem que importa realmente.

Pierre Dansereau

À minha esposa e filhos.

Aos meus pais.

AGRADECIMENTOS

Às Centrais Elétricas de Santa Catarina S.A. - CELESC, pela cessão de seu histórico de medições de potência ativa, temperatura ambiente e velocidade e direção do vento, bem como seu apoio na realização deste trabalho.

Ao Centro Integrado de Meteorologia e Recursos Hídricos de Santa Catarina – CLIMERH, pela cessão de seu histórico de medições das condições climáticas do Estado de Santa Catarina.

Ao Laboratório LABSOLAR (LABSOLAR/NCTS) da Universidade Federal de Santa Catarina, pela cessão de seu histórico de medições das condições climáticas da cidade de Florianópolis - SC.

Ao Luiz Ângelo D. de Luca, Gabriel da S. Beletti e Thiago N. de Holanda, bolsistas do Laboratório de Sistemas de Conhecimento, pelas boas discussões, idéias, sugestões e empenho e dedicação na construção dos programas computacionais.

Aos Engenheiros do Departamento de Operação da CELESC em especial: Walter Zelindro da Silva Filho, Gilberto Paulo Búrigo, Paulo Neves de Lacerda e Luiz Artur F. de Verney, pela ajuda, apoio e sugestões.

A todas as pessoas que, de forma direta ou indireta, contribuíram para a realização deste trabalho.

RESUMO

Este trabalho propõe, valida e verifica um modelo para um sistema de previsão de cargas de curtíssimo e de curto prazo que leva em conta as diferenças regionais e a dinâmica da demanda por carga em um mercado de energia elétrica heterogêneo como o do Estado de Santa Catarina. O trabalho também compara o desempenho deste modelo com o desempenho do modelo proposto por Oliveira (1999) para uso associado a sistemas de tempo real. Ainda, utiliza o modelo proposto para testar a validade das hipóteses descritas a seguir. Hipótese I: existe diferença entre os conjuntos de variáveis de entrada da RNA que otimizam a previsão de carga, em um determinado instante de tempo, para os vários nós de um sistema elétrico com características de consumo distintas entre si. Hipótese II: existe diferença entre os conjuntos de variáveis de entrada da RNA que otimizam a previsão de carga para um determinado nó de um sistema elétrico, ao longo do tempo.

O modelo proposto é dotado da capacidade de adaptação, sendo capaz de ajustar-se e acompanhar a dinâmica de um mercado de energia elétrica composto por micro-regiões de consumo com características fortemente heterogêneas. Dotado de arquitetura híbrida, é fundamentado em duas técnicas da área de Inteligência Artificial: Algoritmos Genéticos e Redes Neurais Artificiais. A rede neural artificial utilizada no modelo é a Rede de Base Radial, tendo demonstrado facilidade de ajuste e boa velocidade de treinamento, propriedades relevantes em um sistema de previsão voltado ao uso associado a sistemas SCADA. O algoritmo genético complementa a capacidade de modelagem inerente ao funcionamento da RNA, definindo a camada de entrada e os parâmetros internos da rede.

Os resultados obtidos comprovam que o modelo funciona de acordo com o esperado, adaptando-se às diversas condições de consumo testadas. Quando comparado ao modelo de Oliveira (1999), apresentou redução no valor dos erros (ganhos de precisão) variando entre 66% e 73%. Também, ambas as hipóteses, hipótese I e hipótese II, se mostraram válidas. Para uma determinada região de consumo, a especialização do modelo em relação à estação climática propiciou ganhos entre 3% a 63%. Já a especialização por região de consumo, considerando-se uma determinada estação climática, produziu ganhos de precisão entre 7% a 29%. Finalmente, durante os testes, foram observadas variações relevantes na precisão dos ajustes do modelo, com ganhos de precisão de até 25%, quando

foram realizadas variações propositais na quantidade de variáveis climáticas utilizadas nos históricos de dados.

ABSTRACT

The present work proposes, validates and verifies a very short and short time bus active load forecast model that takes into account the regional differences and the dynamics of the load demand in a heterogeneous electric energy market such as the market of the State of Santa Catarina. This work also compares the performance of this model with the Oliveira (1999) model that has proposed for real time systems associated use. Furthermore, the proposed model was used to verify the following hypothesis. Hypothesis I: there is difference among the sets of input variables used in artificial neural networks to minimize the load forecasting error, in a specific time stamp, for regions with different load demand behavior. Hypothesis II: there exists difference among the sets of input variables of the artificial neural networks to minimize the load forecasting error in a specific node of an electrical system at different moments of time.

The proposed model can adapt and adjust itself to the dynamic of a market of electrical energy composed of micro regions with heterogeneous characteristics of load demand. The model hybrid and built upon two artificial intelligence techniques: genetic algorithms and artificial neural networks. The artificial neural network uses the radial basis function that is relatively easy to adjust and that is relatively fast to be trained. Such properties are relevant for forecasting systems associated to SCADA. The native modeling capacity of the artificial neural network is complemented with the modeling capacity of the genetic algorithm that set the neural network input layer and some of its internal parameters.

When it is compared to the model of Oliveira (1999), the proposed model shows 66% to 73% of precision improvement (reduction on the values of the errors). Hypothesis I and II are both proved. When a specific region of load demand is considered, the model shows 3% to 63% of precision improvement. When a specific season is considered and the model is specialized to the region of load demand, the model shows 7% to 29% of precision improvement. Finally, when the number of climatic variables was intentionally changed, relevant variations were observed, and the precision improvement was up to 25%.

ÍNDICE DE FIGURAS

<i>Figura 1 – Sistema de Previsão de Cargas</i>	42
<i>Figura 2 - Previsor Especialista</i>	46
<i>Figura 3 - Rede RBF de 3 camadas</i>	47
<i>Figura 4 – Representação genética do Modelador Evolutivo de 1ª Ordem</i>	52
<i>Figura 5 – Representação genética do Modelador Evolutivo de 2ª Ordem</i>	57
<i>Figura 6 - Precipitação típica em Santa Catarina – Anual (in, CLIMERH, 2002)</i>	59
<i>Figura 7 – Sistema de potência da CELESC (documentação interna da CELESC)</i>	60
<i>Figura 8 - Distribuição Geo-administrativa da CELESC (in, [12] CELESC, 2003)</i>	61
<i>Figura 9. Oliveira, 1999 – Ajuste</i>	74
<i>Figura 10. Modelo adaptativo – Ajuste</i>	74
<i>Figura 11. Oliveira, 1999 – Teste, ½ hora à frente.</i>	75
<i>Figura 12. Modelo adaptativo – Teste, ½ hora à frente.</i>	75
<i>Figura 13. Oliveira, 1999 – Teste, ½ hora a 1 semana à frente.</i>	76
<i>Figura 14. Modelo adaptativo – Teste, ½ hora a 1 semana à frente.</i>	76
<i>Figura 15. Florianópolis, Temperatura Ambiente, período de 10/06 a 07/07/02.</i>	77
<i>Figura 16. Florianópolis, Umidade Relativa do Ar, período de 10/06 a 07/07/02.</i>	77
<i>Figura 17. TDE, Potência Ativa, período de 10/06 a 07/07/02.</i>	78
<i>Figura 18 – Distribuição do RMSE, em relação ao desvio padrão, ajuste de 100 exp. em ICO - Inverno</i>	88
<i>Figura 19 – Distribuição do RMSE, por faixa de valores, no ajuste em 100 exp. para ICO - Inverno</i>	89
<i>Figura 20 - Precipitação típica em Santa Catarina – Janeiro (in, CLIMERH,2002)</i>	134
<i>Figura 21 - Precipitação típica em Santa Catarina – Fevereiro (in, CLIMERH,2002)</i>	134
<i>Figura 22 - Precipitação típica em Santa Catarina – Março (in, CLIMERH,2002)</i>	135
<i>Figura 23 - Precipitação típica em Santa Catarina – Abril (in, CLIMERH,2002)</i>	135
<i>Figura 24 - Precipitação típica em Santa Catarina – Maio (in, CLIMERH,2002)</i>	136
<i>Figura 25 - Precipitação típica em Santa Catarina – Junho (in, CLIMERH,2002)</i>	136
<i>Figura 26 - Precipitação típica em Santa Catarina – Julho (in, CLIMERH,2002)</i>	137
<i>Figura 27 - Precipitação típica em Santa Catarina – Agosto (in, CLIMERH,2002)</i>	137
<i>Figura 28 - Precipitação típica em Santa Catarina – Setembro (in, CLIMERH,2002)</i>	138
<i>Figura 29 - Precipitação típica em Santa Catarina – Outubro (in, CLIMERH,2002)</i>	138
<i>Figura 30 - - Precipitação típica em Santa Catarina – Novembro (in, CLIMERH,2002)</i>	139
<i>Figura 31 - Precipitação típica em Santa Catarina – Dezembro (in, CLIMERH,2002)</i>	139
<i>Figura 32 – Área de Concessão da CELESC ([12] CELESC, 2003)</i>	141
<i>Figura 33 - Centros de Operação de Área da CELESC – Distribuição e Áreas de Abrangência</i>	145
<i>Figura 34 – Arquitetura do SDSC ([12] CELESC, 2003)</i>	147
<i>Figura 35 –Potência ativa ICO Verão</i>	149
<i>Figura 36 –Potência ativa ICO Outono</i>	149
<i>Figura 37 –Potência ativa ICO Inverno</i>	150

<i>Figura 38 –Potência ativa TDE Verão</i>	150
<i>Figura 39 –Potência ativa TDE Outono</i>	151
<i>Figura 40 –Potência ativa TDE Inverno</i>	151
<i>Figura 41 –Potência ativa INE Verão</i>	152
<i>Figura 42 –Potência ativa INE Outono</i>	152
<i>Figura 43 –Potência ativa INE Inverno</i>	153
<i>Figura 44 –Potência ativa ISS Verão</i>	153
<i>Figura 45 –Potência ativa ISS Outono</i>	154
<i>Figura 46 –Potência ativa ISS Inverno</i>	154
<i>Figura 47 –Potência ativa SRA Verão</i>	155
<i>Figura 48 –Potência ativa SRA Outono</i>	155
<i>Figura 49 –Potência ativa SRA Inverno</i>	156
<i>Figura 50 –Potência ativa SAD Verão</i>	156
<i>Figura 51 –Potência ativa SAD Outono</i>	157
<i>Figura 52 –Potência ativa SAD Inverno</i>	157
<i>Figura 53 –Temperatura ambiente Florianópolis Verão</i>	158
<i>Figura 54 – Temperatura ambiente Florianópolis Outono</i>	158
<i>Figura 55 – Temperatura ambiente Florianópolis Inverno</i>	159
<i>Figura 56 – Temperatura ambiente Itajaí Verão</i>	159
<i>Figura 57 – Temperatura ambiente Itajaí Outono</i>	160
<i>Figura 58 – Temperatura ambiente Itajaí Inverno</i>	160
<i>Figura 59 –Temperatura ambiente Seara Verão</i>	161
<i>Figura 60 – Temperatura ambiente Seara Outono</i>	161
<i>Figura 61 – Temperatura ambiente Seara Inverno</i>	162
<i>Figura 62 - Rede MLP de 3 camadas</i>	163
<i>Figura 63 - Rede RBF de 3 camadas (in ORR, 1996)</i>	166

ÍNDICE DE TABELAS

<i>Tabela 1 - Resultados da Etapa I: modelo adaptativo versus Oliveira, 1999</i>	71
<i>Tabela 2 - Etapa I: resultados com a aplicação dos Modeladores de 1ª e 2ª Ordem</i>	72
<i>Tabela 3 - Grupo A – Precisão dos melhores experimentos com Carga e Todas as Variáveis Climáticas</i>	84
<i>Tabela 4 - Grupo A – Comparativo de erro (RMSE), ajuste para grupos distintos de variáveis candidatas</i>	86
<i>Tabela 5 - Grupo A – Relação das variáveis climáticas com a precisão da adaptação</i>	87
<i>Tabela 6 - Grupo A – Variação do erro (RMSE) no ajuste em 100 experimentos para ICO - Inverno</i>	88
<i>Tabela 7 - Grupo B – RMSE (MW) no ajuste (treino) utilizando modelos adaptados para a mesma e para outras estações climáticas no Ponto</i>	90
<i>Tabela 8 - Grupo B – Ganho (%) no ajuste (treino) com uso do modelo adaptado para a estação climática dos dados, no Ponto.</i>	90
<i>Tabela 9 - Grupo B – Ganho (%), com grau de confiança de 95,4%, no ajuste (treino) com uso do modelo adaptado para a estação climática dos dados, no Ponto.</i>	91
<i>Tabela 10 - Grupo B – Relação da estação climática com a precisão, em um Ponto</i>	92
<i>Tabela 11 - Grupo C – RMSE (MW) no ajuste (treino) para um dado Ponto, utilizando modelos adaptados para o mesmo Ponto e para outros Pontos, na mesma estação climática</i>	93
<i>Tabela 12 - Grupo C – Ganho (%) no ajuste (treino) com uso do modelo adaptado para o mesmo Ponto do ajuste em relação a modelos adaptados para outros Pontos, em uma mesma estação climática.</i>	94
<i>Tabela 13 - Grupo C – Ganho (%), com grau de confiança de 95,4%, no ajuste (treino) com uso do modelo adaptado para o mesmo Ponto do ajuste em relação a modelos adaptados para outros Pontos, em uma mesma estação climática.</i>	94
<i>Tabela 14 - Grupo C – Relação do Ponto com a precisão, em uma estação climática</i>	96
<i>Tabela 15 - Conjunto de variáveis candidatas e sua forma de representação na RNA</i>	113
<i>Tabela 16 - Períodos de Ocorrência de El Niño e La Nina (NCEP/NOAA, in CLIMERH, 2002)</i>	130
<i>Tabela 17 – CELESC em Números ([12] CELESC, 2003)</i>	142
<i>Tabela 18 – Linhas de Transmissão ([12] CELESC, 2003)</i>	142
<i>Tabela 19 – Redes de Distribuição ([12] CELESC, 2003)</i>	143
<i>Tabela 20 - Subestações ([12] CELESC, 2003)</i>	143
<i>Tabela 21 – Transformadores de Subestação ([12] CELESC, 2003)</i>	143
<i>Tabela 22 - Transformadores de Subestação por Região ([12] CELESC, 2003)</i>	144
<i>Tabela 23 - Grupo A – ICO: Precisão com Carga e Todas as Variáveis Climáticas</i>	171
<i>Tabela 24 - Grupo A – INE: Precisão com Carga e Todas as Variáveis Climáticas</i>	172
<i>Tabela 25 - Grupo A – TDE: Precisão com Carga e Todas as Variáveis Climáticas</i>	173
<i>Tabela 26 - Grupo A – SRA: Precisão com Carga e Todas as Variáveis Climáticas</i>	174
<i>Tabela 27 - Grupo A – ISS: Precisão com Carga e Todas as Variáveis Climáticas</i>	175
<i>Tabela 28 - Grupo A – SAD: Precisão com Carga e Todas as Variáveis Climáticas</i>	176
<i>Tabela 29 - Grupo A – ICO: Precisão com Carga e Temperatura Ambiente</i>	177

<i>Tabela 30 - Grupo A –INE: Precisão com Carga e Temperatura Ambiente</i>	178
<i>Tabela 31 - Grupo A – TDE: Precisão com Carga e Temperatura Ambiente</i>	179
<i>Tabela 32 - Grupo A – SRA: Precisão com Carga e Temperatura Ambiente</i>	180
<i>Tabela 33 - Grupo A – ISS: Precisão com Carga e Temperatura Ambiente</i>	181
<i>Tabela 34 - Grupo A – SAD: Precisão com Carga e Temperatura Ambiente</i>	182
<i>Tabela 35 - Grupo A – ICO: Precisão com Carga</i>	183
<i>Tabela 36 - Grupo A – INE: Precisão com Carga</i>	184
<i>Tabela 37 - Grupo A – TDE: Precisão com Carga</i>	185
<i>Tabela 38 - Grupo A – SRA: Precisão com Carga</i>	186
<i>Tabela 39 - Grupo A – ISS: Precisão com Carga</i>	187
<i>Tabela 40 - Grupo A – SAD: Precisão com Carga</i>	188
<i>Tabela 41 - Grupo A – ICO: Carga e Todas as Variáveis Climáticas</i>	190
<i>Tabela 42 - Grupo A – INE: Carga e Todas as Variáveis Climáticas</i>	195
<i>Tabela 43 - Grupo A – ISS: Carga e Todas as Variáveis Climáticas</i>	200
<i>Tabela 44 - Grupo A – SAD: Carga e Todas as Variáveis Climáticas</i>	205
<i>Tabela 45 - Grupo A – SRA: Carga e Todas as Variáveis Climáticas</i>	210
<i>Tabela 46 - Grupo A – TDE: Carga e Todas as Variáveis Climáticas</i>	215

SUMÁRIO

1. INTRODUÇÃO	15
1.1 Definição e Evolução do Problema	15
1.2 Objetivos	21
1.3 Justificativa.....	22
1.4 Metodologia	23
1.5 Abrangência do Trabalho	24
1.6 Organização do Trabalho	25
2. PREVISÃO DE CARGA E INTELIGÊNCIA ARTIFICIAL.....	26
2.1 Redes Neurais Artificiais em Previsão de Cargas	26
2.2 Arquitetura Perceptron Múltiplas Camadas	30
2.3 Arquitetura de Base Radial.....	31
2.4 Algoritmos Genéticos.....	33
2.5 Entrada e Saída da Rede Neural Artificial.....	35
2.6 Avaliação da Rede Neural Artificial	38
3. O MODELO PROPOSTO	41
3.1 Sistema de Previsão.....	41
3.2 Previsor Especialista.....	43
3.2.1 Modelador Neuro-adaptativo.....	48
3.2.2 Modelador Evolutivo de 1ª Ordem.....	51
3.2.3 Modelador Evolutivo de 2ª Ordem.....	56
4. O OBJETO DE ESTUDO	58

5.	EXPERIMENTAÇÃO.....	65
5.1	Etapa I	66
5.1.1	Organização dos Experimentos	67
5.1.2	Resultados Numéricos e Discussões.....	70
5.2	Etapa II.....	79
5.2.1	Organização dos Experimentos	79
5.2.2	Resultados Numéricos e Discussões.....	81
6.	CONSIDERAÇÕES FINAIS	97
6.1	Conclusões	97
6.2	Principais Contribuições do Trabalho	99
6.3	Recomendações.....	100
7.	REFERÊNCIAS BIBLIOGRÁFICAS.....	103
8.	ANEXOS	111
8.1	Conjunto de Variáveis Candidatas ao Vetor de Entrada da RNA.....	112
8.2	O Clima no Estado de Santa Catarina	128
8.3	Visão geral da CELESC.....	140
8.4	Sistema Hipotético: Condições Climáticas e Comportamento da Carga.....	148
8.5	Arquitetura Perceptron Múltiplas Camadas	163
8.6	Arquitetura de Base Radial.....	166
8.7	Experimentos do Grupo A: Precisão de Ajuste e Previsão	170
8.8	Experimentos do Grupo A: Variáveis selecionadas na Adaptação	189

1. INTRODUÇÃO

1.1 Definição e Evolução do Problema

A energia elétrica é um bem indispensável à existência da sociedade humana atual. Ela é um insumo básico - nos meios urbano e rural - para residências, comércios, indústrias, bancos, hospitais, empresas, órgãos governamentais e demais entidades de nossa sociedade. Presente no dia a dia do homem moderno, ela é utilizada tanto nas atividades essenciais como iluminação, aquecimento, refrigeração, conservação de alimentos e acionamento de equipamentos hospitalares de suporte à vida, quanto nas não essenciais como acionamento de aparelhos de rádio e televisão, outdoors e equipamentos de recreação e lazer.

Largamente consumida, a forte dependência deste tipo de energia e seu complexo processo de produção, distribuição e consumo geralmente passam despercebidos. A energia elétrica possui características que a diferencia dos demais insumos industriais (ANEEL, 2001). Ela precisa ser gerada simultaneamente ao seu consumo, não pode ser armazenada pelos seus consumidores em grande escala, tampouco transportada pelos meios usuais de transporte e sua qualidade depende tanto das empresas, que a produzem, transmitem e distribuem, como dos seus consumidores.

Em função destas características, é de grande importância para os *agentes*¹ envolvidos com a geração, transmissão e distribuição de energia elétrica conhecer a futura *demanda de energia elétrica*² no *sistema de potência*³. Este conhecimento prévio é de

¹ São os agentes, tanto privados quanto públicos, que atuam no setor de geração, transmissão e distribuição de energia elétrica, tais como as usinas, as empresas de transmissão, as concessionárias de distribuição, e os organismos de controle e planejamento global do sistema.

² É o consumo de energia elétrica, tanto da energia ativa como da reativa, efetuada pelos clientes conectados a um sistema de distribuição de eletricidade.

³ É o sistema de geração, transmissão e distribuição de energia elétrica, constituído pelas usinas geradoras, linhas de transmissão e subestações.

grande ajuda em várias de suas atividades diárias efetuadas pelos diversos agentes, tais como o despacho de usinas, a operação do sistema de transmissão e distribuição de energia elétrica, a compra e venda de energia e o planejamento da construção de usinas, subestações e redes de transmissão e distribuição de energia elétrica. Em consequência disto, uma das atividades desenvolvidas pelos agentes é a elaboração de previsões sobre o comportamento futuro do consumo de energia elétrica (previsões de carga). O ponto futuro considerado compreende um horizonte que pode variar de minutos ou horas até anos à frente.

As previsões de carga são necessárias tanto para as cargas nos *nós*⁴ (carga nodal) mais relevantes quanto para a *carga total*⁵ do sistema de potência. Elas podem ser classificadas em função do ponto futuro considerado, como de curtíssimo, curto, médio ou longo prazo. As previsões de curtíssimo prazo são as previsões de carga de poucos minutos até uma hora à frente. Elas são usadas para auxiliar atividades de operação do sistema elétrico, tais como despacho econômico e avaliação da segurança. Já as previsões de curto prazo dizem respeito às previsões da carga horária em um período de até uma semana à frente. Elas são utilizadas na programação da manutenção e no auxílio à operação do sistema elétrico. As previsões de médio prazo, prevendo as cargas semanas ou meses à frente, são utilizadas nos planejamentos da produção e do intercâmbio de energia entre diferentes empresas de energia elétrica. Enfim as de longo prazo, procuram prever as cargas anos à frente e fornecem subsídios para o planejamento estratégico, tal como a previsão de construção das usinas, subestações e redes de transmissão e distribuição de energia elétrica.

A precisão da previsão é de grande importância na gerência da produção e distribuição da eletricidade. Previsões com alto grau de precisão possibilitam otimizar a produção, reduzir os custos de produção, melhorar a coordenação hidro-térmica e melhorar a programação para as transferências de energia entre partes do sistema elétrico de uma concessionária ou entre sistemas elétricos de companhias distintas. Um sistema de previsão de cargas preciso é capaz de prover segurança, confiabilidade e economia para a operação de um sistema de potência (Bakirtzis, Petridis, et al., 1995, Bakirtzis, Theocharis, et al.,

⁴ Os nós considerados são os barramentos dos transformadores das subestações, as subestações e os pontos de interconexão com outros sistemas de potência.

1995, Xiao & McLaren, 1995, Zebulum et al., 1996). Segundo Choueiki et al. (1997), para uma concessionária de eletricidade do Reino Unido, um incremento de 1% no erro da previsão de curto prazo causa um aumento nos custos operacionais anuais de 10 milhões de libras. Kiartzis et al. (1997) cita também o fato de que as funções fundamentais existentes em modernos Sistemas de Gerenciamento de Energia (“*Energy Management Systems*” – EMS) fiam-se em previsões de carga de curto prazo precisas. Para este autor, a desregulamentação do setor elétrico e o conseqüente aumento na competição resultante, fazem com que a capacidade de elaborar previsões de forma precisa, seja um importante fator para o futuro sucesso de uma companhia de energia elétrica.

Por outro lado, ao se observar o comportamento do mercado consumidor de energia elétrica, constata-se um crescimento do nível de exigência quanto aos índices de qualidade e continuidade no fornecimento de energia. Níveis de oscilação na tensão e de interrupção de fornecimento até a pouco tempo considerados normais não são atualmente tolerados. A isto se soma a redução da disponibilidade de recursos energéticos renováveis e o acirramento da competição entre as concessionárias de energia elétrica gerado pela desregulamentação do setor. Estes fatos geram para uma concessionária de eletricidade, a necessidade de reduzir seus custos operacionais, diminuindo o desperdício na geração e distribuição de energia elétrica, e de exercer maior controle sobre seu sistema de potência, com sua operação sendo conduzida dentro de limites cada vez mais justos. Para a função de previsão de cargas, a conseqüência, além da busca por maior precisão nas previsões apontada em Kiartzis et al. (1997), é a necessidade de também conhecer a demanda futura da carga em prazos cada vez menores e para um número maior de nós do sistema de potência controlado. Os trabalhos de AlFuhaid et al. (1997), Liu et al. (1995) e Martin (1996), relativos a previsões de curtíssimo prazo, para os próximos 30min. e 5min., e de Leite (1997), a respeito da previsão da carga nodal, demonstram esforços nesta direção. Por fim, cabe lembrar que o aumento do número de nós e a redução dos horizontes das previsões implicam na necessidade de se dispor de um volume maior de informações renovadas em intervalos de tempo cada vez menores, a respeito do estado do processo controlado.

A tendência geral de automação dos processos produtivos se estende aos *Centros de*

⁵ É a soma das demandas individuais em todos os nós do sistema de potência.

*Operação de Sistema*⁶ – C.O.S das companhias de energia elétrica. Um exemplo disto é a crescente utilização de sistemas SCADA (“*Supervisory, Control and Data Acquisition*”) para supervisão e controle, em tempo real, dos sistemas de potência das concessionárias. O emprego do SCADA disponibiliza leituras de grandezas elétricas, em tempo real, para uma enorme quantidade de nós do sistema de potência controlado. A disponibilidade desta imensa gama de leituras em prazos tão curtos torna viável a construção de sistemas automáticos de previsão de cargas, globais e nodais, de curtíssimo e curto prazo. Tais sistemas, funcionando em tempo real e em fina sintonia com o SCADA, podem utilizar, de forma quase instantânea, as leituras disponibilizadas.

Prever o comportamento futuro da demanda por potência - previsão de carga – não é uma tarefa trivial. O relacionamento entre carga e fatores exógenos ao sistema elétrico é complexo e não linear (Carpinteiro & Alves da Silva, 2000, Carpinteiro et. al. 2000). A extensa bibliografia na área cita que o valor da carga futura possui relação, dentre outros, com o valor de cargas passadas, de variáveis climáticas, tal como a temperatura ambiente, com o ciclo das estações do ano, com o nível de atividade econômica e com indicadores de vida social tais como: dia da semana, hora do dia e feriados. Assim, a construção de modelos que explicitem esta relação enfrenta a dificuldade da modelagem de relacionamentos não lineares.

Outro fato a ser considerado é que, associado ao curso evolutivo das sociedades humanas, observa-se um constante aumento na demanda por energia, bem como uma alteração no comportamento desta demanda. O crescimento e alteração do comportamento da demanda por energia elétrica em um dado espaço geográfico se deve, entre outros fatores, ao crescimento populacional, a trocas na organização de espaços e de seus usos, e a alteração nos hábitos de consumo causados pelas alterações nas bases tecnológica e cultural das comunidades que ocupam um dado espaço. Esta dinâmica implícita à evolução da humanidade contribui para o comportamento dinâmico dos sistemas de energia elétrica e traz mais um complicador à previsão de carga, ajudando a tornar os modelos obsoletos com o passar do tempo.

Ao longo de anos e até a atualidade, o problema de previsão de carga vem sendo

⁶ São as áreas responsáveis pela operação dos sistemas de produção, transmissão e distribuição de energia elétrica das concessionárias de energia elétrica.

utilizado pela ciência como objeto de pesquisa. A previsão de carga de curto prazo foi inicialmente explorada a partir da ótica da Estatística, através do uso de modelos estatísticos, tais como de regressão e de séries temporais (“*time series*”), os quais mostraram-se ineficientes em prover limites aceitáveis de precisão (Dash et al., 1999). Devido às características do problema e dos avanços alcançados na área da Ciência da Computação, em especial em relação à capacidade de computação das máquinas e às técnicas da área da Inteligência Artificial - IA, se verifica nos últimos anos uma forte tendência do emprego de tais técnicas, em especial a técnica de Redes Neurais Artificiais – RNAs, no tratamento do problema em questão.

As RNAs têm tido sucesso com a previsão de cargas (Zebulum et al., 1996, Khotanzad et al., 1998). Elas possuem a habilidade para construir um relacionamento não linear entre suas entradas e suas saídas, através do aprendizado por exemplos. Seu emprego nos modelos de previsão de carga começou a ocorrer de forma intensa em fins da década de 80, após o surgimento do algoritmo de Retropropagação (Rumelhard et al., 1986a, Rumelhard et al., 1986b). Tais modelos para previsão foram inicialmente construídos a partir de uma única RNA clássica, a exemplo dos modelos de Lu et al. (1993) e de Xiao & McLaren (1995). A seguir, os modelos tornaram-se mais complexos, evoluindo para modelos modulares, compostos por módulos especializados, modelos híbridos, combinando diversas técnicas em um mesmo modelo, ou modelos modulares e híbridos. Como exemplos pode-se citar o modelo modular de AlFuhaid et al. (1997), o modelo híbrido de Dash et al. (2000) e o modelo modular e híbrido de Zhang & Dong (2001).

Conforme discutido anteriormente, o comportamento da demanda por carga é dinâmico e tem relação com o clima, a destinação e o uso do espaço e o estágio de desenvolvimento da sociedade, dentre outros. Em relação a estes aspectos, observa-se que os modelos de previsão de carga de curtíssimos e curtos prazos atuais, geralmente baseados em RNAs, i) ainda são normalmente construídos e ajustados a partir de necessidades particulares e ii) não são suficientemente enfáticos em relação à heterogeneidade e dinâmica dos mercados de energia elétrica. Também não se observa consenso ou a adoção de padrões para a sua construção, seja na escolha do modelo de rede neural, na arquitetura, na forma de construção modular e na escolha das variáveis de entrada e saída do modelo. Tais modelos de previsão normalmente têm suas variáveis

identificadas e definidas levando em conta apenas características locais e estáticas da demanda. Nestes, a capacidade de adaptabilidade não supervisionada usualmente limita-se àquela implícita ao treinamento das RNAs que os compõem.

Ao se estudar a demanda por carga em um sistema elétrico sujeito a dinâmica de um mercado composto por micro-regiões de consumo com características fortemente heterogêneas, quanto (a) ao clima, tanto no decorrer do ano quanto entre as várias micro-regiões, (b) à geografia e destinações e usos do espaço, (c) à economia e aspectos sócio-culturais da população, faz-se relevante a consideração das questões que se seguem.

Questões

Em um modelo de previsão de cargas de curtíssimo e de curto prazo baseado em RNAs, existem diferenças entre si ou são iguais os conjuntos de variáveis de entrada da RNA que otimizam a previsão da carga para cada um dos nós deste sistema elétrico, em um dado instante de tempo?

Neste mesmo modelo de previsão, ocorrem alterações ao longo do tempo em cada conjunto de variáveis de entrada da RNA que otimiza a previsão de carga em cada um dos nós deste sistema elétrico?

Como projetar um sistema de previsão de carga nodal de curtíssimo e de curto prazo que seja ágil e autônomo o suficiente para que possa funcionar associado a um sistema SCADA com um mínimo de intervenção humana?

Como projetar tal sistema de previsão de forma a dotá-lo de uma arquitetura de uso geral, mas que ao mesmo tempo possua a capacidade de adaptação, adaptando-se às diversas características micro-regionais da demanda por carga em um dado sistema elétrico com um mínimo de intervenção humana?

Como incluir no projeto deste sistema de previsão a capacidade de que, após a adaptação inicial, este seja capaz de evoluir, acompanhando, simultaneamente, à dinâmica da demanda por carga nos vários nós deste sistema elétrico, com um mínimo de intervenção humana?

Hipóteses

Considere-se um sistema elétrico sujeito à dinâmica de um mercado composto por nós (micro-regiões de consumo) com características fortemente heterogêneas, conforme descrito anteriormente.

Supõe-se que o conjunto das variáveis de entrada da RNA que otimiza a previsão de carga para cada um dos nós deste sistema elétrico seja específico para cada um destes nós, considerando-se um determinado instante de tempo.

Supõe-se que o conjunto das variáveis de entrada da RNA que otimiza a previsão de carga em um dado nó deste sistema elétrico, altera-se com o passar do tempo.

Supõe-se possível projetar um sistema de previsão de carga nodal ativa de curtíssimo e de curto prazo, dotando-o de uma arquitetura de uso genérico, mas que possua a capacidade de adaptação, moldando-se às características da demanda por carga nos vários nós de um sistema elétrico e de evoluir, acompanhando a dinâmica da demanda por carga, e ainda necessitando de um baixo nível de intervenção humana.

1.2 Objetivos

O objetivo geral deste trabalho é propor um modelo para um sistema de previsão de cargas de curtíssimo e de curto prazo que leve em conta as diferenças regionais e a dinâmica da demanda por carga em um mercado de energia elétrica heterogêneo como o do Estado de Santa Catarina.

Os objetivos específicos são:

- a) Propor um modelo para um sistema de previsão de cargas de curtíssimo e de curto prazo, $\frac{1}{2}$ hora à frente em uma janela de uma semana, que seja dotado das características de agilidade, autonomia, adaptação e evolução, necessitando de baixo nível de intervenção humana de forma a facilitar seu uso associado a um sistema SCADA;
- b) Dotar este sistema de previsão da capacidade adaptação, de forma que possa

ajustar-se e acompanhar a dinâmica de um mercado de energia elétrica composto por micro-regiões de consumo com características fortemente heterogêneas, quanto (i) ao clima, tanto no decorrer do ano quanto entre as várias micro-regiões, (ii) à geografia e destinações e usos do espaço e (iii) à economia e aspectos sócio-culturais da população.

- c) Construir, *validar*⁷ e *verificar*⁸ a parte do modelo proposto relativa à capacidade de adaptação;
- d) Testar a validade da hipótese de pesquisa da diferença entre os conjuntos de variáveis de entrada da RNA que otimizam a previsão de carga para os vários nós de um sistema elétrico como o anteriormente descrito, para um dado instante de tempo;
- e) Testar a validade da hipótese de pesquisa da diferença entre os conjuntos de variáveis de entrada da RNA que otimizam a previsão de carga para um determinado nó de um sistema elétrico como o anteriormente descrito, ao longo do tempo;
- f) Empregar o modelo nos testes das hipóteses relacionadas às dependências regional e temporal das variáveis de entrada da RNA.

1.3 Justificativa

É um fato inquestionável a necessidade de se conhecer previamente o comportamento futuro da demanda da carga de curto prazo. Os inúmeros trabalhos disponíveis na literatura demonstram sua importância e os esforços empreendidos nesta direção. Porém, observa-se uma lacuna na investigação relacionada aos estudos das variações no comportamento da demanda por carga no que se referem à heterogeneidade dos sistemas de potência e as suas dinâmicas, em especial no que se refere ao sistema de

⁷ Define-se **validação** como o processo de assegurar-se de que o programa computacional, construído de forma a simular o modelo, funciona sem erros e da forma esperada pelos projetistas e implementadores.

⁸ Define-se **verificação** como o processo de mensurar e interpretar os resultados produzidos pelo modelo.

potência que abastece o mercado de energia elétrica do Estado de Santa Catarina. Observa-se também uma deficiência dos sistemas de previsão de cargas atuais no que tange às suas capacidades de adaptação, excluindo-se as implícitas ao funcionamento das redes neurais artificiais.

Este trabalho traz novos conhecimentos aos temas descritos acima, bem como propõe uma forma de aumentar a capacidade de adaptação dos modelos de previsão de cargas atuais. Isto contribui para (a) uma maior precisão dos modelos de previsão de carga nodal de curtíssimos e de curtos prazos, (b) facilitar o emprego de tais sistemas de previsão por companhias de energia elétrica distintas e/ou que atendam a mercados de energia elétrica com características heterogêneas e (c) reduzir a obsolescência destes sistemas de previsão, decorrente da dinâmica da demanda por carga nos sistemas de potência.

1.4 Metodologia

O trabalho foi dividido em 6 macros atividades, nomeadas: escolha do sistema hipotético, levantamento e estudo da situação atual, obtenção e análise de dados, revisão bibliográfica, proposição de um modelo inicial e experimentação. Na etapa de escolha do sistema hipotético, foi inicialmente escolhido o sistema elétrico da CELESC - Centrais Elétricas de Santa Catarina para servir como base inicial para o estudo proposto. A seguir procedeu-se uma análise do sistema da CELESC para a definição e delimitação de uma subárea do mesmo que foi denominada de sistema hipotético e que foi utilizada para elaboração dos trabalhos. Na atividade de levantamento e estudo da situação atual foi levantado o conhecimento dos técnicos da CELESC acerca do comportamento da demanda por carga no sistema elétrico da CELESC, especialmente o comportamento da demanda no sistema hipotético. Esta atividade foi executada em paralelo com a atividade anterior, na medida em que os diversos nós que compuseram o sistema hipotético foram sendo escolhidos. Na etapa de obtenção e análise de dados foi obtido, consistido e cruzado as medições de carga e temperatura ambiente do sistema SCADA da CELESC relativas aos nós do sistema hipotético, com as medições de velocidade e direção do vento da CELESC e as medições das condições climáticas do CLIMERH - Centro de Informações e Estudos Climáticos do Estado de Santa Catarina e do LABSOLAR/NCTS da Universidade Federal de Santa Catarina. Ainda nesta etapa, as medições disponíveis foram consistidas e

transformadas em informações utilizadas pelo modelo. Na etapa de revisão bibliográfica, foi investigado o estado da arte em modelos de previsão de carga, as variáveis de entrada e saída utilizadas nos modelos já propostos, os modelos de RNAs passíveis de serem empregados no modelo de previsão a ser proposto e técnicas capazes de fundamentar o projeto da estrutura evolutiva-adaptativa do modelo a ser proposto. Na etapa de proposição do modelo foi elaborada uma proposta de modelo de previsão de cargas nodais de curto prazo, ½ hora à frente em uma janela de uma semana. O modelo proposto foi projetado de forma a possuir características de agilidade, autonomia e comportamento adaptativo-evolutivo, de forma a facilitar seu uso associado a um sistema do tipo SCADA. Ainda nesta etapa também foi construído a parte do modelo responsável pela capacidade de adaptação-evolução, o que facilitará os testes das hipóteses relacionadas às dependências regional e temporal das variáveis de entrada da RNA. Por fim, na última etapa que é a de experimentação, se buscou a validação das hipóteses de pesquisa e validação e verificação do funcionamento da parte do modelo que foi construída. Os trabalhos desta última etapa foram realizados por meio de simulação computacional.

1.5 Abrangência do Trabalho

Os estudos tiveram como objeto o mercado de energia elétrica do Estado de Santa Catarina e o sistema elétrico da CELESC, que é a responsável pelo abastecimento de energia elétrica deste Estado, em quase sua totalidade. O mercado de energia do Estado de Santa Catarina, foi escolhido por ser composto por micro-regiões de consumo com características heterogêneas e apresentar variação no comportamento da carga relacionada às estações climáticas do ano.

Em virtude dos prazos estabelecidos para conclusão deste trabalho, foram construídas, validadas e verificadas apenas as partes principais do modelo, responsáveis pelas capacidades adaptativa-evolutiva e preditiva do mesmo. Estas partes foram empregadas para auxiliar nos testes das hipóteses de pesquisa relacionadas às dependências regional e temporal das variáveis de entrada da RNA, utilizando como objeto de estudo o sistema hipotético escolhido e as medições de carga e condições climáticas, relativas a sua área de abrangência, dos anos de 2001 a 2003. O ano de 2001 foi utilizado como marco inicial porque é aproximadamente a partir deste ano que existem disponíveis

históricos das medições de carga monitoradas pelo sistema SCADA da CELESC. Os históricos de leituras relativas à carga e ao clima anteriores a este período, não serão utilizados devido à baixa confiabilidade na sua precisão. Ainda, com relação ao modelo proposto, foi experimentada apenas a função Gaussiana como função de base radial para a RNA. Neste estudo, não foram abordadas as questões da consistência das medições a serem utilizadas pelo sistema de previsão de cargas e das conseqüências à atividade de previsão do modelo de geração distribuída e produtores independentes de energia, injetando potência no sistema elétrico.

1.6 Organização do Trabalho

O trabalho final foi organizado em 6 capítulos: Introdução, Previsão de Carga e Inteligência Artificial, O Modelo Proposto, O Objeto de Estudo, Experimentação e finalmente Considerações Finais. A Introdução apresenta o problema objeto deste trabalho, seu contexto, sua evolução no tempo e o conhecimento científico acumulado a seu respeito. Apresenta ainda as questões e hipóteses de trabalho, os objetivos estabelecidos, a justificativa para tal empreendimento, a metodologia adotada para atingir tais objetivos, a abrangência estabelecida para o trabalho e sua organização. O Capítulo II, Previsão de Carga e Inteligência Artificial, apresenta a base teórica utilizada para o desenvolvimento do trabalho. O Capítulo III, intitulado O Modelo Proposto, apresenta o modelo proposto para tratar o problema alvo e facilitar o teste das hipóteses. O Capítulo IV, O Objeto de Estudo, apresenta o sistema hipotético que foi utilizado para realização do trabalho. O Capítulo V, Experimentação, descreve os processos de construção, validação e verificação do modelo proposto e os testes das hipóteses de pesquisa. Finalmente, o Capítulo VI, Considerações Finais, relata as conclusões acerca do trabalho empreendido e apresenta as recomendações para futuros trabalhos relacionados à previsão de cargas.

2. PREVISÃO DE CARGA E INTELIGÊNCIA ARTIFICIAL

2.1 Redes Neurais Artificiais em Previsão de Cargas

Inteligência Artificial – IA é uma área de conhecimento cujo propósito é o desenvolvimento de paradigmas ou algoritmos que requeiram máquinas para realizar tarefas que aparentemente necessitam *cognição* quando realizadas por humanos (Haykin, 1994). Tafner et. al. (1995) definem IA como um conjunto de técnicas de programação que têm como característica comum desempenhar funções que são normalmente associadas à inteligência humana, tais como: raciocínio, aprendizagem e auto-aperfeiçoamento. Inclui-se neste conjunto a técnica de Redes Neurais Artificiais – RNAs.

Inspiradas nas redes neurais biológicas, as Redes Neurais Artificiais tem sido aplicadas com sucesso na solução problemas em vários e distintos domínios, tais como: processamento de sinais, controle, reconhecimento de padrões, medicina, reconhecimento e produção de voz, e negócios (Fausett, 1994). Uma de suas propriedades, de importância fundamental, é a capacidade de aprender a partir de seu ambiente e de aperfeiçoar sua performance através do aprendizado (Haykin, 1994).

A previsão de cargas pode ser formulada como um problema onde o que se deseja é proceder a um mapeamento não linear entre as entradas e as saídas de um sistema, representadas através de um par de vetores onde um deles contém as entradas (grandezas com valores conhecidos a “*priori*”) e o outro as saídas (grandezas cujos valores futuros se deseja conhecer) do sistema. De acordo com Dandolini (1997), as Redes Neurais Artificiais propiciam uma forma relativamente fácil para modelar e prever sistemas não lineares. Elas possuem a capacidade de construir um relacionamento não linear entre as entradas e saídas de um sistema, representadas pelas entradas e saídas da rede, através do aprendizado por exemplos (dispensando a necessidade de um especialista). As RNAs são muito eficientes na aprendizagem de padrões em dados com ruído, incompletos e que podem conter dados contraditórios. Também são eficientes em questões onde especialistas

são ineficazes ou onde regras claras a respeito do comportamento do problema em questão não podem ser facilmente formuláveis.

As Redes Neurais Artificiais têm tido sucesso também com a previsão de cargas (Zebulum et al., 1996, Khotanzad et al., 1998). Devido à habilidade para construção de relacionamentos não lineares entre suas entradas e suas saídas, através do aprendizado por exemplos, elas não necessitam da identificação de um relacionamento funcional explícito entre cargas passadas, condições climáticas e a carga a ser prevista (Bakirtzis, Petridis, et al., 1995). Para Kiartzis (Kiartzis et al., 1997), esta capacidade de aprender o relacionamento funcional entre as entradas do sistema (cargas passadas e condições climáticas) e suas saídas (as cargas futuras) através de exemplos torna as Redes Neurais Artificiais previsores ideais para este campo de aplicação. Dentre os inúmeros trabalhos que empregam as RNAs em modelos de previsão de cargas, pode-se citar como exemplos os de AlFuhaid et al. (1997), Bakirtzis, Petridis, et al. (1995), Bakirtzis, Theocharis, et al. (1995), Bashir & El-Hawary (2000), Choueiki et al. (1997), Dash et al. (1993), Dash et al. (2000), Kiartzis et al. (1997), Khotanzad et al. (1995), Khotanzad et al. (1997), Khotanzad et al. (1998), Leite (1997), Lambert-Torres et al. (1997), Lu et al. (1993), Mastorocostas et al. (1999), Martin (1996), Reis & Alves da Silva (2002), Srinivasan (1998), Wakita & Yokoyama (1995), Xiao & McLaren (1995), Vellasco et al. (2004), Zebulum et al. (1996) e Zhang & Dong (2001).

O uso das RNAs em previsão iniciou-se em 1964 com o uso da rede linear adaptativa de Widrow para previsão do tempo. Porém, intensificou-se apenas em fins da década de 80, após o surgimento do algoritmo de Retropropagação (Rumelhard et al., 1986a, Rumelhard et al., 1986b) para treino de redes Perceptron Camadas Múltiplas – MLP (*Multilayer Perceptron*) (Zhang et al., 1998). A MLP é a arquitetura de RNA mais utilizada em modelos de previsão de cargas. Fogelman-Souliè (1995), citado em Dandolini (1997), classifica as RNAs, segundo suas principais áreas de atuação, em quatro categorias principais: *classificação e diagnóstico; aproximação de função; compressão, extração de características e quantização; otimização*. Sob esta ótica, o problema da previsão de cargas classifica-se como tratável pelas RNAs da categoria *aproximação de função*. As arquiteturas de Redes Neurais Artificiais Perceptron Múltiplas Camadas (*Multilayer Perceptron - MLP*) treinada com o algoritmo de Retropropagação (*Backpropagation*) e de Base Radial (*Radial Basis Function – RBF*) comportam-se como

aproximadores universais (Haykin, 1994).

Os modelos para previsão de cargas concebidos a partir da técnica de RNAs, foram inicialmente construídos a partir de uma única RNA clássica, tais como os de Choueiki et al. (1997), Kiartzis et al. (1997), Lu et al. (1993), Xiao & McLaren (1995), Zebulum et al. (1996), Bakirtzis, Petridis, et al. (1995), Bakirtzis, Theocharis, et al. (1995), Leite (1997), dentre outros. Em seguida, os modelos tornaram-se mais complexos, evoluindo para modelos modulares, modelos híbridos ou modelos modulares e híbridos. Os modelos modulares, como os de AlFuhaid et al. (1997), Carpinteiro et al. (2004), Dash et al. (1993), Khotanzad et al. (1995), Khotanzad et al. (1997), Khotanzad et al. (1998), Mastorocostas et al. (1999) e Satish et al. (2004) são modelos compostos por módulos especializados, usualmente RNAs. Os híbridos, como os de Bashir & El-Hawary (2000), Dash et al. (2000), Lambert-Torres et al. (1997) e Martin (1996), combinam diversas técnicas, principalmente as técnicas da área de IA (Sistemas Especialistas, Redes Neurais Artificiais, Conjuntos Difusos, dentre outras) e as técnicas da área de tratamento e filtragem de sinais, como a teoria de Wavelets. Nos modelos híbridos, a técnica de RNAs é normalmente uma das utilizadas. Os modelos modulares e híbridos combinam num mesmo modelo as características modulares com as híbridas, como os de Reis & Alves da Silva (2002) Srinivasan (1998), Vellasco et al. (2004) e Zhang & Dong (2001). Viswanathan, et al. (1999) apresenta uma interessante visão geral das estratégias e tendências empregadas por vários autores quanto a técnica para construção de modelos híbridos para previsão de carga.

Embora seja notada uma clara evolução dos modelos baseados em técnicas de Inteligência Artificial, observa-se que, a exemplo dos modelos propostos por AlFuhaid et al. (1997), Bakirtzis, Petridis et al. (1995), Bakirtzis, Theocharis et al. (1995), Kiartzis et al. (1997), Martin (1996) Mastorocostas et al. (1999) e Xiao & McLaren (1995), os modelos são normalmente construídos e ajustados a partir de necessidades particulares. Também não se observa consenso ou a adoção de padrões para a sua construção, seja na escolha do modelo de rede neural, na arquitetura, na forma de construção modular e na escolha das variáveis de entrada e saída do modelo.

As RNAs aprendem por meio de exemplos e os parâmetros internos às redes que necessitam serem ajustados variam em função do modelo de rede considerado. A

capacidade de aprender por meio de exemplos possibilita entender e modelar um determinado problema a partir dos dados (as observações) disponíveis a respeito do mesmo. Para um dado sistema elétrico composto de uma infinidade de nós (micro regiões de consumo), o problema de previsão de carga pode ser visto como sendo o histórico das observações disponíveis acerca dos comportamentos das demandas por carga nestes nós. Desta forma, cada nó considerado pode ser entendido como um problema distinto, ao qual precisa ser atribuído uma RNA com parâmetros e ajustes específicos para o dado nó.

Nos vários modelos baseados em RNAs empregados para previsão de carga, observa-se que, independente do modelo de RNA empregado, após a escolha inicial das variáveis de entrada e saída bem como de alguns dos parâmetros específicos do modelo de rede utilizado, normalmente estes são então mantidos fixos e aplicados para todo o sistema elétrico considerado. Os demais parâmetros do modelo são ajustados a partir da massa de dados disponível. A seguir, durante sua utilização, o mesmo recebe ajustes periódicos a partir da nova massa de dados disponível. Porém, as variáveis de entrada e saída do modelo e alguns dos parâmetros específicos do mesmo são mantidos inalterados.

Um dos poucos exemplos de emprego em larga escala de um modelo de previsão de curto prazo baseado em RNAs pode ser visto nos trabalhos de Khotanzad (Khotanzad et al., 1995, Khotanzad et al., 1997, Khotanzad et al., 1998). Nestes, ao se analisar a evolução do modelo em suas várias versões, observa-se uma tendência à simplificação e generalização, talvez voltada à necessidade de facilitar o suporte ao emprego em larga escala do mesmo. Nestes trabalhos é citado o emprego em larga escala do modelo, mas não é feita qualquer menção a sua adequação às especificidades de cada mercado, a exceção, é claro, da adequação implícita ao treinamento do modelo.

Conforme já discutido, o comportamento da demanda por carga é dinâmico e tem relação com o clima, a destinação e o uso do espaço e o estágio de desenvolvimento da sociedade, dentre outros. Em relação a estes aspectos, observa-se que os modelos de previsão de carga de curtíssimos e curtos prazos atuais, geralmente baseados em RNAs, i) ainda são normalmente construídos e ajustados a partir de necessidades particulares e ii) não são suficientemente enfáticos em relação à heterogeneidade e dinâmica dos mercados de energia elétrica. Ainda, não se observa consenso ou a adoção de padrões para a sua construção, seja na escolha do modelo de rede neural, na arquitetura, na forma de

construção modular e na escolha das variáveis de entrada e saída do modelo. Tais modelos de previsão normalmente têm suas variáveis identificadas e definidas levando em conta apenas características locais e estáticas da demanda. Nestes, a capacidade de adaptabilidade não supervisionada usualmente limita-se àquela implícita ao treinamento das RNAs que os compõem.

2.2 Arquitetura Perceptron Múltiplas Camadas

A arquitetura Perceptron Múltiplas Camadas (*Multilayer Perceptron*), treinada com o algoritmo de Retropropagação (*Backpropagation*), é o paradigma de Rede Neural Artificial de propósito mais geral e mais utilizado (Skapura, 1996). No domínio da previsão de cargas através de Redes Neurais Artificiais, a exemplo dos trabalhos de Kiartzis et al. (1997), Xiao & McLaren, (1995), e Zebulum et al., (1996), esta também é a arquitetura de RNA normalmente utilizada.

A Perceptron Múltiplas Camadas (*Multilayer Perceptron*), treinada com o algoritmo de Retropropagação (*Backpropagation*), é uma RNA não linear, de múltiplas camadas e de percorrimento à frente (*feedforward*). Esta RNA comporta-se como um aproximador universal. A MLP mostra-se um veículo prático para realização de um mapeamento não linear, de natureza geral, entre entrada e saída. Este tipo de treinamento é um método de gradiente descendente, usado para minimizar o erro quadrático total da saída computada pela rede (Fausett, 1994, Haykin, 1994, Skapura, 1996). O ANEXO 8.4 descreve de forma detalhada esta arquitetura de RNA.

A rede MLP pode ser vista como uma aplicação do método de otimização conhecido como *aproximação estocástica*. Treinada com o algoritmo de Retropropagação (*Backpropagation*), ela realiza aproximações locais para o mapeamento entre a entrada e a saída da rede. Por sua vez, treinada com o algoritmo Levenberg-Marquadt (Bazaraa et al., 1993) ela realiza aproximações globais. A principal desvantagem da MLP é a lentidão do processo de aprendizagem Haykin (1994), onde os parâmetros e serem estimados (pesos da rede) estão relacionados de forma não linear com a saída. Além disto, o desempenho da rede (sucesso do treinamento) é altamente dependente da atribuição inicial de valores aos pesos, normalmente realizada de forma aleatória. Embora os algoritmos de treinamento

venham evoluindo e se tornando mais rápidos e atingindo menores erros de treinamento quando comparados com o algoritmo de Retropropagação (*Backpropagation*) clássico, como é o caso do método Levenberg-Marquadt, persiste a falta de garantia de se atingir o mínimo global. Estes fatores dificultam a aplicação da arquitetura MLP em sistemas de tempo real.

2.3 Arquitetura de Base Radial

A arquitetura de Base Radial (*Radial Basis Function*), doravante denominada de RBF, é uma RNA múltiplas camadas e de percorrimento à frente (*feedforward*). Da mesma forma que a MLP, esta rede também se comporta como um aproximador universal. De acordo com Haykin (1994), sempre existe uma rede RBF capaz de reproduzir com precisão o comportamento de uma rede MLP, e vice versa. Segundo este autor, duas das características da arquitetura RBF são suas capacidade de aprendizado rápido e sensibilidade reduzida a ordem de apresentação dos dados de treinamento.

O método função de base radial tem suas origens nas técnicas de interpolação exata de um conjunto de dados dentro de um espaço multidimensional (Powell, 1987, cf. in Bishop, 1995). O aumento dimensional que ocorre na segunda camada (camada oculta) da rede está baseado no princípio, enunciado por Cover (1965, cf. in Haykin, 1994) de que um complexo problema de classificação de padrões lançado de forma não linear em um espaço de grande dimensão é mais fácil de ser linearmente separável do que em um espaço de pequena dimensão. Segundo Haykin (1994), a funcionalidade da RBF pode ser vista como o *ajuste de uma curva (aproximação)* em um espaço de grande dimensão. Visto sob esta perspectiva, o processo de aprendizado da RBF equivale a encontrar uma superfície em um espaço multidimensional que dá o melhor ajuste para os dados de treinamento. Generalização, nesta arquitetura equivale ao uso desta superfície multidimensional para interpolar os dados de teste. O ANEXO 8.6 descreve de forma detalhada esta arquitetura de RNA.

A rede RBF realiza aproximações locais para o mapeamento entre a entrada e a saída da rede. Sua principal vantagem é capacidade de aprendizado rápido e conseqüente possibilidade de operar em tempo real. Uma outra característica desta RNA, segundo

Bishop, 1995, é que a mesma tem dificuldade de ajustes quando no vetor de entrada há variáveis com variância significativa, porém que pouco contribuem para a determinação da saída da rede. Segundo este autor, para estes casos, estudos de Hartman (Hartman et al., 1990, in Bishop, 1995) mostram que a MLP aprende melhor como ignorar entradas irrelevantes, produzindo resultados mais precisos. Esta aparente superioridade da rede MLP, quando vista segundo a ótica dos objetivos deste trabalho, mostra-se na realidade uma desvantagem por tornar mais difícil entender o grau de influência das variáveis estudadas, dentre elas as relacionadas ao clima, no comportamento da carga futura. Além disso, o aumento do número de variáveis de entrada da rede neural está diretamente relacionado ao grau de complexidade da arquitetura da rede e ao número de padrões necessários para seu treino. Por sua vez, a necessidade de uma maior quantidade de exemplos de treino, decorrente do incremento no grau de complexidade da arquitetura da rede ou das características de funcionamento do modelo de rede neural, reflete na necessidade de uso de uma janela de tempo maior para os dados de treino. Isto penaliza a rede no aprendizado do comportamento dinâmico do sistema em questão.

Os resultados obtidos por Dandolini (1997) em seus experimentos com as arquiteturas MLP e RBF, buscando classificar empresas quanto as suas saúdes financeiras, ratificam as afirmações de Haykin (1994) a respeito da rapidez da RBF, quando comparada a MLP, e da equivalência destas duas arquiteturas quanto a capacidade de generalização. No decorrer de seu trabalho, a autora reporta como o melhor resultado alcançado a obtenção do percentual de acerto no teste, de 81,25% para ambas as arquiteturas MLP e RBF. Neste experimento, a rede RBF se mostrou 29 vezes mais rápida que a MLP. Na conclusão de seu trabalho, Dandolini, ao recomendar o uso da RBF para problemas de classificação, cita também a facilidade para a determinação dos parâmetros ótimos para a rede. Embora este enfoque (classificação) seja diferente do enfoque deste trabalho (previsão), em ambos os casos se deseja que a RNA realize a aproximação de uma função não linear, bem como possua capacidade de generalização. Os resultados de Dandolini (1997) são confirmados pelos trabalhos de Oliveira (1999) em previsão de cargas de curto prazo. O autor também comprova em seus experimentos a rapidez e maior facilidade na determinação dos parâmetros ótimos de funcionamento da RBF, bem como a equivalência destas duas arquiteturas quanto a capacidade de generalizar.

2.4 Algoritmos Genéticos

Algoritmos Genéticos-AGs é uma técnica da área de Inteligência Artificial. Técnica de busca, ela tem sido aplicada na solução de problemas em diversas áreas do conhecimento. Baseada em genética e nos conceitos Darwinianos de seleção natural e evolução das espécies, é usada especialmente em problemas que envolvem maximização ou minimização e tem sido utilizada com sucesso em sistemas de potência, em muitas e distintas tarefas envolvendo estes tipos de busca, a exemplo de El-Nagar & Youssef (2000), Gil & da Silva (2001), Robandi et. al. (2001), Wong (2001), Chen & Chern (2000), Hsiao & Chien (2000), Levitin et. al. (2000), Chung & Leung (1999), Park et. al. (1998), Kazarlis et. al. (1996), Miranda et. al. (1994) e Richards & Yang (1993). Técnica estocástica, não oferece garantia que a solução global será obtida. Porém, se a solução ótima encontrada pelo AG não é o ótimo global, muito provavelmente estará próxima a este.

A técnica de Algoritmos Genéticos também tem sido empregada na otimização da arquitetura das RNAs. Seu uso mais comum é na otimização dos pesos de redes do tipo MLP, a exemplo do trabalho de Srinivasan (Srinivasan, 1998) voltado à otimização de uma MLP para previsão de cargas de curto prazo. Outros exemplos são os trabalhos de El-Sharkawi (El-Sharkawi & Huang, 1996) e Dash (Dash et al., 2000) na gerencia do aprendizado em rede do tipo Kohonen e para otimizar a quantidade de regras da camada (*layer*) de regras de uma rede neuro-difusa, respectivamente.

A técnica de AG mapeia uma possível solução de um problema para um cromossomo de um indivíduo de uma dada população, a qual representa um subgrupo do espaço de soluções para o problema. A evolução genética da população é probabilística e direcionada para a maximização de uma função objetivo (*fitness*) por meio de três operações principais: *seleção*, *crossover* e *mutação*. A função de fitness é o aspecto mais importante de qualquer AG (Beasley et al., 1993). Como a evolução da população é direcionada à maximização pela função de fitness, para problemas onde se deseja minimização é necessário se efetuar uma conversão na função objetivo para que se obtenha a otimização.

O operador de *seleção* tem como objetivo selecionar indivíduos que gerarão

descendentes na próxima geração. A seleção de indivíduos é probabilística: quanto mais alto o valor do seu fitness, mais alta a probabilidade de que venha a ser selecionado. Existem diversos algoritmos para a operação de seleção e todos eles buscam atingir um balanço correto entre diversidade de população e a pressão seletiva (El-Naggar & Youssef, 2000), as quais são questões fundamentais na exploração genética. Quando o AG inicia, é comum que superindivíduos apareçam e conduzam a uma convergência prematura do algoritmo. Próximo do fim do AG, a variância do fitness diminui na população e a pressão seletiva baseada no fitness é reduzida, tornando a evolução da população menos eficiente. Em ambas as situações, escalonar o valor do fitness pode auxiliar a reduzir o problema (Goldberg, 1989, Whitley, 1993). Uma possível forma de escalonamento é o procedimento conhecido como *truncamento sigma* (Goldberg, 1989), de acordo com a (1). Neste, é utilizado informação sobre a variância da população no escalonamento do fitness com o objetivo de manter um bom balanço na competição entre indivíduos da população.

$$f^* = \max[f - (\bar{f} - k \times \sigma), 0] \quad (1)$$

Onde:

f^* é o fitness com o valor ponderado

\bar{f} é o fitness médio

σ é o desvio padrão dos fitness

k é uma constante no intervalo [1,0; 3,0]

Crossover é o mais importante operador genético (Park et. al., 1998), com o qual os indivíduos da população selecionados pelo operador de seleção são combinados de forma aleatória (El-Naggar & Youssef, 2000) de acordo com uma probabilidade pré-especificada que geralmente tem o valor em [0,6; 1,0] (Robandi et. al., 2001). Cada par de indivíduos troca porções de genes entre si. Existem vários operadores de crossover e o modo como o intercâmbio ocorre depende do operador de crossover utilizado. Cada técnica de crossover tem seus próprios méritos e é possível utilizar um esquema de crossover que trabalhe simultaneamente com mais de um operador de crossover de forma a tirar proveito das vantagens oferecidas por cada técnica de crossover (Park et. al., 1998).

Mutação é um operador genético que é aplicado após o crossover. É usado para evitar perda de informação (Chung & Leung, 1999) que pode ocorrer se apenas seleção e crossover são usados e para introduzir informação nova nos descendentes (Kazarlis et. al., 1996), levando a pesquisa para regiões do espaço ainda não exploradas e agindo como fonte de diversidade (Gil & da Silva, 2001). Mutação é geralmente considerada como uma operação secundária, porém também importante, a qual dá uma probabilidade diferente de zero de que toda solução possa ser considerada e avaliada (Kazarlis et. al., 1996). A probabilidade de mutação não pode ser ajustada para valores muito altos ou muito baixos. Se a taxa de mutação é muito alta, o AG não converge para uma solução. Se muito baixa, o AG pode estabilizar em um mínimo local e deixar de explorar todo o espaço de possibilidades (Chung & Leung, 1999). Da mesma forma que o operador de crossover, existem vários operadores de mutação disponíveis, cada qual com suas características de funcionamento, e é possível utilizar um esquema de mutação que trabalhe simultaneamente com vários operadores de forma a tirar proveito das vantagens oferecidas por cada técnica. Uma descrição detalhada da técnica de Algoritmos Genéticos pode ser encontrada em Goldberg (1989) e em Whitley (1993).

2.5 Entrada e Saída da Rede Neural Artificial

A RNA aprende por meio de exemplos. Assim a entrada da RNA, ou seja, o número de neurônios da entrada da rede e quais variáveis eles representam, deve ser formada pelas variáveis que influenciam no comportamento da carga. Não há consenso sobre quais são estas variáveis e normalmente as que compõem a entrada da RNA são escolhidas a partir do conjunto de variáveis que se encontra disponível, utilizando-se técnicas heurísticas, estatísticas, experimentação e relatórios de trabalhos anteriores. Zang (Zang et al., 1998) cita que o número de neurônios de entrada é provavelmente a mais crítica variável decisão para um problema envolvendo séries temporais e que os neurônios (e o que eles representam) contêm informação importante acerca da complexa (linear e não linear) estrutura de autocorrelação implícita aos dados. As variáveis mais utilizadas como entrada da RNA são as cargas passadas, as condições climáticas passadas e previstas para o futuro próximo e informações sobre o comportamento periódico e sazonal da curva de carga: hora do dia, dia da semana, semana ou mês do ano e ocorrência de feriado. Dentre as condições

climáticas normalmente utilizadas, a bibliografia disponível relata que a temperatura ambiente é a variável de maior influência no comportamento da carga.

A saída da RNA é a informação que se deseja conhecer: a carga futura. Para o problema de previsão de cargas, existem duas estratégias principais que são normalmente utilizadas para se codificar a saída da RNA e se obter as previsões de carga desejadas. A primeira delas é compor a camada de saída da rede com vários neurônios, obtendo de uma só vez um conjunto de informações desejadas, por exemplo, as previsões de cargas hora a hora para um determinado dia. Exemplos de uso desta estratégia podem ser encontrados em Khotanzad et. al. (1998), Mohamad et. al. (1996) e Satish et al. (2004). Uma segunda abordagem é compor a camada de saída da RNA com um único neurônio, obtendo assim uma única previsão de carga para um instante à frente e utilizar a RNA de forma recorrente, alimentando-a com suas próprias previsões, para obter todo o conjunto de informações desejadas. Exemplos de uso desta estratégia são os trabalhos de Oliveira (1999), Carpinteiro & Alves da Silva (2000), Carpinteiro et. al. (2004), Mohammad & Egbert (2000), Reis & Alves da Silva (2002) e Topalli & Erkmen (2003).

Para a primeira estratégia, as vantagens são a simplificação no uso da rede para a obtenção de um conjunto de previsões e a eliminação da possibilidade de propagação de erro pelo emprego recorrente da RNA. Para a segunda estratégia, as vantagens são a simplificação e a redução da estrutura da RNA, o que traz benefícios na redução do tamanho do conjunto de treino e na velocidade de treinamento da rede, bem como na maior facilidade para a minimização do erro da saída da RNA. A redução no tamanho do conjunto de treino traz também o benefício de poder reduzir o tamanho da janela temporal dos dados de treino, o que por sua vez conduz a uma rede mais ajustada às condições climáticas e de consumo vigentes. A desvantagem é a possibilidade de aumento do erro do conjunto das previsões devido à propagação do erro de cada previsão pelo uso recorrente da RNA, o que não se comprova nos resultados obtidos em trabalhos anteriores.

As redes MLP e RBF apresentadas são modelos de RNA categorizados como estáticos e o comportamento da carga é dinâmico. Implícito às arquiteturas dos modelos estáticos não existe nenhuma estratégia para o aprendizado da relação temporal entre os padrões de entrada da rede. Para que uma RNA seja dinâmica, é preciso que ela tenha memória (Helman, 1990, in Haykin, 1994) e uma das formas de provê-la com memória é

introduzir atrasos (*time delays*) na estrutura da rede. Existem modelos RNAs, normalmente conhecidos como modelos recorrentes, específicos para a modelagem de sistemas dinâmicos. Nestes, uma das estratégias utilizadas para fornecer à rede informações adicionais a respeito da dinâmica do sistema em questão é inserir na estrutura da rede conexões e/ou neurônios adicionais, retro-alimentados, criando atrasos e reforços na propagação de parte dos sinais internos à rede. Isto pode ser feito, por exemplo, criando conexões entre (a) a camada de saída da rede às camadas de entrada e/ou intermediária(s), (b) a(s) camada(s) intermediária(s) e a camada de entrada, (c) neurônios de uma mesma camada da rede e (d) a saída e entrada de um mesmo neurônio. Nestes modelos de rede, a ordem de apresentação dos padrões de entrada à RNA, fornecendo informação temporal à rede, é relevante, o que não ocorre com os modelos estáticos.

Modelos de RNAs estáticos podem ser utilizados para efetuar previsões não lineares em séries temporais estacionárias (Haykin, 1994) e modelar sistemas dinâmicos. Para isto, neurônios representando variáveis com atraso devem ser incluídos na camada de entrada do modelo de RNA. Esta é a estratégia mais utilizada na modelagem de sistemas dinâmicos (Henrique, 1999), bem como a normalmente utilizada na construção de modelos para a previsão de cargas baseados em RNAs. Na modelagem de sistemas dinâmicos, a vantagem das redes recorrentes sobre as estáticas é utilizarem um vetor de entrada reduzido. Sua desvantagem é a maior complexidade dos algoritmos de treinamento (Henrique, 1999). Este autor propõe uma outra técnica para a modelagem de sistemas dinâmicos de controle através de RNAs, via a modelagem das parcelas da equação diferencial do sistema através de RNAs estáticas, sem a inclusão de variáveis com atraso nos vetores de entrada das redes. Claumann (1999) e Tsoi & Back (1997) apresentam *reviews* de redes neurais recorrentes de tempo discreto (*discrete time recurrent neural networks*), categoria de RNAs recorrentes especialmente voltadas à modelagem de séries temporais e sistemas dinâmicos de controle, e Claumann (1999) aplica redes recorrentes em controle de processos. Mais informações sobre técnicas de modelagem de sistemas dinâmicos através de RNAs podem ainda serem obtidas em Claumann (2003), Henrique (1999), Haikin (1994) e Fausett (1994).

2.6 Avaliação da Rede Neural Artificial

A literatura consultada mostra que não há consenso no índice empregado na avaliação da qualidade das previsões de carga. O índice identificado como o mais utilizado é o Erro Percentual Médio (MAPE - Mean Absolute Percentage Error) (2), embora a Raiz Quadrada da Média do Somatório do Erro Quadrático (RMSE - Root Mean Squared Error) (4) também seja bastante utilizada. Outros índices utilizados são: Erro Máximo Percentual (EPM_{max}) (5), Erro Absoluto (EA) (7), Coeficiente de Variação (CV) (9) e Desvio Padrão do Erro. O Coeficiente de Variação, da mesma forma que o Desvio Padrão, é uma medida de dispersão. Ele indica o espalhamento do erro. Leite (1997) utiliza uma variação dos índices MAPE, EPM_{max} e EA, cujos novos índices são respectivamente representados pelos índices MAPE* (3), EPM_{max}* (6) e EA* (8). A diferença entre eles é que os índices originais são apresentados como um percentual da carga real (valores absolutos) e os novos, apresentados como um percentual da *carga base* (valores relativos). O valor utilizado como carga base é o maior valor inteiro da carga máxima verificada em todo conjunto de medidas disponíveis. Oliveira (1999) utiliza os índices MAPE*, EPM_{max}* e CV.

A vantagem do uso dos índices relativos sobre os absolutos, é que os mesmos, por serem ponderados pelo valor da carga máxima, fazem com que a avaliação (e conseqüentemente o projeto e ajuste do modelo do previsor de carga) enfatize as previsões para os valores de cargas relativas aos horários próximos à ponta do sistema elétrico, os quais são os períodos críticos para o sistema. O MAPE, que é o índice mais utilizado, considera os erros de previsão relativos aos valores de suas respectivas cargas reais. Por tratar os erros de forma percentual e pontual dá igual importância à previsão de todos os valores da carga, enfatizando assim a qualidade da previsão da curva de carga como um todo. O RMSE, ao considerar os erros de previsão em valores absolutos, da mesma forma que o MAPE* também enfatiza as previsões para os valores de cargas ativas relativas aos horários próximos à ponta do sistema elétrico. Porém, ao utilizar o quadrado do erro absoluto de previsão, dá mais ênfase que o MAPE* à qualidade das previsões das cargas nestes horários. Por fim, alguns outros indicadores que podem ser utilizados são: o Somatório do Erro Quadrático (SSE) (12) e os Erros Absolutos Máximo (EAM_{max}) (10) e Médio (EAM_{med}) (11).

$$\text{MAPE} = \frac{100}{n} \sum_{k=1}^n \frac{|\hat{C}_k - C_k|}{C_k} \quad (2)$$

$$\text{MAPE}^* = \frac{100}{C_{base}} \frac{1}{n} \sum_{k=1}^n |\hat{C}_k - C_k| \quad (3)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n (\hat{C}_k - C_k)^2} \quad (4)$$

$$\text{EPM}_{\text{Max}} = 100 \text{Max} \left(\frac{|\hat{C}_k - C_k|}{C_k} \right), k = 1, \dots, n \quad (5)$$

$$\text{EPM}_{\text{Max}}^* = \frac{100}{C_{base}} \text{Max} \left(|\hat{C}_k - C_k| \right), k = 1, \dots, n \quad (6)$$

$$\text{EA} = 100 \frac{|\hat{C}_k - C_k|}{C_k}, k = 1, \dots, n \quad (7)$$

$$\text{EA}^* = 100 \frac{|\hat{C}_k - C_k|}{C_{base}}, k = 1, \dots, n \quad (8)$$

$$\text{CV} = \frac{1}{\bar{C}} \sqrt{\frac{1}{n} \sum_{k=1}^n (\hat{C}_k - C_k)^2} \quad (9)$$

$$\text{EAM}_{\text{Max}} = \text{Max} \left(|\hat{C}_k - C_k| \right), k = 1, \dots, n \quad (10)$$

$$\text{EAM}_{\text{Med}} = \frac{1}{n} \left(|\hat{C}_k - C_k| \right), k = 1, \dots, n \quad (11)$$

$$\text{SSE} = \sum_{k=1}^n (\hat{C}_k - C_k)^2 \quad (12)$$

Onde:

C_k é o valor real da carga para o k-ésimo elemento da série

\hat{C}_k é o valor previsto da carga para o k-ésimo elemento da série

\overline{C}_k é o valor médio da carga da série

C_{base} é o maior valor inteiro da carga máxima verificada nas séries disponíveis

n é o número de elementos da série

3. O MODELO PROPOSTO

3.1 Sistema de Previsão

Buscando atender aos objetivos pré-estabelecidos no início deste trabalho é proposto um modelo para um sistema de previsão da carga nodal ativa de curtíssimo e de curto prazos, meia hora à frente em uma janela de uma semana. O modelo proposto deve ser capaz de (a) ajustar-se às características específicas de cada micro-região de consumo de energia elétrica, atendida por cada um dos nós do sistema elétrico em estudo e de (b) acompanhar, adaptando-se, a dinâmica de cada uma destas micro-regiões de consumo, em ambos os casos necessitando de um nível baixo de intervenção humana.

A Figura 1 apresenta a visão geral do modelo proposto. Dotado de arquitetura modular, foi projetado de forma que possa ser facilmente expandido a medida que mais pontos do sistema elétrico passem a ser objeto de previsão de cargas. Sua macro-estrutura é composta de uma base de dados – Base de Dados de Previsão – e quatro tipos de módulos com funcionalidades distintas: Construtor de Históricos, Previsor Especialista, Gerente de Exceções e Gerente de Tarefas Globais. Além destas, o modelo prevê a conexão com uma Base de Dados de Medições, externa ao sistema.

A Base de Dados de Medições, externa ao Sistema de Previsão de Cargas - SPCA, é a responsável pelo suprimento do Sistema de Previsão de Cargas de todos os dados relativos às medições das (a) condições operacionais nos pontos sistema elétrico e das (b) condições climáticas reinantes em seus respectivos mercados de energia elétrica. O módulo Construtor de Históricos é o responsável pela extração dos dados de medições armazenados na Base de Dados de Medições e existente necessários ao Sistema de Previsão de Cargas, a transformação e formatação destes dados em informações úteis ao SPCA e o armazenamento destas informações na Base de Dados de Previsão.

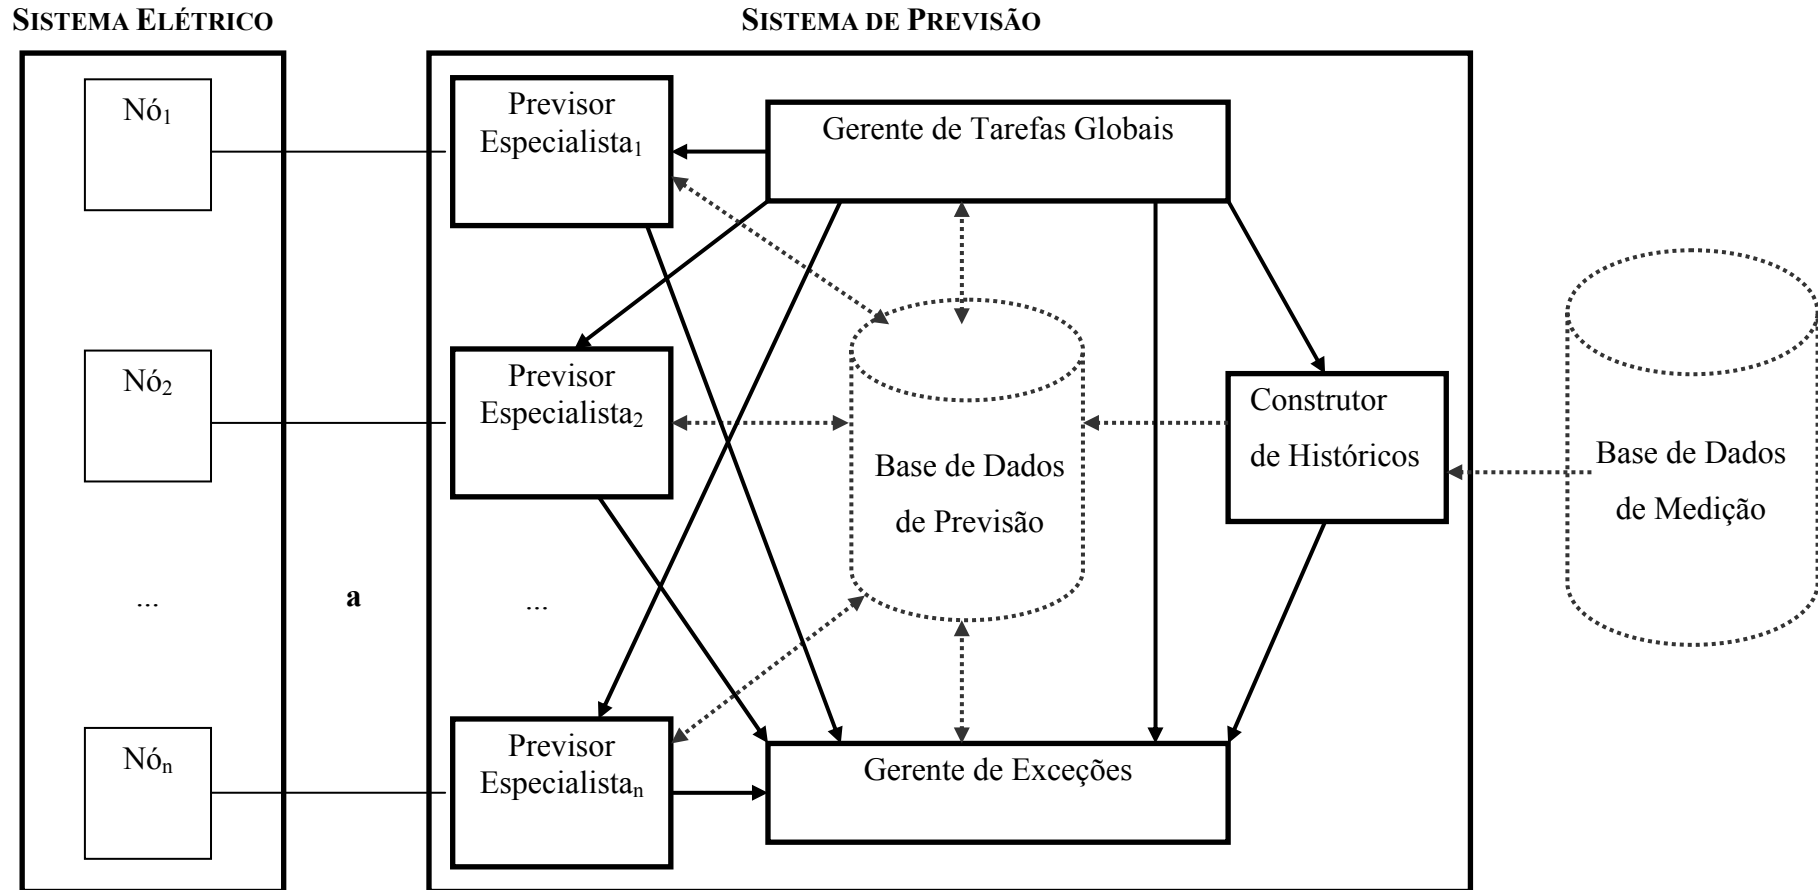


Figura 1 – Sistema de Previsão de Cargas

Preto contínuo - Processos e chamadas entre processos

Preto pontilhado - Base de dados e trânsito de informações

Os módulos do tipo “Previsor Especialista” são os responsáveis pela elaboração das previsões de carga para os vários pontos do sistema elétrico e possuem uma relação de um para um para com os mesmos. Cada módulo “Previsor Especialista” é o responsável pela previsão de carga do ponto do sistema elétrico ao qual está designado. É capaz de aprender acerca do comportamento da carga do ponto em questão e de se ajustar, adaptando-se a dinâmica do mercado de energia elétrica associado ao seu ponto do sistema elétrico.

Na Base de Dados de Previsão são guardadas todas as informações pertinentes ao Sistema de Previsão de Cargas. Os históricos das medições, os modelos de RNA e seus respectivos parâmetros de ajuste e o histórico das previsões, dentre outros, são armazenados em tabelas relacionais e acessados pelos diversos processos internos ao SPCA. O Gerente de Exceções é o módulo é o responsável pelo tratamento das falhas e anormalidades de funcionamento que eventualmente ocorram durante o funcionamento do Sistema de Previsão de Cargas. Por fim, o módulo Gerente de Tarefas Globais tem ao seu encargo o controle e sincronismo das diversas atividades executadas pelos módulos especializados. A seção 3.2 provê uma descrição mais detalhada do módulo Previsor Especialista. Os detalhes dos demais módulos não serão abordados no presente trabalho.

3.2 Previsor Especialista

O Previsor Especialista (Figura 2) é o módulo principal do SPCA. Existe em igual número dos pontos do sistema elétrico ao qual estão associadas às previsões. Cada módulo Previsor Especialista é responsável pela previsão de carga de um ponto do sistema elétrico. Ele possui estrutura modular e é dotado de um mecanismo adaptativo-evolutivo, que o torna capaz de se ajustar às características específicas da demanda por carga do nó a que está relacionado, bem como acompanhar a dinâmica do mercado de energia elétrica suprido pelo nó em questão.

O Previsor Especialista possui duas funcionalidades principais: (a) um dispositivo preditivo, responsável pela elaboração das previsões e um mecanismo adaptativo-evolutivo, responsável por adaptar e fazer evoluir o dispositivo preditivo, de forma que este acompanhe a dinâmica do mercado de energia elétrica a que está em relacionado.

Dotado de arquitetura modular, o Previsor Especialista é composto dos seguintes componentes: Previsor Neural Especializado, Modelador Evolutivo de 1ª Ordem, Modelador Evolutivo de 2ª Ordem, Modelador Evolutivo de 3ª Ordem, Modelador Neuro-adaptativo, Construtor de Conjuntos de Treinamento e Teste Neural e Gerente de Tarefas Especializadas.

O Previsor Neural Especializado é em síntese, uma Rede Neural Artificial do tipo Base Radial (Figura 3). A rede RBF foi escolhida como arquitetura de RNA em função de sua boa capacidade de aproximação e grande velocidade de treinamento, quando comparada à rede MLP, e dos resultados apresentados em Oliveira (1999). Sua arquitetura e seus ajustes internos são especializados para a previsão da carga do nó a que está associada, por intermédio dos componentes Modelador Neuro-adaptativo e Modeladores Evolutivos de 1ª, 2ª e 3ª Ordem. Cada Previsor Neural Especializado é um módulo otimizado para prever a carga do nó a que está relacionado segundo as condições operativas vigentes. Porém, parte dos componentes que o compõe e define sua arquitetura independem do ponto ao qual está associado, e são comuns a todos os módulos. A estrutura geral da rede neural que compõe o módulo Previsor Neural Especializado, as opções de projeto de uso comum e os procedimentos de ajuste (treinamento) da RNA são apresentados em conjunto com a descrição detalhada do Módulo Modelador Neuro-adaptativo na seção 3.2.1.

O módulo Modelador Evolutivo de 1ª Ordem é um algoritmo evolutivo. Ele está encarregado da adaptação inicial do Previsor Neural Especializado ao ponto do sistema elétrico a que foi designado e de adaptações evolutivas periódicas de médio prazo, semanas a meses à frente, de forma que acompanhe as características relevantes a médio prazo da dinâmica do mercado de energia elétrica associado ao nó em questão. O acompanhamento da dinâmica de longo prazo do mercado de energia elétrica é feito de forma indireta, como consequência das sucessivas adaptações evolutivas de médio prazo. O módulo Modelador Evolutivo de 2ª Ordem também é um algoritmo evolutivo, porém de estrutura simplificada, de forma a garantir uma performance de processamento superior a do Modelador Evolutivo de 1ª Ordem. Sua função é refinar a adaptação inicial do Previsor Neural Especializado ao ponto do sistema elétrico a que foi designado e produzir adaptações evolutivas periódicas de curto prazo, horas a dias à frente, de forma que este acompanhe as alterações nas características relevantes no curto prazo da dinâmica do

mercado de energia elétrica associado ao nó em questão.

PREVISOR ESPECIALISTA

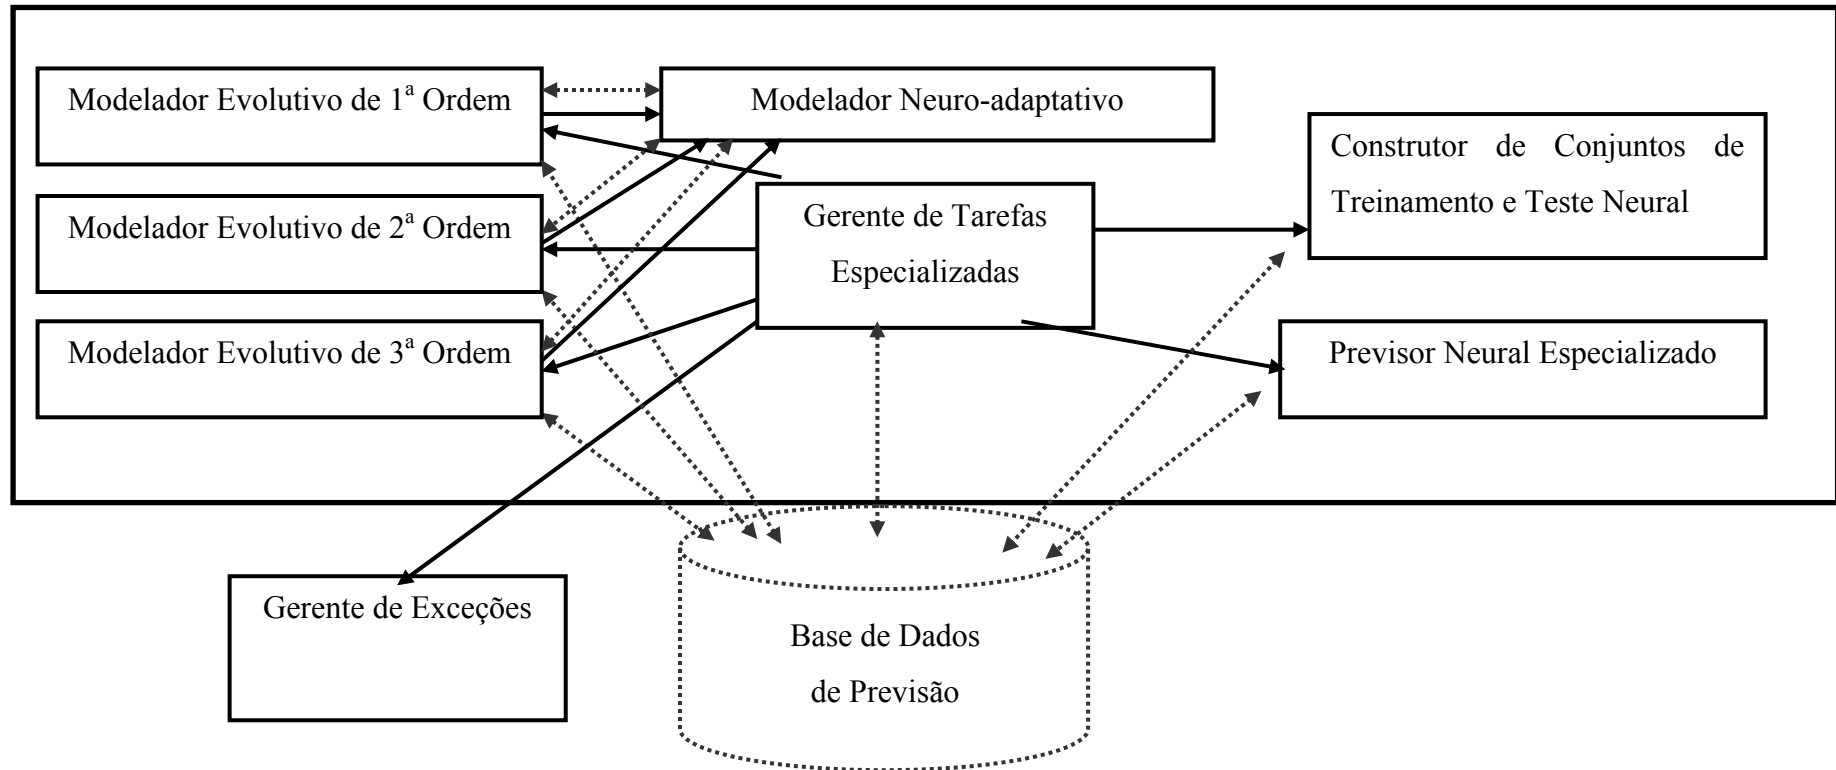


Figura 2 - Previsor Especialista

Preto contínuo - Processos e chamadas entre processos

Preto pontilhado - Base de dados e trânsito de informações

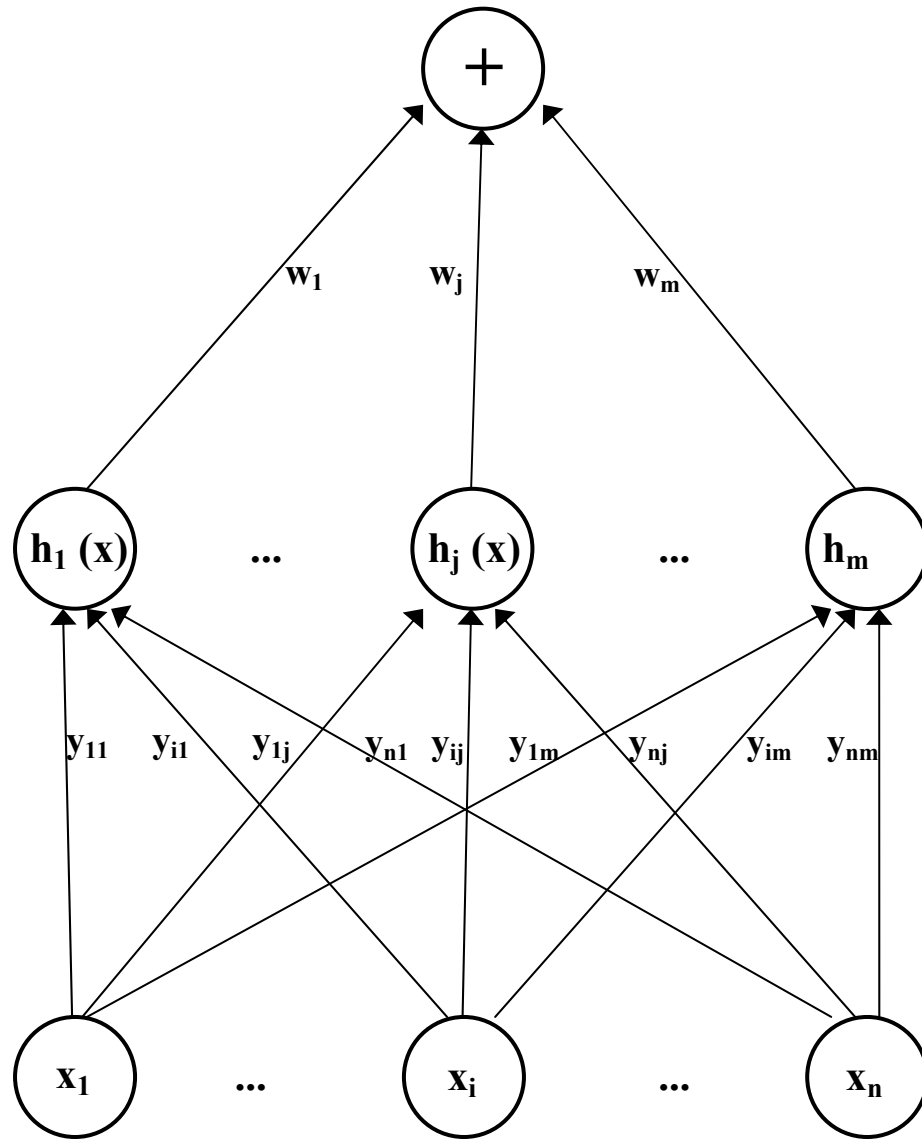


Figura 3 - Rede RBF de 3 camadas

O módulo Modelador Evolutivo de 3ª Ordem tem por finalidade pré-formatar as informações necessárias ao módulo Modelador Neuro-adaptativo e efetuar chamadas periódicas ao mesmo. Em conjunto com este último, deve garantir a ocorrência de adaptações evolutivas periódicas de curtíssimo prazo no Previsor Neural Especializado, minutos à frente, de forma que este acompanhe as alterações nas características relevantes de curtíssimo prazo da dinâmica do mercado de energia elétrica associado ao nó em questão. Já o módulo Modelador Neuro-adaptativo é o componente responsável pela adaptação do Previsor Neural Especializado ao ponto do sistema elétrico a que está associado. A partir das observações contidas nos conjuntos de treinamento e teste construídos pelo módulo Construtor de Conjuntos de Treinamento e Teste Neural e das especificações pré-determinadas pelos Modeladores Evolutivos de 1ª 2ª e 3ª Ordem, o Modelador Neuro-adaptativo ajusta o Previsor Neural Especializado, moldando-o às condições operativas do nó a que está associado.

O Construtor de Conjuntos de Treinamento e Teste Neural é o módulo responsável pela construção dos conjuntos de treinamento e teste a serem utilizados pelo módulo Modelador Neuro-adaptativo. Por fim, o módulo Gerente de Tarefas Especializadas, dotado de uma agenda, tem ao seu encargo o controle e sincronismo das diversas atividades executadas pelos módulos que compõem o Previsor Especialista. As seções 3.2.1, 3.2.2 e 3.2.3 apresentam, respectivamente, descrições detalhadas dos módulos: Modelador Neuro-adaptativo, Modelador Evolutivo de 1ª Ordem e Modelador Evolutivo de 2ª Ordem. Os demais módulos não serão detalhados em maior profundidade no presente trabalho

3.2.1 Modelador Neuro-adaptativo

O Modelador Neuro-adaptativo é o componente responsável pelo ajuste do Previsor Neural Especializado ao ponto do sistema elétrico a que está associado moldando-o às condições operativas vigentes no nó. O ajuste ocorre por meio do treinamento da RNA, segundo os conjuntos de treinamento e teste construídos pelo Construtor de Conjuntos de Treinamento e Teste Neural e as especificações pré-determinadas pelos Modeladores Evolutivos de 1ª 2ª e 3ª Ordem. A estrutura geral da rede neural, as opções de projeto de uso comum a todos os módulos do tipo Previsor Neural Especializado e os procedimentos de ajuste (treinamento) da RNA, específicos a cada Previsor Neural Especializado são

apresentados a seguir.

1ª Camada da rede

A primeira camada da rede é composta das variáveis identificadas pelo Modelador Evolutivo de 1ª Ordem como relevantes para o conhecimento do valor futuro da carga, meia hora à frente, no ponto do sistema elétrico para o qual foi designado o Previsor Especialista. A nível acadêmico, exceto para a carga, considera-se conhecido o valor futuro das variáveis de entrada.

2ª Camada da rede

A segunda camada da rede neural é composta de grupos (*clusters*) ao qual estão relacionados os vários padrões de entrada provenientes da primeira camada da rede. Durante o treinamento da RNA, na camada intermediária da RBF, os padrões oriundos da camada de entrada são classificados e agrupados em grupos segundo sua similaridade com o padrão que identifica cada agrupamento (*cluster*). No modelo proposto, o padrão que identifica cada agrupamento (centro do agrupamento) foi obtido por meio do algoritmo de formação de agrupamentos (*clusterização*) **K-Médias** (*K-Means*, Moody & Darken, 1989, citado em [8] Bishop, 1995). Foi utilizado a distância Euclidiana para a mensuração das distâncias entre cada padrão de entrada e o centro do agrupamento (Haykin, 1994, Pandya & Macy, 1995). O valor do sinal de saída de cada agrupamento é o valor de saída da função de base radial adotada para o agrupamento. Existem várias funções de base radial disponíveis que podem ser testadas. Exemplos são as Gaussiana, multiquadrática, multiquadrática recíproca e *thin plate spline* (Henrique, 1999). Neste trabalho, da mesma forma que em Oliveira (1999), utilizou-se a função Gaussiana, segundo a (13), como função de ativação para todos os agrupamentos da camada intermediária. A Gaussiana é a função de base radial mais utilizada nas redes do tipo RBF. Além disto, é a única função de base radial que possui a propriedade de poder ser fatorada conforme a (14) (Haykin, 1994) o que propicia mais possibilidades de experimentação em redes com entrada multivariável. Na (13) foi testado para o valor de σ_i^2 (a) o quadrado da distância Euclidiana máxima entre o centro do grupo e seus padrões (Oliveira, 1999), (b) a variância do grupo e (c) a variância do grupo ponderada por um fator de escala k , $k \in \mathfrak{R}$ e de domínio $[0, 3]$, de valor específico para cada grupo e determinado pelos Modeladores Evolutivos. O domínio do fator de escala k foi obtido por experimentação. A quantidade de

grupos da segunda camada também é determinada pelos Modeladores Evolutivos.

$$h(x) = \exp\left[-\frac{1}{2\sigma_i^2}\|x - x_i\|^2\right], i = 1, 2, \dots, M \quad (13)$$

Onde:

- x_i são os centros dos agrupamentos
- σ_i^2 são os parâmetros de escalonamento
- M É o número de grupos

$$h(\mathbf{x}) = h(x_1).h(x_2)...h(x_n) \quad (14)$$

Onde:

- \mathbf{x} é o vetor de entrada da RNA
- x_n é uma dimensão do vetor de entrada da RNA
- n é o número de dimensões do vetor de entrada da RNA

3ª Camada da rede

Para a composição da terceira e última camada da rede, adotou-se a mesma estratégia que Oliveira (1999) e Reis & Alves da Silva (2002), em virtude das discussões apresentadas na seção 2.5, compondo a camada de saída da RNA com apenas um neurônio, representando uma única variável, e obtendo as demais variáveis desejadas através do uso recorrente da rede. Assim, a terceira camada da rede é composta por apenas um neurônio, representando o valor futuro da carga meia hora à frente, no ponto do sistema elétrico para o qual foi designado o Previsor Especialista. Para a previsão do valor futuro da carga a cada meia hora em um horizonte de uma semana à frente, se utiliza a RNA de forma recorrente.

Avaliação do erro da rede

Para a avaliação do erro da RNA, foi adotado o RMSE – Root Mean Square Error como função objetivo, dado por

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n (\hat{C}_k - C_k)^2} \quad (15)$$

Onde:

C_k é o valor real da carga para o k-ésimo elemento da série

\hat{C}_k é o valor previsto da carga para o k-ésimo elemento da série

n é o número de elementos da série

A escolha está baseada na fundamentação teórica apresentada na seção 2.6. Com o uso do RMSE pretende-se enfatizar o ajuste da rede de forma a privilegiar a redução de erros nas previsões dos valores de Carga mais altos da série (nos picos de demanda do sistema elétrico ou próximos a estes).

3.2.2 Modelador Evolutivo de 1ª Ordem

O Modelador Evolutivo de 1ª Ordem é um algoritmo evolutivo, fundamentado na técnica de Algoritmos Genéticos - AG. Está ao seu encargo a adaptação inicial da RNA ao ponto do sistema elétrico a que foi designada e de adaptações evolutivas periódicas de médio prazo da rede. Sua função é escolher de forma ótima (a) as variáveis que naquele ponto e instante de tempo estão relacionadas à carga a ser prevista, para que componham o vetor de entrada da rede neural, (b) os coeficientes para ponderação dos valores de cada uma das variáveis escolhidas, (c) o número de agrupamentos da camada intermediária da rede neural e (e) os coeficientes para ponderação da dimensão de cada um dos agrupamentos.

Representando Soluções como Indivíduos

O modelo genético proposto (Figura 4), segundo a técnica de Algoritmos Genéticos, mapeia o problema de otimização da estrutura da RNA para uma população de indivíduos, onde cada indivíduo representa uma solução para o problema e é modelado como um cromossomo. No cromossomo, cada gene representa um parâmetro da RNA a ser otimizado e o alelo (conteúdo do gene) o valor para este parâmetro.

O cromossomo (Figura 4), considerando-se as funcionalidades da RNA a serem otimizadas, pode ser visto como subdividido em duas partes. A primeira parte (vetor de entrada) modela as variáveis que compõem o vetor de entrada da RNA. Cada um dos genes que o compõe representa uma das variáveis que compõem o conjunto de variáveis candidatas e o respectivo alelo o valor para ponderação do valor da variável de entrada da

rede. A segunda parte (grupos) modela cada um dos grupos que compõe a camada intermediária da RNA e o respectivo alelo o valor para ponderação da dimensão do grupo.

Na primeira parte do cromossomo, os valores dos alelos (v_n) variam no intervalo $[0, 1]$, $v_n \in \mathfrak{R}$. O valor “0” significa a inexistência desta variável no vetor de entrada da rede e n é o número de integrantes do conjunto de variáveis candidatas ao vetor de entrada. Na segunda parte, os valores dos alelos (c_m) variam no intervalo $[0, 3]$, $c_m \in \mathfrak{R}$, onde o valor “0” significa a inexistência deste grupo na camada intermediária, e m é número máximo, fixado em 100, de grupos permitidos na camada intermediária da rede. Ainda com relação ao cromossomo, seu projeto permite que a precisão dos valores dos alelos do cromossomo, $\in \mathfrak{R}$, seja atribuída individualmente para cada alelo durante a fase de experimentação. Durante a fase de experimentação, foram testadas precisões de 1, 0,1, 0,01 e 0,001. Por fim, o intervalo dos valores dos alelos (c_m) e o valor máximo de m foram definidos por projeto e validados por meio de experimentação.




Figura 4 – Representação genética do Modelador Evolutivo de 1ª Ordem

Devido ao fato do AG funcionar de forma probabilística, os mecanismos de reprodução e mutação podem produzir indivíduos que não existem no mundo real (indivíduos implausíveis). Exemplos poderiam ser soluções onde a RNA não possuísse variável de entrada ou grupos na camada intermediária. No AG, há três modos de se lidar com problemas com restrições: (a) protegendo o código do AG de forma que soluções implausíveis não possam surgir, (b) permitindo o surgimento de tais indivíduos e

atribuindo a eles um valor nulo de *fitness* e (c) permitindo que tais indivíduos surjam, porém degradando seus respectivos fitness de forma a tornar sua reprodução mais difícil. Neste trabalho se adota a primeira estratégia que é a proteção do código de forma a garantir que todos os indivíduos gerados pelo modelo proposto são soluções viáveis.

A escolha das variáveis que compõem o vetor de entrada da RNA se dá a partir de um conjunto de variáveis de entrada candidatas previamente selecionadas a partir (a) do conjunto de variáveis disponíveis, (b) da revisão bibliográfica empreendida, (c) do conhecimento extraído dos técnicos da Celesc acerca do comportamento do sistema elétrico do Estado de Santa Catarina e (d) do conhecimento acumulado em trabalhos correlatos. Devido às características de projeto do modelo proposto, o conjunto de variáveis candidatas pode evoluir no tempo, agregando novas variáveis para teste pelo AG, ou efetuando podas em variáveis que se comprovem ineficientes. O ANEXO 8.1 apresenta o conjunto de variáveis candidatas utilizado neste trabalho e a sua forma de representação no vetor de entrada da RNA.

A população inicial é gerada de forma aleatória a partir do conjunto de variáveis candidatas e da quantidade máxima de grupos permitidos na segunda camada da RNA. O tamanho da população foi fixado em 50, indivíduos implausíveis não podem ser criados e o número máximo de gerações foi fixado em 2000. Os valores para o tamanho da população e para o número máximo de gerações foram definidos por projeto e validados por meio de experimentação.

No desenvolvimento do código do AG, foi utilizado a biblioteca pública de funções GAOT (Houck & Joines, 1996, Houck & Joines, 1995), a qual foi modificada e estendida. As funções de seleção, *crossover* e mutação foram definidas no decorrer do desenvolvimento do código e da fase de experimentação. Foram testados o uso da roleta convencional e o da roleta ponderada pelo procedimento de truncamento sigma (*sigma truncation*), segundo a (16), de acordo com a fundamentação teórica apresentada na seção 2.4.

$$f^* = \max[f - (\bar{f} - k \times \sigma), 0] \quad (16)$$

Onde:

f^* é o fitness com o valor ponderado

\bar{f} é o fitness médio

σ é o desvio padrão dos fitness

k é uma constante no intervalo $[1,0; 3,0]$

A função de fitness adotada foi baseada na parte variável do RMSE, mantendo a coerência com a função objetivo adotada para avaliação da rede neural artificial. Em problemas que envolvem minimização, a forma usual para a função de fitness é multiplicar a função objetivo pelo valor menos um, tornando-a negativa. Esta foi a primeira abordagem utilizada, segundo a (17) mas, com seu uso a evolução do AG se mostrou instável e com dificuldade de convergência. Assim, foi adotada a (18) como função de fitness, com a qual o AG demonstrou estabilidade e facilidade de convergência.

$$f = -\sum_{k=1}^n (\hat{C}_k - C_k)^2 \quad (17)$$

$$f = 1 / \sum_{k=1}^n (\hat{C}_k - C_k)^2 \quad (18)$$

Onde:

C_k é o valor real da carga para o k-ésimo elemento da série

\hat{C}_k é o valor previsto da carga para o k-ésimo elemento da série

n é o número de elementos da série

Também, foi utilizada a técnica de emprego de múltiplas funções de *crossover* e mutação de acordo com o apresentado na seção 2.4. No *crossover*, foi utilizado combinações das funções simpleXover, heuristicXover, arithXover e PCargaXover, as três primeiras da biblioteca GAOT e a última desenvolvida neste trabalho, perfazendo uma probabilidade total de ocorrência de *crossover* de cerca de 60%. Na mutação foi utilizado combinações das funções boundaryMutation, multiNonUnifMutation, nonUnifMutation,

unifMutation, PCargaUnifMutation, PCargaMultiUnifMutation, PCargaMutation e PCargaCiclicMutation, as quatro primeiras da biblioteca GAOT e as quatro últimas desenvolvidas neste trabalho, com uma probabilidade total de mutação variando entre 8% e 14%.

Nas funções de *crossover*, a função simpleXover, a partir de dois indivíduos, gera dois novos descendentes a partir de corte em um ponto aleatório: início do indivíduo um concatenado com o complemento do indivíduo dois e início do indivíduo dois concatenado com o complemento do indivíduo um. A heuristicXover gera dois descendentes a partir da extrapolação na direção da linha formada por dois indivíduos previamente selecionados, privilegiando a direção da extremidade do melhor indivíduo. A arithXover, a partir de dois indivíduos, escolhe um ponto de corte de forma aleatória e gera dois descendentes a partir da interpolação dos segmentos dos indivíduos originais. Por fim, a PCargaXover, a partir de dois indivíduos, escolhe pontos de corte e gera dois descendentes a partir da combinação dos segmentos dos indivíduos originais. A escolha da quantidade de pontos de corte é feita de acordo com uma distribuição de probabilidades, segundo a (19). A localização de cada ponto de corte é escolhida de forma aleatória e o número máximo de pontos de corte é fixado em 10% do número de genes do cromossomo.

$$y = 1/x \tag{19}$$

Onde:

- y é o valor de entrada para o método de Monte Carlo
- x é o valor de entrada para função y, $x = 1, 2, \dots, n$
- n é igual a 10% do número de genes do cromossomo, $n \in Z$

Nas funções de mutação, a função boundaryMutation, dado um intervalo fechado, escolhe de forma aleatória um gene do indivíduo e o altera (de forma aleatória) para um dos valores extremos do intervalo fechado. A nonUnifMutation, dado um intervalo fechado, escolhe de forma aleatória um gene do indivíduo e o altera segundo uma distribuição de probabilidade não uniforme (uma função Gaussiana). O raio da Gaussiana é inversamente proporcional ao valor da geração corrente (se torna menor com o avanço da

geração corrente em direção o valor de gerações máximo). A direção da mutação (direção positiva ou negativa, na Gaussiana) também é obtida de forma aleatória. A função `multiNonUnifMutation` funciona de forma idêntica a da `nonUnifMutation`, porém todos os genes (e não apenas um) são alterados. A `unifMutation`, dado um intervalo fechado, escolhe de forma aleatória um gene do indivíduo e o altera segundo uma distribuição de probabilidade uniforme (de forma aleatória) dentro do intervalo dado. A função `PCargaUnifMutation` funciona de forma similar a `unifMutation`, porém alterando o gene para um valor inteiro. A função `PCargaMultiUnifMutation` funciona de forma similar a `PCargaUnifMutation`, porém efetuando alterações em todos os genes do indivíduo. A `PCargaMutation` opera mutações binárias em um grupo de genes, representando um tipo de variável (temperatura ambiente, pressão atmosférica,...). O tipo de variável a sofrer mutação binária (ativar, desativar ou inverter o valor) e o tipo de mutação binária são escolhidos de forma aleatória. Finalmente, a `PCargaCiclicMutation` funciona de forma similar a `PCargaMutation`, porém o tipo de variável a sofrer a mutação é escolhido de forma cíclica, dentre o conjunto de tipos de variáveis utilizado, a medida que ocorrem as chamadas à função de mutação.

Uma descrição mais detalhada das funções GAOT de *crossover* e mutação podem ser obtidas na documentação que acompanha a referida biblioteca. Finalmente, ainda com relação aos operadores de *crossover* e de mutação utilizados, os mesmos são operadores de ordem, o que garante que todos os indivíduos gerados pelos mesmos são soluções plausíveis.

3.2.3 Modelador Evolutivo de 2ª Ordem

O Modelador Evolutivo de 2ª Ordem, da mesma forma que o Modelador Evolutivo de 1ª Ordem, também é um algoritmo evolutivo fundamentado na técnica de Algoritmos Genéticos. Está ao seu encargo promover adaptações evolutivas periódicas de curto prazo na RNA, ajustando-a ao ponto do sistema elétrico a que foi designada. Sua função é escolher de forma ótima (a) o número de agrupamentos da camada intermediária da rede neural e (b) os coeficientes para ponderação da dimensão de cada um dos agrupamentos.

Representando Soluções como Indivíduos.

O modelo genético proposto para o Modelador Evolutivo de 2ª Ordem é uma simplificação do modelo proposto para o Modelador Evolutivo de 1ª Ordem (Figura 5)

com o objetivo de propiciar maior velocidade de processamento do AG. Da mesma forma que neste último, no cromossomo, cada gene representa um parâmetro da RNA a ser otimizado e o alelo (conteúdo do gene) o valor para este parâmetro.

O cromossomo (Figura 5) deste módulo é idêntico a segunda parte do cromossomo do Modelador Evolutivo de 1ª Ordem, onde os genes modelam a quantidade de grupos e o valor para ponderação da dimensão de cada grupo. Da mesma forma e pelas mesmas razões detalhadas no módulo Modelador Evolutivo de 1ª Ordem, no cromossomo, os valores dos alelos (c_m) variam no intervalo $[0, 3]$, $c_m \in \mathfrak{R}$, onde o valor “0” significa a inexistência deste grupo na camada intermediária, e m é numero máximo, fixado em 100, de grupos permitidos na camada intermediária da rede. Ainda com relação ao cromossomo e da mesma forma que no módulo Modelador Evolutivo de 1ª Ordem, seu projeto permite que a precisão dos valores dos alelos do cromossomo, $\in \mathfrak{R}$, seja atribuída individualmente para cada alelo durante a fase de experimentação.

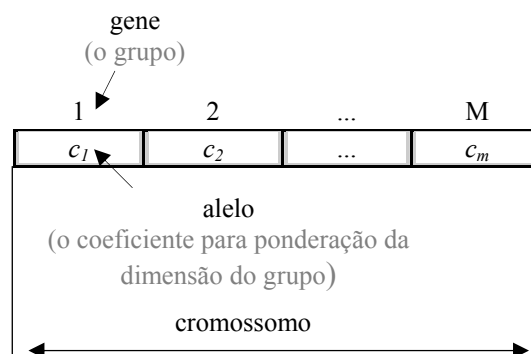


Figura 5 – Representação genética do Modelador Evolutivo de 2ª Ordem

Neste módulo, utilizou-se a mesma estratégia que a do Modelador Evolutivo de 1ª Ordem para lidar com o aparecimento de indivíduos implausíveis durante a evolução da população e as mesmas especificações e recursos para as funções de fitness, seleção, crossover e roleta bem como para os valores das variáveis, para o tamanho da população e para o número de gerações. A população inicial, também foi gerada de forma aleatória.

4. O OBJETO DE ESTUDO

A macro região geoeletrica constituída pelo mercado consumidor de energia elétrica do Estado de Santa Catarina foi escolhida para servir como a base inicial para a definição do objeto de estudo, denominado sistema hipotético. O mercado de energia do Estado de Santa Catarina é quase que totalmente atendido pelo sistema de potência da CELESC. Foi escolhido por ser composto por micro-regiões de consumo com características fortemente heterogêneas e pelo interesse da CELESC nos resultados do presente estudo, bem como seu apoio, fornecendo medições de grandezas elétricas adquiridas por seu sistema SCADA e informações sobre o comportamento da demanda por carga no Estado. O objeto de estudo (sistema hipotético) utilizado no presente trabalho foi definido como uma subárea do sistema elétrico da CELESC e será descrito à frente.

O Estado de Santa Catarina, dos pontos de vista: geográfico, climático, sócio-econômico e cultural, é um estado marcadamente heterogêneo. Composto de regiões: litorâneas, vales, serras e planaltos, possui variação climática acentuada, tanto entre suas diversas regiões geográficas quanto, considerando apenas uma mesma região, no decorrer das várias estações do ano ou mesmo entre períodos mais longos, devido a fenômenos climáticos cíclicos e de maior duração, a exemplo do fenômeno ENOS (El Niño e La Niña). Seus habitantes são descendentes de imigrantes das mais variadas origens: açoriana, germânica, italiana e africana, dentre outras, com fortes concentrações populacionais regionais, marcando as diversas regiões com economias e hábitos sócio-culturais distintos. Do ponto de vista da forma do consumo de energia elétrica, estes fatores contribuem para reforçar a distinção entre o comportamento da demanda nas várias micro-regiões de consumo do Estado, considerando-se um dado instante de tempo, e dentro de uma mesma micro-região de consumo, ao longo do tempo. A Figura 6 apresenta a precipitação típica anual no Estado. O ANEXO 8.2 provê um maior detalhamento dos principais aspectos climáticos de Santa Catarina. Neste, incluem-se informações sobre o clima típico de cada mês do ano. Também no ANEXO 8.2, os períodos de ocorrência do El Niño e do La Niña no século XX são apresentados na Tabela 16.

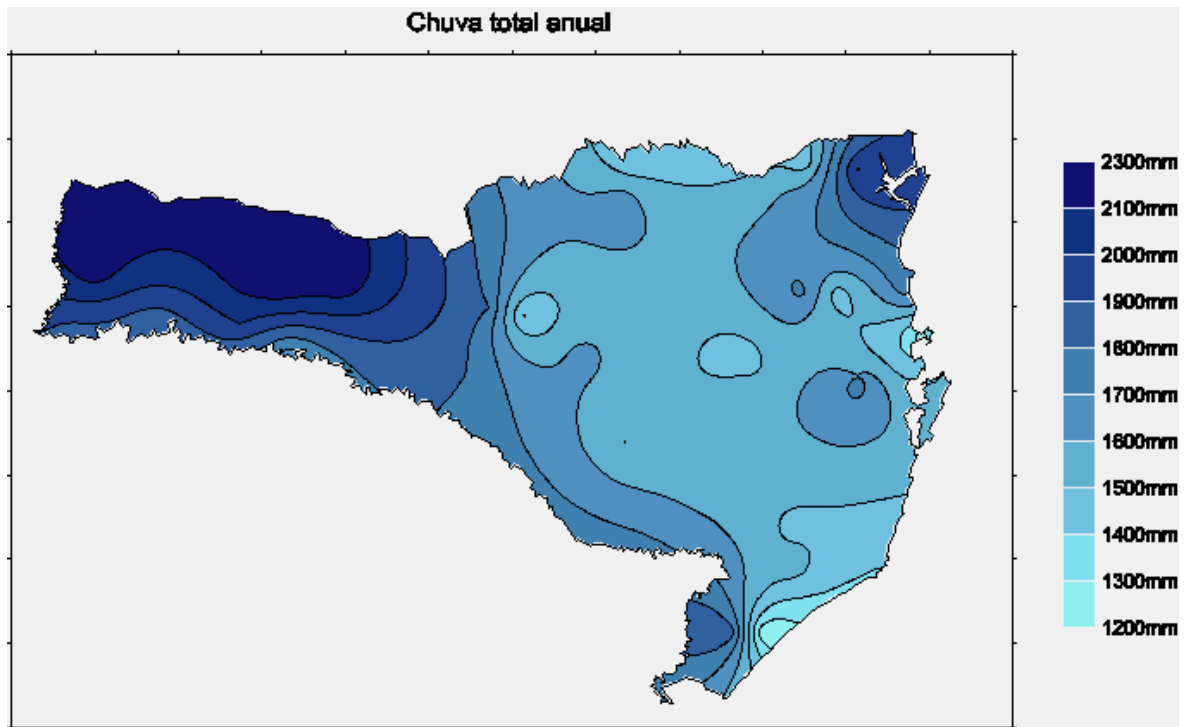


Figura 6 - Precipitação típica em Santa Catarina – Anual (in, CLIMERH, 2002)

O sistema de potência da CELESC é o responsável pelo suprimento de energia elétrica em 91,79% da área do Estado de SC, abastecendo praticamente todos os municípios do Estado, a exceção de alguns poucos municípios atendidos por cooperativas locais ([12] CELESC, 2003). Atende 1.804.503 clientes através de sua infra-estrutura de transmissão e distribuição de energia elétrica, em parte composta de 116 subestações, das quais 55 são telecontroladas pelo SCADA, 111.837 transformadores de distribuição, 1.230.250 postes e 92.755 km de redes de distribuição de energia elétrica com tensões de até 138KV (dados de julho de 2002). A Figura 7 apresenta uma visão simplificada do sistema de potência da CELESC.

SISTEMA DE TRANSMISSÃO - DEZ/00

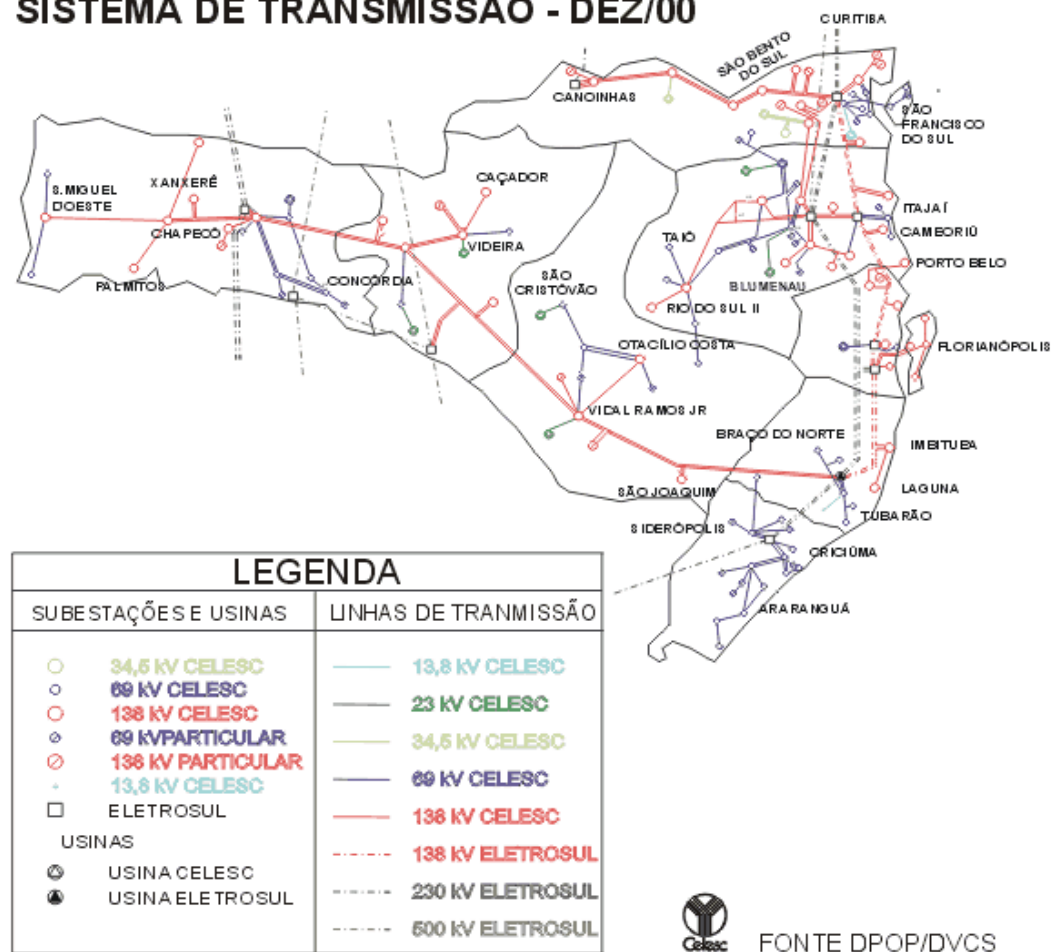


Figura 7 – Sistema de potência da CELESC (documentação interna da CELESC)

A gerência deste enorme patrimônio em redes de distribuição de energia elétrica, bem como o atendimento aos clientes, é feito de forma descentralizada. Para tanto, a CELESC subdivide sua administração em 17 unidades administrativas descentralizadas, denominadas Agências Regionais. Cada uma destas unidades administrativas é responsável pelo seu patrimônio e atendimento aos clientes em determinados municípios catarinenses. A Figura 8 apresenta um mapa com uma visão da distribuição de 16 destas unidades no Estado catarinense. A Agência Regional de Jaraguá do Sul não está representada no mapa. É uma Agência Regional recém criada a partir do desmembramento do município de Jaraguá do Sul e alguns outros próximos a este da área de abrangência da Regional de Joinville. O ANEXO 8.3 provê informações mais detalhadas sobre a infra-estrutura em redes de distribuição da CELESC e de seu sistema SCADA (denominado de SDSC – Sistema Digital de Supervisão e Controle pela companhia).

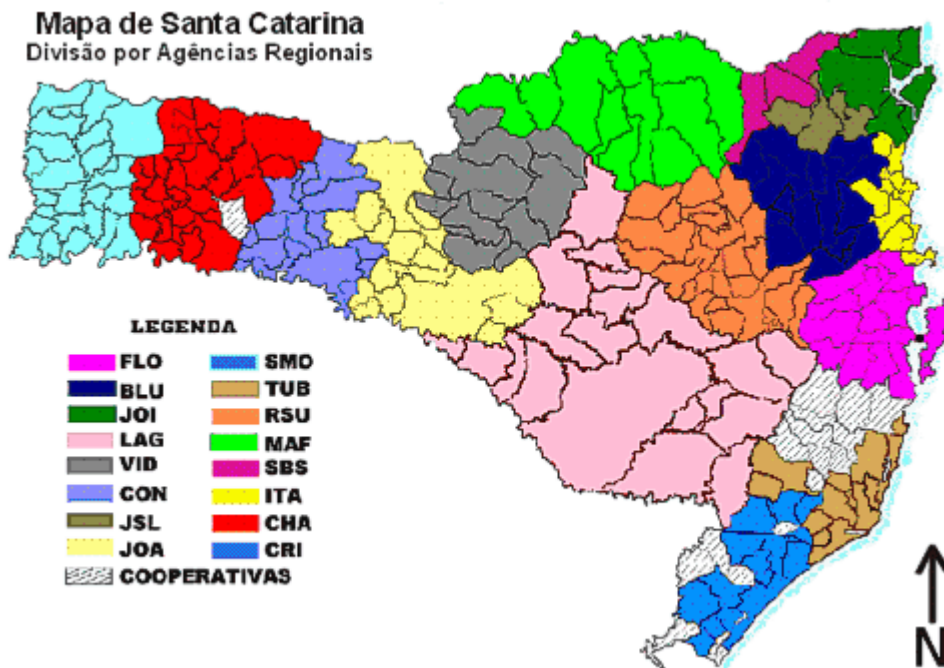


Figura 8 - Distribuição Geo-administrativa da CELESC (in, [12] CELESC, 2003)

O sistema hipotético utilizado como objeto de estudo constitui-se de seis pontos (nós) do sistema de potência da CELESC e três estações climáticas distintas: verão, transição climática (outono) e inverno. Estes seis pontos, doravante denominados Ponto 1 à Ponto 6, são responsáveis pelo suprimento da demanda por carga de seis micro-regiões de consumo da aérea de concessão da CELESC. Os pontos foram escolhidos levando em consideração que (a) cada um deles apresenta um comportamento de demanda por carga distinta dos demais pontos, (b) cada um dos mesmos pode ser considerado como um dos padrões de comportamento da demanda encontrados no sistema de potência da CELESC e (c) existiam disponíveis medições de carga e medições climáticas, em cada um dos pontos, para a realização dos experimentos. As três estações climáticas foram formadas por três períodos de quatro semanas consecutivas cada um. A estação climática **Verão**, com as 4 semanas do período de 13/01/2003 a 09/02/2003. A estação climática **Transição ou Outono**, com as 4 semanas do período de 05/05/2003 a 01/06/2003. A estação climática **Inverno**, com as 4 semanas do período de 14/07/2003 a 10/08/2003, para todos os pontos com exceção dos Pontos 5 e 6 (Sadia e Seara), onde havia extensos períodos sem histórico de dados de carga devido a falhas no sistema de comunicação da CELESC. Para estes dois

pontos, utilizou-se o período de 30/06/2003 a 27/07/2003.

Ponto 1 – Carga dos Transformadores 1 e 2, subestação Trindade

O Ponto 1, doravante denominado Trindade (TDE), é o somatório das cargas dos transformadores 1 e 2 (TT1 e TT2), ambos com tensão de trabalho de 138/13,8KV e potência máxima de 26,67MVA, da subestação Trindade e é o responsável pelo suprimento da demanda por carga do bairro da Trindade, na cidade de Florianópolis, SC. O bairro da Trindade é um bairro de característica mista: residencial e serviços em uma cidade (Florianópolis) litorânea do Estado. A carga do bairro é composta das cargas de residências, tanto uni quanto multifamiliares, das cargas de comércio de bairro (padarias, farmácias, bancos, postos de gasolina, pequenos shopping centers, etc) e da carga da Universidade Federal de Santa Catarina.

Ponto 2 – Carga dos Transformadores 1 e 2, subestação Ilha Norte

O Ponto 2, doravante denominado Ilha Norte (INE), é o somatório das cargas dos transformadores 1 e 2 (TT1 e TT2) da subestação Ilha Norte, ambos com tensão de trabalho de 138/13,8KV e potência máxima de 26,67MVA, e é o responsável pelo suprimento da demanda por carga de toda a região norte da ilha de Santa Catarina, SC. A região norte da Ilha de Santa Catarina abrange a região de Ingleses e parte do município de Florianópolis. Com belíssimas praias e balneários famosos esta região possui demanda de carga predominante de característica de área de veraneio, embora na mesma existam algumas subáreas de característica residencial.

Ponto 3 – Carga do Transformador 2, subestação Ilha Centro

O Ponto 3, doravante denominado Ilha Centro (ICO), é a carga do transformador 1 (TT1) da subestação Ilha Centro, com tensão de trabalho de 138/13,8KV e potência máxima de 33,33MV, e é o responsável pelo suprimento da demanda por carga no centro da cidade de Florianópolis, SC. A carga do centro da cidade possui característica de carga predominante de área comercial embora implícita a esta carga exista um pequeno percentual de carga com característica residencial.

Ponto 4 – Carga dos Transformadores 1, 2 e 3, subestação Itajaí Salseiros

O Ponto 4, doravante denominado Itajaí (ISS), é o somatório das cargas dos

transformadores 1, 2 e 3 (TT1, TT2 e TT3) da subestação Itajaí Salseiros, todos com tensão de trabalho de 69/23KV e potências máximas de 16,67MVA, 20,00MVA e 16,67MVA, respectivamente, e é o responsável pelo suprimento da demanda por carga da cidade de Itajaí, SC. Itajaí é uma cidade litorânea e portuária de médio porte, com demanda por carga: residencial predominantemente unifamiliar, comercial, industrial e do porto de Itajaí.

Ponto 5 – Carga dos Transformadores 1 e 2 da Sadia abastecidos pela subestação Concórdia

O Ponto 5, doravante denominado Sadia (SAD), é a carga do transformador da subestação da indústria de alimentos Sadia, com tensão de trabalho de 69/13,8KV e potência máxima de 6,25MVA, alimentado pela subestação Concórdia, e é o responsável pelo suprimento da demanda por carga da Sadia, localizada no oeste do Estado de Santa Catarina, na cidade de Concórdia.

Ponto 6 – Carga dos Transformadores 1, e 2, subestação Seara

O Ponto 6, doravante denominado Seara (SRA), é o somatório das cargas dos transformadores 1 e 2 (TT1 e TT2) da subestação Seara, ambos com tensão de trabalho de 69/23KV e potência máxima de 9,375MVA, e é o responsável pelo suprimento da demanda por carga da cidade de Seara, SC. Situada próxima à cidade de Concórdia, Seara é uma típica cidade de médio porte do oeste catarinense, com demanda por carga: residencial predominantemente unifamiliar, comercial e industrial.

Na estação climática Outono, para todos os Pontos, os dados sofreram as seguintes alterações:

- a) Dados carga de 01/05/2003 e 2/05/2003 (quinta-feira (feriado) e sexta-feira (dia após feriado)), utilizados como referência de semana anterior na 1ª semana da massa de dados de treino, substituídos pelos de carga de quinta-feira da semana anterior (24/04/03);
- b) Dados de carga de referência ao ano anterior, dos dias 30/5 e 31/05/2002 (quinta (feriado) e sexta (dia após feriado)), utilizados na massa de dados de teste, substituídos pelos dados de 23/05 e 24/05/2002.

Para os Pontos 5 (SAD) e 6 (SRA), estação climática Inverno, havia falha no histórico de dados de carga, relativos ao período de segunda-feira à quinta-feira da segunda semana de dados do ano de 2002 (4 dias). Estes dados foram substituídos pelos dados da média entre as curvas de carga destes dias das semanas anterior e posterior a semana em questão. Já para o Ponto 4 (ISS), na estação climática Verão, não há histórico de medições de umidade relativa do ar e velocidade e direção de vento. Finalmente, para os Pontos 5 (SAD) e 6 (SRA), para as três estações climáticas (Verão, Inverno e Outono), não há histórico de medições de radiação solar.

No ANEXO 8.4, as figuras: Figura 35 à Figura 52, apresentam as curvas da carga média a cada $\frac{1}{2}$ hora para cada uma das quatro semanas de cada Ponto e estação climática considerados. As figuras: Figura 53 à Figura 61, as curvas da temperatura média a cada $\frac{1}{2}$ hora para cada uma das estações climáticas nas regiões estudadas. A macro região **Florianópolis** contém os Pontos ICO, TDE e INE. A macro região **Itajaí**, o Ponto ISS e a macro região **Seara**, os Pontos SAD e SRA. As curvas apresentadas são relativas às cargas e temperaturas ambiente do ano de 2003.

5. EXPERIMENTAÇÃO

A experimentação foi dividida e executada em duas grandes etapas, nomeadas Etapa I e Etapa II. A Etapa I foi utilizada para apoiar a construção e ajuste dos algoritmos, bem como para validar e/ou corrigir as premissas e parâmetros adotados no projeto. Através destes experimentos, foi feita a validação inicial do núcleo do modelo proposto: algoritmos dos modeladores evolutivos e da rede neural artificial e sua comparação como o modelo de Oliveira (1999). Nesta Etapa, os testes foram realizados considerando-se um único ponto do sistema elétrico da CELESC e um mesmo período de tempo. Na Etapa II, os testes com os algoritmos ajustados na Etapa I foram estendidos de forma a abranger os pontos e períodos definidos no sistema hipotético. Em ambas as Etapas considerou-se como conhecidas a priori as condições climáticas futuras.

Na avaliação do modelo proposto foram utilizados oito indicadores distintos: os Erros Percentuais Máximo (EPMax) e Médio (MAPE), o MAPE*, os Erros Absolutos Máximo (EAMax) e Médio (EAMed), a Raiz Quadrada da Média do Somatório do Erro Quadrático (RMSE), o Somatório do Erro Quadrático (SSE) e o Desvio Padrão do Erro. Estes indicadores são detalhados e discutidos na seção 2.6. Dos oito indicadores utilizados, o RMSE, o MAPE e o MAPE* foram considerados como os mais relevantes. Dentre estes, o RMSE foi considerado como o indicador principal para a avaliação do modelo, pois a função objetivo utilizada para proceder a minimização do erro de treinamento da rede neural e para direcionar a evolução do algoritmo evolutivo foi baseada no somatório do erro quadrado absoluto. Como a Etapa I tem o papel de apoio na construção do modelo, nesta Etapa, é apresentada apenas a avaliação do modelo através dos indicadores: RMSE e MAPE. Na Etapa II, onde os testes são estendidos de forma a abranger os pontos e períodos definidos no sistema hipotético, é apresentada uma avaliação do modelo utilizando todos os oito indicadores apresentados na seção 2.6.

Nos Modeladores Evolutivos, as evoluções foram direcionadas de forma a minimizarem a parcela variável dos RMSEs obtidos durante os treinamentos das RNAs. Os Modeladores Evolutivos são fundamentados em técnica probabilística. Devido a isto, os experimentos, cada qual com seus ajustes individuais, foram repetidos buscando a

confirmação da qualidade de seus resultados. Na Etapa I, onde os experimentos serviram para apoiar a construção do modelo, cada um dos experimentos foi repetido até nove vezes, que foi considerado como suficiente para garantir a confiabilidade dos resultados e estabilidade do modelo. Na Etapa II, como o modelo já tinha sido validado e verificado na Etapa anterior, cada experimento realizado foi repetido por duas vezes, número que foi considerado suficiente para a confirmação dos resultados obtidos. Nos experimentos das Etapa I e Etapa II, utilizando dados normalizados, a massa de dados foi normalizada segundo a (20) e a (21), respectivamente. Na (21), as constantes de valores 15 e 55 tiveram como finalidade deslocar a maioria dos valores dos dados para o intervalo [10, 100] com valor médio em 55, evitando com isto o uso de dados com valores zero ou próximos a este. Os experimentos foram realizados por meio de simulação computacional, utilizando a ferramenta computacional Matlab, biblioteca de funções GAOT (Houck & Joines, 1995 e Houck & Joines, 1996), linguagem de programação C, banco de dados PostGreSQL, microcomputadores do tipo PC com sistemas operacionais LINUX, WindowsXP e Windows2000 e interconectados por rede de 100Mbits.

$$x_{norm} = (x - \bar{x}) / \sigma_x \quad (20)$$

$$x_{norm} = 15((x - \bar{x}) / \sigma_x) + 55 \quad (21)$$

Onde:

- x_{norm} É o valor da variável normalizado
- x É o valor da variável
- \bar{x} É o valor médio da variável
- σ_x É o desvio padrão da variável

5.1 Etapa I

Na Etapa I, os experimentos foram realizados apenas para o ponto do sistema elétrico da CELESC referente a carga dos transformadores 1 e 2, da subestação Trindade (Ponto 1 - TDE do sistema hipotético) utilizando uma massa de dados derivada do histórico de medições de carga e clima disponíveis para este Ponto. O histórico utilizado refere-se às medições do comportamento da carga e clima referentes ao período de 13/05 a 07/07 dos anos de 2001 e 2002, para este Ponto. Neste, complementou-se as medições de

carga e temperatura ambiente coletados pelo Sistema Digital de Supervisão e Controle da CELESC com as medições de temperatura ambiente e umidade relativa do ar coletados pela estação meteorológica do Itacorubi e controlada pelo Centro Integrado de Meteorologia e Recursos Hídricos de Santa Catarina – CLIMERH.

A massa de dados resultante foi utilizada para compor dois conjuntos de dados, denominados conjuntos de Treino e de Teste. O conjunto de treino foi composto com dados de um período de três semanas consecutivas e o conjunto de Teste, com dados de uma semana (quarta semana). O conjunto de Treino foi utilizado para treinar as RNAs e o de Teste para testar as redes treinadas com o conjunto de Treino, tanto do modelo proposto quanto do modelo de Oliveira (1999). O vetor de entrada utilizado pelas redes neurais do modelo proposto foi determinado pelo modelador evolutivo de 1ª Ordem, a partir de um conjunto de 88 variáveis candidatas relativas a hora do dia, dia da semana, semana do ano, carga, temperatura ambiente e umidade relativa disponíveis.

5.1.1 Organização dos Experimentos

Os experimentos desta Etapa I foram divididos em grupos, denominados: **Aexp**, **Bexp**, **Cexp**, **Dexp**, **Eexp**, **Fexp** e **Gexp**. O grupo **Bexp** foi subdividido em sete subgrupos: **BexpA**, **BexpB**, **BexpC**, **BexpD**, **BexpE**, **BexpF** e **BexpG**. O grupo **Cexp** foi subdividido em dois subgrupos: **CexpF** e **DexpD**. O grupo **Dexp** compôs o subgrupo **DexpF**. O grupo **Eexp** foi subdividido em dois subgrupos: **EexpA** e **EexpB**. O grupo **Fexp** foi subdividido em dois subgrupos: **FexpA** e **FexpB**. Finalmente, o grupo **Gexp** foi subdividido em dois subgrupos: **GexpA** e **GexpB**. Na Etapa I, foram realizados 227 experimentos.

Grupo Aexp

Esse grupo de experimentos foi realizado para se obter conhecimentos iniciais a cerca dos comportamentos dos algoritmos que estavam sendo desenvolvidos, bem como para proceder pré-ajustes nos mesmos e seus resultados não serão comentados.

Grupo Bexp

Experimentos do grupo BexpA: Neste grupo de experimentos procedeu-se os ajustes iniciais dos algoritmos evolutivos: tamanho da população, número de gerações, probabilidades de mutação e *crossover*; tamanho e período dos conjuntos de treinamento e

teste da RNA. Ainda, foi experimentado o emprego de funções de mutação reais, o uso simultâneo, no vetor de entrada da RNA, de variáveis codificadas em binário e como número Real e o emprego da massa de dados sem normalização.

Experimentos do grupo BexpB: Neste grupo de experimentos foi experimentado o emprego de funções de mutação inteiras (porém os genes do cromossomo foram mantidos codificados como números reais). Ainda, foi testado o comportamento dos algoritmos com a presença de ruído nos dados. O ruído foi introduzido na massa de dados de treinamento da RNA como mais uma variável do vetor de entrada da rede, representada por um neurônio na camada de entrada da rede. Os valores desta variável foram gerados de forma aleatória. Foram testados ruídos com valores nos intervalos [0, 1], [0, 10], [0, 50] e [0, 100]. Foi mantido o uso da massa de dados sem normalização e o uso simultâneo, no vetor de entrada da RNA, de variáveis codificadas em binário e como número real. Neste grupo de experimentos, também foi comparado o melhor resultado obtido com o resultado obtido utilizando uma RNA com o vetor de entrada segundo Oliveira (1999), ambos os experimentos com o uso da mesma massa de dados de treinamento e teste.

Experimentos do grupo BexpC: Neste grupo de experimentos foi efetuada a busca de pesos da primeira camada da RNA, de forma a ponderar as variáveis de entrada da RNA. Ainda, foram experimentadas variações na precisão do conteúdo dos genes do cromossomo, responsáveis pelos valores dos pesos das variáveis de entrada da RNA, e variações na probabilidade de mutação. Foram utilizados funções de mutação reais, massa de dados sem normalização e o uso simultâneo, no vetor de entrada da RNA, de variáveis codificadas em binário e como número real. A partir do experimento BExpC4 deste grupo de experimentos e até o último experimento do grupo BexpE, foi alterada a ordem das variáveis no vetor de entrada da RNA.

Experimentos do grupo BexpD: Neste grupo de experimentos foi iniciado os testes com o escalonamento do valor da função de fitness segundo o discutido na seção 2.4 bem como, a partir deste grupo, deixou-se de utilizar no vetor de entrada da RNA variáveis codificadas em binário, passando-se a utilizar apenas codificação real. Também foram testados, dentre outros, variações no escalonamento da função de fitness e na probabilidade de mutação. Foi mantida a utilização de dados sem normalização.

Experimentos do grupo BexpE: Neste grupo de experimentos foi experimentado

um aumento no número de gerações dos algoritmos evolutivos. Foram feitos testes variando a precisão do valor dos genes do cromossomo em 0,1 e 1 (valor inteiro), a probabilidade de mutação, o valor de escalonamento da função de fitness e o número de gerações, dentre outros. Neste grupo de experimentos foi utilizada uma massa de dados normalizada.

Experimentos do grupo BexpF: A partir deste grupo de experimentos voltou-se a adotar a ordem das variáveis de entrada do vetor de entrada da RNA utilizada anteriormente ao experimento BExpC4. Ainda, foi experimentado a supressão no vetor de entrada de algumas categorias de variáveis climáticas. Foi fixado em $k=2,5$ o escalonamento da função de fitness, utilizado funções de mutação inteiras e utilizado a massa de dados sem normalização.

Experimentos do grupo BexpG: Neste grupo de experimentos, repetiu-se o experimento **BexpF** utilizando a massa de dados normalizada.

Grupo Cexp

Experimentos do grupo CexpF: Neste grupo de experimentos, através da técnica de busca exaustiva, buscou-se a confirmação de que os números de agrupamentos escolhidos pelo algoritmo evolutivo nos experimentos do grupo **BExpF** são realmente os números ótimos de clusters para estes experimentos.

Grupo Dexp

Experimentos dos grupos DexpD e DexpF: Os experimentos deste dois grupos tiveram por finalidade buscar o valor a ser atribuído ao fator de escala k , utilizado para a ponderação da variância de cada agrupamento da RBF, conforme descrito na seção 3.2.1., para as arquiteturas de RNAs obtidas nos experimentos dos grupos **BExpD** e **BExpF**. A massa de dados utilizada foi a sem normalização.

Grupo Eexp

Experimentos do grupo EexpA: Nos experimentos descritos anteriormente, conforme comentado no início da seção 5, a evolução dos Modeladores Evolutivos foi direcionada de forma a minimizar o RMSE obtido durante o treinamento da RNA. Nos experimentos deste grupo, foi adotado um procedimento diferente, porém também utilizando o RMSE para a mensuração do erro, para direcionar a evolução do AG.

Inicialmente, da massa de dados utilizada para a fase de treino (conjunto de Treino) foram retirados de forma aleatória 15% dos padrões, os quais foram utilizados para compor um novo conjunto de dados, denominado de conjunto Teste-Treino. Os 85% de dados remanescentes no conjunto de Treino, foram utilizados como o novo conjunto de Treino. As RNAs destes experimentos foram treinadas de forma a minimizar o RMSE utilizando os dados do novo conjunto de Treino. Em seguida, as redes tiveram o RMSE mensurado com os dados com o conjunto de Teste-Treino, sendo este RMSE utilizado para direcionar a evolução dos Modeladores Evolutivos. Os demais ajustes foram os mesmos adotados para os experimentos do grupo **BExpF**, inclusive adotando-se a massa de dados sem normalização.

Experimentos do grupo EexpB: Este experimento repete o experimento do grupo **EexpA** com a diferença de que a massa de dados utilizada foi expandida para um período de cinco semanas.

Grupo Fexp

Experimentos dos grupos FexpA e FexpB: Neste grupo de experimentos, através da técnica de busca exaustiva, buscou-se a confirmação de que os números de agrupamentos escolhidos pelo algoritmo evolutivo nos experimentos dos grupos **EExpA** e **EExpB** são realmente os números ótimos de clusters para estes experimentos.

Grupo Gexp

Experimentos do grupo GexpA e GexpB: Os experimentos deste dois grupos tiveram por finalidade buscar o valor a ser atribuído ao fator de escala k , utilizado para a ponderação da variância de cada agrupamento da RBF para a arquitetura de RNA obtida nos experimentos **EExpA** e **EExpB**. A massa de dados utilizada foi a sem normalização.

5.1.2 Resultados Numéricos e Discussões

Durante os testes da Etapa I, foi observado que o modelo de cromossomo proposto para o Modelador Evolutivo de 1ª Ordem, não produziu os resultados esperados, apresentando erros elevados e dificuldade de convergência. Com isto, o cromossomo deste Modelador foi redimensionado e reduzido, tendo sido retirado do mesmo os genes responsáveis pela determinação (a) da quantidade de agrupamentos da camada

intermediária da rede e (b) e dos fatores de escala k , utilizados para a ponderação das variâncias dos agrupamentos. O novo cromossomo passou a ser composto dos genes da primeira parte do cromossomo original, relativos a representação das variáveis de entrada da RNA, acrescido de mais um gene responsável pela codificação do número de agrupamentos da camada intermediária da rede. Para a obtenção da parcela de ajuste esperada com a segunda parte (retirada) do cromossomo original, foi adotada a estratégia de execução do Modelador Evolutivo de 2ª Ordem ao término do Modelador de 1ª Ordem.

Os resultados obtidos comprovam o funcionamento segundo o esperado da nova versão do Modelador de 1ª Ordem (versão modificada) e do Modelador de 2ª Ordem, bem como a superioridade do modelo proposto quando comparado ao modelo de Oliveira, (1999). A Tabela 1 apresenta os resultados alcançados nesta Etapa I, na aplicação do modelo proposto para (a) a previsão da carga ½ hora à frente durante uma semana e (b) a previsão da carga ½ hora à uma semana à frente. Também, compara com os resultados obtidos com o modelo de Oliveira (1999), aplicado ao ponto TDE (Trindade) e utilizando a mesma massa de dados. Já a Tabela 2, mostra os resultados obtidos com a aplicação do Modelador de 1ª Ordem (versão modificada) e com a aplicação de ambos Modeladores (Modelador de 2ª Ordem após o de 1ª Ordem). Os melhores resultados foram obtidos com os Modeladores de 1ª e de 2ª Ordem ajustados segundo as configurações dos Grupos BExpF e DExpF, respectivamente.

Tabela 1 - Resultados da Etapa I: modelo adaptativo versus Oliveira, 1999

		TDE, 10/06/02 à 07/07/02	
		Modelo adaptativo Etapa I	Oliveira, 1999
Erro			
Treino	RMSE (MW)	0,64	1,94
	MAPE (%)	1,96	6,31
Teste ½ hora à frente	RMSE (MW)	0,66	2,44
	MAPE (%)	2,08	8,39
Teste ½ hora à 1 semana à	RMSE (MW)	1,16	3,45
	MAPE (%)	3,63	10,93

Tabela 2 - Etapa I: resultados com a aplicação dos Modeladores de 1ª e 2ª Ordem

TDE, 10/06/02 à 07/07/02				
	Erro	Modelo adaptativo de 1ª Ordem	Modelos adaptativos de 1ª e 2ª Ordem	Ganho de precisão (%)
Treino	RMSE (MW)	0,72	0,64	11,1
	MAPE (%)	2,29	1,27	44,5
Teste ½ hora à frente	RMSE (MW)	0,77	0,66	14,3
	MAPE (%)	2,59	1,37	47,1
Teste ½ hora à 1 semana à frente	RMSE (MW)	1,22	1,16	4,9
	MAPE (%)	4,09	2,38	41,8

Os resultados apresentados na Tabela 1 apontam, com o uso dos dados do Ponto TDE, na fase de adaptação, um RMSE de 0,64MW com o modelo adaptativo contra um de 1,94MW com o modelo de Oliveira (1999). Isto representa uma redução no valor do erro (ganho de precisão) de 67,0% ou, em outras palavras, que o modelo de Oliveira (1999) é aproximadamente três vezes pior que o proposto. Na previsão ½ hora à frente durante uma semana, os RMSEs do modelo adaptativo e do modelo de Oliveira (1999) foram de 0,66MW e de 2,44MW, respectivamente. Nesta fase, o ganho de precisão foi de 72,9%. Por fim, na previsão ½ hora à uma semana à frente, os RMSEs do modelo adaptativo e do modelo de Oliveira (1999) foram de 1,16MW e 3,45MW, respectivamente, o que mostra um ganho de aproximadamente 66,4%. Além da maior precisão do modelo proposto, cabe ressaltar a simplificação na identificação dos parâmetros (e respectivos valores) da rede neural, agora, identificados e ajustados pelos Modeladores Evolutivos.

A Tabela 2 confirma o ganho de precisão esperado com o uso combinado dos dois Modeladores. Tomando por base o RMSE, o emprego do Modelador de 2ª Ordem após o de 1ª Ordem, propicia ganhos nas fases de treino, teste e teste recursivo de 11,1%, 14,3% e 4,9%, respectivamente. Os resultados apresentados, referentes ao emprego dos Modeladores de 1ª e de 2ª Ordem, são referentes a experimentos dos grupos BExpF e DExpF, respectivamente.

As figuras: Figura 9 à Figura 14, apresentam de forma gráfica e detalhada os

resultados obtidos utilizando-se os modelos (a) adaptativo e (b) Oliveira (1999), cujos resultados numéricos médios são apresentados na Tabela 1. Os gráficos apresentados nas figuras confirmam os resultados apresentados na referida Tabela, mostrando a superior capacidade de adaptação e previsão do modelo proposto, quando comparado ao modelo de Oliveira (1999). Adicionalmente, os gráficos mostram que além da maior precisão na previsão da carga, apontada pelos índices de avaliação de erro médio utilizados, o modelo proposto privilegia a adaptação e previsão da carga relativa aos horários próximos à ponta do sistema, período crítico para os sistemas de transmissão e distribuição de energia elétrica.




Figura 9. Oliveira, 1999 – Ajuste




Figura 10. Modelo adaptativo – Ajuste




Figura 11. Oliveira, 1999 – Teste, ½ hora à frente.




Figura 12. Modelo adaptativo – Teste, ½ hora à frente.




Figura 13. Oliveira, 1999 – Teste, ½ hora a 1 semana à frente.




Figura 14. Modelo adaptativo – Teste, ½ hora a 1 semana à frente.

As figuras: Figura 15 e Figura 16, apresentam de forma gráfica a temperatura ambiente e a umidade relativa do ar, respectivamente, vigentes em na região de Florianópolis, que compreende o Ponto TDE, nas quatro semanas que compõem o período de 13/05 a 07/07 do ano de 2002. As mesmas mostram a forte variabilidade climática ocorrida em Florianópolis no período, com temperatura ambiente variando entre 6°C e 31°C e umidade relativa do ar variando entre 35% e 100%, aproximadamente. A Figura 17 mostra a carga no Ponto TDE (transformadores 1 e 2 da subestação Trindade) no mesmo período.

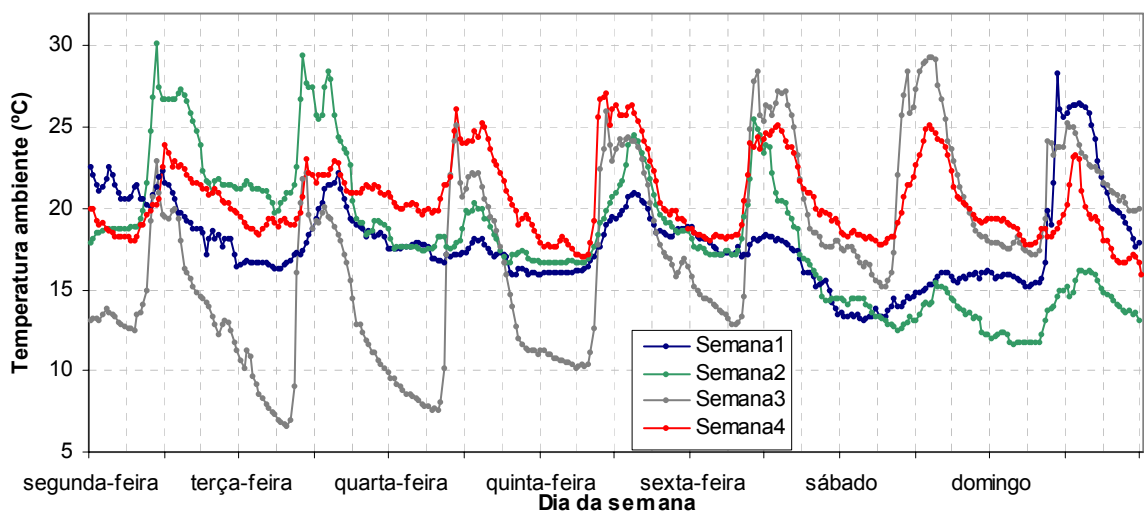


Figura 15. Florianópolis, Temperatura Ambiente, período de 10/06 a 07/07/02.

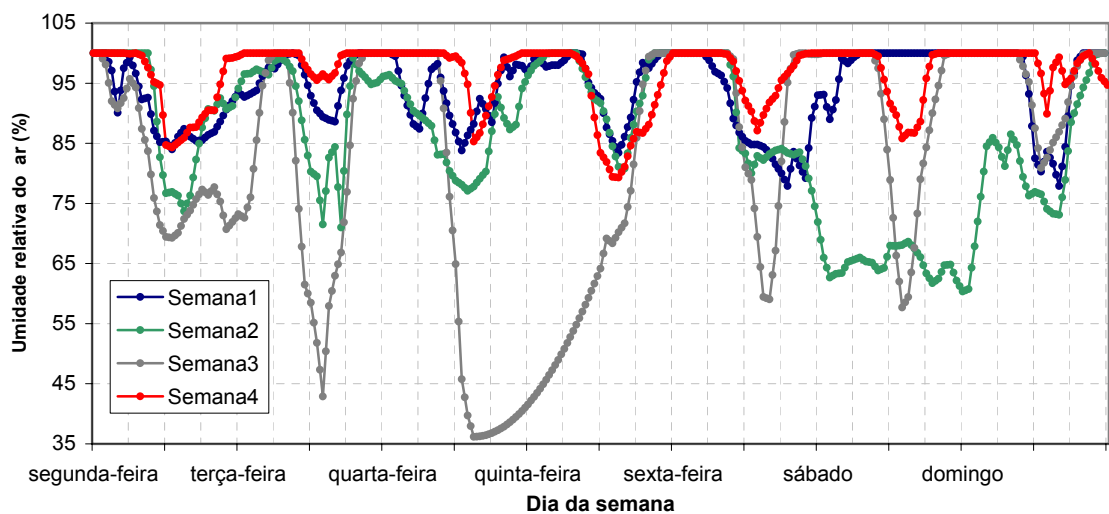


Figura 16. Florianópolis, Umidade Relativa do Ar, período de 10/06 a 07/07/02.




Figura 17. TDE, Potência Ativa, período de 10/06 a 07/07/02.

Concluindo, os resultados obtidos nesta Etapa I mostram que o modelo é mais eficiente quando as variáveis de entrada da rede são utilizadas sem ponderação, o que é feito atribuindo-se valor unitário (um) a todos os pesos da primeira camada da RNA. Os testes mostram ainda que os Modeladores Evolutivos produzem melhores resultados quando se faz uso da roleta ponderada pelo procedimento de truncamento sigma (*sigma truncation*), de acordo com a fundamentação teórica apresentada na seção 2.4. Também, que a composição do vetor de entrada da RNA simultaneamente com variáveis codificadas em valores binários e valores pertencentes ao conjunto dos reais, dificulta o ajuste da RNA. Melhor resultado foi obtido com o uso de todas as variáveis codificadas com valores pertencentes ao conjunto dos reais. Com isto, foi abandonado o uso de variáveis com codificação em binário. Com relação a RNA utilizada, de acordo com o esperado e com o relatado em Oliveira (1999), a RBF demonstrou facilidade de ajuste e boa velocidade treinamento. Os treinamentos das redes foram realizados com matrizes de dados com tamanho de 1008 linhas e, em média, 170 colunas. O tempo de treinamento médio de cada

RNA foi de aproximadamente 13 segundos em microcomputadores do tipo PC, dotados de processador Pentium 4 de 2,4GHz, 512MB de memória RAM e sistema operacional Windows XP Professional. Nesta Etapa I, os melhores resultados foram obtidos com a massa de dados sem aplicação de normalização nos dados. Por fim, a posição em que as variáveis são codificadas no cromossomo do Modelador Evolutivo de 1ª Ordem, em associação com suas vizinhas, influencia na facilidade de convergência do algoritmo evolutivo.

5.2 Etapa II

Nesta Etapa, se utilizou os algoritmos ajustados e validados na Etapa I para os testes, utilizando os pontos e períodos definidos no sistema hipotético detalhado no capítulo 4. A massa de dados que foi utilizada é o histórico de medições de carga e clima disponíveis para os pontos do sistema hipotético, nos anos de 2002 e 2003. O histórico utilizado refere-se às medições do comportamento da carga, temperatura ambiente e velocidade e direção do vento da CELESC, e as medições de temperatura ambiente, velocidade e direção do vento, umidade relativa do ar, pressão atmosférica e radiação solar total do CLIMERH e do Laboratório LABSOLAR (LABSOLAR/NCTS) da Universidade Federal de Santa Catarina. Na Etapa II, foram realizados 317 experimentos.

5.2.1 Organização dos Experimentos

Nesta Etapa II, a massa de dados contendo o histórico de medições de carga e clima relativa ao sistema hipotético descrito na seção 4, referente aos anos de 2002 e 2003, foi utilizada para compor os conjuntos de dados: Verão, Transição (Outono) e Inverno, de quatro semanas cada um, para cada um dos seis pontos do sistema hipotético. A seguir, cada um dos dezoito conjuntos de dados foi dividido em dois subconjuntos, denominados conjuntos de Treino (Ajuste) e de Teste (Previsão). Cada conjunto de Treino foi composto com dados de um período de três semanas consecutivas e cada conjunto de Teste, com dados de uma semana (quarta semana). Os conjuntos de Ajuste foram utilizados para treinar as RNAs e os de Previsão para testar as redes treinadas com os conjuntos de Ajuste.

Nesta Etapa, em virtude do montante de experimentos e realizar e dos prazos para a

conclusão dos trabalhos, foi utilizado apenas o Modelador Evolutivo de 1ª Ordem na adaptação do modelo aos Pontos e estações climáticas em estudo. O vetor de entrada, utilizado pelas redes neurais do modelo proposto, foi determinado pelo modelador evolutivo de 1ª Ordem a partir de um conjunto de 216 variáveis candidatas relativas a hora do dia, dia da semana, semana do ano, carga, temperatura ambiente, umidade relativa do ar, velocidade e direção do vento, pressão atmosférica e radiação solar total. Não foram utilizadas variáveis binárias no vetor de entrada da RNA. O ANEXO 8.1 apresenta uma descrição detalhada das variáveis candidatas.

Os experimentos da Etapa II foram divididos em três grandes grupos, denominados **Grupos A, B e C**. Nos experimentos do Grupo A, foi testada a capacidade de adaptação e ajuste (treino) do modelo proposto a cada um dos Pontos do sistema hipotético, para cada uma das três estações climáticas: Verão, Outono e Inverno. Assim, o modelo foi aplicado a cada um dos seis Pontos (ICO, INE, TDE, ISS, SAD e SRA), em cada Ponto para cada uma das três estações climáticas. Ainda, para cada Ponto e estação climática, o modelo foi adaptado e ajustado com o histórico de (a) carga e de todas as variáveis climáticas disponíveis, (b) carga e temperatura ambiente e (c) apenas carga, obtendo-se assim um total de cinquenta e quatro modelos, originando 54 experimentos distintos, cada um especializado por Ponto e estação climática.

O modelo proposto é probabilístico, não possuindo garantia de atingir sempre o mesmo resultado. Com o intuito de verificar sua estabilidade, elegeu-se um dos 54 experimentos: Ponto ICO, estação climática **Inverno**, carga e todas as variáveis climáticas, e este experimento foi repetido por 99 vezes. Conhecida a estabilidade do modelo, cada um dos cinquenta e três tipos de experimentos restantes foram repetidos por duas vezes, número considerado como suficiente para a avaliação da qualidade dos resultados. No Grupo A, foram realizados um total de 259 experimentos.

Nos experimentos do Grupo B, foram verificadas as perdas de precisão quando modelos adaptados e ajustados (treinados) para um dado Ponto e estação climática são aplicados no mesmo Ponto, porém em outras estações climáticas, após passarem apenas por um processo de retreinamento (reajuste). Para tanto, para cada Ponto e estação climática, após retreinamento, foram aplicados os modelos adaptados (identificados como ótimos) para as duas outras estações climáticas, sendo os resultados obtidos na fase de

reajuste (retreinamento), comparados com o resultado obtido no ajuste com o modelo adaptado para a estação climática em questão. No Grupo B, foram realizados apenas experimentos com o histórico do tipo 'a' (todas as variáveis climáticas disponíveis). Neste Grupo, foram realizados um total de 34 experimentos.

Finalmente, nos experimentos do Grupo C foram verificadas as perdas de precisão quando modelos adaptados e ajustados (treinados) para uma dada estação climática e Ponto são aplicados em outros Pontos, dentro da mesma estação climática, após passarem apenas por um processo de retreinamento (reajuste). Para tanto, para cada estação climática e Ponto, após retreinamento, foram aplicados os modelos adaptados (identificados como ótimos) para os demais Pontos da mesma estação climática, sendo os resultados obtidos na fase de reajuste (retreinamento), comparados com o resultado obtido no ajuste com o modelo adaptado para a estação climática e Ponto em questão. Da mesma forma que no Grupo B, no Grupo C, foram realizados apenas experimentos com o histórico do tipo 'a' (todas as variáveis climáticas disponíveis), tendo sido realizados um total de 24 experimentos.

5.2.2 Resultados Numéricos e Discussões

5.2.2.1 Grupo A

Neste Grupo de experimentos foi testada a capacidade de adaptação e ajuste (treino) do modelo proposto a cada um dos seis Pontos e cada uma das três estações climáticas, utilizando-se três tipos de históricos de dados distintos (a) carga e de todas as variáveis climáticas disponíveis, (b) carga e temperatura ambiente e (c) apenas carga (históricos tipos 'a', 'b' e 'c'). As tabelas: Tabela 23 a Tabela 40, do ANEXO 8.7, apresentam de forma detalhada a capacidade (precisão) de ajuste (treino), previsão ½ hora à frente (teste) e previsão a cada ½ hora, uma semana à frente (teste recursivo) do modelo, para cada um dos 162 experimentos realizados neste Grupo A, utilizando os oito indicadores descritos no início da seção 5. Os resultados apresentados estão agrupados pelo tipo de histórico utilizado. As tabelas: Tabela 23 a Tabela 28, Tabela 29 a Tabela 34 e Tabela 35 a Tabela 40 apresentam, respectivamente, os resultados obtidos com o uso dos históricos de (a) carga e todas as variáveis climáticas, (b) carga e temperatura ambiente e (c) apenas carga. Os resultados obtidos com o uso do histórico de carga e todas as variáveis climáticas

mostra que há superioridade de precisão ao se utilizar um conjunto mais abrangente de variáveis climáticas, bem como confirma a robustez do modelo quanto a sua capacidade de adaptação. Os experimentos em destaque são os eleitos como o melhor resultado de cada conjunto de três experimentos de igual configuração.

Já o ANEXO 8.8 apresenta de forma detalhada quais variáveis, dentre as disponíveis no conjunto de 216 de variáveis candidatas ao vetor de entrada da RNA descritas no ANEXO 8.1, foram selecionadas e utilizadas pelo modelo durante o processo de adaptação de cada um dos 162 experimentos realizados no Grupo A. Nas Tabelas constantes do Anexo, as variáveis com valores em branco significa que as mesmas não foram cogitadas para uso pelo modelo porque não havia histórico de dados disponível para o Ponto e estação climática em questão. Os resultados, apresentados nas tabelas: Tabela 41 à Tabela 46, mostram que o conjunto de variáveis selecionadas pelo modelo é específico para cada Ponto e estação climática do sistema hipotético, validando a hipótese da especificidade do vetor de entrada da RNA ao mercado de energia e condições de consumo vigentes.

A Tabela 3 apresenta um resumo dos resultados apresentados de forma detalhada no ANEXO 8.7. Nesta, através dos oito indicadores descritos no início da seção 5, é apresentada a precisão de ajuste (treino), previsão ½ hora à frente (teste) e previsão a cada ½ hora, uma semana à frente (teste recursivo) do modelo, obtida nos melhores experimentos utilizando o histórico de carga e todas as variáveis climáticas. Como já discutido, o RMSE é o indicador principal na avaliação da precisão do modelo.

A Tabela 4 apresenta os RMSEs obtidos na fase de ajuste (treino) em todos os 162 experimentos realizados no Grupo A. Ainda, verifica o ganho ou perda ocorrida na capacidade de adaptação do modelo, para cada Ponto e estação climática considerado, para os diferentes tipos de histórico de dados utilizado: (a) carga e todas as variáveis climáticas, (b) carga e temperatura ambiente e (c) apenas carga (históricos tipos 'a', 'b' e 'c'). Os resultados apresentados tornaram a confirmar a validade da hipótese da especificidade do vetor de entrada da RNA ao mercado de energia e condições de consumo vigentes. Ao analisar um dado Ponto nas três estações climáticas, tomando como exemplo o Ponto INE, temos para os melhores resultados dos experimentos do Verão, Outono e Inverno, ganhos de 24,62%, 18,27 e 7,7%, respectivamente, com o uso do histórico do tipo 'a' *versus* o do

tipo 'c' e de 5,61%, 14,95% e 7,02% com o do tipo 'a' *versus* o do tipo 'b'. Já para o Ponto SAD, os ganhos passam a ser, respectivamente, de 3,59%, 6,66% e 7,45% e de 1,91%, 4,86% e 5,10%. Ainda na Tabela 4, para os melhores experimentos de cada conjunto de três experimentos de igual configuração, os ganhos com o uso do histórico do tipo 'a' *versus* o do tipo 'c' variam entre 3,59% e 24,64%, dependendo do Ponto e estação climática considerados. Já com o uso do histórico do tipo 'a' *versus* o do tipo 'b', os ganhos variam entre 1,91% e 15,97%. Os experimentos em destaque são os eleitos como o melhor resultado de cada conjunto de três experimentos de igual configuração

Tabela 3 - Grupo A – Precisão dos melhores experimentos com Carga e Todas as Variáveis Climáticas

Fase	Tipo de Erro	Ponto / Estação Climática								
		ICO			INE			TDE		
		Inverno	Verão	Outono	Inverno	Verão	Outono	Inverno	Verão	Outono
Treino	Desvio Padrão Erro (MW)	0,08079	0,13676	0,10111	0,17886	0,29214	0,15348	0,23090	0,23344	0,26668
	Erro Máximo (%)	6,90363	11,60361	7,23448	7,51320	9,37179	8,75486	8,83630	7,45840	15,47509
	Erro Máximo (MW)	0,47214	0,98988	0,59461	1,78530	2,96210	1,20399	1,76690	2,50804	2,69096
	Erro Médio (MW)	0,09752	0,14036	0,11997	0,17733	0,28095	0,15790	0,24181	0,22842	0,25423
	MAPE (%)	1,05941	1,22669	1,16490	1,13894	1,01591	1,00619	0,99727	0,86437	1,02137
	MAPEm (%)	0,57075	0,43788	0,50974	0,65975	0,61659	0,57185	0,65710	0,61894	0,66209
	RMSE (MW)	0,12661	0,19592	0,15686	0,25180	0,40521	0,22015	0,33427	0,32652	0,36835
	SSE (MW)	16,15868	38,69092	24,80295	63,91167	165,50823	48,85410	112,62929	107,46788	136,76533
Teste	Desvio Padrão Erro (MW)	0,14149	0,33017	0,16122	0,29037	0,46788	0,21288	0,46531	0,37077	0,33950
	Erro Máximo (%)	8,96973	14,26380	7,27364	17,04541	7,21967	7,49824	14,87617	6,27101	11,04796
	Erro Máximo (MW)	0,75172	2,05146	0,97970	2,08685	2,95359	1,19347	2,33627	2,14080	1,81471
	Erro Médio (MW)	0,15810	0,28924	0,18559	0,31088	0,61395	0,26092	0,49493	0,56076	0,39898
	MAPE (%)	1,60648	2,03786	1,80620	2,16980	2,12491	1,72147	2,21918	1,72844	1,68649
	MAPEm (%)	0,87586	0,85574	1,06017	1,24965	1,32869	0,98636	1,34746	1,33992	1,08762
	RMSE (MW)	0,21203	0,43858	0,24568	0,42510	0,77149	0,33654	0,67884	0,67194	0,52355
	SSE (MW)	15,10491	64,62971	20,28053	60,71925	199,98428	38,05609	154,83670	151,70683	92,09777
TesteRecursivo	Desvio Padrão Erro (MW)	0,22914	2,63559	0,55531	0,44323	1,63187	0,37080	1,13229	1,77390	0,92983
	Erro Máximo (%)	10,97233	88,55965	20,67476	18,04484	22,57535	12,02032	29,80887	22,42406	24,36090
	Erro Máximo (MW)	1,35819	10,68487	3,12235	2,63632	6,87784	1,83501	5,41338	7,02862	4,41172
	Erro Médio (MW)	0,24622	5,16876	0,61514	0,49729	2,91037	0,59711	1,08242	3,28731	1,00203
	MAPE (%)	2,44560	37,58613	5,63090	3,50869	10,22047	4,14545	4,96816	10,17783	4,29648
	MAPEm (%)	1,36408	15,29195	3,51390	1,99897	6,29857	2,25727	2,94693	7,85498	2,73153
	RMSE (MW)	0,33611	5,80015	0,82815	0,66571	3,33547	0,70258	1,56521	3,73414	1,36604
	SSE (MW)	37,95887	11303,6254	230,44212	148,90323	3738,11528	165,85709	823,16253	4685,12061	626,99895

Fase	Tipo de Erro	Ponto / Estação Climática								
		ISS			SAD			SRA		
		Inverno	Verão	Outono	Inverno	Verão	Outono	Inverno	Verão	Outono
Treino	Desvio Padrão Erro (MW)	0,33350	0,32988	0,38288	0,19359	0,22670	0,22139	0,19370	0,14855	0,17288
	Erro Máximo (%)	8,07786	6,58705	10,34332	26,43096	41,16130	45,46330	17,70446	11,52866	19,79226
	Erro Máximo (MW)	3,50045	2,17830	3,67464	1,28374	1,83258	1,83340	2,02536	0,88913	1,25942
	Erro Médio (MW)	0,37416	0,37882	0,37531	0,23401	0,26531	0,26614	0,21463	0,18000	0,20370
	MAPE (%)	1,02454	1,02715	0,99857	2,55314	2,73873	2,55017	2,13062	1,68954	2,09697
	MAPEm (%)	0,76980	0,78045	0,71761	1,42937	1,49770	1,52250	1,38184	1,16504	1,37163
	RMSE (MW)	0,50111	0,50221	0,53601	0,30365	0,34890	0,34611	0,28905	0,23333	0,26711
	SSE (MW)	253,11802	254,23298	289,60528	92,93817	122,70380	120,75170	84,21732	54,88034	71,91958
Teste	Desvio Padrão Erro (MW)	0,61641	0,51147	0,60439	1,13812	0,52211	0,35250	0,30999	0,19580	0,26620
	Erro Máximo (%)	16,27343	9,88046	10,65357	54,85033	43,55181	31,62782	16,79589	12,90462	16,07693
	Erro Máximo (MW)	4,78273	3,82107	3,70695	6,86401	2,82474	1,99506	1,43972	1,07633	1,50081
	Erro Médio (MW)	0,72241	0,54244	0,79876	0,96075	0,54101	0,37154	0,43489	0,25452	0,35131
	MAPE (%)	2,07014	1,35300	2,08028	9,22115	4,42682	3,69307	4,55600	2,31373	3,60754
	MAPEm (%)	1,61585	1,10438	1,51436	5,87962	3,03769	2,28030	2,84855	1,64601	2,43121
	RMSE (MW)	0,94906	0,74503	1,00111	1,48812	0,75131	0,51179	0,53380	0,32094	0,44053
	SSE (MW)	302,63784	186,50117	336,74604	744,07163	189,66287	88,00787	95,73939	34,60882	65,20692
TesteRecursivo	Desvio Padrão Erro (MW)	1,47982	1,51680	2,41567	1,80026	2,60959	0,93946	0,82235	0,50518	1,10620
	Erro Máximo (%)	31,27247	37,37137	22,89399	114,72538	102,82566	64,22248	35,09949	19,70271	45,79822
	Erro Máximo (MW)	9,88294	11,04331	9,54134	10,84890	8,39126	4,69974	3,40916	2,08227	5,58137
	Erro Médio (MW)	1,95764	2,16946	3,72854	2,65223	2,18794	0,99348	1,23075	0,68639	1,53484
	Erro Mínimo (%)	0,03417	0,13354	0,16862	0,02573	0,03551	0,02368	0,01214	0,02064	0,09891
	Erro Mínimo (MW)	0,01020	0,05114	0,04301	0,00366	0,00482	0,00284	0,00151	0,00286	0,01136
	MAPE (%)	5,66639	5,50657	9,63218	27,06440	19,05012	10,13327	12,86262	6,37622	15,64604
	MAPEm (%)	4,37874	4,41695	7,06886	16,23112	12,28505	6,09734	8,06148	4,43902	10,62181
	RMSE (MW)	2,45270	2,64583	4,44073	3,20400	3,40247	1,36637	1,47953	0,85181	1,89097
	SSE (MW)	2021,28764	2352,13254	6625,94830	3449,25228	3889,80719	627,29722	735,50604	243,79301	1201,46096

Tabela 4 - Grupo A – Comparativo de erro (RMSE), ajuste para grupos distintos de variáveis candidatas

			Variáveis do Modelo – Fase de ajuste (treino)						
			RMSE (MW)			Ganho (%)			
Estação climática	Ponto	experimento	carga	carga-temp	todas	carga-temp x carga	Todas X carga-temp	Todas X carga	
Verão	ICO	exp1	0,22468	0,21672	0,19592	3,67	10,62	14,68	
		exp2	0,22650	0,22419	0,19864	1,03	12,86	14,03	
		exp3	0,22343	0,23134	0,19804	-3,42	16,81	12,82	
	INE	exp1	0,50506	0,42793	0,40521	18,02	5,61	24,64	
		exp2	0,47862	0,45888	0,41012	4,30	11,89	16,70	
		exp3	0,47421	0,41248	0,41936	14,97	-1,64	13,08	
	TDE	exp1	0,37448	0,35052	0,33544	6,84	4,50	11,64	
		exp2	0,38463	0,35819	0,34350	7,38	4,28	11,97	
		exp3	0,37035	0,37217	0,32652	-0,49	13,98	13,42	
	SRA	exp1	0,24909	0,24424	0,23333	1,98	4,67	6,75	
		exp2	0,25032	0,24629	0,23547	1,64	4,60	6,31	
		exp3	0,25340	0,25115	0,23381	0,90	7,42	8,38	
	SAD	exp1	0,35825	0,36281	0,35152	-1,26	3,21	1,91	
		exp2	0,36142	0,35557	0,34890	1,64	1,91	3,59	
		exp3	0,35818	0,36738	0,35559	-2,50	3,32	0,73	
	ISS	exp1	0,56224	0,54040	0,51437	4,04	5,06	9,30	
		exp2	0,56267	0,62367	0,50221	-9,78	24,18	12,04	
		exp3	0,56365	0,59653	0,51438	-5,51	15,97	9,58	
	Outono	ICO	exp1	0,18092	0,17336	0,15969	4,36	8,56	13,30
			exp2	0,18190	0,17202	0,15991	5,74	7,57	13,75
			exp3	0,19237	0,17105	0,15686	12,46	9,05	22,64
INE		exp1	0,25610	0,25296	0,22540	1,24	12,23	13,62	
		exp2	0,25341	0,25352	0,22979	-0,04	10,33	10,28	
		exp3	0,26038	0,25307	0,22015	2,89	14,95	18,27	
TDE		exp1	0,40755	0,39907	0,36835	2,12	8,34	10,64	
		exp2	0,40307	0,39969	0,37542	0,85	6,46	7,37	
		exp3	0,40814	0,39923	0,37862	2,23	5,44	7,80	
SRA		exp1	0,28451	0,28439	0,27263	0,04	4,32	4,36	
		exp2	0,28470	0,28949	0,26711	-1,66	8,38	6,58	
		exp3	0,28403	0,28632	0,27161	-0,80	5,42	4,57	
SAD		exp1	0,37278	0,36324	0,34652	2,63	4,82	7,58	
		exp2	0,36917	0,36292	0,34611	1,72	4,86	6,66	
		exp3	0,36865	0,36578	0,35190	0,79	3,94	4,76	
ISS		exp1	0,58104	0,57317	0,54951	1,37	4,31	5,74	
		exp2	0,57373	0,56729	0,54622	1,14	3,86	5,04	
		exp3	0,56750	0,56535	0,53601	0,38	5,47	5,87	
Inverno		ICO	exp1	0,14280	0,13837	0,12661	3,20	9,28	12,79
			exp2	0,14075	0,14055	0,12821	0,14	9,62	9,78
			exp3	0,14041	0,14061	0,13126	-0,15	7,13	6,97
	INE	exp1	0,27546	0,27027	0,25926	1,92	4,25	6,25	
		exp2	0,27365	0,27170	0,26792	0,72	1,41	2,14	
		exp3	0,27136	0,26947	0,25180	0,70	7,02	7,77	

	TDE	exp1	0,37224	0,35714	0,34541	4,23	3,40	7,76
		exp2	0,35692	0,35968	0,33883	-0,77	6,15	5,34
		exp3	0,36251	0,36235	0,33427	0,04	8,40	8,45
	SRA	exp1	0,31210	0,30879	0,29421	1,07	4,96	6,08
		exp2	0,30820	0,30930	0,28957	-0,36	6,82	6,43
		exp3	0,30925	0,31110	0,28905	-0,59	7,63	6,99
	SAD	exp1	0,32499	0,31781	0,30723	2,26	3,45	5,78
		exp2	0,32626	0,31912	0,30365	2,24	5,10	7,45
		exp3	0,32626	0,31487	0,31317	3,61	0,55	4,18
	ISS	exp1	0,56441	0,55496	0,50111	1,70	10,75	12,63
		exp2	0,55976	0,55939	0,54567	0,07	2,51	2,58
		exp3	0,56066	0,55001	0,53798	1,94	2,24	4,22

A Tabela 5 apresenta uma síntese da Tabela 4. Ela mostra que, na média e para o sistema estudado, a precisão obtida na adaptação do modelo está diretamente relacionada ao número de variáveis climáticas colocadas à disposição do Modelador Evolutivo de 1ª Ordem. Na fase de adaptação, ao se considerar para uso a carga e todas as variáveis climáticas disponíveis, obtém-se, em média, um aumento de precisão de 8,96% em relação à utilização apenas da carga. Já o alto valor do desvio padrão do ganho em relação ao ganho médio, com valor próximo de 5%, mostra que, para as condições estudadas, há forte variação no ganho de precisão. Isto torna a demonstrar que, no sistema hipotético considerado, a relação das condições climáticas com a carga é fortemente dependente do Ponto (mercado) e da estação climática considerados.

Tabela 5 - Grupo A – Relação das variáveis climáticas com a precisão da adaptação

Variáveis disponíveis na adaptação do modelo			
	Ganho (%)		
	carga-temperatura <i>versus</i> Carga	Todas <i>versus</i> Carga-temperatura	Todas <i>versus</i> Carga
Médio	1,91	7,00	8,96
Desvio Padrão	4,28	4,56	4,90

Finalmente, a Tabela 6 e as Figuras: Figura 18 e Figura 19, apresentam a estabilidade demonstrada pelo modelo ao ser solicitado a repetir por noventa e nove vezes a adaptação para o Ponto ICO na estação climática **Inverno**. A Tabela 6 mostra a variação do erro, em RMSE, na fase de ajuste do modelo. Através desta constata-se a pequena variação do RMSE nos cem experimentos realizados e o pequeno valor de seu desvio padrão. Os resultados apresentados na Tabela 6 permitem concluir que, para um grau de confiança de 95,4%, o modelo apresenta uma instabilidade em relação ao valor do RMSE médio de 2,56%. Finalmente, as Figuras: Figura 18 e Figura 19, mostram a distribuição do erro em RMSE(MW) na fase de ajuste do modelo. A Figura 18, a distribuição em relação ao desvio padrão e a Figura 19, a distribuição em relação ao número de ocorrências por faixa de valores.

Tabela 6 - Grupo A – Variação do erro (RMSE) no ajuste em 100 experimentos para ICO - Inverno

Erro em RMSE(MW) no ajuste	
Médio	0,129040
Máximo	0,131749
Mínimo	0,125173
Desvio padrão	0,001654
Diferença entre o máximo e o mínimo	0,006575

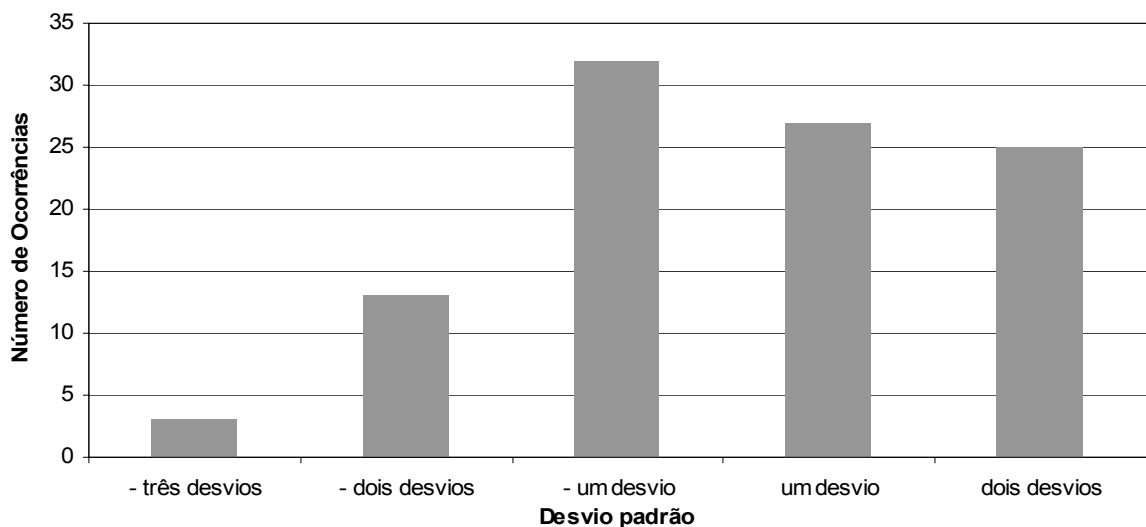


Figura 18 – Distribuição do RMSE, em relação ao desvio padrão, ajuste de 100 exp. em ICO - Inverno

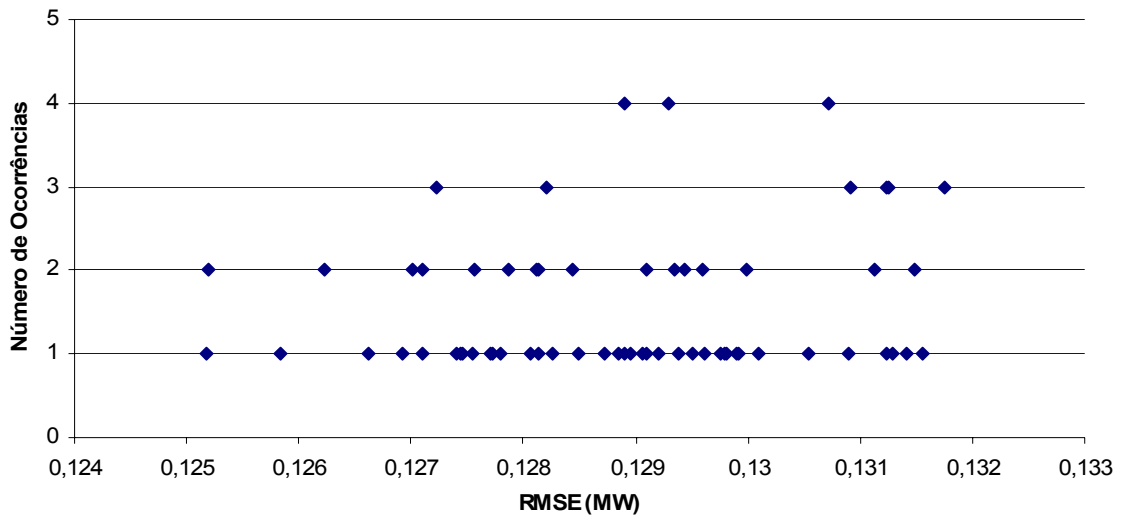


Figura 19 –Distribuição do RMSE, por faixa de valores, no ajuste em 100 exp. para ICO - Inverno

5.2.2.2 Grupo B

Nos experimentos do Grupo B, foram verificadas as perdas de precisão quando modelos adaptados e ajustados (treinados) para um dado Ponto e estação climática são aplicados no mesmo Ponto, porém em outras estações climáticas, após passarem apenas por um processo de retreinamento (reajuste). As Tabela 7, Tabela 8 e Tabela 9 apresentam os resultados obtidos neste grupo de experimentos. A Tabela 7 apresenta os RMSEs (MW) obtidos nos experimentos na fase de ajuste (treino) dos modelos. Já a Tabela 8 apresenta o ganho (%) no ajuste (treino) com uso do modelo adaptado para a mesma estação climática do ajuste em relação ao ajuste com uso de modelos adaptados para outras estações climáticas. Por fim, a Tabela 9 apresenta uma reavaliação dos ganhos apresentados na Tabela 8 considerando um nível de confiança de 95,4%. Os resultados apresentados na Tabela 9 são obtidos através da reavaliação dos ganhos apresentados na Tabela 8 levando em conta a instabilidade no ajuste do modelo discutida no final da seção 5.2.2.1. Nas Tabela 7, Tabela 8 e Tabela 9, as células em branco significam que o histórico de dados disponível não permitia a realização dos experimentos. Na Tabela 7, os resultados em destaque são os RMSEs obtidos com o modelo adaptado para o Ponto e estação climática em questão.

Tabela 7 - Grupo B – RMSE (MW) no ajuste (treino) utilizando modelos adaptados para a mesma e para outras estações climáticas no Ponto

Ponto	Estação climática do histórico de dados								
	Verão			Outono			Inverno		
	Estação climática da adaptação do modelo			Estação climática da adaptação do modelo			Estação climática da adaptação do modelo		
	Verão	Outono	Inverno	Verão	Outono	Inverno	Verão	Outono	Inverno
	ICO	0,19592	0,30577	0,24267	0,18321	0,15686	0,20437	0,15910	0,14383
INE	0,40521	0,54757	0,51592	0,28263	0,22015	0,27356	0,28727	0,31666	0,25180
TDE	0,32652	0,37717	0,38442	0,40341	0,36835	0,41058	0,39248	0,36735	0,33451
SRA	0,23333	0,24648	0,24761	0,28834	0,26711	0,28643	0,31390	0,30341	0,28905
SAD	0,34890	0,38265	0,36611	0,36616	0,34611	0,37053	0,31250	0,33055	0,30365
ISS	0,50221	1,30861	1,34238		0,53601	0,58116		0,57129	0,50111

Tabela 8 - Grupo B – Ganho (%) no ajuste (treino) com uso do modelo adaptado para a estação climática dos dados, no Ponto.

Ponto	Estação climática do histórico de dados					
	Verão		Outono		Inverno	
	Estação climática da adaptação do modelo		Estação climática da adaptação do modelo		Estação climática da adaptação do modelo	
	Verão versus Outono	Verão versus Inverno	Outono versus Verão	Outono versus Inverno	Inverno versus Verão	Inverno versus Outono
	ICO	35,93	19,26	14,38	23,25	20,42
INE	26,00	21,46	22,11	19,53	12,35	20,48
TDE	13,43	15,06	8,69	10,29	14,77	8,94
SRA	5,33	5,77	7,36	6,75	7,92	4,73
SAD	8,82	4,70	5,48	6,59	2,83	8,14
ISS	61,62	62,59		7,77		12,28

Tabela 9 - Grupo B – Ganho (%), com grau de confiança de 95,4%, no ajuste (treino) com uso do modelo adaptado para a estação climática dos dados, no Ponto.

Ponto	Estação climática do histórico de dados					
	Verão		Outono		Inverno	
	Estação climática da adaptação do modelo		Estação climática da adaptação do modelo		Estação climática da adaptação do modelo	
	Verão versus Outono	Verão versus Inverno	Outono versus Verão	Outono versus Inverno	Inverno versus Verão	Inverno versus Outono
ICO	33,37	16,70	11,82	20,69	17,86	9,41
INE	23,44	18,90	19,55	16,97	9,79	17,92
TDE	10,87	12,50	6,13	7,73	12,21	6,38
SRA	2,77	3,21	4,80	4,19	5,36	2,17
SAD	6,26	2,14	2,92	4,03	0,27	5,58
ISS	59,06	60,03		5,21		9,72

Os resultados apresentados confirmam a hipótese da dinâmica de um dado mercado de energia elétrica e da especificidade do vetor de entrada da RNA em relação a esta dinâmica. A partir da Tabela 8, ao analisar um dado Ponto nas três estações climáticas, tomando como exemplo o Ponto INE, temos para o Verão, ganhos de 26,00% e de 21,46%, ao se comparar a precisão do modelo adaptado e utilizado nesta estação climática com a precisão dos modelos adaptados para o Outono e o Inverno e utilizados no Verão. Para o Outono, os ganhos são de 22,11% e 19,53% quando comparados aos modelos adaptados para o Verão e o Inverno. Para o Inverno, os ganhos sobre os modelos de Verão e Outono são de 12,35% e 20,48%, respectivamente. Para o Ponto SAD, os ganhos são, respectivamente, no Verão: 8,82% e 4,70%, no Outono: 5,48% e 6,59% e no Inverno: 2,83% e 8,14%. Considerando-se um nível de confiança de 95,4% (Tabela 9), para o Ponto INE os ganhos passam a ser de, respectivamente, 23,44% e de 18,90 % no Verão, 19,55% e de 16,97% no Outono e 9,79% e de 17,92% no Inverno. Para o Ponto SAD, os ganhos passam a ser de, respectivamente, 6,26% e de 2,14% no Verão, 2,92% e de 4,03% no Outono e 0,27% e de 5,58% no Inverno.

Ainda com relação à Tabela 8, de uma forma geral, os ganhos com o uso de modelos adaptados a um dado Ponto e estação climática em relação a modelos adaptados à outras estações climáticas, no mesmo Ponto, variam de 2,83% a 62,59%, dependendo do

Ponto, estação climática e modelo utilizado. Considerando-se um nível de confiança de 95,4% (Tabela 9) os ganhos passam a variar entre 0,27% e 60,03%. Os modelos utilizados neste Grupo de experimentos são os obtidos nos melhores experimentos do Grupo A com o uso das variáveis: carga e todas as variáveis climáticas disponíveis, para cada Ponto e estação climática.

A Tabela 10 apresenta uma síntese das Tabela 8 e Tabela 9. Ela mostra que, para o sistema estudado, há um ganho de precisão médio de 15,79% (13,23%, quando se adota um nível de confiança de 95,4%) para modelos adaptados e utilizados no mesmo Ponto e estação climática em relação a modelos adaptados para um dado Ponto e reutilizados no mesmo Ponto, porém em outras estações climáticas. Cabe ressaltar o alto valor do desvio padrão do ganho de precisão, quando comparado com o valor do ganho de precisão médio. Isto mostra que, quando o modelo é reutilizado sob as condições descritas, ocorre forte variação na sua precisão. Adicionalmente, as Tabela 8 e Tabela 9 mostram que esta variação é bastante dependente do Ponto (mercado) que está sendo considerado.

Tabela 10 - Grupo B – Relação da estação climática com a precisão, em um Ponto

Adaptação do modelo e uso na mesma estação climática		
	Ganho (%)	Ganho (%) com 95,4% de confiança
Médio	15,79	13,23
Desvio Padrão	13,90	13,90

5.2.2.3 Grupo C

Nos experimentos do Grupo C foram verificadas as perdas de precisão quando modelos adaptados e ajustados (treinados) para uma dada estação climática e Ponto são aplicados em outros Pontos, dentro da mesma estação climática, após passarem apenas por um processo de retreinamento (reajuste). As Tabela 11, Tabela 12 e Tabela 13 apresentam os resultados obtidos nos experimentos deste Grupo, na fase de ajuste (treino) dos modelos. A Tabela 11 apresenta os RMSEs (MW) obtidos nos experimentos na fase de ajuste (treino) dos modelos. A Tabela 12 apresenta o ganho (%) no ajuste (treino) com uso do modelo adaptado para o mesmo Ponto do ajuste em relação ao ajuste com uso de modelos adaptados para outros Pontos. A Tabela 13 apresenta uma reavaliação dos ganhos apresentados na Tabela 12 considerando um nível de confiança de 95,4%, segundo a metodologia descrita e empregada na seção anterior. Na Tabela 11, os resultados em destaque são os RMSEs obtidos com o modelo adaptado para a estação climática e Ponto em questão.

Tabela 11 - Grupo C – RMSE (MW) no ajuste (treino) para um dado Ponto, utilizando modelos adaptados para o mesmo Ponto e para outros Pontos, na mesma estação climática

	Estação climática do histórico de dados							
	Outono				Inverno			
	Ponto da adaptação do modelo				Ponto da adaptação do modelo			
Ponto de ajuste do modelo	ICO	INE	ISS	TDE	ICO	INE	ISS	TDE
ICO	0,15686	0,22235	0,19548	0,18343	0,12661	0,15657	0,14336	0,14234
INE	0,27041	0,22015	0,27190	0,26216	0,27867	0,25180	0,27303	0,28069
ISS	0,58484	0,58784	0,53601	0,57457	0,56103	0,56178	0,50111	0,54794
TDE	0,39778	0,40916	0,40352	0,36835	0,37998	0,37076	0,36910	0,33427

Tabela 12 - Grupo C – Ganho (%) no ajuste (treino) com uso do modelo adaptado para o mesmo Ponto do ajuste em relação a modelos adaptados para outros Pontos, em uma mesma estação climática.

	Estação climática do histórico de dados							
	Outono				Inverno			
	Ponto da adaptação do modelo				Ponto da adaptação do modelo			
Ponto de ajuste do modelo	ICO	INE	ISS	TDE	ICO	INE	ISS	TDE
ICO		29,5	19,8	14,5		19,1	11,7	11,1
INE	18,6		19,0	16,0	9,6		7,8	10,3
ISS	8,3	8,8		6,7	10,7	10,8		8,5
TDE	7,4	10,0	8,7		12,0	9,8	9,4	

Tabela 13 - Grupo C – Ganho (%), com grau de confiança de 95,4%, no ajuste (treino) com uso do modelo adaptado para o mesmo Ponto do ajuste em relação a modelos adaptados para outros Pontos, em uma mesma estação climática.

	Estação climática do histórico de dados							
	Outono				Inverno			
	Ponto da adaptação do modelo				Ponto da adaptação do modelo			
Ponto de ajuste do modelo	ICO	INE	ISS	TDE	ICO	INE	ISS	TDE
ICO		26,94	17,24	11,94		16,54	9,14	8,54
INE	16,04		16,44	13,44	7,04		5,24	7,74
ISS	5,74	6,24		4,14	8,14	8,24		5,94
TDE	4,84	7,44	6,14		9,44	7,24	6,84	

Os resultados apresentados confirmam a hipótese da especificidade dos mercados de energia elétrica em um determinado instante de tempo e da especificidade dos vetores de entrada das RNAs para os modelos destes mercados. Ao analisar um dado Ponto nas estações climáticas Outono e Inverno (Tabela 12), tomando como exemplo o Ponto ICO, ao se comparar a precisão do modelo adaptado e utilizado neste Ponto com a precisão dos modelos adaptados para os Pontos INE, ISS e TDE e reajustados e utilizados no Ponto ICO, temos para no Outono ganhos de 29,50%, 19,80% e 14,50%, respectivamente. Já no Inverno, os ganhos são de 19,10%, 11,70% e 11,10%, respectivamente. Para o Ponto ISS, em relação aos modelos dos Pontos ICO, INE e TDE, os ganhos são, no Outono, 8,3%, 8,8% e 6,7%, e no Inverno 10,7%, 10,8% e 8,5%, respectivamente. Considerando-se um nível de confiança de 95,4% (Tabela 13), no Ponto ICO os ganhos são, no Outono de 26,94%, 17,24% e de 11,94%, e no Inverno de 16,54%, 9,14% e de 8,54%. Para o Ponto ISS os ganhos são, no Outono de 26,94%, 17,24% e de 11,94%, e no Inverno de 16,54%, 9,14% e de 8,54%.

Ainda com relação a Tabela 12, de uma forma geral, os ganhos com o uso de modelos adaptados a um dado Ponto e estação climática em relação à modelos adaptados à outros Pontos, dentro da mesma estação climática, variam de 6,7% a 29,5%, dependendo do Ponto, estação climática e modelo utilizado. Considerando-se um nível de confiança de 95,4% (Tabela 13) os ganhos passam a variar entre 4,14% e 26,94%. Devido a limitações no histórico de dados disponível, não foi possível realizar os experimentos para os Pontos SAD e SRA nas estações climáticas Outono e Inverno, bem como para todos os Pontos na estação climática Verão. Da mesma forma que nos experimentos do Grupo B, os modelos utilizados neste grupo de experimentos foram os obtidos nos melhores experimentos do Grupo A com o uso das variáveis carga e todas as variáveis climáticas disponíveis, para cada Ponto e estação climática.

A Tabela 14 apresenta uma síntese das Tabelas 12 e 13. Ela mostra que, para o sistema estudado, há um ganho de precisão médio de 12,42% (9,86%, quando se adota um nível de confiança de 95,4%) para modelos adaptados e utilizados na mesma estação climática e Ponto em relação a modelos adaptados para um dado Ponto e reutilizados em outros Pontos, dentro da mesma estação climática. O valor do desvio padrão do ganho de precisão, de 5,4%, mostra que quando o modelo é reutilizado sob as condições descritas, ocorre bastante variação na sua precisão. Adicionalmente, as Tabelas 12 e 13

mostram que esta variação é dependente tanto do Ponto (mercado) considerado quanto da estação climática em questão.

Tabela 14 - Grupo C – Relação do Ponto com a precisão, em uma estação climática

Adaptação do modelo e uso no mesmo Ponto		
	Ganho (%)	Ganho (%) com 95,4% de confiança
Médio	12,42	9,86
Desvio Padrão	5,40	5,40

Finalmente, a comparação dos resultados apresentados na Tabela 10 com os apresentados na Tabela 14, permite concluir que, para o sistema objeto de estudo, os ganhos médios de precisão com ambas as abordagens se aproximam. Porém é grande a diferença entre os valores dos desvios padrões do ganho, de 13,90% na primeira abordagem contra 5,40% na segunda. Isto mostra que a diferença entre a relação das variáveis de entrada do modelo com a estação climática considerada, para cada tipo de Ponto, é bem maior do que a diferença entre a relação destas mesmas variáveis com o Ponto, em uma mesma estação climática. Em outras palavras, que os ganhos com a segunda abordagem são mais parecidos entre si, enquanto que são mais distintos entre si os ganhos com a primeira abordagem.

6. CONSIDERAÇÕES FINAIS

6.1 Conclusões

Foi proposto um modelo para um sistema de previsão de cargas de curtíssimo e de curto prazos que leva em conta as diferenças regionais e a dinâmica da demanda por carga em um mercado de energia elétrica heterogêneo como o do Estado de Santa Catarina. O modelo proposto é dotado da capacidade de adaptação, sendo capaz de ajustar-se e acompanhar a dinâmica de um mercado de energia elétrica composto por micro-regiões de consumo com características fortemente heterogêneas. As partes do modelo proposto relativas às capacidades de adaptação e previsão foram construídas, validadas, verificadas e comparadas ao modelo de Oliveira (1999). Ainda, foram empregadas nos testes das hipóteses formuladas, relacionadas às dependências regional e temporal das variáveis de entrada da RNA.

O sistema de previsão proposto é um sistema híbrido, fundamentado em duas técnicas da área de Inteligência Artificial: Algoritmos Genéticos e Redes Neurais Artificiais. O AG complementa a capacidade de modelagem inerente ao funcionamento de uma RNA, definindo a camada de entrada e os parâmetros internos da rede. A RNA utilizada no modelo é a de Base Radial a qual, segundo o esperado e de acordo com o relatado em Oliveira (1999), demonstrou facilidade de ajuste e boa velocidade de treinamento, propriedades relevantes em um sistema de previsão voltado ao uso associado com sistemas SCADA.

A experimentação do modelo foi dividida e executada em duas grandes etapas, nomeadas Etapa I e Etapa II. A Etapa I foi utilizada para apoiar a construção das partes do modelo escolhidas para tal. Nesta Etapa, estas partes foram validadas, verificadas de forma simplificada e comparadas ao modelo de Oliveira (1999). A Etapa II foi utilizada para uma verificação mais detalhada e abrangente dos componentes construídos e para os testes das hipóteses formuladas.

Os resultados obtidos Na Etapa I comprovam que o modelo funciona de acordo com o esperado, bem como a sua superioridade quando comparado ao modelo de Oliveira (1999). Os resultados alcançados com o modelo nesta Etapa mostram, em relação ao modelo de Oliveira (1999), um ganho de precisão na fase de ajuste de 67,0%. Na previsão ½ hora à frente durante uma semana e na previsão ½ hora a uma semana à frente, os ganhos foram 72,9% e 66,4%, respectivamente. Ainda, uso dos Modeladores Evolutivos torna mais fácil a identificação e o ajuste dos valores dos parâmetros da rede neural. Além disto, o modelo privilegia a precisão das previsões de carga relativas aos horários de carga mais elevada, as quais normalmente ocorrem próximas à carga da ponta do sistema, período crítico para os sistemas de transmissão e distribuição de energia elétrica.

Os resultados dos testes da Etapa II atestam que o modelo probabilístico proposto é robusto, estável e possui uma boa capacidade de adequar-se aos nós do sistema elétrico a que foi associado. Os resultados alcançados mostram que, para o sistema hipotético estudado e de uma forma geral, a precisão do ajuste do modelo está diretamente relacionada ao número de variáveis climáticas utilizadas. Porém, nas adaptações do modelo aos diversos Pontos e estações climáticas do sistema hipotético, foram observadas variações relevantes nas precisões dos ajustes, com ganhos de precisão de até 24,62%, quando foram realizadas variações propositais na quantidade de variáveis climáticas utilizadas nos históricos de dados. Os resultados obtidos mostram que a influência das variáveis climáticas no comportamento da carga varia em função do Ponto e estação climática considerados.

Ainda na Etapa II, foi observado que as adaptações do modelo aos diversos Pontos e estações climáticas do sistema hipotético geraram modelos específicos para cada Ponto e estação climática. Para estes Pontos e estações climáticas foi observada perda de precisão no ajuste quando o modelo fruto da adaptação para um determinado Ponto e estação climática é reajustado para uma outra estação climática, no mesmo Ponto. Para o contexto estudado, os ganhos com o uso de modelos adaptados a um dado Ponto e estação climática em relação a modelos adaptados as outras estações climáticas, no mesmo Ponto, variam de 2,83% a 62,59%, (0,27% a 60,03%, quando se adota um nível de confiança de 95,4%) dependendo do Ponto, estação climática e modelo utilizado. Tais resultados validam a hipótese da diferença entre os conjuntos de variáveis de entrada da RNA que otimizam a previsão de carga para um determinado nó de um sistema elétrico, ao longo do tempo.

Finalmente, também na Etapa II e em relação à especificidade dos modelos aos Pontos e estações climáticas, foi observada perda de precisão no ajuste quando um modelo que foi adaptado para um determinado Ponto e estação climática é reajustado para um outro Ponto, na mesma estação climática. Para o sistema hipotético estudado, os ganhos com o uso de modelos adaptados a uma dada estação climática e Ponto e em relação a modelos adaptados a outros Pontos, na mesma estação climática, variam de 6,7% a 29,5% (4,14% a 26,94%, quando se adota um nível de confiança de 95,4%), dependendo do Ponto, estação climática e modelo utilizado. Estes resultados validam a hipótese da diferença entre os conjuntos de variáveis de entrada da RNA que otimizam a previsão de carga, em um determinado instante de tempo, para os vários nós de um sistema elétrico com características de consumo distintas entre si.

6.2 Principais Contribuições do Trabalho

As principais contribuições deste trabalho são:

- a) Aprofundar o conhecimento no domínio das técnicas de Inteligência Artificial aplicadas a sistemas adaptativos variantes no tempo;
- b) Aprofundar o conhecimento no domínio das técnicas de Inteligência Artificial aplicadas a sistemas de previsão de cargas em tempo real.
- c) Aprofundar o conhecimento sobre o grau de influência de um determinado conjunto de variáveis, relacionadas a cargas passadas, condições climáticas passadas e futuras e indicadores de vida social, dentre outras, sobre diferentes micro-regiões de um mercado de energia elétrica em um dado instante de tempo e sobre uma mesma micro-região de um mercado de energia elétrica em diferentes instantes de tempo;
- d) Aprofundar o conhecimento sobre o comportamento da demanda por carga nas várias micro-regiões de consumo que compõem o mercado de energia elétrica do Estado de Santa Catarina;
- e) Propor um modelo para a previsão de cargas de curto prazo com capacidade de

adaptação superior à dos modelos de previsão de cargas atuais.

As contribuições inéditas deste trabalho estão no enfoque à heterogeneidade e dinâmica dos sistemas de energia elétrica e na proposta de uma estratégia capaz de dotar um sistema de previsão de cargas nodais de curtíssimo e de curto prazos de características adaptativas e evolutivas complementares àquelas implícitas ao funcionamento das redes neurais artificiais.

6.3 Recomendações

Há vários temas, relacionados a este trabalho, que podem ser estudados. Destes temas, alguns exemplos são: otimização do modelo, inclusão de novas características no modelo, especialização do modelo, verificação da robustez do modelo e construção de novos modelos.

No grupo de otimização do modelo proposto recomendam-se trabalhos relativos à composição do conjunto de variáveis candidatas ao vetor de entrada da RNA; à camada intermediária da rede, à função objetivo utilizada e ao tratamento diferenciado para dias anômalos ou situações em que se identifica antecipadamente que o comportamento da carga a ser prevista será diferente do comportamento da carga implícito aos dados da janela de treino. Quanto à composição do conjunto de variáveis candidatas, recomenda-se o estudo do emprego de técnicas estatísticas como ferramentas de apoio na sua definição. Com relação à camada intermediária da rede, incluem-se, entre outros: experimentações com (a) outros tipos de funções de base radial; (b) mapas auto-organizáveis de Kohonen (Haykin, 1994, Fausett, 1995) e algoritmo OLS (*Orthogonal Least Square*) (Chen et. al., 1991) para efetuar o agrupamento dos padrões de entrada e (c) no Modelador Evolutivo de 2ª Ordem, métodos de otimização não linear, a exemplo do algoritmo Levenberg-Marquadt (Bazaraa et al., 1993), em lugar do AG.

Ainda em relação ao grupo de otimização do modelo proposto, quanto à função objetivo, recomenda-se alterá-la de forma a que também penalize o tamanho do cromossomo. Em relação aos dias anômalos como, por exemplo, feriados, os dias posteriores a estes e os que os antecedem, se recomenda que um módulo inteligente, a

exemplo de um Sistema Especialista, seja agregado ao sistema, dotando o sistema de previsão de conhecimento adicional sobre as peculiaridades do comportamento da carga para estes dias. O Sistema Especialista também pode ser utilizado em situações onde é possível identificar com antecipação que o comportamento da carga a ser prevista será diferente do comportamento da carga implícito aos dados da janela de treino. Exemplos são situações onde a previsão de tempo prevê alterações significativas no tempo ou situações de transição em padrões de demanda por carga de uma determinada região: férias escolares e volta às aulas em bairros universitários, início e fim de temporada turística em regiões afetadas pelo turismo, etc.

No grupo de inclusão de novas características no modelo, recomenda-se modificar o modelo para que adicionalmente forneça índices de confiabilidade para as previsões. Os índices podem ser calculados a partir das distâncias entre os centros dos agrupamentos e o padrão de entrada.

Como trabalhos relacionados ao grupo especialização do modelo, recomenda-se experimentar especializar o modelo por (a) tipo de dia da semana (curvas de carga similares), que é a abordagem tradicional e (b) por períodos (horários) onde o comportamento da variação da carga seja similar. No segundo caso, deve-se pré-agrupar os padrões em agrupamentos onde os períodos/horários com percentual e o sinal (positivo ou negativo) de variação das cargas sejam semelhantes. O agrupamento pode ser feito por meio dos mapas auto-organizáveis de Kohonen (Haykin, 1994, Fausett, 1995). Também é possível experimentar especializar a rede em função da faixa de demanda (ponta, média, leve, mínima). Outra forma é experimentar especializar a rede para os horários onde ocorrerem erros de previsão acima de um valor pré-estabelecido. Isto pode ser feito incluindo-se na estrutura de controle a capacidade de identificar dinamicamente os erros muito altos e subdividir (especializar) a RNA de acordo com a necessidade/comportamento do ponto elétrico (nó) em questão.

Ainda com relação à especialização do modelo, cabe lembrar que o treinamento da RNA pressupõe o uso de um conjunto de dados (histórico) suficientemente abrangente. Com isto, ao se especializar a rede neural, classificando de alguma forma o conjunto de dados de treino e criando subconjuntos especializados, também se reduz o tamanho de cada um destes subconjuntos resultantes e, para compensar a redução, é necessário alargar

a janela de tempo do histórico de dados utilizado no treino, o que traz um complicador, pois agrega no conjunto de dados de treino padrões de consumo mais antigos. Assim, a atividade de especialização do modelo pressupõe o equilíbrio entre estes dois fatores: subdivisão dos padrões em subgrupos mais homogêneos e largura da janela de tempo dos históricos de dados dos novos subgrupos.

No grupo construção de novos modelos, recomenda-se experimentar RNAs com capacidade de aprendizado por treinamento incremental, como é o caso das RNAs do tipo ART (*“Adaptive Resonance Theory”*). Outro trabalho é a investigação da aplicabilidade na modelagem do comportamento da carga, da técnica proposta por Henrique (1999), para a modelagem de sistemas dinâmicos de controle através de RNAs, via a modelagem das parcelas da equação diferencial do sistema por meio de RNAs estáticas.

Finalmente, quanto à verificação da robustez do modelo, sugere-se observar o comportamento do modelo durante um período mais longo que o efetuado neste trabalho: pelo menos alguns meses ou um ano completo.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] AlFuhaid A. S., El-Sayed M. A., Mahmoud M. S. (1997). Cascaded Artificial Neural Networks for Short-Term Load Forecasting. *IEEE Transactions on Power Systems*, 12 (4), 1524-1529.
- [2] ANEEL (2001). Manual dos Programas de Pesquisa e Desenvolvimento Tecnológico do Setor Elétrico Brasileiro. *ANNEE - Agência Nacional de Energia Elétrica*.
- [3] Bakirtzis, A. G., Petridis, V., Kiartzis S. J., Alexiadis M. C., Maissis A. H. (1995). A Neural Network Short Term Load Forecasting Model for the Greek Power System. *IEEE Transactions on Power Systems*, 11 (2), 858-863.
- [4] Bakirtzis, A. G., Theocharis, J. B., Kiartzis S. J., Satsios, K. J. (1995). Short Term Load Forecasting using Fuzzy Neural Networks. *IEEE Transactions on Power Systems*, 10 (3), 1518-1524.
- [5] Bashir, Z, El-Hawary, M. E. (2000) Short Term Load Forecasting by Using Wavelet Neural Networks. *Canadian Conference on Electrical and Computer Engineering*, 1, 163 -166.
- [6] Bazaraa, M. S., Sherali, H. D., Shetty C. M. (1993) *Nonlinear programming: theory and algorithms*. New York: John Wiley & Sons, 2nd ed.
- [7] Beasley D., Bull D.R., Martin R.R., 1993. An Overview of Genetic Algorithms: Part 1, Fundamentals. *University Computing*, 15(2), 58-69.
- [8] Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. New York: Oxford University Press.
- [9] Carpinteiro, O. A. S., Alves da Silva A. P. (2000). A hierarchical neural model in short-term load forecasting. *Sixth Brazilian Symposium on Neural Networks*, 120-124.

- [10] Carpinteiro, O. A. S., Alves da Silva, A. P., Feichas, C. H. L. (2000). A hierarchical neural model in short-term load forecasting. *IEEE-INNS-ENNS International Joint Conference on Neural Networks*, 6, 241 – 246.
- [11] Carpinteiro, O. A. S., Reis, A. J. R., Alves da Silva, A. P. (2004). A hierarchical neural model in short-term load forecasting. *Applied Soft Computing*, 4 (4), 405 – 412.
- [12] CELESC (2003). HOME PAGE. *Centrais Elétricas de Santa Catarina S. A.* <http://celesc.com.br>, 16/05/03
- [13] Chen T-H., Cherng J-T. (2000) Optimal Phase Arrangement of Distribution Transformers Connected to a Primary Feeder for System Unbalance Improvement and Loss Reduction Using a Genetic Algorithm. *IEEE Trans. Power Syst.* 15(3), 994-1000.
- [14] Chen, S., Cowan, C. F. N., Grant, P. M. (1991). Orthogonal Least Squares Learning Algorithm for Radial Basis Functions Networks, *IEEE Transactions on neural Networks*, 2(2), 302-309.
- [15] Choueiki, M. H., Mount-Campbel, C. A., Ahalt, S. C. (1997). Building a 'Quasi Optimal' Neural Network to solve the Short-Term Load Forecasting Problem. *IEEE Transactions on Power Systems*, 12 (4), 1432-1439.
- [16] Chung TS, Leung HC. (1999). A genetic algorithm approach in optimal capacitor selection with harmonic distortion considerations. *Electrical Power & Energy Systems*, 21, 561-569.
- [17] Claumann, Carlos. (1999). Modelagem dinâmica e controle de processos não lineares: Uma aplicação de algoritmos genéticos para treinamento de redes neurais recorrentes. Florianópolis: UFSC (Dissertação).
- [18] Claumann, Carlos. (2003). Desenvolvimento e aplicações de redes neurais wavelets e da teoria de regularização na modelagem de processos. Florianópolis: UFSC (Tese).
- [19] CLIMERH (2002). HOME PAGE. *Centro Integrado de Meteorologia e Recursos*

Hidricos de Santa Catarina. <http://sol.climerh.rct-sc.br>, 28/05/02.

- [20] Dash, P.K., Dash, S., Rahman, S. (1993) A Fuzzy Adaptive Correction Scheme for Short Term Load Forecasting using Fuzzy Layered Neural Network. *Second International Forum on Applications of Neural Networks to Power Systems*, 432-437.
- [21] Dash, P. K., Mishra, S., Dash, S., Liew, A. C. (2000). Genetic Optimization of Self Organizing Fuzzy-Neural Network for Load Forecasting. *IEEE Power Engineering Society Winter Meeting*, 2. (.../Load Forecasting IV/00850076.pdf) (Citado na Tese como 2000).
- [22] Dandolini, G. V. (1997). *Um Procedimento para Avaliação da Saúde Financeira de Pequenas Empresas: Estudo de um Caso Usando Redes Neurais Artificiais*, Dissertação, Florianópolis: UFSC/PPEG.
- [23] El-Naggar K. M., Youssef H. K. M. (2000). A genetic based algorithm for frequency-relaying applications. *Electrical Power Systems Research*; 55, 173-178.
- [24] El-Sharkawi, M. A., Huang, S. J. (1996). Development of genetic algorithm embedded Kohonen neural network for dynamic. *International Conference on Intelligent Systems Applications to Power Systems*, 44-49
- [25] Fausett, L. V. (1994). *Fundamentals of Neural Networks*. Englewood Cliffs, New Jersey: Prentice- Hall.
- [26] Gil H. A., da Silva E. L. (2001). A reliable approach for solving the transmission network expansion planning problem using genetic algorithms. *Electrical Power Systems Research*, 58, 45-51.
- [27] Goldberg D. E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Alabama, Addison-Wesley.
- [28] Haykin, S. (1994). *Neural Networks: A Comprehensive Foundation*. Englewood Cliffs, New Jersey: Macmillan College.
- [29] Henrique, H. M. (1999). *Uma Contribuição ao Estudo de Redes Neurais*

Aplicadas ao Controle de Processos, Tese, Rio de Janeiro, COPPE/UFRJ.

- [30] Houck CR, Joines JÁ, Kay MG. *The Genetic Algorithm Optimization Toolbox (GAOT) for Matlab 5*, <http://www.ie.ncsu.edu/mirage/GAToolBox/gaot/>, 30-july-2001.
- [31] Houck CR, Joines JA, Kay MG. (1995) *A Genetic Algorithm for Function Optimization: A Matlab Implementation*. Technical Report IE TR 95-09. North Carolina: North Carolina State University.
- [32] Hsiao Y-T, Chien C-Y. (2000). Enhancement of Restoration Service in Distribution Systems Using a Combination Fuzzy-GA Method. *IEEE Trans. Power Syst.*, 15(4), 1394-1400.
- [33] Kazarlis A. S., Bakirtzis A. G., Petridis V. (1996). A Genetic Algorithm Solution to the Unit Commitment Problem. *IEEE Trans Power Syst.*, 11(1), 83-91.
- [34] Kiartzis S. J., Zoumas C. E., Theocharis J. B., Bakirtzis, A. G., Petridis, V. (1997). Short Term Load Forecasting in an Autonomous Power System using Artificial Neural Networks. *IEEE Transactions on Power Systems*, 12(4), 1591-1596.
- [35] Khotanzad, A., Hwang, A. A., Maratukulam, D. (1995) An Adaptive Modular Artificial Neural Network Hourly Load Foecaster and its Implementation at Electric Utilities, *IEEE Trans. Power Systems*, 10 (3), 1716-1722.
- [36] Khotanzad, A., Afkhani-Rohani R., Lu, T. L., Davis, M. H., Abaye, A., Maratukulam, D. (1997) ANNSTLF – A Neural Network-Based Electric Load Forecasting System, *IEEE Trans. on Neural Networks*, 8 (4), 835-846.
- [37] Khotanzad, A., Afkhani-Rohani, R., Maratukulam, D. (1998) ANNSTLF – Artificial Neural Network Short Term Load Forecaster – Generation Three, *IEEE Trans. Power Systems*, 13 (4), 1413-1422.
- [38] Lambert-Torres, G., Alves da Silva, A.P., Costa, C.I.A., Cardoso, A.F., Marra, W. (1997). Short-term load forecasting: CEMIG industry's approach. *IEEE International Conference on Computational Cybernetics and Simulation. Systems, Man, and Cybernetics*, 4, 3289-3294.

- [39] Leite, F. E. A. (1997). *Aplicação de Redes Neurais Artificiais na Previsão de Curto Prazo da Carga Nodal de Sistemas de Energia Elétrica*. Campinas: Unicamp (Dissertação).
- [40] Levitin G., Kalyuzhny A., Shenkman A., Chertkov M. (2000). Optimal Capacitor Allocation in Distribution Systems Using a Genetic Algorithm and a Fast Energy Loss Computation Technique. *IEEE Trans. Power Syst.*, 15(2), 623-628.
- [41] Lu C. N., Wu H. T., Vemuri S. (1993). Neural Network based Short Term Load Forecasting. *IEEE Transactions on Power Systems*, 8(1), 336-342.
- [42] Martin, M (1996). Integrated Model for Very Short-Term Load Forecasting. *12th Power Systems Computation Conference*, Dresden, 245-251.
- [43] Mastorocostas, P. A., Theocharis, J. B., Bakirtzis, A. G. (1999) Fuzzy Modeling for Short Term Load Forecasting Using the Orthogonal Least Squares Method. *IEEE Transactions on Power Systems*, 14 (1).
- [44] Miranda V, Ranito JV, Proença LM. Genetic Algorithms in Optimal Multistage Distribution Networking Planning. *IEEE Trans. Power Syst.* 9(4), 1927-1933.
- [45] Mohammad, T., Egbert R. (2000). Short term electric load forecasting via fuzzy neural collaboration. *Electric Power Systems Research*, 56, 243-248
- [46] Mohamad, T. E., Mansour M. M., El-Debeiky, S., Mohamad, K. G., Rao, N. D., Ramakrishna, G. (1996). Results of Egyptian unified grid hourly load forecasting using an artificial neural network with expert system interface. *Electric Power Systems Research*, 39, 171-177.
- [47] Oliveira, C. M. de (1999). *Um Modelo de Rede Neural Artificial para Previsão Automática da Carga Ativa Nodal de Curto Prazo em Sistemas de Transmissão e Distribuição de Energia Elétrica com Supervisão e Controle Automatizados*. Florianópolis: UFSC (Dissertação)
- [48] Orr, M. J. L. (1996) *Introduction to Radial Basis Function Networks*. Edinburg, <http://www.cns.ed.ac.uk/people/mark/papers/rbf.html>, em 07/10/98

- [49] Pandya, A. S., Macy, R. B. (1995) *Pattern Recognition with Neural Networks in C++*. USA: IEEE Press.
- [50] Park Y.M., Park J.B., Won J.R. (1998). A hybrid genetic algorithm/dynamic programming approach to optimal long-term generation expansion planning. *Electrical Power & Energy Systems*, 20(4), 295-303.
- [51] Reis, A. J. R., Alves da Silva, A. P. (2002) Previsor Neural de Carga Elétrica Baseado em Análise de Multiresolução via Wavelets. *VIII Symposium of Specialists in Electric Operational and Expansion Planning*.
- [52] Richards G. G., Yang H. (1993). Distribution System Harmonic Worst Case Design Using a Genetic Algorithm. *IEEE Trans Power Syst*, 8(3), 1484-1491.
- [53] Robandi I., Nishimori K., Nishimura R., Ishihara N. (2001). Optimal feedback control design using genetic algorithm in multimachine power system. *Electrical Power & Energy Systems*, 23, 263-271.
- [54] Rumelhard, D. G., Hinton, G. E., Williams, R. J. (1986) Learning Internal Representations by Error Propagation. In D. E. Rumelhard & J. L. McClelland, eds., *Parallel Distributed Processing*, 1(8), reprinted in Anderson & Rosenfeld [1988], 575-695.
- [55] Rumelhard, D. G., Hinton, G. E., Williams, R. J. (1986) Learning Representations by Back-Propagating Error. *Nature*, 323, 533-536, reprinted in Anderson & Rosenfeld [1988], 696-699.
- [56] Satish, B., Swarup, K. S., Srinivas, S., Hanumantha Rao, A. (2004). Effect of Temperature on Short Term Load Forecasting Using an Integrated ANN. *Electric Power Systems Research*, 72(1), 95-101.
- [57] Skapura, D. M. (1996). *Building Neural Networks*. New York: ACM Press.
- [58] Srinivasan (1998) – Srinivasan, D. (1998). Evolving Artificial Neural Networks for Short Term Load Forecasting. *Neurocomputing*, 23, 265-276.
- [59] Tafner, M. A., Xerez, M., Filho, I. W. R. (1995). *Redes Neurais Artificiais:*

introdução e princípios de neurocomputação. Blumenau: EKO: Ed. da FURB.

- [60] Topalli, A. K., Erkmen, I. (2003). Hybrid Learning for Neural Networks Applied to Short Term Load Forecasting. *Neurocomputing*, 51, 495-500.
- [61] Tsoi, A. C., Black, A. (1997). Discrete Time Recurrent Neural Network Architectures: A Unifying Review. *Neurocomputing*, 15, 183-223.
- [62] Viswanathan V., Krshnan V., Tsoukalas L. H. (1999) Novel AI Approaches in Power Systems. *International Conference on Information Intelligence and Systems*, 275-280.
- [63] Vellasco, M. M. B. R., Pacheco, M. A. C., Ribeiro Neto, L. S., Souza, F. J. (2004) Electric load forecasting: evaluating the novel hierarchical neuro-fuzzy BSP model. *International Journal of Electrical Power & Energy Systems*, 26 (2), 131-142
- [64] Wakita R., Yokoyama A. (1995). Next Day Peak Load Forecasting Using Seasonal Artificial Neural Network Model. *International Power Engineering Conference IEEE Transactions on Power Systems*. Singapore, 660-665.
- [65] Whitley, D. (1993). *A Genetic Algorithm Tutorial*. Technical Report CS-93-103, Colorado, Colorado State University.
- [66] Wong S.Y.W. (2001). Hybrid simulated annealing/genetic algorithm approach to short-term hydro-thermal scheduling with multiple thermals plants. *Electrical Power & Energy Systems*, 23, 565-575.
- [67] Xiao, B., McLaren, P. G. (1995). An Artificial Neural Network for Short Term Load Forecasting. *IEEE/WESCANEX'95 Proceedings*, 129-132.
- [68] Zhang, B-L., Dong, Z-Y (2001) An Adaptive Neural-Wavelet Model for Short Term Load Forecasting. *Electric Power Systems Research*, 59, 121-129.
- [69] Zhang G., Patuwo B. E., Hu M. Y. (1998) Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14, 35-62.
- [70] Zebulum, R. S., Pacheco, M. A., Vellasco M. (1996). Um Sistema Inteligente de Previsão de Carga Aplicado ao Setor Elétrico Brasileiro. *V Simpósio de*

Especialistas em Planejamento da Operação e Expansão Elétrica, Recife, 791-797.

8. ANEXOS

8.1 Conjunto de Variáveis Candidatas ao Vetor de Entrada da RNA

Conforme já foi discutido na seção 2.5, não há consenso sobre quais são as variáveis que influenciam no comportamento da carga. Normalmente elas são escolhidas a partir do conjunto de variáveis que se encontram disponíveis utilizando-se técnicas heurísticas, estatísticas, experimentação e relatórios de trabalhos anteriores. As variáveis mais utilizadas na previsão de carga de curto prazo são as cargas, as condições climáticas e informações sobre o comportamento periódico e sazonal da curva de carga. Dentre as condições climáticas, a temperatura ambiente é a variável que normalmente mais influencia no comportamento da carga e é a mais utilizada. Para que a RNA aprenda o comportamento periódico e sazonal da carga, são utilizadas variáveis que fornecem informação sobre tal comportamento, tais como: hora do dia, dia da semana, semana ou mês do ano e ocorrência de feriado. Ainda em decorrência do comportamento periódico, é costume se utilizar defasagens (atrasos) nas variáveis de carga e nas relativas ao clima, atrasos e adiantamentos (previsões de tempo).

Neste trabalho, a partir das variáveis disponíveis, a escolha das variáveis e suas defasagens que resultaram no conjunto de variáveis candidatas foi apoiada em heurística, relatórios de trabalhos anteriores, conhecimento dos técnicos da CELESC e experimentação. A Tabela 15, apresenta as variáveis utilizadas no Conjunto de Variáveis Candidatas ao vetor de entrada das RNAs modeladas pelos algoritmos evolutivos, quando disponíveis para o ponto do sistema hipotético estudado. As variáveis foram compostas a partir de informações de carga, temperatura ambiente, umidade relativa do ar, pressão atmosférica, radiação solar total (direta + difusa), velocidade e direção do vento, hora do dia, dia da semana e semana do ano.

É possível observar que o Conjunto de Variáveis Candidatas contém alguns subconjuntos de variáveis que são redundantes entre si, como é o caso dos subconjuntos (a) $C_{h-30min}$ e $C_{h-1hora}$ e (b) $C_{h-30min}$ e $C_{h-30min} - C_{h-1hora}$. Tais redundâncias foram inseridas propositalmente, para que, no escopo deste trabalho, a escolha fique a cargo do Modelador Evolutivo. Técnicas estatísticas podem ser utilizadas para auxiliar na construção do

Conjunto de Variáveis Candidatas, porém este tema está fora do escopo deste trabalho e não será abordado. Cabe ainda ressaltar a quantidade de variáveis climáticas utilizadas, que se deve ao interesse na investigação de suas influências nas demandas por carga do sistema hipotético, para as diferentes regiões de consumo e épocas do ano. Foi utilizado um total de 216 variáveis codificadas em 237 neurônios no vetor de entrada da RNA. As variáveis representadas na entrada da RNA por mais de um neurônio, têm sua respectiva quantidade de neurônios explicitada.

Os valores médios da carga, para uma dada meia hora, foram calculados utilizando as medições a cada minuto dos 30 últimos valores de cada variável. Os valores médios das variáveis, temperatura ambiente, umidade relativa do ar, pressão atmosférica e radiação solar, para uma dada meia hora, quando havia medições confiáveis a cada minuto, foram calculados da mesma forma que os valores médios da carga. Para estas variáveis, em pontos onde só havia medições de médias horárias, os valores médios de cada meia hora foram obtidos interpolando as médias horárias disponíveis. Para o vento, as medições vetoriais médias de vento (velocidade e direção) a cada 10 minutos, foram desmembradas em suas duas componentes: velocidade e direção (em graus). A seguir, foram calculadas médias da direção velocidade para cada intervalo de 30 minutos. Isto feito, a direção do vento foi discretizada, em graus, nas oito direções básicas da rosa dos ventos.

Tabela 15 - Conjunto de variáveis candidatas e sua forma de representação na RNA

H_{bin}	½ hora do dia (48 valores no dia), em binário. O primeiro valor representa a hora e minuto 00:00, como “000001” (6 neurônios de entrada da RNA). Nome no banco de dados: AGORA_MEIAHoraAtualBinario
H_{sen}	½ hora do dia (48 valores no dia), como função trigonométrica (seno). O primeiro valor representa a hora e minuto 00:00”. Nome no banco de dados: AGORA_MEIAHoraAtualSeno
H_{cos}	½ hora do dia (48 valores no dia), como função trigonométrica (cosseno). O primeiro valor representa a hora e minuto 00:00”. Nome no banco de dados: AGORA_MEIAHoraAtualCosseno
D_{bin}	Dia da semana (7 dias na semana), em binário. O primeiro valor representa o Domingo como “001” (3 neurônios de entrada da RNA). Nome no banco de dados: AGORA_DiaSemanaAtualBinario
D_{sen}	Dia da semana (7 dias na semana), como função trigonométrica (seno). O primeiro valor representa o Domingo. Nome no banco de dados: AGORA_DiaSemanaAtualSeno

D_{\cos}	Dia da semana (7 dias na semana), como função trigonométrica (cosseno). O primeiro valor representa o Domingo. Nome no banco de dados: AGORA_DiaSemanaAtualCosseno
S_{bin}	Semana do ano (52 semanas no ano), em binário. A semana começa no Domingo e termina no Sábado. A primeira semana do ano (primeira semana de Janeiro) começa no primeiro Domingo após o dia 31 de dezembro e é representada como “000001” (6 neurônios de entrada da RNA). Nome no banco de dados: AGORA_SemanaAnoAtualBinario
S_{sen}	Semana do ano (52 semanas no ano), como função trigonométrica (seno). A semana começa no Domingo e termina no Sábado. A primeira semana do ano (primeira semana de Janeiro) começa no primeiro Domingo após o dia 31 de dezembro. Nome no banco de dados: AGORA_SemanaAnoAtualSeno
S_{\cos}	Semana do ano (52 semanas no ano), como função trigonométrica (cosseno). A semana começa no Domingo e termina no Sábado. A primeira semana do ano (primeira semana de Janeiro) começa no primeiro Domingo após o dia 31 de dezembro. Nome no banco de dados: AGORA_SemanaAnoAtualCosseno
$C_{\text{h-30min}}$	Carga média ½ hora antes. Nome no banco de dados: AGORA_CargaMediaMeiaHoraAntes
$C_{\text{h-1hora}}$	Carga média 1 hora antes. Nome no banco de dados: AGORA_CargaMediaUmaHoraAntes
$C_{\text{h-1hora30min}}$	Carga média 1 hora e ½ antes. Nome no banco de dados: AGORA_CargaMediaUmaHoraAntes
$C_{\text{h-30min}} - C_{\text{h-1hora}}$	Diferença entre a Carga média ½ hora antes e a Carga média 1 hora antes. Nome no banco de dados: AGORA_DerivadaCargaMeiaHoraAntes
$(C_{\text{h-30min}} - C_{\text{h-1hora}}) - (C_{\text{h-1hora}} - C_{\text{h-1hora30min}})$	Diferença entre (a) diferença entre a Carga média ½ hora antes e a Carga média 1 hora antes e (b) diferença entre a Carga média 1 hora antes e a Carga média 1½ horas antes. Nome no banco de dados: AGORA_Derivada2CargaMeiaHoraAntes
$C_{\text{h-168horas}}$	Carga média na hora atual 1 semana antes. Nome no banco de dados: SEMANA_CargaMediaAtual
$C_{\text{h-168horas30min}}$	Carga média ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_CargaMediaMeiaHoraAntes
$C_{\text{h-169horas}}$	Carga média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_CargaMediaUmaHoraAntes
$C_{\text{h-169horas30min}}$	Carga média 1 ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_CargaMediaUmaHoraMeiaAntes
$C_{\text{h-168horas}} - C_{\text{h-168horas30min}}$	Diferença entre e a Carga média na hora atual, 1 semana antes e a Carga média ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_DerivadaCargaAtual

$C_{h-168\text{horas}30\text{min}} - C_{h-169\text{horas}}$	Diferença entre a Carga média ½ hora antes, 1 semana antes e a Carga média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_DerivadaCargaMeiaHoraAntes
$(C_{h-168\text{horas}} - C_{h-168\text{horas}30\text{min}}) - (C_{h-168\text{horas}30\text{min}} - C_{h-169\text{horas}})$	Diferença entre (a) diferença entre a Carga média na hora atual, 1 semana antes e a Carga média ½ hora antes, 1 semana antes (b) diferença entre a Carga média ½ hora antes, 1 semana antes e a Carga média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_Derivada2CargaAtual
$(C_{h-168\text{horas}30\text{min}} - C_{h-169\text{horas}}) - (C_{h-169\text{horas}} - C_{h-169\text{horas}30\text{min}})$	Diferença entre (a) diferença entre a Carga média ½ hora antes, 1 semana antes e a Carga média 1 hora antes, 1 semana antes e (b) diferença entre a Carga média 1 hora antes, 1 semana antes e a Carga média 1½ horas antes, 1 semana antes. Nome no banco de dados: SEMANA_Derivada2CargaMeiaHoraAntes
$C_{\text{minSemana}}$	Carga mínima do dia, 1 semana antes. Nome no banco de dados: SEMANA_CargaMinimaDia
$C_{\text{medSemana}}$	Carga média do dia, 1 semana antes. Nome no banco de dados: SEMANA_CargaMediaDia
$C_{\text{maxSemana}}$	Carga máxima do dia, 1 semana antes. Nome no banco de dados: SEMANA_CargaMaximaDia
$C_{\text{min-52semanas}}$	Carga mínima do dia, 52 semanas antes. Nome no banco de dados: ANO_CargaMinimaDia
$C_{\text{max-52semanas}}$	Carga máxima do dia, 52 semanas antes. Nome no banco de dados: ANO_CargaMaximaDia
$C_{\text{med-52semanas}}$	Carga média do dia, 52 semanas antes. Nome no banco de dados: ANO_CargaMediaDia
$C_{h-52semanas}$	Carga média na hora atual, 52 semanas antes. Nome no banco de dados: ANO_CargaMediaAtual
$C_{h-52semanas30\text{min}}$	Carga média ½ hora antes, 52 semanas antes. Nome no banco de dados: ANO_CargaMediaMeiaHoraAntes
$C_{h-52semanas1\text{hora}}$	Carga média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_CargaMediaUmaHoraAntes
$C_{h-52semanas1\text{hora}30\text{min}}$	Carga média 1 ½ hora antes, 52 semanas antes. Nome no banco de dados: ANO_CargaMediaUmaHoraeMeiaAntes
$C_{h-52semanas} - C_{h-52semanas30\text{min}}$	Diferença entre e a Carga média na hora atual, 52 semanas antes e a Carga média ½ hora antes, 52 semanas. Nome no banco de dados: ANO_DerivadaCargaAtual
$C_{h-52semanas30\text{min}} - C_{h-52semanas1\text{hora}}$	Diferença entre a Carga média ½ hora antes, 52 semanas antes e a Carga média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_DerivadaCargaMeiaHoraAntes

$(C_{h-52semanas} - C_{h-52semanas30min}) - (C_{h-52semanas30min} - C_{h-52semanas1hora})$	Diferença entre (a) diferença entre a Carga média na hora atual, 52 semanas antes e a Carga média ½ hora antes, 52 semanas antes (b) diferença entre a Carga média ½ hora antes, 52 semanas antes e a Carga média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_Derivada2CargaAtual
$(C_{h-52semanas30min} - C_{h-52semanas1hora}) - (C_{h-52semanas1hora} - C_{h-52semanas1hora30min})$	Diferença entre (a) diferença entre a Carga média ½ hora antes, 52 semanas antes e a Carga média 1 hora antes, 52 semanas antes e (b) diferença entre a Carga média 1 hora antes, 52 semanas antes e a Carga média 1½ horas antes, 52 semanas antes. Nome no banco de dados: ANO_Derivada2CargaMeiaHoraAntes
C_{minAno}	Carga mínima do dia, 52 semanas antes. Nome no banco de dados: ANO_CargaMinimaDia
C_{medAno}	Carga média do dia, 52 semanas antes. Nome no banco de dados: ANO_CargaMediaDia
C_{maxAno}	Carga máxima do dia, 52 semanas antes. Nome no banco de dados: ANO_CargaMaximaDia
T_h	Temperatura ambiente média na hora atual. Nome no banco de dados: AGORA_TemperaturaMediaAtual
$T_{h-30min}$	Temperatura ambiente média ½ hora antes. Nome no banco de dados: AGORA_TemperaturaMediaMeiaHoraAntes
$T_{h-1hora}$	Temperatura ambiente média 1 hora antes. Nome no banco de dados: AGORA_TemperaturaMediaUmaHoraAntes
$T_{h-1hora30min}$	Temperatura ambiente média 1 ½ hora antes. Nome no banco de dados: AGORA_TemperaturaMediaUmaHoraeMeiaAntes
$T_h - T_{h-30min}$	Diferença entre e a Temperatura ambiente média na hora atual e a Temperatura ambiente média ½ hora antes. Nome no banco de dados: AGORA_DerivadaTemperaturaAtual
$T_{h-30min} - T_{h-1hora}$	Diferença entre a Temperatura ambiente média ½ hora antes e a Temperatura ambiente média 1 hora antes. Nome no banco de dados: AGORA_DerivadaTemperaturaMeiaHoraAntes
$(T_h - T_{h-30min}) - (T_{h-30min} - T_{h-1hora})$	Diferença entre (a) diferença entre a Temperatura ambiente média na hora atual e a Temperatura ambiente média ½ hora antes (b) diferença entre a Temperatura ambiente média ½ hora antes e a Temperatura ambiente média 1 hora antes. Nome no banco de dados: AGORA_Derivada2TemperaturaAtual
$(T_{h-30min} - T_{h-1hora}) - (T_{h-1hora} - T_{h-1hora30min})$	Diferença entre (a) diferença entre a Temperatura ambiente média ½ hora antes e a Temperatura ambiente média 1 hora antes e (b) diferença entre a Temperatura ambiente média 1 hora antes e a Temperatura ambiente média 1½ horas antes. Nome no banco de dados: AGORA_Derivada2TemperaturaMeiaHoraAntes
$T_{minAgora}$	Temperatura ambiente mínima do dia. Nome no banco de dados: AGORA_TemperaturaMinimaDia

$T_{medAgora}$	Temperatura ambiente média do dia. Nome no banco de dados: AGORA_TemperaturaMediaDia
$T_{maxAgora}$	Temperatura ambiente máxima do dia. Nome no banco de dados: AGORA_TemperaturaMaximaDia
$T_{h-168horas}$	Temperatura ambiente média na hora atual 1 semana antes, 1 semana antes. Nome no banco de dados: SEMANA_TemperaturaMediaAtual
$T_{h-168horas30min}$	Temperatura ambiente média ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_TemperaturaMediaMeiaHoraAntes
$T_{h-169horas}$	Temperatura ambiente média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_TemperaturaMediaUmaHoraAntes
$T_{h-169horas30min}$	Temperatura ambiente média 1 ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_TemperaturaMediaUmaHoraeMeiaAntes
$T_{h-168horas} - T_{h-168horas30min}$	Diferença entre e a Temperatura ambiente média na hora atual, 1 semana antes e a Temperatura ambiente média ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_DerivadaTemperaturaAtual
$T_{h-168horas30min} - T_{h-169horas}$	Diferença entre a Temperatura ambiente média ½ hora antes, 1 semana antes e a Temperatura ambiente média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_DerivadaTemperaturaMeiaHoraAntes
$(T_{h-168horas} - T_{h-168horas30min}) - (T_{h-168horas30min} - T_{h-169horas})$	Diferença entre (a) diferença entre a Temperatura ambiente média na hora atual, 1 semana antes e a Temperatura ambiente média ½ hora antes, 1 semana antes (b) diferença entre a Temperatura ambiente média ½ hora antes, 1 semana antes e a Temperatura ambiente média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_Derivada2TemperaturaAtual
$(T_{h-168horas30min} - T_{h-169horas}) - (T_{h-169horas} - T_{h-169horas30min})$	Diferença entre (a) diferença entre a Temperatura ambiente média ½ hora antes, 1 semana antes e a Temperatura ambiente média 1 hora antes, 1 semana antes e (b) diferença entre a Temperatura ambiente média 1 hora antes, 1 semana antes e a Temperatura ambiente média 1 ½ horas antes, 1 semana antes. Nome no banco de dados: SEMANA_Derivada2TemperaturaMeiaHoraAntes
$T_{minSemana}$	Temperatura ambiente mínima do dia, 1 semana antes. Nome no banco de dados: SEMANA_TemperaturaMinimaDia
$T_{medSemana}$	Temperatura ambiente média do dia, 1 semana antes. Nome no banco de dados: SEMANA_TemperaturaMediaDia
$T_{maxSemana}$	Temperatura ambiente máxima do dia, 1 semana antes. Nome no banco de dados: SEMANA_TemperaturaMaximaDia
$T_{h-52semanas}$	Temperatura ambiente média na hora atual, 52 semanas antes. Nome no banco de dados: ANO_TemperaturaMediaAtual
$T_{h-52semanas30min}$	Temperatura ambiente média ½ hora antes, 52 semanas antes. Nome no banco de dados: ANO_TemperaturaMediaMeiaHoraAntes

$T_{h-52semanas1hora}$	Temperatura ambiente média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_TemperaturaMediaUmaHoraAntes
$T_{h-52semanas1hora30min}$	Temperatura ambiente média 1 ½ hora antes, 52 semanas antes. Nome no banco de dados: ANO_TemperaturaMediaUmaHoraeMeiaAntes
$T_{h-52semanas} - T_{h-52semanas30min}$	Diferença entre e a Temperatura ambiente média na hora atual, 52 semanas antes e a Temperatura ambiente média ½ hora antes, 52 semanas. Nome no banco de dados: ANO_DerivadaTemperaturaAtual
$T_{h-52semanas30min} - T_{h-52semanas1hora}$	Diferença entre a Temperatura ambiente média ½ hora antes, 52 semanas antes e a Temperatura ambiente média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_DerivadaTemperaturaMeiaHoraAntes
$(T_{h-52semanas} - T_{h-52semanas30min}) - (T_{h-52semanas30min} - T_{h-52semanas1hora})$	Diferença entre (a) diferença entre a Temperatura ambiente média na hora atual, 52 semanas antes e a Temperatura ambiente média ½ hora antes, 52 semanas antes (b) diferença entre a Temperatura ambiente média ½ hora antes, 52 semanas antes e a Temperatura ambiente média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_Derivada2TemperaturaAtual
$(T_{h-52semanas30min} - T_{h-52semanas1hora}) - (T_{h-52semanas1hora} - T_{h-52semanas1hora30min})$	Diferença entre (a) diferença entre a Temperatura ambiente média ½ hora antes, 52 semanas antes e a Temperatura ambiente média 1 hora antes, 52 semanas antes e (b) diferença entre a Temperatura ambiente média 1 hora antes, 52 semanas antes e a Temperatura ambiente média 1½ horas antes, 52 semanas antes. Nome no banco de dados: ANO_Derivada2TemperaturaMeiaHoraAntes
T_{minAno}	Temperatura ambiente mínima do dia, 52 semanas antes. Nome no banco de dados: ANO_TemperaturaMinimaDia
T_{medAno}	Temperatura ambiente média do dia, 52 semanas antes. Nome no banco de dados: ANO_TemperaturaMediaDia
T_{maxAno}	Temperatura ambiente máxima do dia, 52 semanas antes. Nome no banco de dados: ANO_TemperaturaMaximaDia
U_h	Umidade relativa média na hora atual. Nome no banco de dados: AGORA_UmidadeMediaAtual
$U_{h-30min}$	Umidade relativa média ½ hora antes. Nome no banco de dados: AGORA_UmidadeMediaMeiaHoraAntes
$U_{h-1hora}$	Umidade relativa média 1 hora antes. Nome no banco de dados: AGORA_UmidadeMediaUmaHoraAntes
$U_{h-1hora30min}$	Umidade relativa média 1 ½ hora antes. Nome no banco de dados: AGORA_UmidadeMediaUmaHoraeMeiaAntes
$U_h - U_{h-30min}$	Diferença entre e a Umidade relativa média na hora atual e a Umidade relativa média ½ hora antes. Nome no banco de dados: AGORA_DerivadaUmidadeAtual
$U_{h-30min} - U_{h-1hora}$	Diferença entre a Umidade relativa média ½ hora antes e a Umidade relativa média 1 hora antes. Nome no banco de dados: AGORA_DerivadaUmidadeMeiaHoraAntes

$(U_h - U_{h-30\text{min}}) - (U_{h-30\text{min}} - U_{h-1\text{hora}})$	Diferença entre (a) diferença entre a Umidade relativa média na hora atual e a Umidade relativa média ½ hora antes (b) diferença entre a Umidade relativa média ½ hora antes e a Umidade relativa média 1 hora antes. Nome no banco de dados: AGORA_Derivada2UmidadeAtual
$(U_{h-30\text{min}} - U_{h-1\text{hora}}) - (U_{h-1\text{hora}} - U_{h-1\text{hora}30\text{min}})$	Diferença entre (a) diferença entre a Umidade relativa média ½ hora antes e a Umidade relativa média 1 hora antes e (b) diferença entre a Umidade relativa média 1 hora antes e a Umidade relativa média 1½ horas antes. Nome no banco de dados: AGORA_Derivada2UmidadeMeiaHoraAntes
U_{minAgora}	Umidade relativa mínima do dia. Nome no banco de dados: AGORA_UmidadeMinimaDia
U_{medAgora}	Umidade relativa média do dia. Nome no banco de dados: AGORA_UmidadeMediaDia
U_{maxAgora}	Umidade relativa máxima do dia. Nome no banco de dados: AGORA_UmidadeMaximaDia
$U_{h-168\text{horas}}$	Umidade relativa média na hora atual 1 semana antes, 1 semana antes. Nome no banco de dados: SEMANA_UmidadeMediaAtual
$U_{h-168\text{horas}30\text{min}}$	Umidade relativa média ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_UmidadeMediaMeiaHoraAntes
$U_{h-169\text{horas}}$	Umidade relativa média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_UmidadeMediaUmaHoraAntes
$U_{h-169\text{horas}30\text{min}}$	Umidade relativa média 1 ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_UmidadeMediaUmaHoraMeiaAntes
$U_{h-168\text{horas}} - U_{h-168\text{horas}30\text{min}}$	Diferença entre e a Umidade relativa média na hora atual, 1 semana antes e a Umidade relativa média ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_DerivadaUmidadeAtual
$U_{h-168\text{horas}30\text{min}} - U_{h-169\text{horas}}$	Diferença entre a Umidade relativa média ½ hora antes, 1 semana antes e a Umidade relativa média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_DerivadaUmidadeMeiaHoraAntes
$(U_{h-168\text{horas}} - U_{h-168\text{horas}30\text{min}}) - (U_{h-168\text{horas}30\text{min}} - U_{h-169\text{horas}})$	Diferença entre (a) diferença entre a Umidade relativa média na hora atual, 1 semana antes e a Umidade relativa média ½ hora antes, 1 semana antes (b) diferença entre a Umidade relativa média ½ hora antes, 1 semana antes e a Umidade relativa média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_Derivada2UmidadeAtual
$(U_{h-168\text{horas}30\text{min}} - U_{h-169\text{horas}}) - (U_{h-169\text{horas}} - U_{h-169\text{horas}30\text{min}})$	Diferença entre (a) diferença entre a Umidade relativa média ½ hora antes, 1 semana antes e a Umidade relativa média 1 hora antes, 1 semana antes e (b) diferença entre a Umidade relativa média 1 hora antes, 1 semana antes e a Umidade relativa média 1½ horas antes, 1 semana antes. Nome no banco de dados: SEMANA_Derivada2UmidadeMeiaHoraAntes
$U_{\text{minSemana}}$	Umidade relativa mínima do dia, 1 semana antes. Nome no banco de dados: SEMANA_UmidadeMinimaDia

$U_{medSemana}$	Umidade relativa média do dia, 1 semana antes. Nome no banco de dados: SEMANA_UmidadeMediaDia
$U_{maxSemana}$	Umidade relativa máxima do dia, 1 semana antes. Nome no banco de dados: SEMANA_UmidadeMaximaDia
$U_{h-52semanas}$	Umidade relativa média na hora atual, 52 semanas antes. Nome no banco de dados: ANO_UmidadeMediaAtual
$U_{h-52semanas30min}$	Umidade relativa média ½ hora antes, 52 semanas antes. Nome no banco de dados: ANO_UmidadeMediaMeiaHoraAntes
$U_{h-52semanas1hora}$	Umidade relativa média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_UmidadeMediaUmaHoraAntes
$U_{h-52semanas1hora30min}$	Umidade relativa média 1 ½ hora antes, 52 semanas antes. Nome no banco de dados: ANO_UmidadeMediaUmaHoraeMeiaAntes
$U_{h-52semanas} - U_{h-52semanas30min}$	Diferença entre a Umidade relativa média na hora atual, 52 semanas antes e a Umidade relativa média ½ hora antes, 52 semanas. Nome no banco de dados: ANO_DerivadaUmidadeAtual
$U_{h-52semanas30min} - U_{h-52semanas1hora}$	Diferença entre a Umidade relativa média ½ hora antes, 52 semanas antes e a Umidade relativa média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_DerivadaUmidadeMeiaHoraAntes
$(U_{h-52semanas} - U_{h-52semanas30min}) - (U_{h-52semanas30min} - U_{h-52semanas1hora})$	Diferença entre (a) diferença entre a Umidade relativa média na hora atual, 52 semanas antes e a Umidade relativa média ½ hora antes, 52 semanas antes (b) diferença entre a Umidade relativa média ½ hora antes, 52 semanas antes e a Umidade relativa 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_Derivada2UmidadeAtual
$(U_{h-52semanas30min} - U_{h-52semanas1hora}) - (U_{h-52semanas1hora} - U_{h-52semanas1hora30min})$	Diferença entre (a) diferença entre a Umidade relativa média ½ hora antes, 52 semanas antes e a Umidade relativa média 1 hora antes, 52 semanas antes e (b) diferença entre a Umidade relativa média 1 hora antes, 52 semanas antes e a Umidade relativa média 1 ½ horas antes, 52 semanas antes. Nome no banco de dados: ANO_Derivada2UmidadeMeiaHoraAntes
$U_{min-Ano}$	Umidade relativa mínima do dia, 52 semanas antes. Nome no banco de dados: ANO_UmidadeMinimaDia
U_{medAno}	Umidade relativa média do dia, 52 semanas antes. Nome no banco de dados: ANO_UmidadeMediaDia
U_{maxAno}	Umidade relativa máxima do dia, 52 semanas antes. Nome no banco de dados: ANO_UmidadeMaximaDia
P_h	Pressão atmosférica média na hora atual. Nome no banco de dados: AGORA_PressaoMediaAtual
$P_{h-30min}$	Pressão atmosférica média ½ hora antes. Nome no banco de dados: AGORA_PressaoMediaMeiaHoraAntes
$P_{h-1hora}$	Pressão atmosférica média 1 hora antes. Nome no banco de dados: AGORA_PressaoMediaUmaHoraAntes

$P_{h-1hora30min}$	Pressão atmosférica média 1 ½ hora antes. Nome no banco de dados: AGORA_PressaoMediaUmaHoraMeiaAntes
$P_h - P_{h-30min}$	Diferença entre a Pressão atmosférica média na hora atual e a Pressão atmosférica média ½ hora antes. Nome no banco de dados: AGORA_DerivadaPressaoAtual
$P_{h-30min} - P_{h-1hora}$	Diferença entre a Pressão atmosférica média ½ hora antes e a Pressão atmosférica média 1 hora antes. Nome no banco de dados: AGORA_DerivadaPressaoMeiaHoraAntes
$(P_h - P_{h-30min}) - (P_{h-30min} - P_{h-1hora})$	Diferença entre (a) diferença entre a Pressão atmosférica média na hora atual e a Pressão atmosférica média ½ hora antes (b) diferença entre a Pressão atmosférica média ½ hora antes e a Pressão atmosférica média 1 hora antes. Nome no banco de dados: AGORA_Derivada2PressaoAtual
$(P_{h-30min} - P_{h-1hora}) - (P_{h-1hora} - P_{h-1hora30min})$	Diferença entre (a) diferença entre a Pressão atmosférica média ½ hora antes e a Pressão atmosférica média 1 hora antes e (b) diferença entre a Pressão atmosférica média 1 hora antes e a Pressão atmosférica média 1½ horas antes. Nome no banco de dados: AGORA_Derivada2PressaoMeiaHoraAntes
$P_{minAgora}$	Pressão atmosférica mínima do dia. Nome no banco de dados: AGORA_PressaoMinimaDia
$P_{medAgora}$	Pressão atmosférica média do dia. Nome no banco de dados: AGORA_PressaoMediaDia
$P_{maxAgora}$	Pressão atmosférica máxima do dia. Nome no banco de dados: AGORA_PressaoMaximaDia
$P_{h-168horas}$	Pressão atmosférica média na hora atual 1 semana antes, 1 semana antes. Nome no banco de dados: SEMANA_PressaoMediaAtual
$P_{h-168horas30min}$	Pressão atmosférica média ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_PressaoMediaMeiaHoraAntes
$P_{h-169horas}$	Pressão atmosférica média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_PressaoMediaUmaHoraAntes
$P_{h-169horas30min}$	Pressão atmosférica média 1 ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_PressaoMediaUmaHoraMeiaAntes
$P_{h-168horas} - P_{h-168horas30min}$	Diferença entre a Pressão atmosférica média na hora atual, 1 semana antes e a Pressão atmosférica média ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_DerivadaPressaoAtual
$P_{h-168horas30min} - P_{h-169horas}$	Diferença entre a Pressão atmosférica média ½ hora antes, 1 semana antes e a Pressão atmosférica média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_DerivadaPressaoMeiaHoraAntes
$(P_{h-168horas} - P_{h-168horas30min}) - (P_{h-168horas30min} - P_{h-169horas})$	Diferença entre (a) diferença entre a Pressão atmosférica média na hora atual, 1 semana antes e a Pressão atmosférica média ½ hora antes, 1 semana antes (b) diferença entre a Pressão atmosférica média ½ hora antes, 1 semana antes e a Pressão atmosférica média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_Derivada2PressaoAtual

$(P_{h-168\text{horas}30\text{min}} - P_{h-169\text{horas}}) - (P_{h-169\text{horas}} - P_{h-169\text{horas}30\text{min}})$	Diferença entre (a) diferença entre a Pressão atmosférica média ½ hora antes, 1 semana antes e a Pressão atmosférica média 1 hora antes, 1 semana antes e (b) diferença entre a Pressão atmosférica média 1 hora antes, 1 semana antes e a Pressão atmosférica média 1½ horas antes, 1 semana antes. Nome no banco de dados: SEMANA_Derivada2PressaoMeiaHoraAntes
$P_{\text{minSemana}}$	Pressão atmosférica mínima do dia, 1 semana antes. Nome no banco de dados: SEMANA_PressaoMinimaDia
$P_{\text{medSemana}}$	Pressão atmosférica média do dia, 1 semana antes. Nome no banco de dados: SEMANA_PressaoMediaDia
$P_{\text{maxSemana}}$	Pressão atmosférica máxima do dia, 1 semana antes. Nome no banco de dados: SEMANA_PressaoMaximaDia
$P_{h-52\text{semanas}}$	Pressão atmosférica média na hora atual, 52 semanas antes. Nome no banco de dados: ANO_PressaoMediaAtual
$P_{h-52\text{semanas}30\text{min}}$	Pressão atmosférica média ½ hora antes, 52 semanas antes. Nome no banco de dados: ANO_PressaoMediaMeiaHoraAntes
$P_{h-52\text{semanas}1\text{hora}}$	Pressão atmosférica média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_PressaoMediaUmaHoraAntes
$P_{h-52\text{semanas}1\text{hora}30\text{min}}$	Pressão atmosférica média 1 ½ hora antes, 52 semanas antes. Nome no banco de dados: ANO_PressaoMediaUmaHoraeMeiaAntes
$P_{h-52\text{semanas}} - P_{h-52\text{semanas}30\text{min}}$	Diferença entre e a Pressão atmosférica média na hora atual, 52 semanas antes e a Pressão atmosférica média ½ hora antes, 52 semanas. Nome no banco de dados: ANO_DerivadaPressaoAtual
$P_{h-52\text{semanas}30\text{min}} - P_{h-52\text{semanas}1\text{hora}}$	Diferença entre a Pressão atmosférica média ½ hora antes, 52 semanas antes e a Pressão atmosférica média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_DerivadaPressaoMeiaHoraAntes
$(P_{h-52\text{semanas}} - P_{h-52\text{semanas}30\text{min}}) - (P_{h-52\text{semanas}30\text{min}} - P_{h-52\text{semanas}1\text{hora}})$	Diferença entre (a) diferença entre a Pressão atmosférica média na hora atual, 52 semanas antes e a Pressão atmosférica média ½ hora antes, 52 semanas antes (b) diferença entre a Pressão atmosférica média ½ hora antes, 52 semanas antes e a Pressão atmosférica 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_Derivada2PressaoAtual
$(P_{h-52\text{semanas}30\text{min}} - P_{h-52\text{semanas}1\text{hora}}) - (P_{h-52\text{semanas}1\text{hora}} - P_{h-52\text{semanas}1\text{hora}30\text{min}})$	Diferença entre (a) diferença entre a Pressão atmosférica média ½ hora antes, 52 semanas antes e a Pressão atmosférica média 1 hora antes, 52 semanas antes e (b) diferença entre a Pressão atmosférica média 1 hora antes, 52 semanas antes e a Pressão atmosférica média 1½ horas antes, 52 semanas antes. Nome no banco de dados: ANO_Derivada2PressaoMeiaHoraAntes
$P_{\text{min-Ano}}$	Pressão atmosférica mínima do dia, 52 semanas antes. Nome no banco de dados: ANO_PressaoMinimaDia
P_{medAno}	Pressão atmosférica média do dia, 52 semanas antes. Nome no banco de dados: ANO_PressaoMediaDia
P_{maxAno}	Pressão atmosférica máxima do dia, 52 semanas antes. Nome no banco de dados: ANO_PressaoMaximaDia

R_h	Radiação solar média na hora atual. Nome no banco de dados: AGORA_RadiacaoMediaAtual
$R_{h-30min}$	Radiação solar média ½ hora antes. Nome no banco de dados: AGORA_RadiacaoMediaMeiaHoraAntes
$R_{h-1hora}$	Radiação solar média 1 hora antes. Nome no banco de dados: AGORA_RadiacaoMediaUmaHoraAntes
$R_{h-1hora30min}$	Radiação solar média 1 ½ hora antes. Nome no banco de dados: AGORA_RadiacaoMediaUmaHoraMeiaAntes
$R_h - R_{h-30min}$	Diferença entre a Radiação solar média na hora atual e a Radiação solar média ½ hora antes. Nome no banco de dados: AGORA_DerivadaRadiacaoAtual
$R_{h-30min} - R_{h-1hora}$	Diferença entre a Radiação solar média ½ hora antes e a Radiação solar média 1 hora antes. Nome no banco de dados: AGORA_DerivadaRadiacaoMeiaHoraAntes
$(R_h - R_{h-30min}) - (R_{h-30min} - R_{h-1hora})$	Diferença entre (a) diferença entre a Radiação solar média na hora atual e a Radiação solar média ½ hora antes (b) diferença entre a Radiação solar média ½ hora antes e a Radiação solar média 1 hora antes. Nome no banco de dados: AGORA_Derivada2RadiacaoAtual
$(R_{h-30min} - R_{h-1hora}) - (R_{h-1hora} - R_{h-1hora30min})$	Diferença entre (a) diferença entre a Radiação solar média ½ hora antes e a Radiação solar média 1 hora antes e (b) diferença entre a Radiação solar média 1 hora antes e a Radiação solar média 1 ½ horas antes. Nome no banco de dados: AGORA_Derivada2RadiacaoMeiaHoraAntes
$R_{minAgora}$	Radiação solar mínima do dia. Nome no banco de dados: AGORA_RadiacaoMinimaDia
$R_{medAgora}$	Radiação solar média do dia. Nome no banco de dados: AGORA_RadiacaoMediaDia
$R_{maxAgora}$	Radiação solar máxima do dia. Nome no banco de dados: AGORA_RadiacaoMaximaDia
$R_{h-168horas}$	Radiação solar média na hora atual 1 semana antes, 1 semana antes. Nome no banco de dados: SEMANA_RadiacaoMediaAtual
$R_{h-168horas30min}$	Radiação solar média ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_RadiacaoMediaMeiaHoraAntes
$R_{h-169horas}$	Radiação solar média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_RadiacaoMediaUmaHoraAntes
$R_{h-169horas30min}$	Radiação solar média 1 ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_RadiacaoMediaUmaHoraMeiaAntes
$R_{h-168horas} - R_{h-168horas30min}$	Diferença entre a Radiação solar média na hora atual, 1 semana antes e a Radiação solar média ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_DerivadaRadiacaoAtual
$R_{h-168horas30min} - R_{h-169horas}$	Diferença entre a Radiação solar média ½ hora antes, 1 semana antes e a Radiação solar média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_DerivadaRadiacaoMeiaHoraAntes

$(R_{h-168\text{horas}} - R_{h-168\text{horas}30\text{min}}) - (R_{h-168\text{horas}30\text{min}} - R_{h-169\text{horas}})$	Diferença entre (a) diferença entre a Radiação solar média na hora atual, 1 semana antes e a Radiação solar média ½ hora antes, 1 semana antes (b) diferença entre a Radiação solar média ½ hora antes, 1 semana antes e a Radiação solar média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_Derivada2RadiacaoAtual
$(R_{h-168\text{horas}30\text{min}} - R_{h-169\text{horas}}) - (R_{h-169\text{horas}} - R_{h-169\text{horas}30\text{min}})$	Diferença entre (a) diferença entre a Radiação solar média ½ hora antes, 1 semana antes e a Radiação solar média 1 hora antes, 1 semana antes e (b) diferença entre a Radiação solar média 1 hora antes, 1 semana antes e a Radiação solar média 1½ horas antes, 1 semana antes. Nome no banco de dados: SEMANA_Derivada2RadiacaoMeiaHoraAntes
$R_{\text{minSemana}}$	Radiação solar mínima do dia, 1 semana antes. Nome no banco de dados: SEMANA_RadiacaoMinimaDia
$R_{\text{medSemana}}$	Radiação solar média do dia, 1 semana antes. Nome no banco de dados: SEMANA_RadiacaoMediaDia
$R_{\text{maxSemana}}$	Radiação solar máxima do dia, 1 semana antes. Nome no banco de dados: SEMANA_RadiacaoMaximaDia
$R_{h-52\text{semanas}}$	Radiação solar média na hora atual, 52 semanas antes. Nome no banco de dados: ANO_RadiacaoMediaAtual
$R_{h-52\text{semanas}30\text{min}}$	Radiação solar média ½ hora antes, 52 semanas antes. Nome no banco de dados: ANO_RadiacaoMediaMeiaHoraAntes
$R_{h-52\text{semanas}1\text{hora}}$	Radiação solar média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_RadiacaoMediaUmaHoraAntes
$R_{h-52\text{semanas}1\text{hora}30\text{min}}$	Radiação solar média 1 ½ hora antes, 52 semanas antes. Nome no banco de dados: ANO_RadiacaoMediaUmaHoraeMeiaAntes
$R_{h-52\text{semanas}} - R_{h-52\text{semanas}30\text{min}}$	Diferença entre e a Radiação solar média na hora atual, 52 semanas antes e a Radiação solar média ½ hora antes, 52 semanas. Nome no banco de dados: ANO_DerivadaRadiacaoAtual
$R_{h-52\text{semanas}30\text{min}} - R_{h-52\text{semanas}1\text{hora}}$	Diferença entre a Radiação solar média ½ hora antes, 52 semanas antes e a Radiação solar média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_DerivadaRadiacaoMeiaHoraAntes
$(R_{h-52\text{semanas}} - R_{h-52\text{semanas}30\text{min}}) - (R_{h-52\text{semanas}30\text{min}} - R_{h-52\text{semanas}1\text{hora}})$	Diferença entre (a) diferença entre a Radiação solar média na hora atual, 52 semanas antes e a Radiação solar média ½ hora antes, 52 semanas antes (b) diferença entre a Radiação solar média ½ hora antes, 52 semanas antes e a Radiação solar 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_Derivada2RadiacaoAtual
$(R_{h-52\text{semanas}30\text{min}} - R_{h-52\text{semanas}1\text{hora}}) - (R_{h-52\text{semanas}1\text{hora}} - R_{h-52\text{semanas}1\text{hora}30\text{min}})$	Diferença entre (a) diferença entre a Radiação solar média ½ hora antes, 52 semanas antes e a Radiação solar média 1 hora antes, 52 semanas antes e (b) diferença entre a Radiação solar média 1 hora antes, 52 semanas antes e a Radiação solar média 1½ horas antes, 52 semanas antes. Nome no banco de dados: ANO_Derivada2RadiacaoMeiaHoraAntes
$R_{\text{min-Ano}}$	Radiação solar mínima do dia, 52 semanas antes. Nome no banco de dados: ANO_RadiacaoMinimaDia

R_{medAno}	Radiação solar média do dia, 52 semanas antes. Nome no banco de dados: ANO_RadiacaoMediaDia
R_{maxAno}	Radiação solar máxima do dia, 52 semanas antes. Nome no banco de dados: ANO_RadiacaoMaximaDia
V_h	Velocidade do vento média na hora atual. Nome no banco de dados: AGORA_VentoMediaAtual
$V_{h-30min}$	Velocidade do vento média ½ hora antes. Nome no banco de dados: AGORA_VentoMediaMeiaHoraAntes
$V_{h-1hora}$	Velocidade do vento média 1 hora antes. Nome no banco de dados: AGORA_VentoMediaUmaHoraAntes
$V_{h-1hora30min}$	Velocidade do vento média 1 ½ hora antes. Nome no banco de dados: AGORA_VentoMediaUmaHoraeMeiaAntes
$V_h - V_{h-30min}$	Diferença entre a Velocidade do vento média na hora atual e a Velocidade do vento média ½ hora antes. Nome no banco de dados: AGORA_DerivadaVentoAtual
$V_{h-30min} - V_{h-1hora}$	Diferença entre a Velocidade do vento média ½ hora antes e a Velocidade do vento média 1 hora antes. Nome no banco de dados: AGORA_DerivadaVentoMeiaHoraAntes
$(V_h - V_{h-30min}) - (V_{h-30min} - V_{h-1hora})$	Diferença entre (a) diferença entre a Velocidade do vento média na hora atual e a Velocidade do vento média ½ hora antes (b) diferença entre a Velocidade do vento média ½ hora antes e a Velocidade do vento média 1 hora antes. Nome no banco de dados: AGORA_Derivada2VentoAtual
$(V_{h-30min} - V_{h-1hora}) - (V_{h-1hora} - V_{h-1hora30min})$	Diferença entre (a) diferença entre a Velocidade do vento média ½ hora antes e a Velocidade do vento média 1 hora antes e (b) diferença entre a Velocidade do vento média 1 hora antes e a Velocidade do vento média 1½ horas antes. Nome no banco de dados: AGORA_Derivada2VentoMeiaHoraAntes
$V_{minAgora}$	Velocidade do vento mínima do dia. Nome no banco de dados: AGORA_VentoMinimaDia
$V_{medAgora}$	Velocidade do vento média do dia. Nome no banco de dados: AGORA_VentoMediaDia
$V_{maxAgora}$	Velocidade do vento máxima do dia. Nome no banco de dados: AGORA_VentoMaximaDia
V_{dsen}	Direção do vento na hora atual, como função trigonométrica (seno). Nome no banco de dados: AGORA_VentoDSenMediaAtual
V_{dcos}	Direção do vento na hora atual, como função trigonométrica (cosseno). Nome no banco de dados: AGORA_VentoDCosMediaAtual
$V_{h-168horas}$	Velocidade do vento média na hora atual 1 semana antes, 1 semana antes. Nome no banco de dados: SEMANA_VentoMediaAtual
$R_{h-168horas30min}$	Velocidade do vento média ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_VentoMediaMeiaHoraAntes

$V_{h-169\text{horas}}$	Velocidade do vento média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_VentoMediaUmaHoraAntes
$R_{h-169\text{horas}30\text{min}}$	Velocidade do vento média 1 ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_VentoMediaUmaHoraMeiaAntes
$V_{h-168\text{horas}} - V_{h-168\text{horas}30\text{min}}$	Diferença entre e a Velocidade do vento média na hora atual, 1 semana antes e a Velocidade do vento média ½ hora antes, 1 semana antes. Nome no banco de dados: SEMANA_DerivadaVentoAtual
$V_{h-168\text{horas}30\text{min}} - V_{h-169\text{horas}}$	Diferença entre a Velocidade do vento média ½ hora antes, 1 semana antes e a Velocidade do vento média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_DerivadaVentoMeiaHoraAntes
$(V_{h-168\text{horas}} - V_{h-168\text{horas}30\text{min}}) - (V_{h-168\text{horas}30\text{min}} - V_{h-169\text{horas}})$	Diferença entre (a) diferença entre a Velocidade do vento média na hora atual, 1 semana antes e a Velocidade do vento média ½ hora antes, 1 semana antes (b) diferença entre a Velocidade do vento média ½ hora antes, 1 semana antes e a Velocidade do vento média 1 hora antes, 1 semana antes. Nome no banco de dados: SEMANA_Derivada2VentoAtual
$(V_{h-168\text{horas}30\text{min}} - V_{h-169\text{horas}}) - (V_{h-169\text{horas}} - V_{h-169\text{horas}30\text{min}})$	Diferença entre (a) diferença entre a Velocidade do vento média ½ hora antes, 1 semana antes e a Velocidade do vento média 1 hora antes, 1 semana antes e (b) diferença entre a Velocidade do vento média 1 hora antes, 1 semana antes e a Velocidade do vento média 1½ horas antes, 1 semana antes. Nome no banco de dados: SEMANA_Derivada2VentoMeiaHoraAntes
$V_{\text{minSemana}}$	Velocidade do vento mínima do dia, 1 semana antes. Nome no banco de dados: SEMANA_VentoMinimaDia
$V_{\text{medSemana}}$	Velocidade do vento média do dia, 1 semana antes. Nome no banco de dados: SEMANA_VentoMediaDia
$V_{\text{maxSemana}}$	Velocidade do vento máxima do dia, 1 semana antes. Nome no banco de dados: SEMANA_VentoMaximaDia
$V_{\text{dsenSemana}}$	Direção do vento na hora atual, 1 semana antes, como função trigonométrica (seno). Nome no banco de dados: SEMANA_VentoDSenMediaAtual
$V_{\text{dcosSemana}}$	Direção do vento na hora atual, 1 semana antes, como função trigonométrica (cosseno). Nome no banco de dados: SEMANA_VentoDCosMediaAtual
$V_{h-52\text{semanas}}$	Velocidade do vento média na hora atual, 52 semanas antes. Nome no banco de dados: ANO_VentoMediaAtual
$V_{h-52\text{semanas}30\text{min}}$	Velocidade do vento média ½ hora antes, 52 semanas antes. Nome no banco de dados: ANO_VentoMediaMeiaHoraAntes
$V_{h-52\text{semanas}1\text{hora}}$	Velocidade do vento média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_VentoMediaUmaHoraAntes
$V_{h-52\text{semanas}1\text{hora}30\text{min}}$	Velocidade do vento média 1 ½ hora antes, 52 semanas antes. Nome no banco de dados: ANO_VentoMediaUmaHoraMeiaAntes

$V_{h-52semanas} - V_{h-52semanas30min}$	Diferença entre a Velocidade do vento média na hora atual, 52 semanas antes e a Velocidade do vento média ½ hora antes, 52 semanas. Nome no banco de dados: ANO_DerivadaVentoAtual
$V_{h-52semanas30min} - V_{h-52semanas1hora}$	Diferença entre a Velocidade do vento média ½ hora antes, 52 semanas antes e a Velocidade do vento média 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_DerivadaVentoMeiaHoraAntes
$(V_{h-52semanas} - V_{h-52semanas30min}) - (V_{h-52semanas30min} - V_{h-52semanas1hora})$	Diferença entre (a) diferença entre a Velocidade do vento média na hora atual, 52 semanas antes e a Velocidade do vento média ½ hora antes, 52 semanas antes (b) diferença entre a Velocidade do vento média ½ hora antes, 52 semanas antes e a Velocidade do vento 1 hora antes, 52 semanas antes. Nome no banco de dados: ANO_Derivada2VentoAtual
$(V_{h-52semanas30min} - V_{h-52semanas1hora}) - (V_{h-52semanas1hora} - V_{h-52semanas1hora30min})$	Diferença entre (a) diferença entre a Velocidade do vento média ½ hora antes, 52 semanas antes e a Velocidade do vento média 1 hora antes, 52 semanas antes e (b) diferença entre a Velocidade do vento média 1 hora antes, 52 semanas antes e a Velocidade do vento média 1½ horas antes, 52 semanas antes. Nome no banco de dados: ANO_Derivada2VentoMeiaHoraAntes
V_{minAno}	Velocidade do vento mínima do dia, 52 semanas antes. Nome no banco de dados: ANO_VentoMinimaDia
V_{medAno}	Velocidade do vento média do dia, 52 semanas antes. Nome no banco de dados: ANO_VentoMediaDia
V_{maxAno}	Velocidade do vento máxima do dia, 52 semanas antes. Nome no banco de dados: ANO_VentoMaximaDia
$V_{dsenAno}$	Direção do vento na hora atual, 52 semanas antes, como função trigonométrica (seno). Nome no banco de dados: ANO_VentoDSenMediaAtual
$V_{dcosAno}$	Direção do vento na hora atual, 52 semanas antes, como função trigonométrica (cosseno). Nome no banco de dados: ANO_VentoDCosMediaAtual

8.2 O Clima no Estado de Santa Catarina

Este anexo apresenta uma visão geral do clima no Estado de Santa Catarina. No Estado de Santa Catarina, o Centro Integrado de Meteorologia e Recursos Hídricos de Santa Catarina – CLIMERH, é o órgão estadual oficialmente encarregado de efetuar medições, estudos e previsões acerca do clima no Estado. As informações apresentadas são uma síntese da caracterização climática do Estado, realizada por este órgão e apresentada em (CLIMERH, 2002).

O clima de uma determinada região é formado pela interação entre os continentes, oceanos e a quantidade de radiação solar recebida. O movimento de translação da Terra faz com que a quantidade de energia recebida na região varie ao longo do ano, criando um ciclo sazonal responsável pelas estações de verão, outono, inverno e primavera.

A localização geográfica do Estado de Santa Catarina torna a variação sazonal do clima bastante definida. No verão, a quantidade de radiação solar global recebida alcança 502 cal/cm² e no inverno fica em torno de 215 cal/cm². No inverno, é muito maior a frequência de inserção de frentes frias e massas de ar frio que contrastam com as altas temperaturas de verão, geradas pela permanência da massa de ar tropical. As estações de transição, outono e primavera, mesclam características das duas outras estações.

Além da variação climática relacionada à sazonalidade, há a variação climática decorrente da orografia de Santa Catarina e da proximidade do mar, os grandes responsáveis pelas diferenças de clima existentes entre as diversas localidades do Estado. A planície litorânea do Estado tem altitudes variando de 0 a 300m. Já no Planalto Serrano e Meio Oeste, elas passam a variar entre 800 e 1500m. Seguindo em direção oeste, as altitudes vão ficando menores, até atingirem, no Extremo Oeste, cerca de 200m. Toda essa variação de altitudes e distanciamento do mar faz com que o clima varie bruscamente entre uma região e outra. As temperaturas, por exemplo, podem variar mais de 10°C entre os Planaltos e o Litoral. Além disto, o clima de uma determinada região nem sempre é igual de um ano para o outro, pois também sofre a influência de fatores de grande escala, a exemplo dos fenômenos El Niño e La Nina que quando ocorrem, alteram

significativamente o clima típico no Estado.

O El Niño - La Niña é um fenômeno de interação atmosfera-oceano, associado a alteração dos padrões normais da Temperatura da Superfície do Mar (TSM) e dos ventos alísios na região do Pacífico Equatorial, entre a Costa Peruana e a Austrália. A fase positiva do fenômeno é denominada de El Niño. Está associada ao enfraquecimento dos ventos alísios e caracteriza-se pelo aquecimento das águas superficiais do Pacífico Tropical. A fase negativa do fenômeno é denominada de La Niña. Está associada ao aumento na intensidade dos ventos alísios e resfriamento das águas superficiais do Pacífico Tropical.

Para o Estado de Santa Catarina, o El Niño traz como consequência um aumento da precipitação (chuva), principalmente na primavera do ano em que se inicia e no outono-inverno do ano seguinte, principalmente nas áreas próximas ao oceano. Também, nos invernos de anos de El Niño as temperaturas médias são maiores que a média típica para o inverno. O La Niña caracteriza-se por passagens rápidas de frentes frias na região, com tendência de diminuição da precipitação, principalmente nos meses de junho a dezembro. A Tabela 16 apresenta os períodos de ocorrência do fenômeno no último século

Em janeiro, as frentes frias são muito pouco frequentes em Santa Catarina. Com isso, a massa de ar de origem tropical passa a predominar sobre o Estado. Essa massa de ar tropical é a grande responsável pelas temperaturas elevadas observadas nesse período. A série histórica de dados de SC registra temperaturas máximas médias mensais de janeiro oscilando entre 23,1°C (São Joaquim) e 32,7°C (Itapiranga). Na maior parte do Estado, os totais de chuvas, neste mês, são os mais elevados de todo ano. Apesar das chuvas concentrarem-se nos finais dos dias, apresentam volumes bastante elevados em curtos períodos de tempo. Essas chuvas, típicas de verão, normalmente são acompanhadas de rajadas de vento, trovoadas, descargas elétricas e, por vezes, granizo. As chuvas mais intensas ocorrem principalmente no litoral desde a Grande Florianópolis até o norte do Estado. Os menores índices pluviométricos do Estado são observados nos municípios localizados na costa sul de Santa Catarina.

Com um alto índice pluviométrico, fevereiro é um dos meses de maior precipitação na maior parte dos municípios catarinenses. Quase toda a precipitação é resultante da convecção, ou seja, está associada à pancadas de chuva provocadas pelo aquecimento

diurno.

Tabela 16 - Períodos de Ocorrência de El Niño e La Niña (NCEP/NOAA, in CLIMERH, 2002)

El Niño	La Niña
1900 - 1901	1903 - 1904
1902 - 1903	1906 - 1907
1905 - 1906	1908 - 1909
1911 - 1912	1916 - 1917
1914 - 1915	1920 - 1921
1918 - 1919	1924 - 1925
1923 - 1924	1928 - 1929
1925 - 1926	1931 - 1932
1930 - 1931	1938 - 1939
1932 - 1933	1942 - 1943
1939 - 1940	1949 - 1950
1940 - 1941	1954 - 1955
1941 - 1942	1964 - 1965
1946 - 1947	1970 - 1971
1951 - 1952	1973 - 1974
1953 - 1954	1975 - 1976
1957 - 1958	1988 - 1989
1963 - 1964	1985 - 1986
1965 - 1966	
1969 - 1970	
1972 - 1973	
1976 - 1977	
1977 - 1978	
1982 - 1983	
1986 - 1987	
1991 - 1992	
1993 - 1994	
1997 - ?	

Em geral, no mês de fevereiro, as temperaturas máximas variam de 28°C a 30°C no planalto e de 30°C a 34°C em áreas mais baixas, como o litoral, podendo chegar a 40°C em algumas regiões do Estado. As mínimas variam de 18°C a 23°C nas áreas de menor altitude

e, no planalto, de 14°C a 17°C.

Durante o mês de março, em Santa Catarina, normalmente há diminuição nas temperaturas em relação aos meses de verão. Normalmente na segunda quinzena são observadas as primeiras incursões de massas polares. As massas de ar frio são ainda fracas nesse período, mas podem provocar queda de temperatura brusca no Estado e ocasionarem geadas fracas nas áreas serranas. O volume de precipitação diminui na maioria dos municípios catarinenses, principalmente na segunda quinzena de março. Nesse mês, a área de maior precipitação do Estado é o Litoral, com índices médios próximos de 160mm, enquanto os índices mais baixos são registrados no Planalto Sul e Alto Vale.

O mês de abril caracteriza-se pela transição entre as estações de verão e inverno, geralmente alternando períodos de temperaturas baixas com períodos de temperaturas um pouco mais altas. Neste mês, as massas de ar frio e seco começam a avançar sobre o Estado favorecendo a ocorrência de temperaturas negativas. Há a ocorrência de dias com pouca nebulosidade, predomínio de sol e baixos índices pluviométricos. Neste mês, também, é comum a ocorrência de bloqueios atmosféricos, que impedem o avanço das frentes frias e permite o domínio da massa de ar tropical, o que favorece os dias de sol e temperaturas altas no Estado, caracterizando o conhecido "veranico". Observa-se também uma frequência maior de ventos de forte intensidade.

O mês de maio, assim como o de abril, caracteriza-se pela transição entre as estações de verão e inverno. Neste mês, com o enfraquecimento da fonte de calor gerada pelo sol devido ao deslocamento do sol em direção ao Hemisfério Norte, as massas de ar frio penetram com maior frequência e intensidade no Estado de Santa Catarina, o que torna a média de temperatura mais baixa do que em abril. Este mês geralmente também alterna períodos de temperaturas baixas com dias de temperaturas um pouco mais altas. Também, observa-se em maio uma frequência maior de ventos de forte intensidade. A ocorrência destes eventos também causa forte agitação marítima e marés meteorológicas altas, fenômenos responsáveis pelas ressacas.

O mês de junho caracteriza-se pela entrada das massas de ar polar no Sul do Brasil, provenientes do continente antártico. O ar frio é trazido pela aproximação de anticiclones que se deslocam sobre a Argentina em direção à região. Quando instalados sobre Santa Catarina, esses sistemas ocasionam dias de céu claro e acentuado declínio de temperatura

no Estado, o que favorece a formação de geada e nevoeiro, fenômenos típicos da estação.

O mês de julho é o mais significativo do inverno, apresentando registros de temperaturas mais baixas, geadas, nevoeiros e ocorrência de neve. Neste mês ocorrem dias de céu claro e acentuado declínio de temperatura durante as noites, favorecendo a formação de geadas e nevoeiros.

O mês de agosto caracteriza-se por sucessivas incursões de frentes frias, acompanhadas de fortes massas de ar frio. Neste mês são registradas temperaturas muito baixas, geadas, nevoeiros e por vezes ocorrência de neve, que normalmente ficam restritas no Planalto Sul catarinense. As áreas mais frias do Estado são as do Meio Oeste e do Planalto. A menor temperatura já registrada no Estado ocorreu em Canoinhas, onde os termômetros, neste mês, marcaram 12°C negativos no ano de 1963. Já a faixa litorânea apresenta temperaturas amenas que dificilmente baixam dos 10°C. Neste mês, as chuvas são bem distribuídas em todo o Estado com volumes que variam entre 100 e 200mm.

O mês de setembro caracteriza-se pelo início da transição entre o verão e o inverno. As temperaturas começam a elevar-se, porém nos municípios do Planalto e do Meio-Oeste ainda podem ser registradas temperaturas mínimas inferiores a 0°C provocando geadas. As áreas de chuva e trovoadas típicas da primavera que se formam nas proximidades do Paraguai, apresentam um deslocamento rápido para Santa Catarina provocando um aumento nos índices pluviométricos do Estado. Também há um aumento na intensidade dos ventos e são observadas constantes rajadas de ventos.

Outubro é outro mês que se caracteriza pela transição entre o inverno e o verão. Diminui a frequência da entrada das massas polares no Estado e aumenta a temperatura média mensal. Apesar disso, nos municípios do Planalto e do Meio-Oeste ainda podem ser registradas temperaturas mínimas próximas a 0°C provocando geadas. As áreas de chuva e trovoadas típicas da primavera e se formam nas proximidades do Paraguai, apresentam um deslocamento rápido para Santa Catarina. Esses sistemas provocam altos índices pluviométricos do Estado e atingem especialmente o oeste catarinense com chuvas intensas e precipitação de granizo. Da mesma forma que no mês de setembro, há um aumento nos índices pluviométricos e na intensidade dos ventos, bem como são observadas constantes rajadas de ventos.

Em novembro observam-se os menores índices pluviométricos do ano em grande parte dos municípios catarinenses. A precipitação concentra-se na primeira quinzena, associada às incursões de frentes frias. Na segunda quinzena, a massa de ar tropical é que vai influenciar as condições de tempo no Estado. O volume de chuva diminui consideravelmente nesse período, pois a massa tropical encontra-se ainda com baixa umidade. Novembro é o mês que apresenta as temperaturas mais elevadas da primavera. É comum, nesta época do ano, a ocorrência de temperaturas máximas em torno de 30°C, principalmente no Oeste. Ainda pode ocorrer formação de geada fraca na serra.

Dezembro é um mês marcado por temperaturas elevadas. As séries históricas de dados de SC registram temperaturas médias mensais máximas de dezembro oscilando entre 22.3°C (São Joaquim) e 32.5°C (Itapiranga). Na segunda quinzena do mês são registrados, em geral, totais de precipitação superiores aos observados na primeira quinzena. A região de São Miguel D'Oeste apresenta a maior média mensal de precipitação em dezembro e os municípios localizados na costa sul de Santa Catarina, de Araranguá a Laguna, os menores índices pluviométricos do mês.

As figuras a seguir apresentam a precipitação típica de Santa Catarina para cada um dos meses do ano.

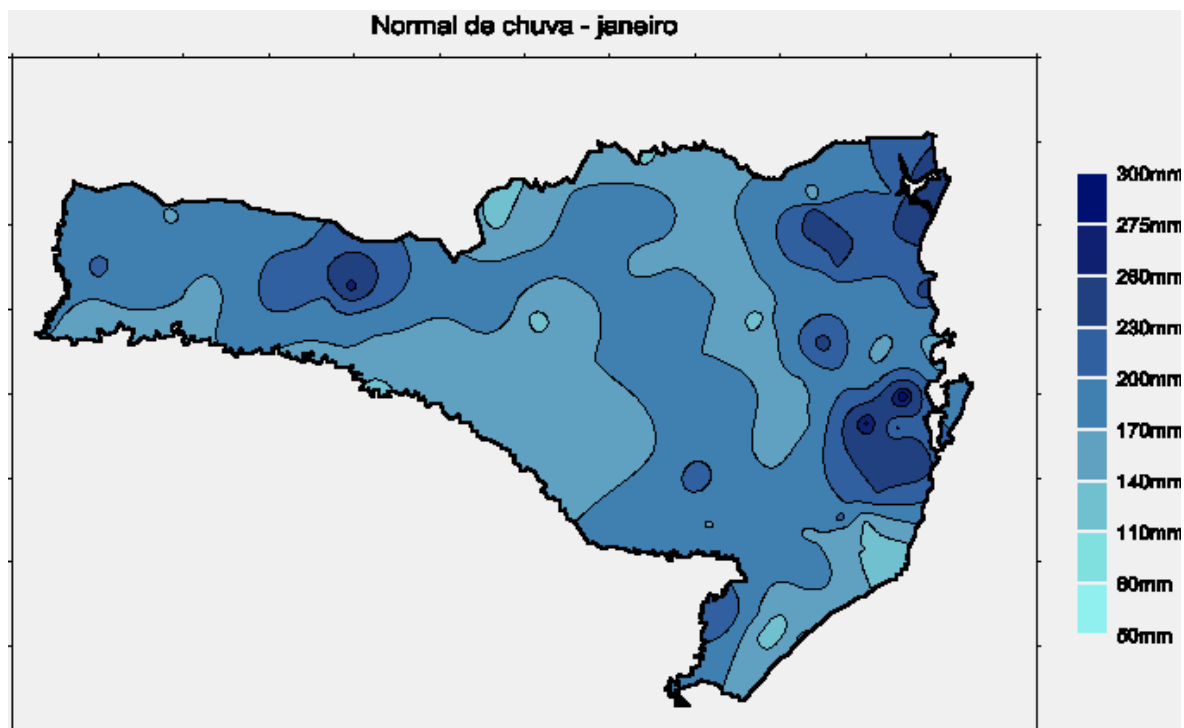


Figura 20 - Precipitação típica em Santa Catarina – Janeiro (in, CLIMERH,2002)

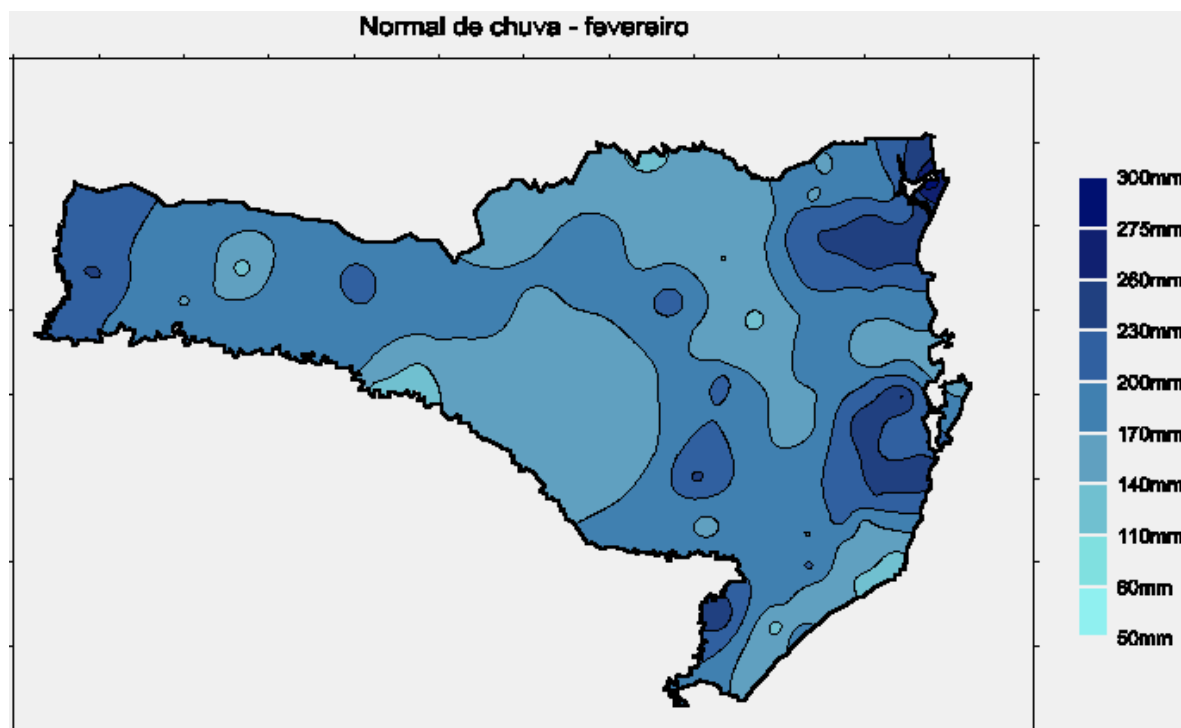


Figura 21 - Precipitação típica em Santa Catarina – Fevereiro (in, CLIMERH,2002)

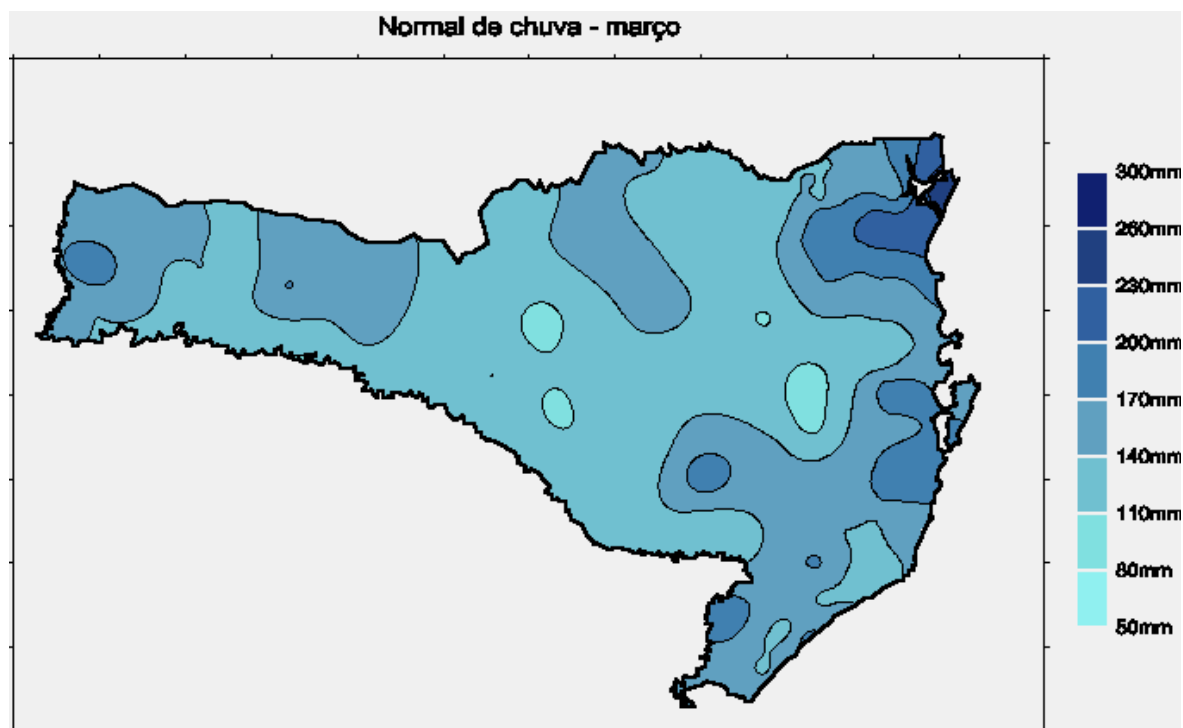


Figura 22 - Precipitação típica em Santa Catarina – Março (in, CLIMERH,2002)

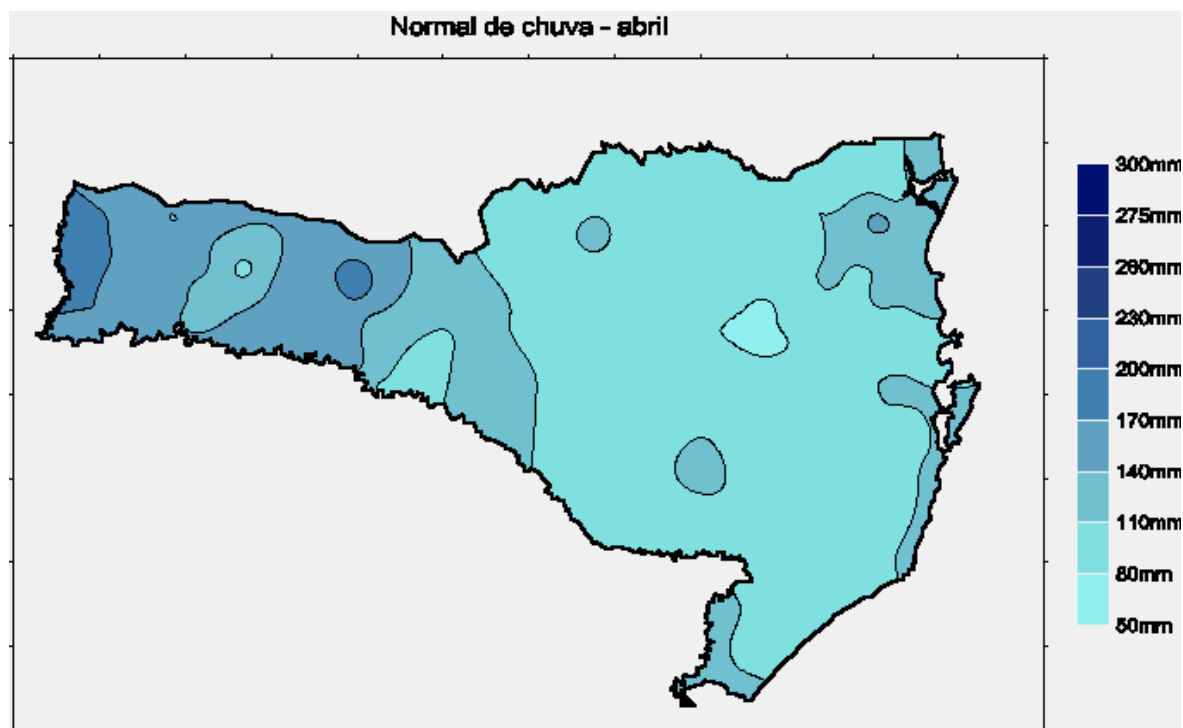


Figura 23 - Precipitação típica em Santa Catarina – Abril (in, CLIMERH,2002)

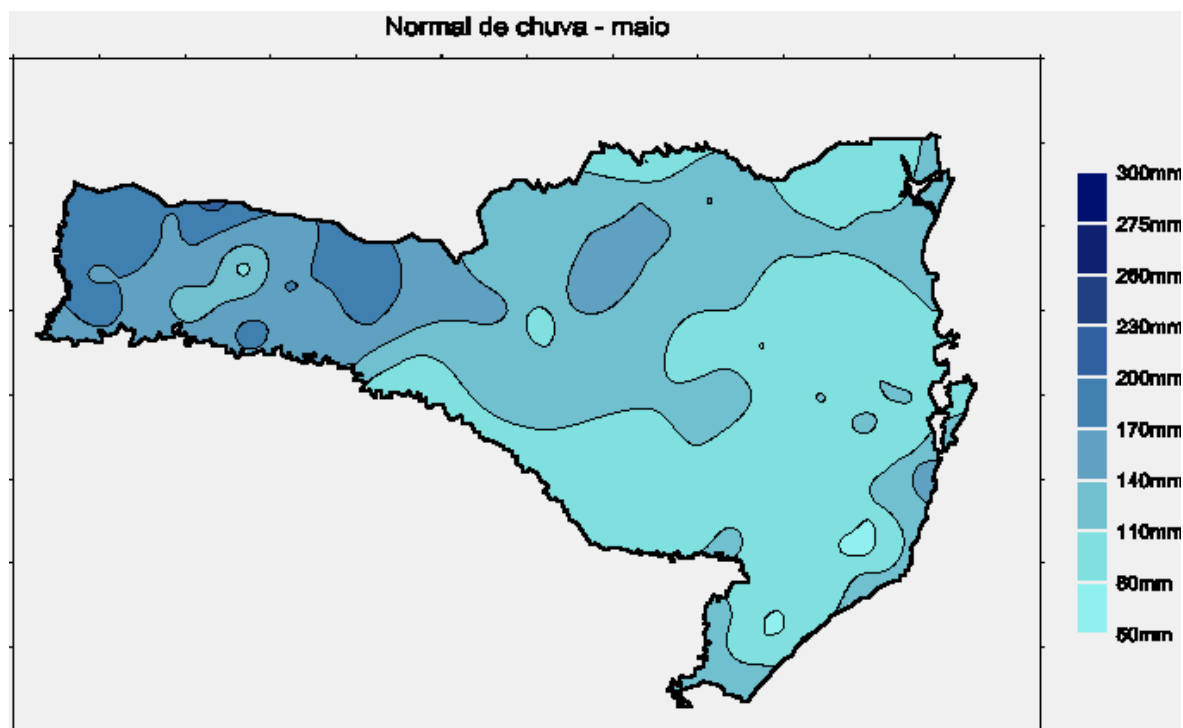


Figura 24 - Precipitação típica em Santa Catarina – Maio (in, CLIMERH,2002)

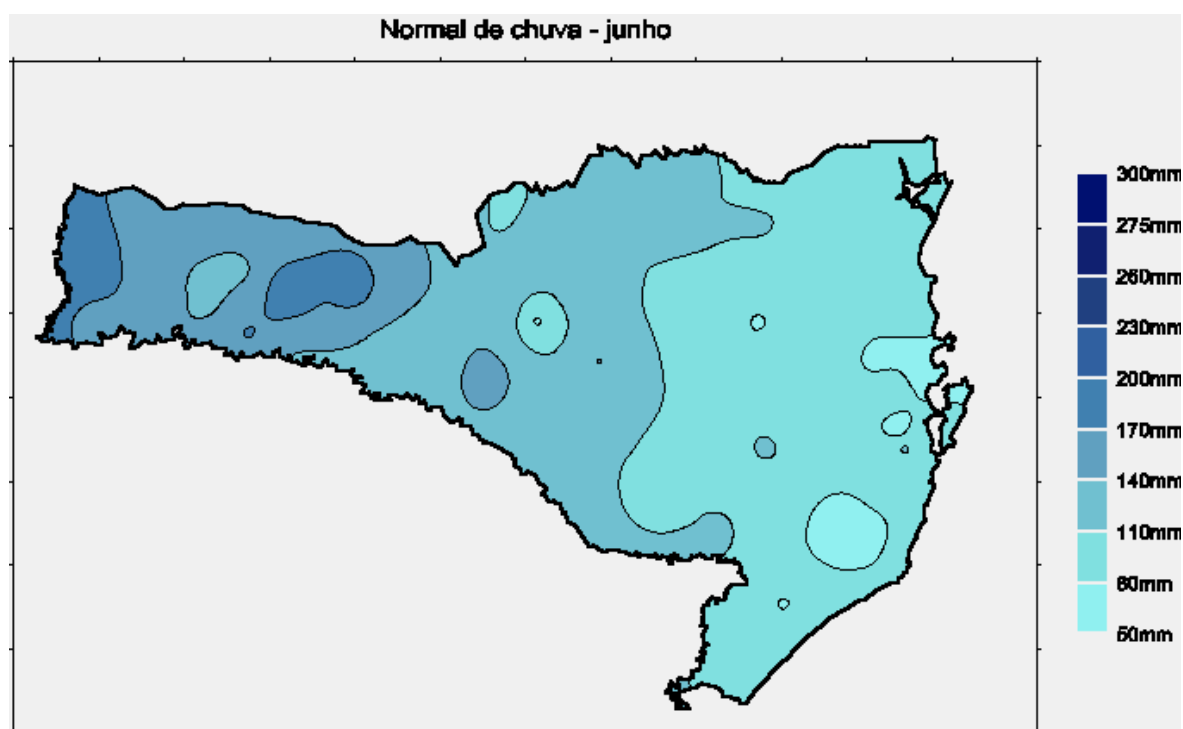


Figura 25 - Precipitação típica em Santa Catarina – Junho (in, CLIMERH,2002)

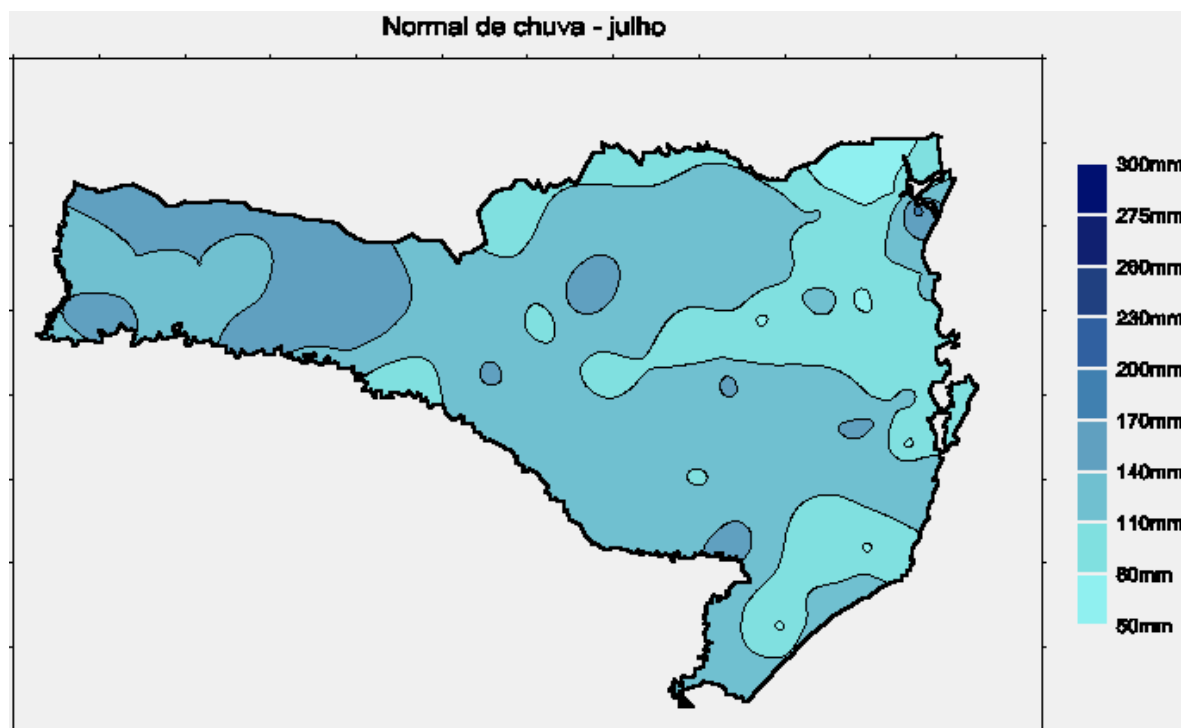


Figura 26 - Precipitação típica em Santa Catarina – Julho (in, CLIMERH,2002)

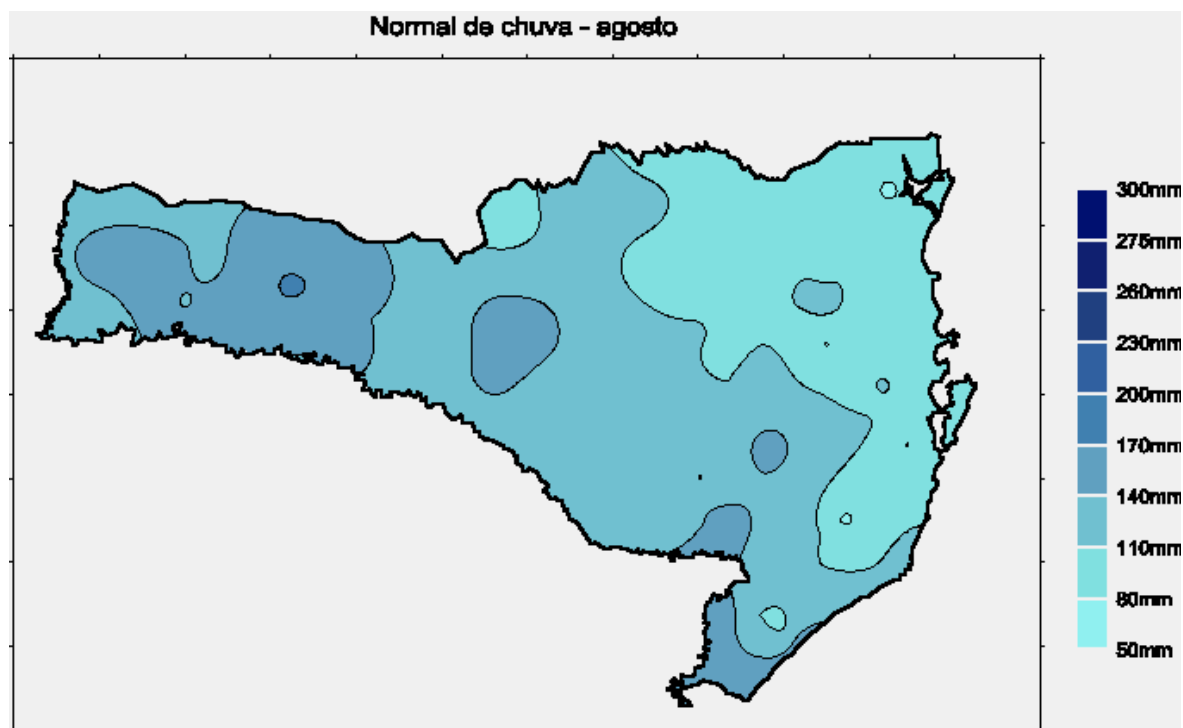


Figura 27 - Precipitação típica em Santa Catarina – Agosto (in, CLIMERH,2002)

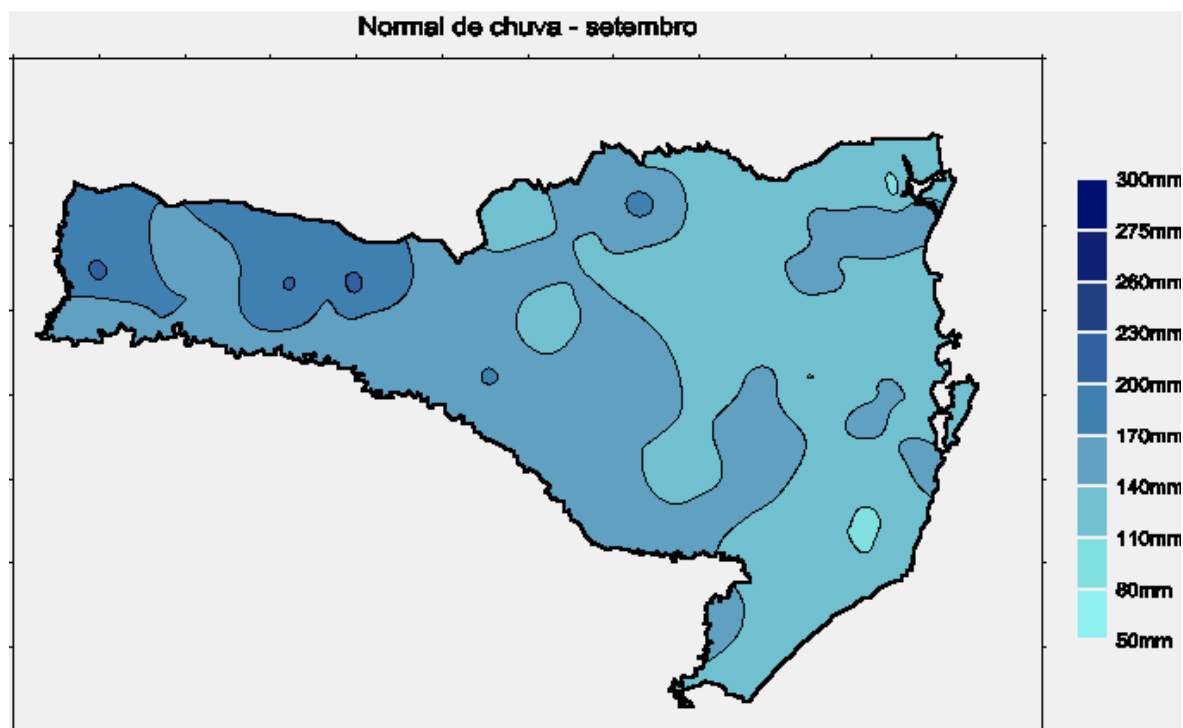


Figura 28 - Precipitação típica em Santa Catarina – Setembro (in, CLIMERH,2002)

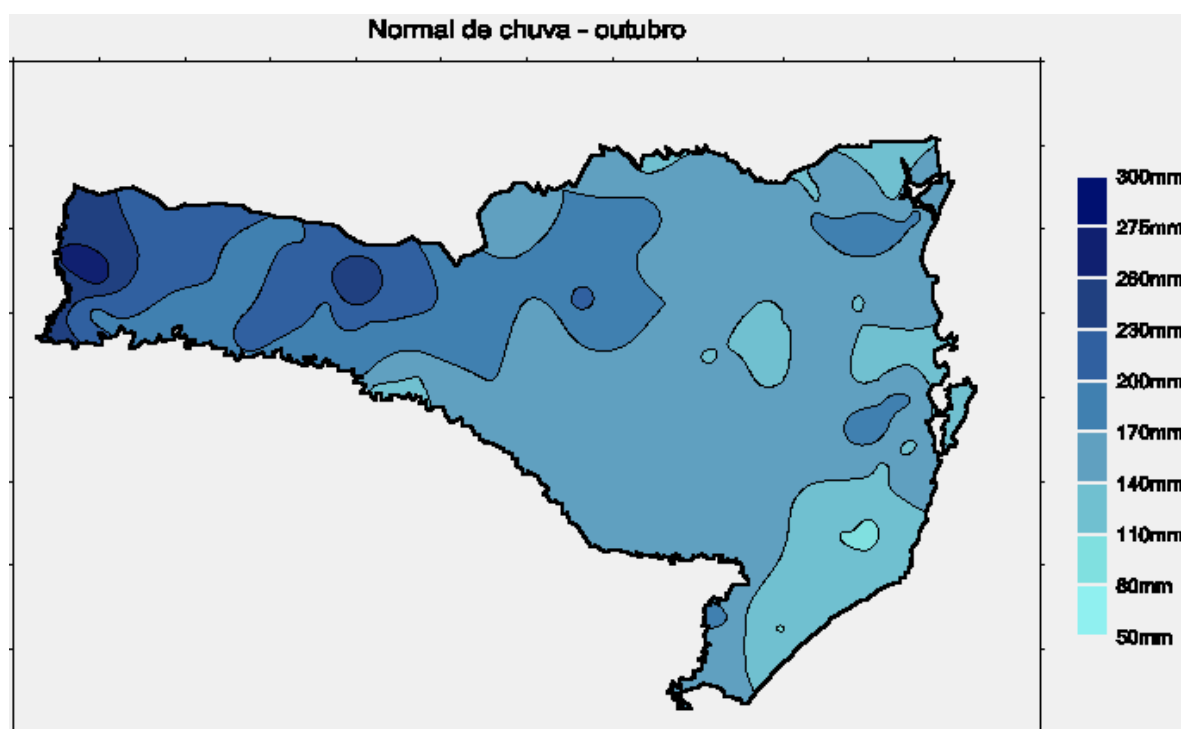


Figura 29 - Precipitação típica em Santa Catarina – Outubro (in, CLIMERH,2002)

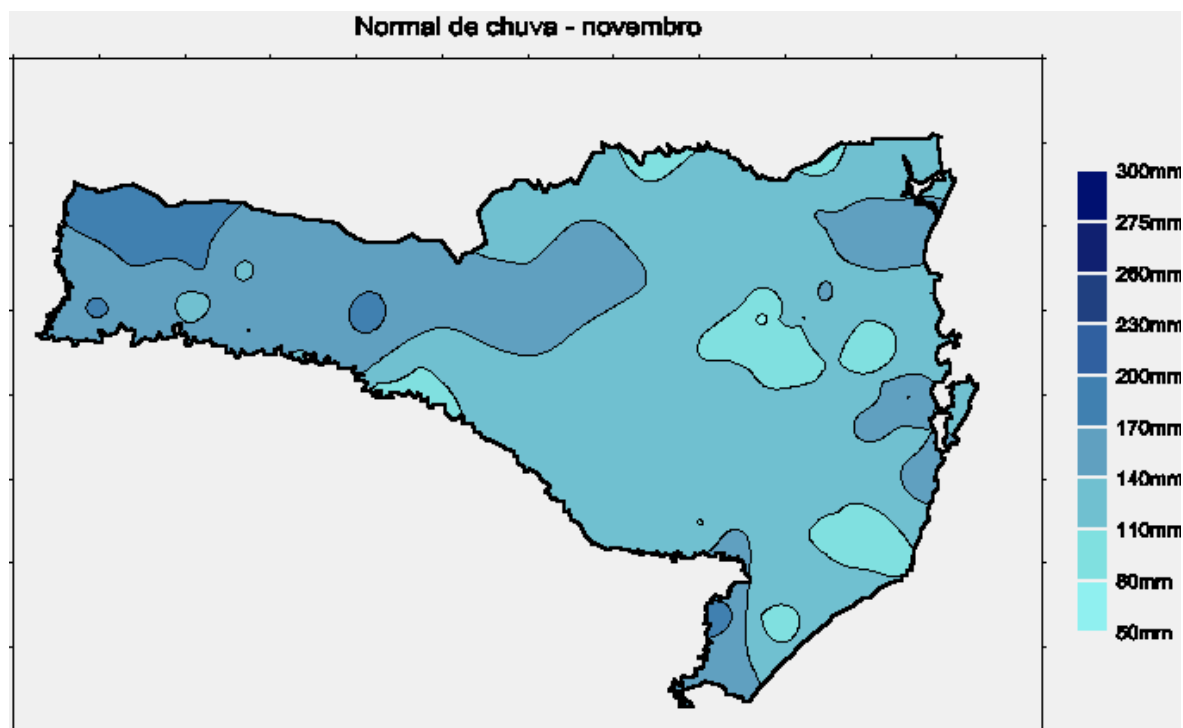


Figura 30 - - Precipitação típica em Santa Catarina – Novembro (in, CLIMERH,2002)

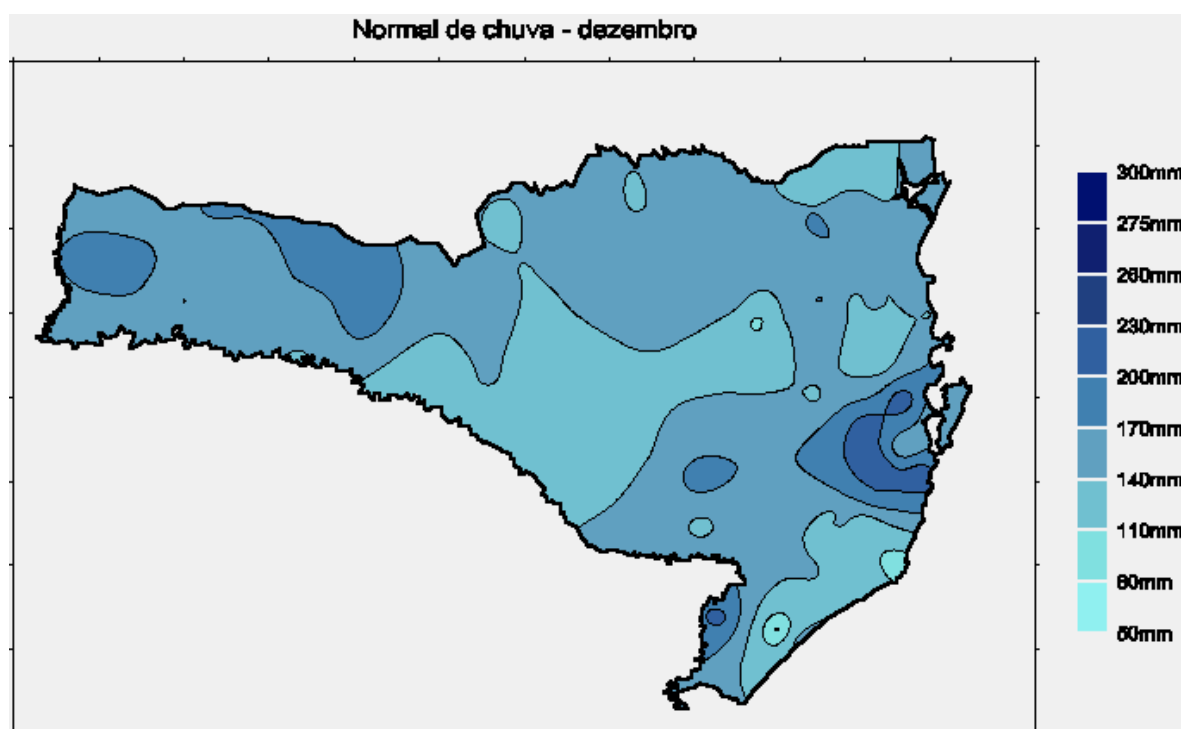


Figura 31 - Precipitação típica em Santa Catarina – Dezembro (in, CLIMERH,2002)

8.3 Visão geral da CELESC

Este anexo apresenta uma série de informações relativas à CELESC, extraídas de CELESC (2003), e tem como objetivo proporcionar uma visão geral da empresa. Segundo o procedimento padrão da ANEEL – Agência Nacional de Energia Elétrica para classificação de concessionárias de energia elétrica vigente, a CELESC é uma empresa distribuidora de energia elétrica. Porém, as informações fornecidas a seguir apresentam a CELESC como empresa de transmissão e também de distribuição de energia elétrica. Tal classificação, embora correta à pouco tempo atrás, está desatualizada. Mesmo assim, a apresentação das informações seguiu tal padrão para que fosse mantida a coerência com o documento original da qual foram extraídas e porque tal alteração não é relevante para o contexto deste trabalho. A Figura 32 apresenta a área de concessão da CELESC e a Tabela 17 os indicadores globais acerca da empresa. As Tabela 18 e Tabela 19 apresentam, respectivamente, as redes de energia de tensão mais elevada (linhas de transmissão) e de tensão inferior (redes de distribuição) da CELESC. Na Tabela 18, os comprimentos elétrico e físico representam, respectivamente, o comprimento da rede elétrica poste a poste e a distância física (em linha reta) entre as subestações. A Tabela 20, as subestações e as Tabela 21 e Tabela 22 os Transformadores de Transmissão (Transformadores de Subestação) da empresa.

A linha de transmissão é o componente do sistema elétrico responsável em transmitir a energia elétrica de uma usina geradora ou de um ponto de interligação com a supridora até as subestações. Essas linhas, no sistema CELESC, normalmente operam em dois níveis de tensão: 138.000Volt e 69.000Volt. A subestação é a responsável em receber a energia elétrica transmitida pelas linhas de transmissão em um nível de tensão chamado Alta Tensão (normalmente na CELESC entre 230.000 e 69.000Volt) e distribuir para as redes de distribuição em um nível mais baixo, chamado de Baixa Tensão (normalmente abaixo de 69.000Volt). As redes de distribuição transmitem a energia elétrica nas cidades e no campo. É através destas redes que a eletricidade chega até os clientes. Os transformadores de transmissão são os responsáveis pela interligação entre as linhas de transmissão e as redes de distribuição, transformando a alta tensão em baixa tensão, e os transformadores de distribuição em reduzir ainda mais o valor na baixa tensão, para

valores de até 220Volt, dentro das redes de distribuição. A capacidade de transferência de energia de um lado para o outro é determinada pela sua potência.

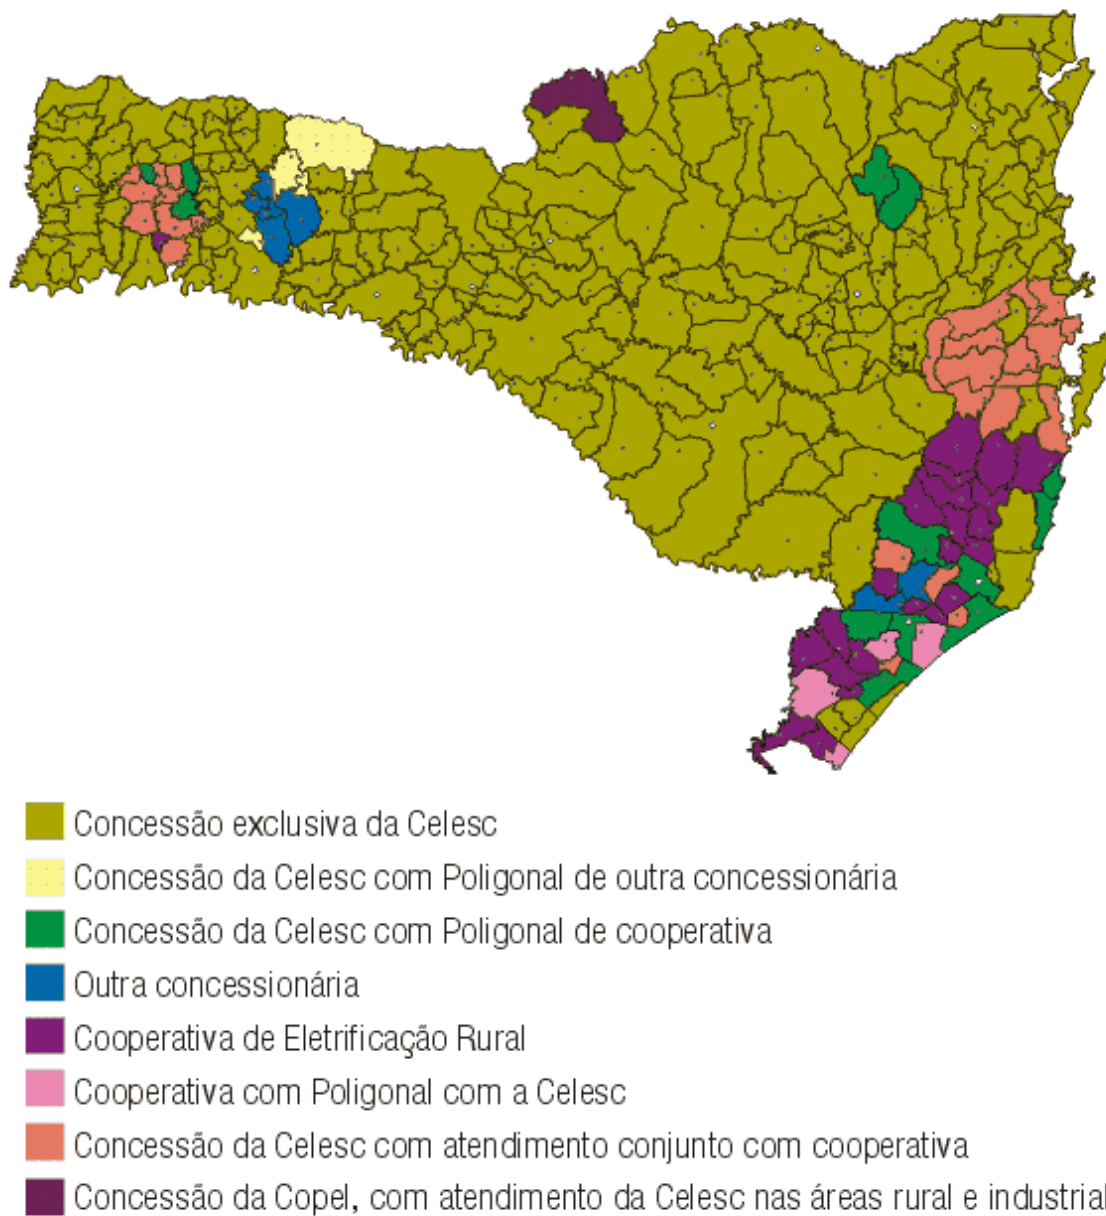


Figura 32 – Área de Concessão da CELESC ([12] CELESC, 2003)

Tabela 17 – CELESC em Números ([12] CELESC, 2003)

CELESC em Números	
Área de concessão	91,79% da área do Estado de SC
Número de clientes	1.804.503
Número de empregados	4.240
Número de usinas	12
Capacidade instalada nas usinas	80,60 MW
Número de subestações de transmissão	94
Número de subestações de distribuição	22
Subestações telecontroladas	55
Capacidade de transformação	3.955MVA
Número de postes	1.230.250
Extensão de redes de transmissão	3.755km
Extensão de redes de distribuição	89.000km
Número de transformadores de distribuição	111.837

Dados de julho de 2002

Tabela 18 – Linhas de Transmissão ([12] CELESC, 2003)

COMPRIMENTO DE LINHAS DE TRANSMISSÃO			
TIPO	COMPRIMENTO	TENSÃO (V)	DISTÂNCIA (km)
	ELÉTRICO	138.000	2368,30
	FÍSICO	138.000	1459,80
	ELÉTRICO	69.000	1348,00
	FÍSICO	69.000	1142,20
	ELÉTRICO	34.500	36,00
	FÍSICO	34.500	18,00
	ELÉTRICO	23.000	2,00
	FÍSICO	23.000	2,00
	ELÉTRICO	TOTAL	3754,30
	FÍSICO	TOTAL	2622,00

Dados de 14/04/2003

Tabela 19 – Redes de Distribuição ([12] CELESC, 2003)

REDES DE DISTRIBUIÇÃO	
Km DE REDE	NÚMERO DE POSTES
85.328	1.200.300

Dados de Fevereiro de 2001

Tabela 20 - Subestações ([12] CELESC, 2003)

SUBESTAÇÕES	
TIPO	QUANTIDADE
SUBESTAÇÕES DE TRANSMISSÃO DA CELESC	93
SUBESTAÇÕES PARTICULARES (>=69kV)	32
SUBESTAÇÕES DE USINAS DA CELESC	12

Dados de 14/04/2003

Tabela 21 – Transformadores de Subestação ([12] CELESC, 2003)

TRANSFORMADORES DE SUBESTAÇÃO		
TENSÃO (kV)	POTÊNCIA (MVA)	QUANTIDADE
138/69	631,22	16
138/69/23	66,67	1
138/69/13,8	200,01	3
138/34,5/13,8	26,67	1
138/34,5	80,01	3
138/23	800,46	32
138/13,8	823,41	31
69/34,5	20,00	1
69/23	604,34	48
69/13,8	783,00	59
34,5/13,8	9,38	1
34,5/23	9,38	1
TOTAL	4054,55	197

Tabela 22 - Transformadores de Subestação por Região ([12] CELESC, 2003)

TRANSFORMADORES DE SUBESTAÇÃO POR REGIÃO		
REGIÃO	POTÊNCIA	QUANTIDADE
FLORIANÓPOLIS	495,66	19
NORTE	772,48	33
VALE DO ITAJAÍ	1173,28	49
PLANALTO	233,31	12
MEIO OESTE	328,37	16
EXTREMO OESTE	533,17	30
SUL	210,13	14
EXTREMO SUL	288,15	24
TOTAL	4034,55	197

Dados de 14/04/2003

Na CELESC, o SCADA recebe o nome de SDSC - Sistema Digital de Supervisão e Controle. O SDSC divide operacionalmente a CELESC em 3 áreas: Área Sudeste, Área Norte e Área Oeste. A Área Sudeste compreende as regiões Florianópolis, Sul e Extremo Sul. É controlada pelo COA-S (Centro de Operação de Área – Sudeste), localizado em Florianópolis, junto ao COS (Centro de Operação do Sistema), no edifício sede da empresa. A Área Norte compreende as regiões Norte e Vale do Itajaí. É controlada pelo COA-N (Centro de Operação de Área – Norte), localizado em Blumenau. Por fim, a Área Oeste compreende as regiões Planalto, Meio-Oeste e Extremo Oeste. É controlada pelo COA-O (Centro de Operação de Área – Oeste), localizado em Chapecó. A Figura 33 apresenta a distribuição e abrangência das áreas operacionais do SDSC.

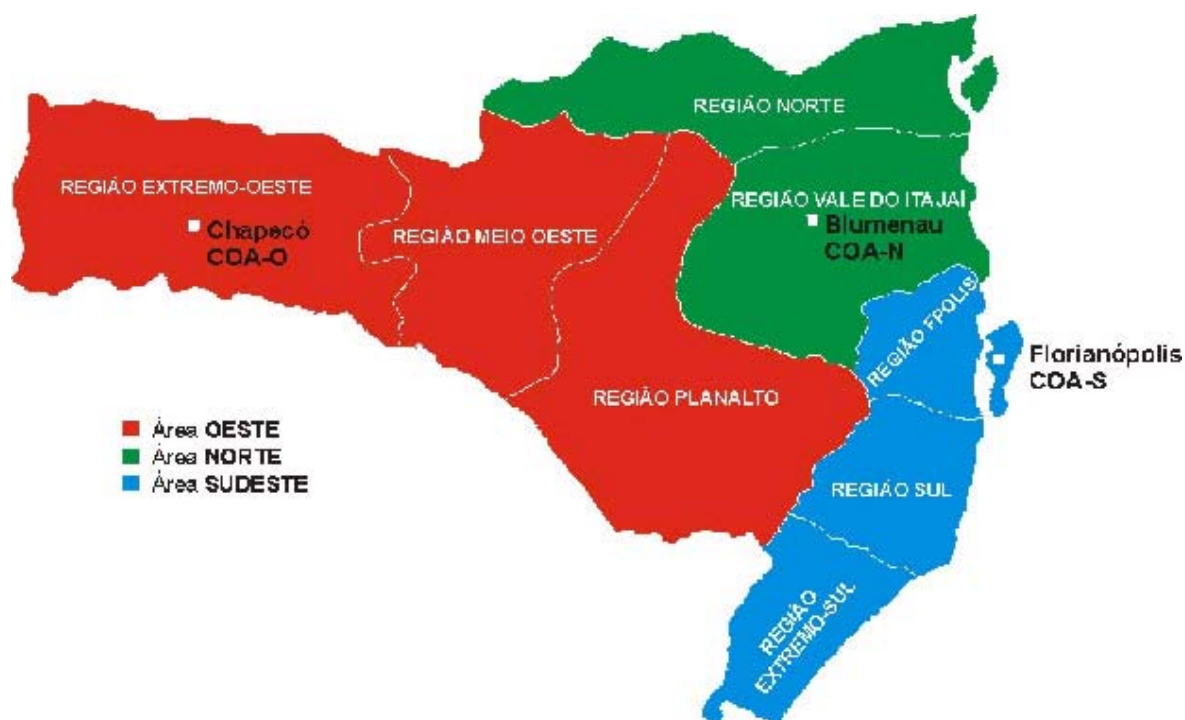


Figura 33 - Centros de Operação de Área da CELESC – Distribuição e Áreas de Abrangência

([12] CELESC, 2003)

O COS tem como principal função supervisionar o sistema elétrico da CELESC como um todo. Além disso, comunica-se com o computador central da CELESC, por onde acontece a transferência de informações referentes ao sistema elétrico, e com o COSR-S do ONS – Operador Nacional do Sistema, para receber dados de suas Subestações e do sistema interligado de interesse da operação do sistema elétrico da CELESC. O SDSC inclui um sistema piloto para o COD - Centro de Operação da Distribuição da agência regional de Joinville, destinado a controlar os alimentadores das Subestações da região. A implantação do SDSC contempla inicialmente 53 Subestações, num total aproximado de 10.000 pontos supervisionados e/ou controlados à distância. As principais funções do SDSC são (a) aquisição de dados, em tempo real, dos diversos dispositivos e proteções das Subestações, (b) controle supervisão, (c) telessinalização e telemedição, (d) telecomando, (e) comunicação com sistemas externos, (f) suporte para o desenvolvimento de software em tempo real e (g) manutenção de base de dados. Na aquisição de dados, as UTRs - Unidades Terminais Remotas coletam informações provenientes dos dispositivos das

Subestações e as enviam, em tempo real, aos Centros de Operação para serem processadas. No controle supervísório, todos os estados e as medições recebidos das Subestações são armazenados num banco de dados, em tempo real, e exteriorizados em representações unifilares nos monitores de vídeo das estações de operação e na tela do sistema de retroprojeção. Alarme e relatórios de eventos fazem parte da interface homem/máquina das estações de operação. Na telessinalização e telemedição os pontos telessinalizados referentes aos estados dos equipamentos são obtidos durante a aquisição de dados, em tempo real, através dos cartões de entradas digitais. Limites operativos podem ser associados a grandezas analógicas, de forma a gerar um alarme toda vez que estes limites forem atingidos. Os telecomandos são executados a partir de janelas do tipo pop-up disponíveis na interface homem/máquina da estação de operação. O envio do comando é feito para a UTR, que vai executar o telecomando através do cartão de saídas digitais. Procedimentos de "check before operation" são realizados para cada envio de comando. A comunicação com sistemas externos é realizada através das Estações de Conversão de Protocolo. O SDSC permite que programas externos possam ser agregados e oferece um ambiente para manutenção da base de dados. A Figura 34 oferece uma visão geral da arquitetura do SDSC.

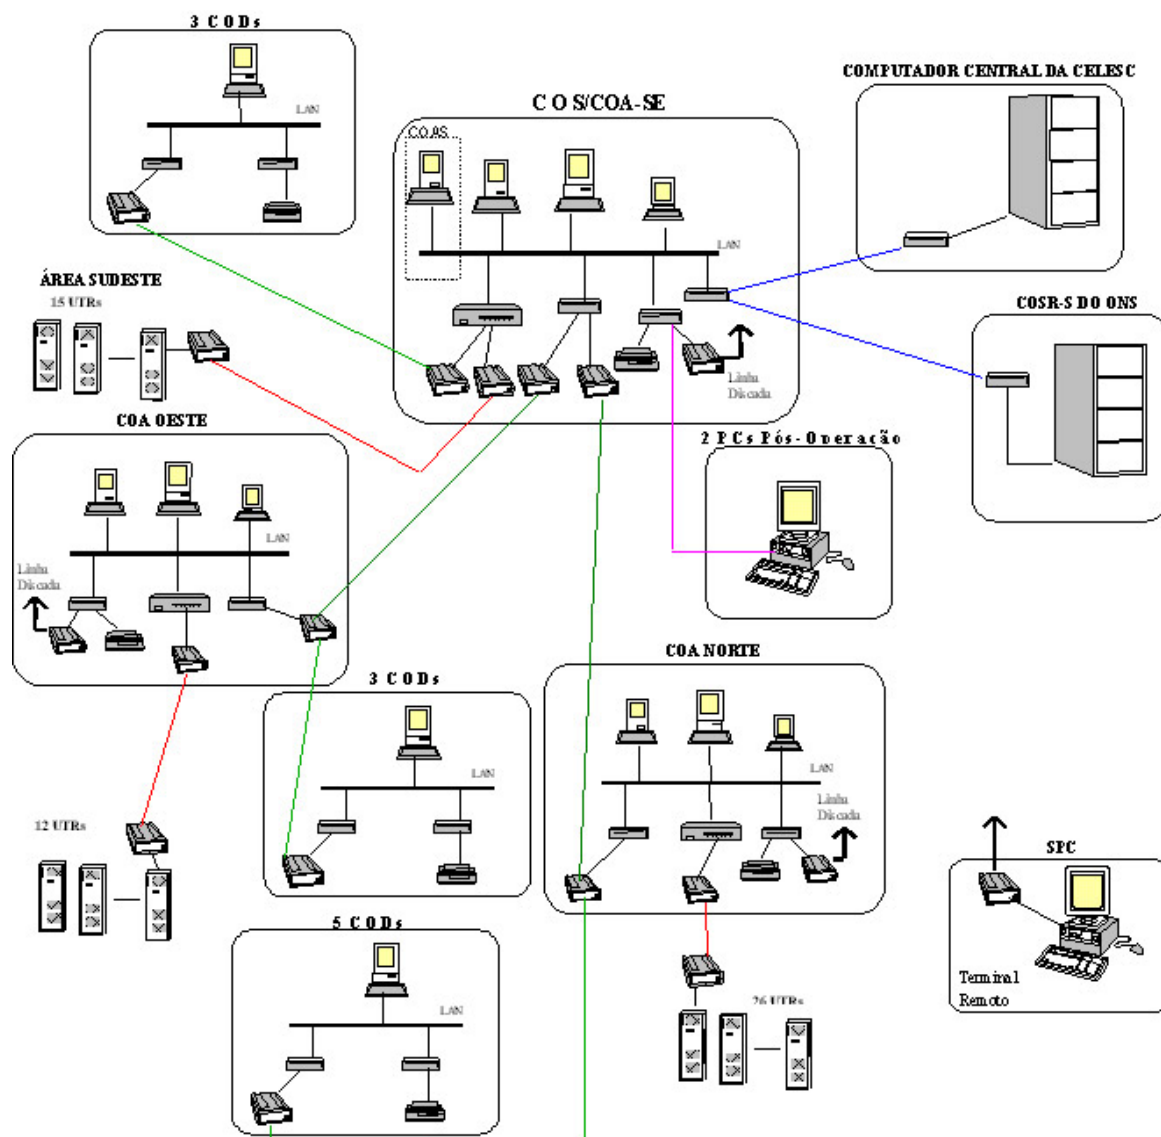


Figura 34 – Arquitetura do SDSC ([12] CELESC, 2003)

8.4 Sistema Hipotético: Condições Climáticas e Comportamento da Carga

Este anexo apresenta de forma gráfica o comportamento da carga e as condições climáticas vigentes, utilizadas nos estudos com o sistema hipotético descrito na seção 4. Dentre as informações das condições climáticas utilizadas neste trabalho, serão apresentadas somente os gráficos referentes às curvas de temperatura ambiente. Isto se deve ao grande volume de informações e a relevância, de uma forma geral, da temperatura ambiente no comportamento da carga. As curvas de carga apresentadas são derivadas das medições de carga coletadas pelo Sistema Digital de Supervisão e Controle da CELESC. As curvas de temperatura ambiente são derivadas das medições desta variável climática, coletadas pelas estações meteorológicas controladas pelo Centro Integrado de Meteorologia e Recursos Hídricos de Santa Catarina – CLIMERH. Os dados são relativos ao ano de 2003.




Figura 35 –Potência ativa ICO Verão




Figura 36 –Potência ativa ICO Outono




Figura 37 –Potência ativa ICO Inverno




Figura 38 –Potência ativa TDE Verão




Figura 39 –Potência ativa TDE Outono




Figura 40 –Potência ativa TDE Inverno




Figura 41 –Potência ativa INE Verão




Figura 42 –Potência ativa INE Outono




Figura 43 –Potência ativa INE Inverno




Figura 44 –Potência ativa ISS Verão




Figura 45 –Potência ativa ISS Outono




Figura 46 –Potência ativa ISS Inverno

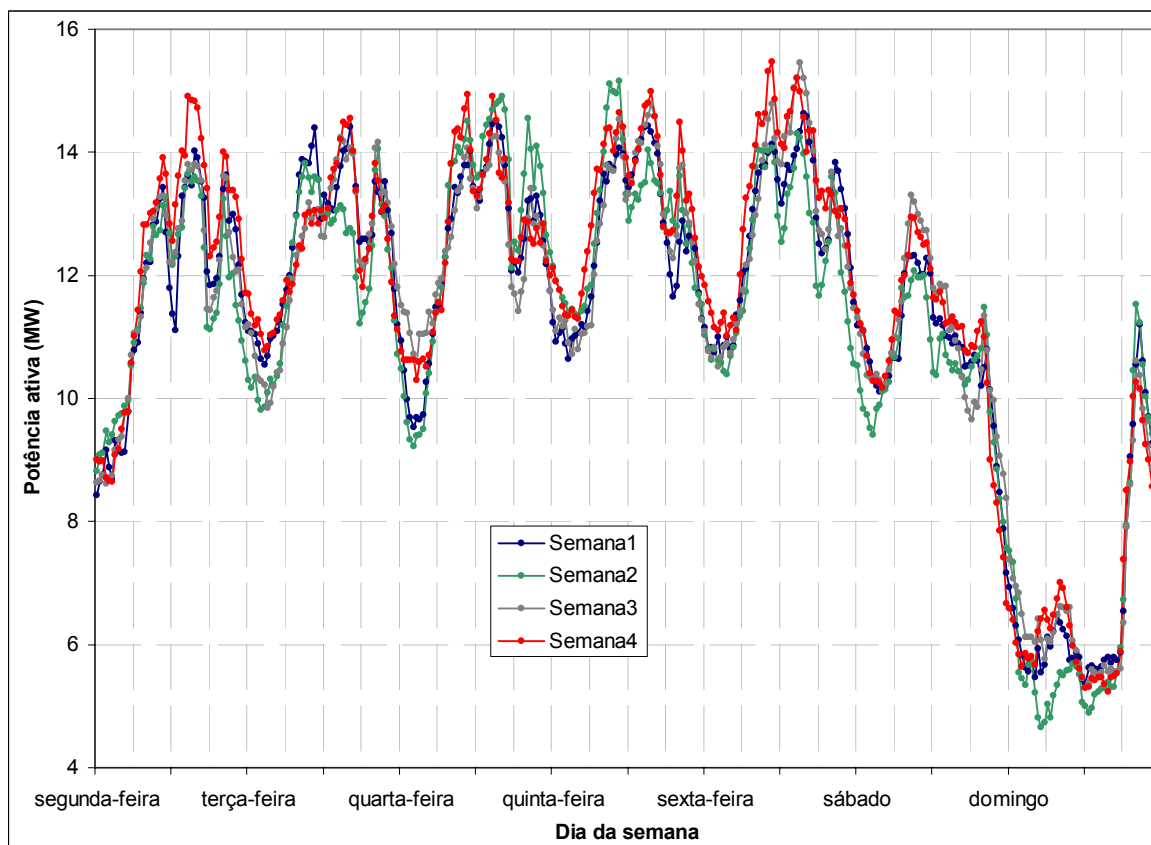


Figura 47 –Potência ativa SRA Verão




Figura 48 –Potência ativa SRA Outono




Figura 49 –Potência ativa SRA Inverno




Figura 50 –Potência ativa SAD Verão




Figura 51 –Potência ativa SAD Outono




Figura 52 –Potência ativa SAD Inverno




Figura 53 – Temperatura ambiente Florianópolis Verão




Figura 54 – Temperatura ambiente Florianópolis Outono




Figura 55 – Temperatura ambiente Florianópolis Inverno




Figura 56 – Temperatura ambiente Itajaí Verão




Figura 57 – Temperatura ambiente Itajaí Outono




Figura 58 – Temperatura ambiente Itajaí Inverno




Figura 59 – Temperatura ambiente Seara Verão




Figura 60 – Temperatura ambiente Seara Outono




Figura 61 – Temperatura ambiente Seara Inverno

8.5 Arquitetura Perceptron Múltiplas Camadas

A arquitetura Perceptron Múltiplas Camadas (*Multilayer Perceptron*) é o paradigma de Rede Neural Artificial de propósito mais geral e mais utilizado. Esta arquitetura de RNA é inspirada nas redes neurais biológicas e composta por neurônios do tipo Perceptron, proposto por Rosenblatt em 1962. A MLP é uma RNA não linear, de múltiplas camadas e de percorrimto à frente (*feedforward*). Esta rede comporta-se como um aproximador universal e mostra-se um veículo prático para realização de um mapeamento não linear, de natureza geral, entre entrada e saída.

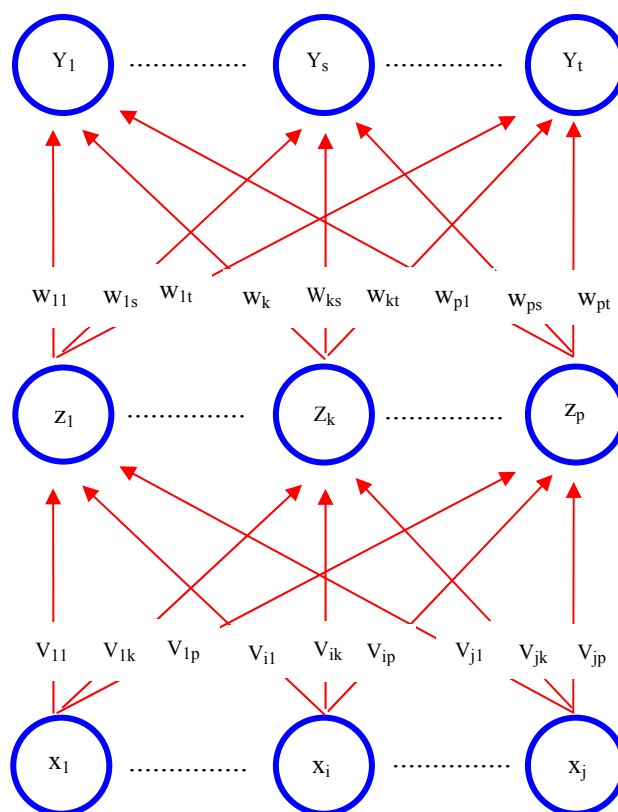


Figura 62 - Rede MLP de 3 camadas

A rede MLP (Figura 62) é formada por 3 ou 4 camadas de neurônios. A primeira camada contém os sinais de entrada da rede, a(s) camada(s) intermediária(s) ou oculta(s) representa(m) a distribuição do conhecimento dentro da rede e a última camada os valores da saída da rede. As ligações entre as camadas de neurônios são ponderadas por pesos,

cujo valor traduz a intensidade entre estas ligações.

Na maioria das implementações atuais a saída de cada neurônio é dada por uma função de ativação não linear. As duas funções de ativação normalmente utilizadas são a função sigmoideal binária (22) e a função sigmoideal bipolar (23). A função sigmoideal binária produz valores de saída entre 0 e 1 e a bipolar entre -1 e 1.

Função sigmoideal binária:

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (22)$$

Função sigmoideal bipolar:

$$f(x) = \frac{2}{(1 + \exp(-x)) - 1} \quad (23)$$

Onde x representa o nível de ativação do neurônio.

A rede MLP pode ser vista como uma aplicação do método de otimização conhecido como *aproximação estocástica* (Haykin, 1994). Ela realiza aproximações globais para o mapeamento entre a entrada e a saída da rede. O treinamento da rede é normalmente efetuado por meio do algoritmo de Retropropagação (*Backpropagation*). Este algoritmo executa um treinamento supervisionado da rede, utilizando a retropropagação do erro entre a saída produzida pela rede e o alvo. O treinamento é feito em três fases: propagação à frente (*feedforward*) do padrão de entrada (padrão de treinamento), cálculo e retropropagação do erro apurado e ajuste dos pesos associados às conexões dos neurônios na direção do menor erro entre a saída produzida pela rede e o alvo. Após o treinamento, o uso da rede envolve apenas a fase de propagação à frente (*feedforward*).

A base matemática para o algoritmo de Retropropagação é a técnica de otimização do gradiente descendente. A idéia básica é calcular derivadas parciais de uma função de aproximação $F(\mathbf{w}; \mathbf{x})$, realizada pela rede para todos os elementos do vetor de pesos ajustáveis \mathbf{w} para um dado valor do vetor de entrada \mathbf{x} (Haykin, 1994). O gradiente da função dá a direção na qual a função aumenta mais rapidamente e o negativo do gradiente

dá a direção na qual a função diminui mais rapidamente. Aplicada à minimização de erro da rede, a função representa o erro e suas variáveis são os pesos da rede.

Os parâmetros livres, que necessitam serem ajustados para o treinamento da rede são: o número de neurônios na camada oculta, a iniciação dos pesos da rede, o valor da taxa de aprendizado, o erro máximo admissível no treinamento e número máximo de épocas de treinamento. Caso não haja conhecimento prévio a respeito de quais sejam os bons valores de iniciação de pesos para o problema em questão, uma boa alternativa é a sua iniciação aleatória. A taxa de aprendizado se traduz no tamanho dos passos dados, ao percorrer a superfície de erro, em busca do ponto de erro mínimo global. Passos mais largos propiciam um treinamento mais rápido porém aumentam o risco de que se passe o ponto de mínimo e a rede não consiga estabilizar. O número de épocas de treinamento e o erro máximo admissível no treinamento são critérios para a parada do treinamento. Redes treinadas com um número de épocas excessivo memorizam os vetores de entrada e perdem a capacidade de generalizar. Por fim, um valor muito baixo para o erro máximo admissível pode se mostrar impossível de ser alcançado durante o treinamento.

Um outro parâmetro que pode ser utilizado no algoritmo de Retropropagação é o momento (*momentum*). A introdução deste parâmetro modifica a direção para a alteração de pesos. A direção que era função do gradiente descendente corrente, passa a ser função da combinação entre os gradientes descendentes corrente e anterior. Esta técnica procura aumentar as chances da rede estabilizar no ponto de erro mínimo global, diminuindo portanto a possibilidade da rede estabilizar em um ponto de mínimo local.

A rede MLP treinada com o algoritmo de Retropropagação possui equilíbrio entre uma boa memorização do conjunto de treinamento e uma boa capacidade de resposta às entradas similares ao padrão de treinamento (generalização). Isto habilita a rede a reconhecer padrões que são similares aos do conjunto de treinamento ou padrões com ruído. Suas desvantagens são o elevado tempo para treinamento e o grande número de parâmetros a ajustar. A quantidade de parâmetros soma-se a falta de uma metodologia para o ajuste ideal de seus valores. Os valores são geralmente obtidos através de técnicas heurísticas e experimentação. Uma descrição detalhada da arquitetura Perceptron Múltiplas Camadas pode ser obtida em Dandolini (1997), Fausett (1994), Haykin (1994) e Skapura (1996).

8.6 Arquitetura de Base Radial

A arquitetura de Base Radial é uma rede de múltiplas camadas e propagação direta (*feedforward*). Esta rede pertence a classe de RNAs onde a ativação dos neurônios da camada oculta é determinada pela distância entre o vetor de entrada e um vetor padrão. Segundo Haykin (1994), o funcionamento da RBF se baseia na procura do ajuste de uma curva (aproximação) em um espaço de grande dimensão. Sob esta ótica, seu processo de aprendizado busca encontrar uma superfície num espaço multidimensional que dá o melhor ajuste para os dados de treinamento. A generalização é obtida utilizando esta superfície multidimensional para interpolar os dados de teste.




Figura 63 - Rede RBF de 3 camadas (in ORR, 1996)

A RBF (Figura 63) é normalmente composta de uma estrutura de três camadas. A primeira camada é composta por neurônios (\mathbf{x}) que representam os sinais de entrada da rede. A segunda camada é composta por neurônios ($h(\mathbf{x})$) normalmente denominados de agrupamentos. Cada um destes agrupamentos circunscreve uma região espacial por meio de um centro e um raio, próprios. Nesta camada, o espaço de entrada é transformado, de maneira não linear, em um espaço de maior dimensão. A terceira camada é formada por

neurônios que representam a dimensão do vetor de saída desejado. Nesta última camada, os padrões resultantes da camada intermediária são então transformados no padrão de saída.

O método função de base radial tem suas origens nas técnicas de interpolação exata de um conjunto de dados dentro de um espaço multidimensional (Powell, 1987, cf. in Bishop, 1995). O problema da interpolação exata requer que todo vetor de entrada seja mapeado exatamente para um vetor alvo. Assim, o objetivo é encontrar uma função $f(\mathbf{x})$ capaz de proceder este mapeamento, como mostra a (24)

$$f(x_n) = t_n \tag{24}$$

Onde:

- \mathbf{x} é o vetor de entrada da rede;
- t é o alvo;
- n é o número de vetores de entrada.

A interpolação exata implica no uso de uma função de interpolação que passe exatamente por todos os pontos do mapeamento. Uma de suas desvantagens é que quando há ruído nos dados, a função de interpolação que dá a melhor generalização é uma função mais suave e que faz uma média sobre o ruído. Uma outra desvantagem é que o número de funções da camada oculta é igual ao número de padrões do conjunto de dados (Bishop, 1995). Buscando eliminar estas desvantagens, Broomhead e Lowe (1988) e Moody e Darken (1989), citados em Bishop (1995), introduziram modificações no procedimento de interpolação exata de forma a suavizar a função de interpolação e fazer com que o número de funções da camada oculta seja determinado pela complexidade do mapeamento a ser representado.

O aumento dimensional que ocorre na segunda camada (camada oculta) da rede está baseado no princípio, enunciado por Cover (1965, cf. in Haykin, 1994) de que um complexo problema de classificação de padrões lançado de forma não linear em um espaço de grande dimensão é mais fácil de ser linearmente separável do que em um espaço de pequena dimensão. Procedido o aumento dimensional, a função $f(\mathbf{x})$ é mapeada para um vetor formado de um conjunto de funções $\{f_i(\mathbf{x}) \mid i=1,2,\dots,M\}$ como mostrado na (25).

$$f(x) = [f_1(x), f_2(x), \dots, f_M(x)]^T \quad (25)$$

Onde:

x é o padrão de entrada;

M é a quantidade de agrupamentos da camada oculta.

A transformação das dimensões que ocorre na camada oculta da rede é efetivada pelo mapeamento não linear do espaço de entrada. Para a consecução deste mapeamento são utilizadas funções de base radial. A saída de uma rede RBF (Haykin, 1994, p. 243) tem a forma da (26).

$$F(x) = \sum_{i=1}^M w_i h(\|x - x_i\|) \quad (26)$$

Onde:

$\{h(\|x - x_i\|) | i = 1, 2, \dots, M\}$ é o conjunto das M funções (agrupamentos) da camada oculta conhecidas como funções de base radial;

x é o padrão de entrada;

$\|x - x_i\|$ é a norma da distância (usualmente a distância euclidiana);

$x_i \in \mathfrak{R}^p, i = 1, 2, \dots, M$ são os centros das funções de base radial (agrupamentos);

w são os coeficientes desconhecidos (pesos) que minimizam a diferença da função $F(x)$ em relação ao alvo.

Normalmente utiliza-se a função gaussiana como a função $h(x)$. A função $h(x)$ assume então a forma da (13).

$$h(x) = \exp\left[-\frac{1}{2\sigma_i^2} \|x - x_i\|^2\right], i = 1, 2, \dots, M \quad (27)$$

Onde:

x_i são os centros dos agrupamentos;

σ_i são as larguras dos agrupamentos.

O treinamento da RBF acontece em dois estágios. No primeiro estágio os parâmetros das funções de base radial são determinados utilizando métodos de treinamento

não supervisionado. Os métodos de treinamento empregados são rápidos e usam apenas os dados de entrada da rede (não utilizam os dados relativos ao alvo). No segundo estágio o treinamento é supervisionado e implica na determinação dos pesos da última camada da rede. Os pesos podem ser otimizados através da minimização de uma função de erro tal com a função de erro da soma dos quadrados.

Bishop (1995) mostra que o emprego da álgebra linear na metodologia de cálculo da rede torna os cálculos mais fáceis e mais rápidos. Para que isto se torne possível, é necessário que as funções de base radial sejam mantidas fixas. Além disto, o uso da função de erro como uma função quadrática dos pesos torna possível que seu mínimo seja encontrado a partir da solução de um conjunto de equações lineares em uma única iteração. Como demonstra Bishop (1995), utilizando-se os conceitos expostos, a partir da (24) e da (26) pode-se escrever, em notação matricial, a (28), a qual provê a solução para o problema da otimização dos pesos da rede. Por fim, embora possível, não é interessante o emprego de uma função não linear para a ativação dos neurônios da última camada. O emprego de uma função não linear no cálculo da saída da rede, bem como de outra função de erro, faz com que o problema de otimização dos pesos deixe de ser um problema tratável pela álgebra linear. Além disto, também deixa de existir a garantia de convergência para o ótimo global.

$$\mathbf{W}^T = \mathbf{H}^\Psi \mathbf{T} \quad (28)$$

Onde:

\mathbf{W}^T é a transposta da matriz de pesos;

\mathbf{H}^Ψ é a pseudo-inversa da matriz de funções de base radial;

\mathbf{T} é a matriz de alvos.

O uso da álgebra linear na metodologia de cálculo da rede torna a RBF extremamente rápida. Segundo Haykin (1994), duas das características da arquitetura de Base Radial são: sua capacidade de aprendizado rápido e sua sensibilidade reduzida a ordem de apresentação dos dados de treinamento. Maiores detalhes a respeito desta arquitetura de RNA podem ser obtidos em Bishop (1995), Haykin (1994), Orr (1996) e Pandya & Macy (1995).

8.7 Experimentos do Grupo A: Precisão de Ajuste e Previsão

Tabela 23 - Grupo A – ICO: Precisão com Carga e Todas as Variáveis Climáticas

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,0808	0,0805	0,0825	0,1057	0,1035	0,1011	0,1368	0,1346	0,1354
	Erro Máximo (%)	6,9036	6,5766	7,0806	6,8249	7,6306	7,2345	11,6036	10,8834	13,8142
	Erro Máximo (MW)	0,4721	0,4407	0,4263	0,6882	0,6778	0,5946	0,9899	1,2937	1,1532
	Erro Médio (MW)	0,0975	0,0998	0,1021	0,1197	0,1220	0,1200	0,1404	0,1462	0,1446
	MAPE (%)	1,0594	1,0840	1,1167	1,1604	1,1918	1,1649	1,2267	1,2952	1,2689
	MAPEm (%)	0,5708	0,5842	0,5978	0,5087	0,5182	0,5097	0,4379	0,4560	0,4512
	RMSE (MW)	0,1266	0,1282	0,1313	0,1597	0,1599	0,1569	0,1959	0,1986	0,1980
	SSE (MW)	16,1587	16,5700	17,3660	25,7053	25,7763	24,8029	38,6909	39,7726	39,5348
Teste	Desvio Padrão Erro (MW)	0,1415	0,1661	0,1228	0,2623	0,2515	0,1612	0,3302	0,6822	0,4220
	Erro Máximo (%)	8,9697	9,0425	8,4659	9,2723	10,8337	7,2736	14,2638	14,9797	15,0181
	Erro Máximo (MW)	0,7517	1,2884	0,7148	1,5514	1,4478	0,9797	2,0515	3,1528	2,4847
	Erro Médio (MW)	0,1581	0,1826	0,1471	0,2739	0,3635	0,1856	0,2892	0,7110	0,3842
	MAPE (%)	1,6065	1,7233	1,5063	2,5672	3,7191	1,8062	2,0379	4,4216	2,5788
	MAPEm (%)	0,8759	1,0116	0,8149	1,5649	2,0765	1,0602	0,8557	2,1036	1,1367
	RMSE (MW)	0,2120	0,2467	0,1915	0,3790	0,4418	0,2457	0,4386	0,9847	0,5703
	SSE (MW)	15,1049	20,4418	12,3250	48,2669	65,5838	20,2805	64,6297	325,7660	109,2673
TesteRecursivo	Desvio Padrão Erro (MW)	0,2291	0,2898	0,2274	0,8750	1,2610	0,5553	2,6356	2,4725	2,7793
	Erro Máximo (%)	10,9723	11,7064	12,1068	27,5353	49,1343	20,6748	88,5596	39,0892	35,9845
	Erro Máximo (MW)	1,3582	1,7423	1,2531	4,8002	6,0228	3,1223	10,6849	10,1247	10,6608
	Erro Médio (MW)	0,2462	0,3259	0,2648	0,9409	1,9258	0,6151	5,1688	2,5566	2,5500
	MAPE (%)	2,4456	2,9606	2,7304	8,5899	19,4456	5,6309	37,5861	15,2737	16,3740
	MAPEm (%)	1,3641	1,8057	1,4670	5,3746	11,0009	3,5139	15,2920	7,5639	7,5441
	RMSE (MW)	0,3361	0,4359	0,3488	1,2840	2,3009	0,8282	5,8002	3,5541	3,7688
	SSE (MW)	37,9589	63,8299	40,8771	553,9137	1778,8308	230,4421	11303,6254	4244,2008	4772,4252

Tabela 24 - Grupo A – INE: Precisão com Carga e Todas as Variáveis Climáticas

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,1873	0,1966	0,1789	0,1615	0,1634	0,1535	0,2921	0,3025	0,3045
	Erro Máximo (%)	8,3072	7,7662	7,5132	8,6533	7,5660	8,7549	9,3718	9,8336	8,8348
	Erro Máximo (MW)	1,7743	1,8837	1,7853	1,5544	1,7629	1,2040	2,9621	3,1717	3,1125
	Erro Médio (MW)	0,1794	0,1821	0,1773	0,1573	0,1616	0,1579	0,2809	0,2771	0,2884
	MAPE (%)	1,1523	1,1703	1,1389	1,0044	1,0250	1,0062	1,0159	1,0117	1,0502
	MAPEm (%)	0,6675	0,6776	0,6598	0,5697	0,5853	0,5719	0,6166	0,6082	0,6331
	RMSE (MW)	0,2593	0,2679	0,2518	0,2254	0,2298	0,2202	0,4052	0,4101	0,4194
	SSE (MW)	67,7529	72,3541	63,9117	51,2100	53,2242	48,8541	165,5082	169,5462	177,2658
Teste	Desvio Padrão Erro (MW)	0,2812	0,3433	0,2904	0,2279	0,2740	0,2129	0,4679	0,5043	0,4543
	Erro Máximo (%)	13,3862	14,8108	17,0454	6,9660	8,2624	7,4982	7,2197	9,3271	9,7183
	Erro Máximo (MW)	1,7595	1,9780	2,0869	1,6465	1,3397	1,1935	2,9536	3,8158	3,9758
	Erro Médio (MW)	0,3127	0,3802	0,3109	0,3049	0,3381	0,2609	0,6139	0,6644	0,4111
	MAPE (%)	2,2000	2,6826	2,1698	2,0690	2,2968	1,7215	2,1249	2,2584	1,3846
	MAPEm (%)	1,2568	1,5284	1,2497	1,1526	1,2781	0,9864	1,3287	1,4379	0,8897
	RMSE (MW)	0,4202	0,5119	0,4251	0,3805	0,4349	0,3365	0,7715	0,8336	0,6122
	SSE (MW)	59,3338	88,0556	60,7192	48,6396	63,5603	38,0561	199,9843	233,5083	125,9324
TesteRecursivo	Desvio Padrão Erro (MW)	0,4286	0,5866	0,4432	0,5049	0,7326	0,3708	1,6319	2,3605	1,4404
	Erro Máximo (%)	20,5474	20,1482	18,0448	14,4302	20,8504	12,0203	22,5753	34,2629	19,7642
	Erro Máximo (MW)	2,7008	3,0684	2,6363	2,6864	3,2890	1,8350	6,8778	9,6788	8,6767
	Erro Médio (MW)	0,4906	0,6263	0,4973	0,8212	0,9052	0,5971	2,9104	4,0946	1,5214
	MAPE (%)	3,4919	4,4617	3,5087	5,6687	6,2109	4,1454	10,2205	14,3804	5,1972
	MAPEm (%)	1,9720	2,5175	1,9990	3,1045	3,4219	2,2573	6,2986	8,8615	3,2927
	RMSE (MW)	0,6510	0,8575	0,6657	0,9636	1,1638	0,7026	3,3355	4,7245	2,0936
	SSE (MW)	142,3935	247,0771	148,9032	311,9981	455,0842	165,8571	3738,1153	7499,9240	1472,8006

Tabela 25 - Grupo A – TDE: Precisão com Carga e Todas as Variáveis Climáticas

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,2433	0,2383	0,2309	0,2667	0,2701	0,2768	0,2332	0,2500	0,2334
	Erro Máximo (%)	6,7939	8,1146	8,8363	15,4751	15,4205	14,3274	7,2623	7,8630	7,4584
	Erro Máximo (MW)	1,8019	1,7380	1,7669	2,6910	2,5737	2,3515	2,3304	2,6905	2,5080
	Erro Médio (MW)	0,2453	0,2410	0,2418	0,2542	0,2609	0,2584	0,2412	0,2357	0,2284
	MAPE (%)	1,0113	0,9989	0,9973	1,0214	1,0577	1,0453	0,9136	0,8929	0,8644
	MAPEm (%)	0,6665	0,6548	0,6571	0,6621	0,6794	0,6731	0,6536	0,6387	0,6189
	RMSE (MW)	0,3454	0,3388	0,3343	0,3683	0,3754	0,3786	0,3354	0,3435	0,3265
	SSE (MW)	120,2658	115,7230	112,6293	136,7653	142,0673	144,5007	113,4177	118,9375	107,4679
Teste	Desvio Padrão Erro (MW)	0,3802	0,3399	0,4653	0,3395	0,3875	0,4276	0,4007	0,3991	0,3708
	Erro Máximo (%)	10,1652	11,8359	14,8762	11,0480	12,4954	9,0076	6,7155	7,1841	6,2710
	Erro Máximo (MW)	2,5159	1,7363	2,3363	1,8147	1,9359	2,2182	2,6862	2,1222	2,1408
	Erro Médio (MW)	0,5065	0,4088	0,4949	0,3990	0,5689	0,5653	0,5475	0,5933	0,5608
	MAPE (%)	2,1985	1,7777	2,2192	1,6865	2,5134	2,3922	1,6919	1,8643	1,7284
	MAPEm (%)	1,3791	1,1130	1,3475	1,0876	1,5507	1,5410	1,3083	1,4176	1,3399
	RMSE (MW)	0,6330	0,5313	0,6788	0,5235	0,6879	0,7084	0,6781	0,7147	0,6719
	SSE (MW)	134,6392	94,8479	154,8367	92,0978	159,0164	168,6341	154,5066	171,6106	151,7068
TesteRecursivo	Desvio Padrão Erro (MW)	0,6107	0,5822	1,1323	0,9298	1,2568	1,2186	1,5139	1,8065	1,7739
	Erro Máximo (%)	12,9644	20,6294	29,8089	24,3609	37,4061	23,9397	16,6096	24,0032	22,4241
	Erro Máximo (MW)	2,8688	3,3523	5,4134	4,4117	5,2430	5,2761	6,7041	6,9419	7,0286
	Erro Médio (MW)	0,9595	0,6877	1,0824	1,0020	1,9398	1,8835	2,4340	2,5901	3,2873
	MAPE (%)	4,1919	3,0365	4,9682	4,2965	8,8039	8,0404	7,4690	8,1380	10,1778
	MAPEm (%)	2,6123	1,8723	2,9469	2,7315	5,2879	5,1344	5,8159	6,1890	7,8550
	RMSE (MW)	1,1369	0,9005	1,5652	1,3660	2,3104	2,2423	2,8652	3,1563	3,7341
	SSE (MW)	434,2857	272,4643	823,1625	626,9989	1793,4881	1689,4178	2758,3183	3347,3581	4685,1206

Tabela 26 - Grupo A – SRA: Precisão com Carga e Todas as Variáveis Climáticas

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,1980	0,1964	0,1937	0,1742	0,1729	0,1761	0,1485	0,1511	0,1494
	Erro Máximo (%)	18,2463	20,1882	17,7045	20,3470	19,7923	22,1448	11,5287	13,9146	12,2441
	Erro Máximo (MW)	2,0873	2,3095	2,0254	1,1410	1,2594	1,2418	0,8891	0,9960	1,0632
	Erro Médio (MW)	0,2177	0,2128	0,2146	0,2098	0,2037	0,2069	0,1800	0,1807	0,1799
	MAPE (%)	2,1517	2,1069	2,1306	2,1909	2,0970	2,1699	1,6895	1,6872	1,6831
	MAPEm (%)	1,4018	1,3703	1,3818	1,4125	1,3716	1,3931	1,1650	1,1693	1,1646
	RMSE (MW)	0,2942	0,2896	0,2890	0,2726	0,2671	0,2716	0,2333	0,2355	0,2338
	SSE (MW)	87,2493	84,5212	84,2173	74,9197	71,9196	74,3627	54,8803	55,8892	55,1028
Teste	Desvio Padrão Erro (MW)	0,2723	0,2577	0,3100	0,2863	0,2662	0,3310	0,1958	0,2004	0,2012
	Erro Máximo (%)	14,9342	11,9899	16,7959	19,2829	16,0769	35,1217	12,9046	13,3243	24,2428
	Erro Máximo (MW)	1,7019	1,5530	1,4397	1,8001	1,5008	2,1939	1,0763	1,1127	1,3255
	Erro Médio (MW)	0,3498	0,3451	0,4349	0,4216	0,3513	0,4598	0,2545	0,2509	0,2554
	MAPE (%)	3,6232	3,5080	4,5560	4,4269	3,6075	4,8123	2,3137	2,2375	2,4416
	MAPEm (%)	2,2910	2,2604	2,8486	2,9175	2,4312	3,1821	1,6460	1,6224	1,6518
	RMSE (MW)	0,4430	0,4305	0,5338	0,5093	0,4405	0,5663	0,3209	0,3209	0,3250
	SSE (MW)	65,9444	62,2670	95,7394	87,1671	65,2069	107,7350	34,6088	34,5974	35,4792
TesteRecursivo	Desvio Padrão Erro (MW)	0,5848	0,5731	0,8224	0,8832	1,1062	1,0206	0,5052	0,4832	0,4719
	Erro Máximo (%)	38,2915	25,2686	35,0995	47,6155	45,7982	92,1814	19,7027	20,8233	49,5287
	Erro Máximo (MW)	2,7279	2,5319	3,4092	4,2741	5,5814	5,1390	2,0823	2,1751	2,7180
	Erro Médio (MW)	0,7775	0,7682	1,2308	1,7943	1,5348	1,7863	0,6864	0,6201	0,6501
	MAPE (%)	8,2293	7,9027	12,8626	18,7247	15,6460	18,3876	6,3762	5,4678	6,4140
	MAPEm (%)	5,0930	5,0319	8,0615	12,4171	10,6218	12,3623	4,4390	4,0104	4,2045
	RMSE (MW)	0,9724	0,9580	1,4795	1,9993	1,8910	2,0566	0,8518	0,7857	0,8029
	SSE (MW)	317,7038	308,3389	735,5060	1342,9975	1201,4610	1421,1566	243,7930	207,4268	216,6202

Tabela 27 - Grupo A – ISS: Precisão com Carga e Todas as Variáveis Climáticas

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,3335	0,3715	0,3648	0,3916	0,3878	0,3829	0,3429	0,3299	0,3375
	Erro Máximo (%)	8,0779	8,0487	8,4676	9,1260	8,8688	10,3433	7,4005	6,5871	6,8271
	Erro Máximo (MW)	3,5005	3,4537	3,6694	3,2422	3,5044	3,6746	2,6274	2,1783	2,3997
	Erro Médio (MW)	0,3742	0,3998	0,3955	0,3857	0,3848	0,3753	0,3836	0,3788	0,3884
	MAPE (%)	1,0245	1,0926	1,0843	1,0283	1,0293	0,9986	1,0392	1,0272	1,0544
	MAPEm (%)	0,7698	0,8226	0,8138	0,7375	0,7358	0,7176	0,7902	0,7805	0,8001
	RMSE (MW)	0,5011	0,5457	0,5380	0,5495	0,5462	0,5360	0,5144	0,5022	0,5144
	SSE (MW)	253,1180	300,1356	291,7380	304,3717	300,7453	289,6053	266,6981	254,2330	266,7062
Teste	Desvio Padrão Erro (MW)	0,6164	0,6564	0,7372	0,5306	0,5890	0,6044	0,4977	0,5115	0,6076
	Erro Máximo (%)	16,2734	15,1669	19,7433	10,3994	9,1286	10,6536	9,8738	9,8805	12,7824
	Erro Máximo (MW)	4,7827	4,4575	5,8025	3,6185	3,1763	3,7069	3,7419	3,8211	3,7940
	Erro Médio (MW)	0,7224	0,7571	0,9332	0,7784	0,9913	0,7988	0,5412	0,5424	0,6858
	MAPE (%)	2,0701	2,1674	2,7169	2,0837	2,6600	2,0803	1,3605	1,3530	1,7400
	MAPEm (%)	1,6159	1,6935	2,0873	1,4757	1,8794	1,5144	1,1019	1,1044	1,3963
	RMSE (MW)	0,9491	1,0014	1,1885	0,9416	1,1526	1,0011	0,7347	0,7450	0,9156
	SSE (MW)	302,6378	336,9431	474,6394	297,8981	446,4071	336,7460	181,3891	186,5012	281,6995
TesteRecursivo	Desvio Padrão Erro (MW)	1,4798	1,2482	1,7344	1,7804	3,3591	2,4157	1,8133	1,5168	2,0456
	Erro Máximo (%)	31,2725	25,5148	34,3846	20,6205	31,1670	22,8940	33,6010	37,3714	37,8265
	Erro Máximo (MW)	9,8829	8,0634	10,1462	7,7684	12,7077	9,5413	9,9292	11,0433	11,1365
	Erro Médio (MW)	1,9576	1,7153	2,6776	3,3093	5,7541	3,7285	2,3680	2,1695	2,5927
	MAPE (%)	5,6664	4,9465	7,8642	8,8589	15,4659	9,6322	6,0219	5,5066	6,6616
	MAPEm (%)	4,3787	3,8367	5,9890	6,2741	10,9090	7,0689	4,8211	4,4170	5,2787
	RMSE (MW)	2,4527	2,1203	3,1888	3,7566	6,6603	4,4407	2,9808	2,6458	3,3006
	SSE (MW)	2021,2876	1510,5511	3416,6731	4741,663	14904,709	6625,948	2985,5158	2352,1325	3660,4274

Tabela 28 - Grupo A – SAD: Precisão com Carga e Todas as Variáveis Climáticas

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,1920	0,1936	0,2006	0,2228	0,2214	0,2278	0,2295	0,2267	0,2280
	Erro Máximo (%)	31,6586	26,4310	33,4013	45,6589	45,4633	44,5787	39,3876	41,1613	35,8132
	Erro Máximo (MW)	1,2607	1,2837	1,3194	1,8413	1,8334	1,8019	1,5324	1,8326	1,5663
	Erro Médio (MW)	0,2399	0,2340	0,2406	0,2655	0,2661	0,2684	0,2664	0,2653	0,2730
	MAPE (%)	2,6309	2,5531	2,6365	2,5424	2,5502	2,5791	2,7109	2,7387	2,8261
	MAPEm (%)	1,4652	1,4294	1,4696	1,5190	1,5225	1,5352	1,5038	1,4977	1,5411
	RMSE (MW)	0,3072	0,3036	0,3132	0,3465	0,3461	0,3519	0,3515	0,3489	0,3556
	SSE (MW)	95,1428	92,9382	98,8585	121,0387	120,7517	124,8250	124,5560	122,7038	127,4529
Teste	Desvio Padrão Erro (MW)	0,3052	1,1381	0,2775	0,3222	0,3525	0,3382	0,6046	0,5221	0,4041
	Erro Máximo (%)	21,2414	54,8503	19,8248	45,9489	31,6278	41,4492	35,5058	43,5518	27,7036
	Erro Máximo (MW)	1,5142	6,8640	1,3390	2,4250	1,9951	2,1875	2,5205	2,8247	1,9485
	Erro Médio (MW)	0,4060	0,9608	0,3929	0,4760	0,3715	0,4886	0,6309	0,5410	0,4723
	MAPE (%)	3,8907	9,2211	3,5591	5,4645	3,6931	5,7088	5,1447	4,4268	3,7591
	MAPEm (%)	2,4848	5,8796	2,4042	2,9213	2,2803	2,9985	3,5425	3,0377	2,6517
	RMSE (MW)	0,5076	1,4881	0,4808	0,5745	0,5118	0,5939	0,8732	0,7513	0,6212
	SSE (MW)	86,5871	744,0716	77,6584	110,9022	88,0079	118,5291	256,2156	189,6629	129,6397
TesteRecursivo	Desvio Padrão Erro (MW)	0,9723	1,8003	0,7853	1,1617	0,9395	0,9702	2,2222	2,6096	1,3940
	Erro Máximo (%)	58,4587	114,7254	54,1215	144,1078	64,2225	126,2093	72,7033	102,8257	58,6382
	Erro Máximo (MW)	5,3577	10,8489	3,7637	5,0868	4,6997	4,2008	7,6634	8,3913	5,9833
	Erro Médio (MW)	1,5706	2,6522	1,6365	1,8453	0,9935	1,6464	1,9627	2,1879	1,4734
	MAPE (%)	14,9760	27,0644	14,7505	22,9637	10,1333	19,7975	16,6690	19,0501	12,1852
	MAPEm (%)	9,6117	16,2311	10,0148	11,3251	6,0973	10,1049	11,0204	12,2850	8,2729
	RMSE (MW)	1,8465	3,2040	1,8146	2,1796	1,3664	1,9103	2,9624	3,4025	2,0269
	SSE (MW)	1145,5531	3449,2523	1106,4038	1596,1798	627,2972	1226,1661	2948,6792	3889,8072	1380,4182

Tabela 29 - Grupo A – ICO: Precisão com Carga e Temperatura Ambiente

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,0910	0,0922	0,0910	0,1119	0,1135	0,1109	0,1523	0,1592	0,1646
	Erro Máximo (%)	8,2340	8,6342	7,9735	6,2918	6,7214	7,2859	13,8269	13,2803	12,7161
	Erro Máximo (MW)	0,5400	0,4850	0,5045	0,5869	0,6489	0,6068	1,0281	1,3050	1,4838
	Erro Médio (MW)	0,1043	0,1061	0,1072	0,1324	0,1293	0,1303	0,1542	0,1579	0,1626
	MAPE (%)	1,1207	1,1456	1,1542	1,2703	1,2323	1,2442	1,2917	1,3322	1,3765
	MAPEm (%)	0,6102	0,6211	0,6277	0,5627	0,5495	0,5536	0,4812	0,4927	0,5073
	RMSE (MW)	0,1384	0,1406	0,1406	0,1734	0,1720	0,1711	0,2167	0,2242	0,2313
	SSE (MW)	19,2985	19,9131	19,9303	30,2939	29,8275	29,4938	47,3449	50,6642	53,9470
Teste	Desvio Padrão Erro (MW)	0,1566	0,1225	0,1134	0,2131	0,1456	0,1516	0,3148	0,3017	0,3021
	Erro Máximo (%)	10,0728	10,6453	8,5300	8,9342	9,2250	8,5800	14,7950	13,3517	14,2477
	Erro Máximo (MW)	1,0041	0,6677	0,6690	1,1114	0,8034	0,8028	2,3993	2,1042	2,0947
	Erro Médio (MW)	0,2033	0,1573	0,1387	0,2283	0,1777	0,1995	0,2493	0,2942	0,2828
	MAPE (%)	2,0105	1,7879	1,4167	2,0892	1,8117	2,0952	1,7336	2,2125	2,1043
	MAPEm (%)	1,1263	0,8713	0,7685	1,3044	1,0148	1,1397	0,7375	0,8704	0,8368
	RMSE (MW)	0,2565	0,1992	0,1791	0,3121	0,2296	0,2504	0,4012	0,4211	0,4135
	SSE (MW)	22,0978	13,3366	10,7749	32,7263	17,7112	21,0751	54,0728	59,5797	57,4544
TesteRecursivo	Desvio Padrão Erro (MW)	0,3911	0,3459	0,2363	1,2595	0,6724	0,8551	1,5338	2,6954	1,3878
	Erro Máximo (%)	21,4322	24,7570	11,8842	31,0426	36,2290	47,7084	54,7196	152,5197	46,4582
	Erro Máximo (MW)	1,7431	1,5733	1,2326	5,1982	2,5271	3,8413	6,3159	12,1954	6,0040
	Erro Médio (MW)	0,6766	0,3949	0,3222	1,3647	0,8404	1,2265	2,2275	4,1306	2,0049
	MAPE (%)	6,7546	5,0533	3,2242	11,2362	7,9721	12,4235	16,8246	34,9990	15,4498
	MAPEm (%)	3,7485	2,1880	1,7849	7,7959	4,8007	7,0060	6,5902	12,2207	5,9315
	RMSE (MW)	0,7812	0,5247	0,3993	1,8558	1,0757	1,4944	2,7032	4,9301	2,4372
	SSE (MW)	205,0535	92,4994	53,5757	1157,2376	388,7808	750,3377	2455,2875	8166,8012	1995,7539

Tabela 30 - Grupo A –INE: Precisão com Carga e Temperatura Ambiente

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,3136	0,3477	0,3007	0,1845	0,1891	0,1853	0,1984	0,2022	0,1972
	Erro Máximo (%)	8,1945	14,2247	8,7090	10,4639	10,2354	9,9951	9,4547	9,0967	9,3200
	Erro Máximo (MW)	2,9707	3,3839	2,7463	1,8045	1,9383	2,0920	1,6525	1,7139	1,4320
	Erro Médio (MW)	0,2914	0,2996	0,2825	0,1731	0,1689	0,1725	0,1836	0,1816	0,1838
	MAPE (%)	1,0553	1,0776	1,0254	1,1001	1,0616	1,0893	1,1554	1,1509	1,1627
	MAPEm (%)	0,6395	0,6576	0,6200	0,6269	0,6118	0,6246	0,6831	0,6757	0,6837
	RMSE (MW)	0,4279	0,4589	0,4125	0,2530	0,2535	0,2531	0,2703	0,2717	0,2695
	SSE (MW)	184,5930	212,2529	171,4979	64,4991	64,7864	64,5552	73,6278	74,4124	73,1951
Teste	Desvio Padrão Erro (MW)	0,6422	0,4180	0,6624	0,2002	0,2046	0,2249	0,2406	0,2642	0,2756
	Erro Máximo (%)	13,0288	9,8610	12,7585	7,9693	8,9977	8,7121	9,1302	11,3231	12,7477
	Erro Máximo (MW)	5,9155	3,6243	5,2195	1,3015	1,1933	1,1554	1,9127	1,4376	1,6040
	Erro Médio (MW)	0,5015	0,3482	0,7872	0,2151	0,2366	0,2480	0,2539	0,3106	0,2896
	MAPE (%)	1,6191	1,1876	2,7196	1,4098	1,5708	1,6172	1,7449	2,2270	1,9799
	MAPEm (%)	1,0854	0,7536	1,7036	0,8132	0,8944	0,9375	1,0205	1,2485	1,1642
	RMSE (MW)	0,8141	0,5436	1,0282	0,2936	0,3126	0,3345	0,3495	0,4075	0,3996
	SSE (MW)	222,6605	99,2827	355,1946	28,9732	32,8244	37,6046	41,0406	55,7924	53,6395
TesteRecursivo	Desvio Padrão Erro (MW)	1,8472	2,0214	2,2798	0,4001	0,4547	0,5789	0,4981	0,6520	0,6357
	Erro Máximo (%)	25,3931	27,7929	32,1422	13,1127	17,0318	17,9513	20,5611	29,2801	22,9542
	Erro Máximo (MW)	7,7898	8,8496	8,4011	2,3596	2,1517	2,5688	2,2573	3,4671	3,2190
	Erro Médio (MW)	2,5778	2,4784	3,2290	0,4766	0,7744	0,8544	0,6618	0,7579	0,6399
	MAPE (%)	8,7699	8,5026	11,6194	3,2445	5,2534	5,7393	4,6998	5,5395	4,5243
	MAPEm (%)	5,5788	5,3637	6,9881	1,8015	2,9273	3,2300	2,6604	3,0467	2,5720
	RMSE (MW)	3,1697	3,1963	3,9507	0,6219	0,8977	1,0316	0,8279	0,9991	0,9013
	SSE (MW)	3375,7526	3432,6018	5244,3376	129,9410	270,7491	357,5753	230,2885	335,4115	272,9252

Tabela 31 - Grupo A – TDE: Precisão com Carga e Temperatura Ambiente

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,2542	0,2644	0,2749	0,2908	0,2947	0,2944	0,2472	0,2482	0,2533
	Erro Máximo (%)	8,4656	7,8191	8,6934	16,0295	15,6945	16,1228	8,1766	8,1100	7,1368
	Erro Máximo (MW)	2,7312	2,7525	2,9891	2,3210	2,5030	2,4773	1,6350	1,7888	1,7198
	Erro Médio (MW)	0,2415	0,2418	0,2510	0,2735	0,2702	0,2698	0,2579	0,2604	0,2592
	MAPE (%)	0,9133	0,9070	0,9421	1,1055	1,0859	1,0859	1,0607	1,0677	1,0562
	MAPEm (%)	0,6544	0,6551	0,6802	0,7123	0,7037	0,7025	0,7008	0,7077	0,7044
	RMSE (MW)	0,3505	0,3582	0,3722	0,3991	0,3997	0,3992	0,3571	0,3597	0,3624
	SSE (MW)	123,8441	129,3271	139,6155	160,5341	161,0301	160,6611	128,5711	130,4039	132,3512
Teste	Desvio Padrão Erro (MW)	0,3506	0,3281	0,3565	0,2809	0,2845	0,3001	0,3276	0,3552	0,4700
	Erro Máximo (%)	8,0369	8,0550	8,6322	13,5809	8,5379	10,4271	8,5849	11,8374	17,7158
	Erro Máximo (MW)	2,4550	2,3728	2,5429	1,9035	1,6236	1,6259	2,0052	1,7397	3,0849
	Erro Médio (MW)	0,4260	0,3384	0,3795	0,2958	0,3185	0,3454	0,3911	0,4876	0,5144
	MAPE (%)	1,3613	1,0645	1,1819	1,2512	1,3672	1,4480	1,6459	2,2375	2,2640
	MAPEm (%)	1,0180	0,8085	0,9068	0,8064	0,8681	0,9415	1,0647	1,3274	1,4006
	RMSE (MW)	0,5514	0,4710	0,5203	0,4076	0,4267	0,4573	0,5098	0,6029	0,6963
	SSE (MW)	102,1691	74,5390	90,9714	55,8295	61,1879	70,2555	87,3374	122,1326	162,9185
TesteRecursivo	Desvio Padrão Erro (MW)	1,3509	1,2371	1,1859	0,5718	0,7442	0,6040	0,7448	1,0426	1,3223
	Erro Máximo (%)	24,7252	20,2868	16,7828	20,6063	19,1341	18,6836	17,8758	27,3238	53,8487
	Erro Máximo (MW)	7,8220	6,1953	5,2066	2,8883	3,2075	2,9592	3,7470	4,9394	8,1554
	Erro Médio (MW)	2,1827	1,3268	1,7440	0,6574	0,9778	1,0385	1,0554	1,3413	1,7221
	MAPE (%)	7,1278	4,4343	5,3761	2,9270	4,3152	4,4195	4,5439	6,4609	7,9530
	MAPEm (%)	5,2156	3,1703	4,1672	1,7922	2,6654	2,8309	2,8734	3,6517	4,6885
	RMSE (MW)	2,5659	1,8128	2,1080	0,8707	1,2281	1,2009	1,2911	1,6979	2,1700
	SSE (MW)	2212,1381	1104,1238	1493,0546	254,7354	506,7334	484,5880	560,1018	968,5944	1582,2223

Tabela 32 - Grupo A – SRA: Precisão com Carga e Temperatura Ambiente

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,1570	0,1618	0,1630	0,1847	0,1884	0,1875	0,2081	0,2071	0,2116
	Erro Máximo (%)	15,9654	14,0295	14,2832	23,0456	21,5857	22,3225	15,2738	16,0408	16,9550
	Erro Máximo (MW)	1,1668	1,2375	1,1891	1,3944	1,3158	1,3911	1,7473	1,6527	1,8993
	Erro Médio (MW)	0,1871	0,1857	0,1911	0,2163	0,2198	0,2165	0,2282	0,2298	0,2282
	MAPE (%)	1,7392	1,7149	1,7739	2,2272	2,2583	2,2249	2,2574	2,2761	2,2701
	MAPEm (%)	1,2113	1,2022	1,2370	1,4566	1,4804	1,4578	1,4694	1,4796	1,4691
	RMSE (MW)	0,2442	0,2463	0,2511	0,2844	0,2895	0,2863	0,3088	0,3093	0,3111
	SSE (MW)	60,1307	61,1453	63,5794	81,5251	84,4744	82,6372	96,1125	96,4348	97,5556
Teste	Desvio Padrão Erro (MW)	0,1971	0,2049	0,1827	0,2117	0,2527	0,2130	0,2357	0,2684	0,2629
	Erro Máximo (%)	17,6131	16,4377	11,9289	17,0170	13,5570	16,5561	16,1271	14,9242	15,0437
	Erro Máximo (MW)	1,0334	1,4288	0,9637	1,4568	1,3159	1,3450	1,6152	2,2785	1,7589
	Erro Médio (MW)	0,2309	0,2380	0,2459	0,2444	0,3279	0,2551	0,3148	0,3157	0,3634
	MAPE (%)	2,1238	2,2157	2,3502	2,5112	3,2027	2,7057	3,2888	3,0484	4,0336
	MAPEm (%)	1,4932	1,5393	1,5904	1,6913	2,2694	1,7654	2,0621	2,0681	2,3800
	RMSE (MW)	0,3034	0,3138	0,3062	0,3231	0,4138	0,3321	0,3931	0,4141	0,4483
	SSE (MW)	30,9321	33,0952	31,4969	35,0868	57,5251	37,0560	51,9207	57,6276	67,5198
TesteRecursivo	Desvio Padrão Erro (MW)	0,4347	0,5394	0,5587	0,8159	1,1229	0,9384	0,6726	0,7004	0,7658
	Erro Máximo (%)	46,7918	39,4121	39,9885	31,8517	46,6422	61,0727	39,4227	26,4191	56,7811
	Erro Máximo (MW)	2,5862	2,6286	2,6670	4,1555	5,5508	5,1614	3,2426	3,6058	3,1137
	Erro Médio (MW)	0,5586	0,7543	0,8414	1,0661	2,1411	1,2271	0,9593	0,7613	1,2804
	MAPE (%)	5,2331	7,3754	8,6901	10,7019	20,5946	13,8826	10,5029	7,1271	15,0189
	MAPEm (%)	3,6125	4,8782	5,4418	7,3777	14,8171	8,4923	6,2832	4,9869	8,3865
	RMSE (MW)	0,7074	0,9268	1,0096	1,3417	2,4169	1,5439	1,1710	1,0338	1,4913
	SSE (MW)	168,1326	288,6200	342,4630	604,8540	1962,6832	800,9365	460,7508	359,0851	747,2964

Tabela 33 - Grupo A – ISS: Precisão com Carga e Temperatura Ambiente

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,3517	0,4261	0,3972	0,4127	0,4070	0,4095	0,3812	0,3912	0,3680
	Erro Máximo (%)	6,8211	8,6937	7,1868	13,4376	12,9357	13,0821	8,5105	9,1244	8,4969
	Erro Máximo (MW)	2,4744	3,1536	2,6070	4,5280	4,3589	4,4082	3,6879	3,9540	3,6821
	Erro Médio (MW)	0,4104	0,4556	0,4452	0,3980	0,3954	0,3900	0,4035	0,4001	0,4090
	MAPE (%)	1,1165	1,2385	1,2095	1,0608	1,0555	1,0403	1,1058	1,0942	1,1229
	MAPEm (%)	0,8455	0,9386	0,9172	0,7610	0,7560	0,7458	0,8302	0,8231	0,8414
	RMSE (MW)	0,5404	0,6237	0,5965	0,5732	0,5673	0,5653	0,5550	0,5594	0,5500
	SSE (MW)	294,3698	392,0711	358,6899	331,1524	324,3920	322,1764	310,4466	315,4201	304,9353
Teste	Desvio Padrão Erro (MW)	0,4891	0,6334	0,5371	0,4820	0,5861	0,3926	1,0150	0,5559	0,5719
	Erro Máximo (%)	8,0353	12,3047	9,6681	11,9776	11,2193	12,2995	20,2987	12,6376	12,3075
	Erro Máximo (MW)	3,4079	4,6661	3,5413	4,1676	3,9038	4,2797	4,8551	3,7142	4,0789
	Erro Médio (MW)	0,5113	0,6561	0,6775	0,5840	0,9837	0,4257	1,0728	0,6369	0,6950
	MAPE (%)	1,2861	1,6661	1,7261	1,5059	2,6081	1,1353	3,4833	1,7873	2,0084
	MAPEm (%)	1,0410	1,3359	1,3794	1,1073	1,8650	0,8071	2,3997	1,4246	1,5545
	RMSE (MW)	0,7071	0,9113	0,8641	0,7568	1,1446	0,5787	1,4758	0,8448	0,8995
	SSE (MW)	167,9837	279,0307	250,8800	192,4363	440,2257	112,5311	731,8295	239,8095	271,8691
TesteRecursivo	Desvio Padrão Erro (MW)	1,5347	2,6093	5,0903	1,5501	2,0840	1,1139	2,8920	1,1700	1,4812
	Erro Máximo (%)	28,2591	35,0583	73,6774	14,7855	30,4931	18,1353	53,4453	19,1492	25,2312
	Erro Máximo (MW)	8,3506	10,4909	22,0565	6,6226	9,5931	6,3103	12,6700	5,6279	6,1898
	Erro Médio (MW)	2,0975	3,8148	5,8779	2,8698	4,7941	1,6926	3,1400	1,7195	1,9732
	MAPE (%)	5,3641	9,6908	15,8658	7,3855	12,7938	4,5733	10,3390	4,7278	5,7235
	MAPEm (%)	4,2704	7,7668	11,9672	5,4407	9,0891	3,2089	7,0235	3,8461	4,4135
	RMSE (MW)	2,5976	4,6196	7,7707	3,2606	5,2262	2,0253	4,2660	2,0788	2,4659
	SSE (MW)	2267,2099	7170,5526	20289,056	3572,1009	9177,3371	1378,2007	6114,7680	1452,0391	2043,1443

Tabela 34 - Grupo A – SAD: Precisão com Carga e Temperatura Ambiente

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,2405	0,2357	0,2417	0,2363	0,2365	0,2357	0,2021	0,2037	0,1999
	Erro Máximo (%)	35,2950	43,1733	37,4056	44,5045	50,1395	51,0314	29,5085	31,2370	33,1345
	Erro Máximo (MW)	1,7575	1,9371	1,7517	1,7947	2,0220	2,0580	1,3342	1,3263	1,3770
	Erro Médio (MW)	0,2718	0,2663	0,2768	0,2760	0,2754	0,2798	0,2454	0,2457	0,2433
	MAPE (%)	2,8352	2,7393	2,8731	2,6511	2,6131	2,6599	2,6859	2,6577	2,6483
	MAPEm (%)	1,5343	1,5034	1,5627	1,5789	1,5754	1,6007	1,4989	1,5010	1,4863
	RMSE (MW)	0,3628	0,3556	0,3674	0,3632	0,3629	0,3658	0,3178	0,3191	0,3149
	SSE (MW)	132,6858	127,4443	136,0508	132,9956	132,7675	134,8628	101,8129	102,6542	99,9393
Teste	Desvio Padrão Erro (MW)	0,4409	0,4200	0,4727	0,2187	0,2237	0,2642	0,2551	0,2538	0,2355
	Erro Máximo (%)	27,6820	27,9322	31,2396	32,0659	31,4865	37,0470	27,2599	23,4978	19,9584
	Erro Máximo (MW)	1,9826	1,9708	2,1183	1,6923	1,6617	1,9552	1,4843	1,3098	1,2972
	Erro Médio (MW)	0,4929	0,4824	0,5238	0,2793	0,2635	0,3807	0,3113	0,3098	0,2908
	MAPE (%)	3,9478	3,9038	4,2399	2,7725	2,6752	4,2786	3,4918	3,3896	3,0286
	MAPEm (%)	2,7674	2,7086	2,9412	1,7139	1,6171	2,3364	1,9048	1,8959	1,7794
	RMSE (MW)	0,6608	0,6392	0,7051	0,3545	0,3454	0,4632	0,4022	0,4002	0,3739
	SSE (MW)	146,7305	137,2990	167,0413	42,2340	40,0841	72,0825	54,3476	53,8230	46,9800
TesteRecursivo	Desvio Padrão Erro (MW)	2,1767	2,4380	2,3630	0,5617	0,5541	0,9928	1,1157	1,1358	1,1413
	Erro Máximo (%)	67,1049	88,4361	90,2579	62,6444	56,3427	141,5601	90,3319	91,3355	98,0621
	Erro Máximo (MW)	7,9705	9,6176	8,2551	2,3606	2,6226	4,7211	4,9121	4,9104	4,7355
	Erro Médio (MW)	1,6881	2,0957	1,9463	0,7079	0,6845	1,8761	1,0178	1,1158	1,2588
	MAPE (%)	13,9507	17,9257	17,0431	7,8451	7,8823	22,7739	13,6085	14,4769	15,8649
	MAPEm (%)	9,4785	11,7669	10,9283	4,3444	4,2010	11,5142	6,2289	6,8284	7,7034
	RMSE (MW)	2,7520	3,2122	3,0587	0,9031	0,8801	2,1219	1,5090	1,5910	1,6980
	SSE (MW)	2544,6963	3466,8719	3143,3943	274,0507	260,2801	1512,7798	765,0853	850,5203	968,7255

Tabela 35 - Grupo A – ICO: Precisão com Carga

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,1609	0,1619	0,1585	0,1211	0,1239	0,1292	0,0934	0,0918	0,0920
	Erro Máximo (%)	12,5121	13,5972	11,3575	7,8928	7,9076	6,9694	8,0918	7,3915	8,1059
	Erro Máximo (MW)	1,2054	1,2440	1,2309	0,7484	0,7187	0,8558	0,5934	0,6099	0,5831
	Erro Médio (MW)	0,1569	0,1585	0,1576	0,1345	0,1332	0,1426	0,1080	0,1068	0,1061
	MAPE (%)	1,2806	1,2957	1,2982	1,2838	1,2574	1,3537	1,1565	1,1446	1,1449
	MAPEm (%)	0,4894	0,4946	0,4916	0,5714	0,5660	0,6057	0,6322	0,6249	0,6213
	RMSE (MW)	0,2247	0,2265	0,2234	0,1809	0,1819	0,1924	0,1428	0,1408	0,1404
	SSE (MW)	50,8861	51,7130	50,3192	32,9950	33,3511	37,3033	20,5550	19,9699	19,8716
Teste	Desvio Padrão Erro (MW)	0,3311	0,3616	0,3299	0,3041	0,2365	0,2776	0,1449	0,2159	0,1679
	Erro Máximo (%)	15,7563	14,5165	14,4168	10,4688	10,9691	10,7300	9,9374	7,6388	8,9711
	Erro Máximo (MW)	1,9516	2,3542	2,1473	1,3819	1,1997	1,2956	0,8021	1,1916	0,9411
	Erro Médio (MW)	0,2888	0,3000	0,2724	0,2856	0,2757	0,3470	0,1712	0,2252	0,1845
	MAPE (%)	1,9115	2,1784	1,8234	2,6055	3,0788	3,3709	1,6942	1,9435	1,7565
	MAPEm (%)	0,8546	0,8875	0,8058	1,6314	1,5748	1,9823	0,9482	1,2474	1,0222
	RMSE (MW)	0,4390	0,4695	0,4274	0,4168	0,3630	0,4441	0,2241	0,3118	0,2493
	SSE (MW)	64,7512	74,0509	61,3744	58,3780	44,2747	66,2741	16,8780	32,6559	20,8785
TesteRecursivo	Desvio Padrão Erro (MW)	2,4689	2,4880	3,3141	4,3743	2,3558	2,4825	0,3493	0,5521	0,4361
	Erro Máximo (%)	61,4086	124,9719	78,7482	117,9213	107,8412	57,4620	17,3151	13,9880	18,0580
	Erro Máximo (MW)	9,1567	10,4021	12,6508	13,9144	9,7459	8,9968	1,7371	2,4493	2,1302
	Erro Médio (MW)	3,7363	4,7169	5,5041	5,9360	4,0145	2,9942	0,4618	0,6305	0,4693
	MAPE (%)	24,2662	43,8672	36,1638	52,3767	41,4114	25,4910	4,5781	5,2372	4,2258
	MAPEm (%)	11,0539	13,9552	16,2841	33,9090	22,9326	17,1041	2,5583	3,4929	2,5998
	RMSE (MW)	4,4763	5,3311	6,4223	7,3698	4,6529	3,8871	0,5787	0,8375	0,6402
	SSE (MW)	6732,4990	9549,4791	13858,546	18249,560	7274,3603	5076,9313	112,5281	235,6871	137,7128

Tabela 36 - Grupo A – INE: Precisão com Carga

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,3936	0,3690	0,3553	0,1882	0,1841	0,1932	0,2048	0,2023	0,1994
	Erro Máximo (%)	35,0507	33,8571	21,4644	9,5843	9,6872	10,3237	8,2392	8,8075	8,2023
	Erro Máximo (MW)	7,1944	6,9494	4,4057	1,5504	1,5671	1,8256	1,5336	1,5347	1,5867
	Erro Médio (MW)	0,3167	0,3050	0,3143	0,1738	0,1743	0,1747	0,1844	0,1844	0,1842
	MAPE (%)	1,1457	1,1197	1,1453	1,1050	1,0978	1,0937	1,1563	1,1620	1,1613
	MAPEm (%)	0,6951	0,6694	0,6898	0,6294	0,6312	0,6327	0,6859	0,6860	0,6853
	RMSE (MW)	0,5051	0,4786	0,4742	0,2561	0,2534	0,2604	0,2755	0,2737	0,2714
	SSE (MW)	257,1276	230,9096	226,6696	66,1128	64,7285	68,3393	76,4858	75,4836	74,2259
Teste	Desvio Padrão Erro (MW)	0,6178	0,5657	0,5169	0,2308	0,2614	0,2496	0,3725	0,2810	0,2631
	Erro Máximo (%)	10,4275	10,4757	8,2549	11,7794	14,7005	10,7457	16,4923	10,6223	16,1422
	Erro Máximo (MW)	4,5197	3,6736	3,3771	1,5622	1,9136	1,4251	1,6809	2,3810	1,9763
	Erro Médio (MW)	0,5078	0,5375	0,4780	0,4396	0,8284	0,4501	0,4547	0,2724	0,2754
	MAPE (%)	1,6716	1,8090	1,6593	3,0889	5,9689	3,1388	3,2502	1,8008	1,8241
	MAPEm (%)	1,0989	1,1633	1,0345	1,6618	3,1317	1,7015	1,8276	1,0950	1,1070
	RMSE (MW)	0,7990	0,7797	0,7034	0,4963	0,8686	0,5145	0,5874	0,3911	0,3806
	SSE (MW)	214,4949	204,2893	166,2658	82,7772	253,4734	88,9364	115,9456	51,3861	48,6713
TesteRecursivo	Desvio Padrão Erro (MW)	2,1705	2,4183	2,2280	0,6069	0,9095	0,9125	1,1188	0,4968	0,4827
	Erro Máximo (%)	28,3888	36,1152	39,5097	31,6798	49,5594	32,7302	43,7278	16,5383	17,4787
	Erro Máximo (MW)	9,5794	13,8347	10,3928	3,8881	5,7527	4,0170	4,6047	2,9356	2,3649
	Erro Médio (MW)	2,6542	3,0762	2,7161	1,7825	3,3466	2,1010	1,3897	0,6887	0,6222
	MAPE (%)	9,4415	10,6778	9,9300	12,8338	24,5482	15,0363	10,2606	4,7398	4,1267
	MAPEm (%)	5,7443	6,6574	5,8781	6,7383	12,6511	7,9424	5,5864	2,7682	2,5010
	RMSE (MW)	3,4267	3,9107	3,5109	1,8827	3,4676	2,2900	1,7831	0,8487	0,7870
	SSE (MW)	3945,3611	5138,7413	4141,7071	1190,9427	4040,1587	1762,0768	1068,2756	242,0250	208,1301

Tabela 37 - Grupo A – TDE: Precisão com Carga

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,2756	0,2859	0,2715	0,2953	0,2956	0,3026	0,2590	0,2473	0,2499
	Erro Máximo (%)	7,5701	8,7261	6,7543	16,4911	15,8957	15,9303	8,1115	7,7696	7,9140
	Erro Máximo (MW)	2,7828	3,0004	2,2655	2,5215	2,5363	2,6057	2,0221	1,7048	1,5825
	Erro Médio (MW)	0,2537	0,2574	0,2521	0,2810	0,2742	0,2740	0,2674	0,2574	0,2628
	MAPE (%)	0,9456	0,9589	0,9376	1,1300	1,0992	1,1070	1,1007	1,0627	1,0838
	MAPEm (%)	0,6874	0,6976	0,6830	0,7318	0,7141	0,7136	0,7268	0,6996	0,7140
	RMSE (MW)	0,3745	0,3846	0,3703	0,4076	0,4031	0,4081	0,3722	0,3569	0,3625
	SSE (MW)	141,3566	149,1271	138,2554	167,4280	163,7660	167,9072	139,6679	128,4087	132,4677
Teste	Desvio Padrão Erro (MW)	0,4152	0,3906	0,3897	0,3032	0,2846	0,3484	0,3107	0,3176	0,5156
	Erro Máximo (%)	7,3077	9,5026	5,8681	11,2116	11,6872	9,4747	8,9830	10,5993	13,1207
	Erro Máximo (MW)	2,3118	2,7993	1,7794	1,5715	1,6381	1,9192	1,8392	1,8877	2,9664
	Erro Médio (MW)	0,7195	0,3741	0,4462	0,3372	0,4299	0,5124	0,4065	0,3628	0,8290
	MAPE (%)	2,2649	1,1668	1,3375	1,4199	1,9440	2,2392	1,7819	1,5537	3,9336
	MAPEm (%)	1,7193	0,8938	1,0661	0,9192	1,1719	1,3968	1,1068	0,9878	2,2571
	RMSE (MW)	0,8304	0,5404	0,5920	0,4532	0,5154	0,6193	0,5114	0,4819	0,9759
	SSE (MW)	231,6942	98,1150	117,7584	69,0002	89,2375	128,8838	87,8662	78,0148	319,9978
TesteRecursivo	Desvio Padrão Erro (MW)	2,1090	1,3942	1,9719	0,7792	1,2627	1,3090	0,6708	0,8075	1,3566
	Erro Máximo (%)	31,5879	22,5248	31,3687	22,8125	47,1194	23,7408	17,2062	19,9104	33,1543
	Erro Máximo (MW)	12,1842	6,8788	10,7133	3,2001	6,6044	5,3202	3,2199	4,3760	5,8145
	Erro Médio (MW)	6,5440	1,8655	5,6170	0,9875	3,4445	1,9501	1,0335	0,9833	2,4303
	MAPE (%)	20,5484	5,8062	17,7030	4,2795	15,8806	8,5862	4,6758	4,4632	11,6671
	MAPEm (%)	15,6368	4,4576	13,4218	2,6919	9,3898	5,3159	2,8138	2,6772	6,6165
	RMSE (MW)	6,8745	2,3277	5,9521	1,2571	3,6680	2,3476	1,2316	1,2716	2,7823
	SSE (MW)	15878,9688	1820,4671	11903,7502	531,0198	4520,7375	1851,7144	509,6688	543,3148	2601,0159

Tabela 38 - Grupo A – SRA: Precisão com Carga

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,1608	0,1629	0,1637	0,1852	0,1873	0,1884	0,2119	0,2088	0,2096
	Erro Máximo (%)	14,6928	14,9569	14,9954	22,2902	22,3291	23,0283	15,6521	14,3086	16,0103
	Erro Máximo (MW)	1,2322	1,2666	1,0761	1,3702	1,3945	1,3497	1,7129	1,6917	1,7421
	Erro Médio (MW)	0,1903	0,1901	0,1935	0,2160	0,2145	0,2126	0,2293	0,2268	0,2275
	MAPE (%)	1,7605	1,7668	1,7851	2,2264	2,2062	2,1972	2,2744	2,2421	2,2538
	MAPEm (%)	1,2316	1,2306	1,2526	1,4547	1,4442	1,4318	1,4761	1,4599	1,4645
	RMSE (MW)	0,2491	0,2503	0,2534	0,2845	0,2847	0,2840	0,3121	0,3082	0,3093
	SSE (MW)	62,5415	63,1623	64,7257	81,5916	81,7013	81,3201	98,1832	95,7489	96,4036
Teste	Desvio Padrão Erro (MW)	0,2619	0,2128	0,2093	0,1966	0,2099	0,2132	0,2454	0,2375	0,2314
	Erro Máximo (%)	19,4107	13,0440	13,9653	17,9257	17,6567	17,5425	13,1467	11,2031	11,3181
	Erro Máximo (MW)	2,7428	1,8753	1,2473	1,1544	1,3189	1,2587	1,7392	1,6334	1,6200
	Erro Médio (MW)	0,2480	0,2539	0,2637	0,2258	0,2267	0,2243	0,3007	0,2865	0,2794
	MAPE (%)	2,2769	2,3669	2,5105	2,2859	2,3063	2,2607	3,0860	2,8928	2,8129
	MAPEm (%)	1,6039	1,6417	1,7054	1,5628	1,5689	1,5524	1,9699	1,8768	1,8299
	RMSE (MW)	0,3604	0,3310	0,3364	0,2992	0,3088	0,3093	0,3880	0,3719	0,3625
	SSE (MW)	43,6523	36,8156	38,0324	30,0800	32,0298	32,1416	50,5707	46,4823	44,1595
TesteRecursivo	Desvio Padrão Erro (MW)	0,6723	0,7422	0,8058	0,9396	0,8998	0,9680	0,5345	0,4748	0,4739
	Erro Máximo (%)	45,9193	56,7891	60,8458	35,3008	34,7398	37,9208	31,0514	24,4547	21,0702
	Erro Máximo (MW)	5,0115	3,7876	4,0581	4,7336	4,8870	5,1466	2,6493	2,5476	2,0872
	Erro Médio (MW)	0,7963	1,3436	0,9941	0,9359	1,1651	1,3919	0,8142	0,6774	0,6980
	MAPE (%)	7,9775	13,4027	10,4766	9,3111	12,0648	13,8510	8,5445	6,9263	7,0501
	MAPEm (%)	5,1497	8,6895	6,4288	6,4770	8,0633	9,6326	5,3330	4,4368	4,5718
	RMSE (MW)	1,0415	1,5345	1,2789	1,3252	1,4713	1,6946	0,9735	0,8268	0,8432
	SSE (MW)	364,4451	791,1457	549,5465	590,0930	727,3471	964,8317	318,4341	229,6942	238,9188

Tabela 39 - Grupo A – ISS: Precisão com Carga

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,3696	0,3778	0,3782	0,4151	0,4120	0,4158	0,3899	0,3833	0,3864
	Erro Máximo (%)	7,2948	8,6030	7,2343	13,2823	13,5291	13,6913	9,9108	8,5831	9,9112
	Erro Máximo (MW)	2,6918	3,3493	2,8164	4,4756	4,5588	4,6135	4,2947	3,7194	4,2949
	Erro Médio (MW)	0,4238	0,4172	0,4181	0,4067	0,3995	0,3865	0,4083	0,4081	0,4064
	MAPE (%)	1,1487	1,1345	1,1327	1,0859	1,0662	1,0301	1,1177	1,1174	1,1158
	MAPEm (%)	0,8732	0,8594	0,8613	0,7777	0,7638	0,7389	0,8400	0,8396	0,8361
	RMSE (MW)	0,5622	0,5627	0,5636	0,5810	0,5737	0,5675	0,5644	0,5598	0,5607
	SSE (MW)	318,6375	319,1278	320,2420	340,3072	331,8040	324,6296	321,1058	315,8324	316,8584
Teste	Desvio Padrão Erro (MW)	0,5764	0,5865	0,5195	0,4254	0,4309	0,4158	0,6630	0,7608	0,6895
	Erro Máximo (%)	9,5816	10,8347	8,7246	12,6837	13,9790	12,6063	11,4044	16,5644	16,4939
	Erro Máximo (MW)	3,8578	3,6141	4,1706	4,4134	4,8640	4,3864	5,0688	5,2253	4,8475
	Erro Médio (MW)	0,5738	0,5567	0,5350	0,4908	0,4405	0,4030	0,8032	0,8572	0,6319
	MAPE (%)	1,4519	1,4094	1,3351	1,3613	1,1968	1,0734	2,2974	2,5664	1,9196
	MAPEm (%)	1,1683	1,1335	1,0893	0,9305	0,8350	0,7641	1,7965	1,9173	1,4134
	RMSE (MW)	0,8127	0,8081	0,7452	0,6491	0,6158	0,5786	1,0409	1,1454	0,9345
	SSE (MW)	221,9404	219,3908	186,6034	141,5663	127,3987	112,4900	364,0123	440,7913	293,4228
TesteRecursivo	Desvio Padrão Erro (MW)	1,9706	1,7098	2,4178	1,7855	2,9165	1,2043	1,6638	1,5949	1,4113
	Erro Máximo (%)	38,7590	34,5655	25,9788	25,5542	41,2381	16,0433	26,5128	30,2277	27,3773
	Erro Máximo (MW)	11,4534	9,9329	10,3942	7,6229	12,3356	5,7939	7,3903	10,0178	8,0461
	Erro Médio (MW)	2,8359	2,1505	3,5745	3,0128	2,5109	1,5458	2,6076	2,4586	2,0977
	MAPE (%)	7,2668	5,5836	9,0256	8,6588	7,4816	4,2314	7,4212	7,2784	6,2720
	MAPEm (%)	5,7737	4,3783	7,2775	5,7118	4,7604	2,9306	5,8324	5,4994	4,6920
	RMSE (MW)	3,4517	2,7458	4,3134	3,5007	3,8452	1,9584	3,0918	2,9293	2,5271
	SSE (MW)	4003,0871	2533,1601	6251,3118	4117,7065	4967,9407	1288,6545	3211,9066	2883,2195	2145,7849

Tabela 40 - Grupo A – SAD: Precisão com Carga

		Estação climática / Experimento								
		Inverno			Outono			Verão		
Fase	Erro	exp1	exp2	exp3	exp1	exp2	exp3	exp1	exp2	exp3
Treino	Desvio Padrão Erro (MW)	0,2405	0,2440	0,2366	0,2436	0,2386	0,2408	0,2097	0,2106	0,2106
	Erro Máximo (%)	47,7942	50,4982	40,9968	49,2724	48,1187	45,6294	36,1757	35,2001	35,2001
	Erro Máximo (MW)	2,0765	2,0614	1,8913	1,9870	1,9405	2,0232	1,3264	1,3296	1,3296
	Erro Médio (MW)	0,2656	0,2668	0,2690	0,2823	0,2818	0,2792	0,2484	0,2493	0,2493
	MAPE (%)	2,7800	2,7300	2,7830	2,7071	2,7145	2,6847	2,6770	2,6770	2,6770
	MAPEm (%)	1,4996	1,5060	1,5185	1,6150	1,6123	1,5973	1,5171	1,5225	1,5225
	RMSE (MW)	0,3583	0,3614	0,3582	0,3728	0,3692	0,3687	0,3250	0,3263	0,3263
	SSE (MW)	129,3716	131,6686	129,3213	140,0794	137,3759	136,9906	106,4608	107,2949	107,2949
Teste	Desvio Padrão Erro (MW)	0,2899	0,2648	0,3335	0,2520	0,2633	0,2563	0,2376	0,2256	0,2256
	Erro Máximo (%)	20,3076	19,4858	25,4843	35,5162	37,0631	38,1570	27,2881	25,5322	25,5322
	Erro Máximo (MW)	1,7965	1,7276	1,6788	1,8744	1,9560	2,0138	1,3462	1,3356	1,3356
	Erro Médio (MW)	0,3595	0,3278	0,4751	0,3364	0,3696	0,3321	0,2784	0,2706	0,2706
	MAPE (%)	2,8146	2,5859	3,7064	3,7670	4,1186	3,6927	2,7579	2,6096	2,6096
	MAPEm (%)	2,0187	1,8406	2,6678	2,0649	2,2681	2,0385	1,7035	1,6558	1,6558
	RMSE (MW)	0,4616	0,4212	0,5802	0,4201	0,4535	0,4193	0,3658	0,3521	0,3521
	SSE (MW)	71,5865	59,6053	113,1088	59,3022	69,1162	59,0698	44,9549	41,6551	41,6551
TesteRecursivo	Desvio Padrão Erro (MW)	1,8308	1,7942	1,5839	0,7375	0,7797	0,8181	0,6147	0,4796	0,4796
	Erro Máximo (%)	68,7710	59,6155	84,1618	96,5270	106,2997	103,6846	66,2873	58,8633	58,8633
	Erro Máximo (MW)	7,8787	7,9607	8,0873	3,8050	3,9481	3,5021	3,4400	2,9507	2,9507
	Erro Médio (MW)	1,9999	2,5228	2,4105	1,2657	1,5448	1,2609	0,7996	0,6560	0,6560
	MAPE (%)	15,6206	18,8322	19,3524	15,0857	17,8345	15,6435	8,4249	6,3844	6,3844
	MAPEm (%)	11,2292	14,1652	13,5349	7,7683	9,4810	7,7383	4,8931	4,0147	4,0147
	RMSE (MW)	2,7095	3,0942	2,8831	1,4644	1,7299	1,5023	1,0080	0,8122	0,8122
	SSE (MW)	2466,7405	3216,9330	2792,8500	720,4963	1005,4573	758,3670	341,3965	221,6494	221,6494

8.8 Experimentos do Grupo A: Variáveis selecionadas na Adaptação

Tabela 41 - Grupo A – ICO: Carga e Todas as Variáveis Climáticas

Época	Tipo	Classe	Deslocamento	Estação												Total uso (%)
				Inverno				Outono				Verão				
				exp1	exp2	exp3	Uso (%)	exp1	exp2	exp3	Uso (%)	exp1	exp2	exp3	Uso (%)	
tempo	dia semana	cosseno	0min	0	0	1	0,33	0	0	1	0,33	1	1	0	0,67	0,44
		seno	0min	1	0	0	0,33	1	1	0	0,67	0	1	1	0,67	0,56
	meia hora dia	cosseno	0min	0	1	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22
		seno	0min	1	1	1	1,00	1	0	1	0,67	0	1	0	0,33	0,67
	semana do ano	cosseno	0min	1	1	1	1,00	1	1	1	1,00	0	0	1	0,33	0,78
		seno	0min	1	0	0	0,33	0	1	1	0,67	0	0	0	0,00	0,33
agora	Carga	absoluto	30min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00
			60min	1	1	1	1,00	1	0	1	0,67	1	1	1	1,00	0,89
			90min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00
		derivada	30min	0	0	0	0,00	1	0	1	0,67	1	1	1	1,00	0,56
			60min	1	1	1	1,00	0	1	1	0,67	1	1	1	1,00	0,89
			derivada2	30min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00
	temperatura ambiente	absoluto	0min	0	0	0	0,00	1	0	0	0,33	0	1	0	0,33	0,22
			30min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
			60min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
			90min	0	0	0	0,00	0	1	1	0,67	1	0	0	0,33	0,33
		derivada	0min	0	0	0	0,00	0	0	0	0,00	1	1	0	0,67	0,22
			30min	0	0	0	0,00	0	1	0	0,33	1	0	0	0,33	0,22
			60min	0	0	0	0,00	1	1	0	0,67	0	1	0	0,33	0,33
		derivada2	0min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
			30min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11
		máximo	0min	0	0	0	0,00	1	1	0	0,67	1	1	0	0,67	0,44
			30min	0	0	0	0,00	1	1	1	1,00	1	1	0	0,67	0,67
			60min	0	0	0	0,00	1	0	0	0,33	1	0	0	0,33	0,22
	90min		0	0	0	0,00	1	0	0	0,33	1	0	0	0,33	0,22	
	umidade relativa do ar	absoluto	0min	0	0	1	0,33	0	0	1	0,33	0	0	0	0,00	0,22
			30min	0	1	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22
			60min	1	1	0	0,67	0	0	0	0,00	0	0	1	0,33	0,33
			90min	0	1	0	0,33	1	1	0	0,67	0	1	0	0,33	0,44
		derivada	0min	1	1	0	0,67	0	0	0	0,00	0	1	0	0,33	0,33
			30min	0	1	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22
			60min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22
		derivada2	0min	1	0	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22
			30min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
		máximo	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
	30min		1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
	60min		0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
	90min		0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
	radiação solar	absoluto	0min	0	1	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22
			30min	0	0	0	0,00	0	1	0	0,33	1	1	1	1,00	0,44
			60min	0	0	0	0,00	1	0	0	0,33	1	1	0	0,67	0,33
			90min	0	0	0	0,00	0	1	1	0,67	0	0	0	0,00	0,22
derivada		0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
		30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	

semana	pressão atmosférica		60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		derivada2	0min	0	0	1	0,33	0	0	0	0,00	1	0	0	0,33	0,22
			30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		máximo	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		média	0min	1	0	1	0,67	0	0	0	0,00	1	0	0	0,33	0,33
		mínimo	0min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11
		absoluto	0min	1	0	0	0,33	1	0	0	0,33	1	1	1	1,00	0,56
			30min	1	0	0	0,33	0	0	1	0,33	1	0	0	0,33	0,33
			60min	0	1	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22
			90min	1	1	1	1,00	0	0	1	0,33	1	1	0	0,67	0,67
	derivada	0min	0	1	0	0,33	0	0	0	0,00	0	1	1	0,67	0,33	
		30min	0	1	0	0,33	0	0	0	0,00	1	1	1	1,00	0,44	
		60min	0	1	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22	
	derivada2	0min	0	0	0	0,00	1	0	0	0,33	1	0	1	0,67	0,33	
		30min	1	0	0	0,33	0	0	1	0,33	1	1	1	1,00	0,56	
	máximo	0min	0	1	0	0,33	1	0	0	0,33	1	1	1	1,00	0,56	
	média	0min	1	1	1	1,00	1	1	0	0,67	1	1	1	1,00	0,89	
	mínimo	0min	1	0	1	0,67	0	0	0	0,00	1	1	1	1,00	0,56	
	velocidade e direção do vento	absoluto	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
			30min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			60min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22
			90min	0	1	1	0,67	0	1	0	0,33	0	0	0	0,00	0,33
		derivada	0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			30min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			60min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
		derivada2	0min	0	0	1	0,33	1	0	0	0,33	0	0	0	0,00	0,22
			30min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
		máximo	0min	0	1	0	0,33	1	1	0	0,67	0	0	0	0,00	0,33
		média	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		mínimo	0min	0	1	1	0,67	0	0	1	0,33	0	0	0	0,00	0,33
		coseno	0min	1	1	0	0,67	1	0	0	0,33	0	0	0	0,00	0,33
		seno	0min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
	carga	absoluto	0min	1	1	1	1,00	1	0	0	0,33	0	1	0	0,33	0,56
			30min	1	0	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22
			60min	0	1	0	0,33	0	0	1	0,33	0	1	1	0,67	0,44
			90min	1	0	0	0,33	1	0	0	0,33	0	1	0	0,33	0,33
		derivada	0min	1	1	0	0,67	1	0	1	0,67	0	1	1	0,67	0,67
			30min	1	0	1	0,67	1	1	0	0,67	1	1	0	0,67	0,67
			60min	0	1	0	0,33	0	1	0	0,33	0	1	0	0,33	0,33
		derivada2	0min	1	1	1	1,00	0	1	0	0,33	1	1	1	1,00	0,78
			30min	1	1	1	1,00	0	1	0	0,33	0	0	1	0,33	0,56
		máximo	0min	1	0	0	0,33	1	1	1	1,00	1	0	0	0,33	0,56
média		0min	1	1	1	1,00	1	1	1	1,00	1	0	1	0,67	0,89	
mínimo		0min	0	0	0	0,00	0	0	0	0,00	1	1	0	0,67	0,22	
temperatura ambiente		absoluto	0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			30min	0	1	1	0,67	1	1	0	0,67	0	1	0	0,33	0,56
		60min	0	0	1	0,33	1	1	0	0,67	1	1	0	0,67	0,56	
		90min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11	
	derivada	0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11	
		30min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11	

umidade relativa do ar	derivada2	60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
		0min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
		30min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
		0min	0	1	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22	
		0min	0	0	0	0,00	1	0	0	0,33	1	0	0	0,33	0,22	
	mínimo	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
	absoluto	0min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22	
		30min	1	1	1	1,00	0	0	1	0,33	0	0	0	0,00	0,44	
		60min	0	0	0	0,00	0	0	0	0,00	0	0	1	0,33	0,11	
		90min	0	1	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22	
		derivada	0min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			30min	1	1	1	1,00	0	0	0	0,00	0	0	0	0,00	0,33
60min			0	1	1	0,67	0	0	0	0,00	0	1	0	0,33	0,33	
derivada2		0min	0	0	0	0,00	0	0	0	0,00	0	0	1	0,33	0,11	
		30min	0	0	1	0,33	0	0	0	0,00	0	1	1	0,67	0,33	
máximo		0min	0	1	0	0,33	0	0	0	0,00	1	1	0	0,67	0,33	
média	0min	0	1	1	0,67	0	0	0	0,00	0	1	1	0,67	0,44		
mínimo	0min	0	0	1	0,33	0	0	0	0,00	1	1	1	1,00	0,44		
radiação solar	absoluto	0min	1	0	1	0,67	0	0	0	0,00	0	0	1	0,33	0,33	
		30min	1	1	1	1,00	1	0	0	0,33	0	0	0	0,00	0,44	
		60min	1	0	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22	
		90min	1	1	1	1,00	0	0	1	0,33	1	1	0	0,67	0,67	
	derivada	0min	1	1	0	0,67	0	0	0	0,00	1	0	0	0,33	0,33	
		30min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11	
		60min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11	
	derivada2	0min	0	0	0	0,00	0	0	0	0,00	1	1	0	0,67	0,22	
		30min	0	0	0	0,00	0	0	0	0,00	1	1	0	0,67	0,22	
	máximo	0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
	média	0min	0	1	0	0,33	0	0	0	0,00	1	1	1	1,00	0,44	
	mínimo	0min	0	0	0	0,00	0	0	0	0,00	1	1	0	0,67	0,22	
pressão atmosférica	absoluto	0min	0	1	0	0,33	0	0	0	0,00	1	0	1	0,67	0,33	
		30min	1	0	1	0,67	1	0	0	0,33	1	1	1	1,00	0,67	
		60min	0	1	1	0,67	0	0	1	0,33	1	1	1	1,00	0,67	
		90min	0	1	1	0,67	0	1	1	0,67	0	0	1	0,33	0,56	
	derivada	0min	0	0	0	0,00	0	1	1	0,67	1	0	0	0,33	0,33	
		30min	0	1	0	0,33	0	1	0	0,33	1	0	0	0,33	0,33	
		60min	0	1	1	0,67	0	0	0	0,00	1	0	0	0,33	0,33	
	derivada2	0min	0	1	0	0,33	0	1	0	0,33	0	0	0	0,00	0,22	
		30min	0	1	0	0,33	0	1	1	0,67	1	0	1	0,67	0,56	
	máximo	0min	1	1	0	0,67	1	0	1	0,67	1	1	1	1,00	0,78	
	média	0min	1	0	0	0,33	1	1	1	1,00	1	1	1	1,00	0,78	
	mínimo	0min	1	1	0	0,67	1	1	0	0,67	1	1	1	1,00	0,78	
velocidade e direção do vento	absoluto	0min	0	0	0	0,00	1	0	0	0,33	1	0	0	0,33	0,22	
		30min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11	
		60min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
		90min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
	derivada	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
		30min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11	
		60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
	derivada2	0min	0	0	0	0,00	1	0	0	0,33	1	0	0	0,33	0,22	

ano	carga		30min	1	0	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22		
		máximo	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00		
		média	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00		
		mínimo	0min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11		
		cosseno	0min	1	1	1	1,00	0	0	0	0,00	0	0	0	0,00	0,33		
		seno	0min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11		
	temperatura ambiente	absoluto		0min	0	1	0	0,33	1	1	0	0,67	0	1	0	0,33	0,44	
				30min	1	0	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22	
				60min	0	0	1	0,33	0	0	1	0,33	0	0	0	0,00	0,22	
				90min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11	
		derivada		0min	1	0	1	0,67	0	0	1	0,33	1	1	1	1,00	0,67	
				30min	0	0	0	0,00	1	1	1	1,00	1	0	0	0,33	0,44	
				60min	0	1	0	0,33	0	1	1	0,67	0	1	0	0,33	0,44	
		derivada2		0min	0	1	1	0,67	1	1	1	1,00	1	0	0	0,33	0,67	
				30min	1	1	0	0,67	1	0	0	0,33	0	0	1	0,33	0,44	
			máximo	0min	1	0	0	0,33	1	1	1	1,00	1	0	1	0,67	0,67	
			média	0min	0	0	1	0,33	1	1	0	0,67	0	0	1	0,33	0,44	
			mínimo	0min	1	1	1	1,00	0	0	1	0,33	1	0	1	0,67	0,67	
		umidade relativa do ar	absoluto		0min	0	0	0	0,00	0	0	1	0,33	1	0	0	0,33	0,22
					30min	0	0	0	0,00	0	0	1	0,33	0	1	0	0,33	0,22
					60min	0	0	0	0,00	0	0	1	0,33	1	1	0	0,67	0,33
					90min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11
			derivada		0min	0	0	1	0,33	0	1	0	0,33	0	1	0	0,33	0,33
					30min	0	0	0	0,00	0	1	0	0,33	1	0	0	0,33	0,22
				60min	0	0	0	0,00	1	0	0	0,33	1	1	0	0,67	0,33	
	derivada2			0min	0	0	0	0,00	0	1	0	0,33	1	0	0	0,33	0,22	
				30min	0	0	1	0,33	0	0	0	0,00	1	0	0	0,33	0,22	
			máximo	0min	0	0	1	0,33	0	1	0	0,33	0	0	0	0,00	0,22	
		média	0min	0	0	0	0,00	1	1	0	0,67	0	1	0	0,33	0,33		
		mínimo	0min	0	0	1	0,33	0	1	0	0,33	1	1	0	0,67	0,44		
	radiação solar	absoluto		0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
				30min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
				60min	1	0	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22	
				90min	0	1	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22	
		derivada		0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
				30min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
				60min	1	0	0	0,33	0	0	0	0,00	0	0	1	0,33	0,22	
		derivada2		0min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
				30min	1	0	0	0,33	0	0	0	0,00	0	0	1	0,33	0,22	
			máximo	0min	0	1	1	0,67	0	0	0	0,00	0	0	1	0,33	0,33	
			média	0min	1	1	1	1,00	0	0	0	0,00	1	0	1	0,67	0,56	
			mínimo	0min	1	1	1	1,00	0	0	0	0,00	1	0	1	0,67	0,56	
derivada2			0min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11		
			30min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11		
		60min	1	0	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22			
		90min	1	0	0	0,33	1	1	0	0,67	0	0	0	0,00	0,33			
		0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00			
		30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00			
	60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00				
	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00				

			30min	0	0	0	0,00	1	0	1	0,67	0	0	0	0,00	0,22
		máximo	0min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
		média	0min	0	1	1	0,67	1	0	1	0,67	0	0	0	0,00	0,44
		mínimo	0min	0	1	0	0,33	1	1	0	0,67	0	1	0	0,33	0,44
	pressão atmosférica	absoluto	0min	0	1	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22
			30min	0	0	0	0,00	0	0	1	0,33	0	1	0	0,33	0,22
			60min	0	1	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
			90min	0	1	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
		derivada	0min	0	1	0	0,33	0	0	0	0,00	0	0	1	0,33	0,22
			30min	0	1	0	0,33	0	0	0	0,00	0	1	1	0,67	0,33
			60min	0	1	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
		derivada2	0min	0	1	0	0,33	0	0	1	0,33	1	0	0	0,33	0,33
			30min	1	0	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22
		máximo	0min	1	0	0	0,33	0	0	0	0,00	0	0	1	0,33	0,22
		média	0min	0	1	0	0,33	0	0	0	0,00	0	0	1	0,33	0,22
		mínimo	0min	1	1	1	1,00	1	0	0	0,33	0	1	1	0,67	0,67
	velocidade e direção do vento	absoluto	0min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
			30min	1	0	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
			60min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			90min	1	0	0	0,33	1	1	0	0,67	0	0	0	0,00	0,33
		derivada	0min	0	0	0	0,00	0	1	0	0,33	1	1	0	0,67	0,33
			30min	0	1	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
			60min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22
		derivada2	0min	0	1	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22
			30min	0	1	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
		máximo	0min	1	0	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
		média	0min	0	1	1	0,67	1	0	0	0,33	0	0	0	0,00	0,33
		mínimo	0min	0	1	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22
cosseño		0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
seno		0min	0	1	0	0,33	0	0	1	0,33	0	1	0	0,33	0,33	

Tabela 42 - Grupo A – INE: Carga e Todas as Variáveis Climáticas

Época	Tipo	Classe	Deslocamento	Estação												Total uso (%)	
				Inverno				Outono				Verão					
				exp1	exp2	exp3	Uso (%)	exp1	exp2	exp3	Uso (%)	exp1	exp2	exp3	Uso (%)		
tempo	dia semana	cosseno	0min	0	0	0	0,00	0	1	1	0,67	0	1	0	0,33	0,33	
		seno	0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11	
	meia hora dia	cosseno	0min	0	1	1	0,67	0	1	0	0,33	0	0	0	0,00	0,33	
		seno	0min	0	0	0	0,00	0	1	1	0,67	1	0	1	0,67	0,44	
	semana do ano	cosseno	0min	0	1	1	0,67	1	0	1	0,67	1	1	0	0,67	0,67	
		seno	0min	1	1	1	1,00	0	1	1	0,67	0	1	0	0,33	0,67	
agora	Carga	absoluto	30min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00	
			60min	1	1	1	1,00	0	1	1	0,67	1	1	1	1,00	0,89	
			90min	0	1	0	0,33	1	1	0	0,67	1	1	1	1,00	0,67	
		derivada	30min	1	0	1	0,67	1	1	1	1,00	1	1	1	1,00	0,89	
			60min	0	1	0	0,33	1	1	1	1,00	1	1	1	1,00	0,78	
			derivada2	30min	0	1	0	0,33	1	1	0	0,67	1	0	0	0,33	0,44
	temperatura ambiente	absoluto	0min	0	0	0	0,00	0	0	1	0,33	0	1	1	0,67	0,33	
			30min	0	1	1	0,67	0	1	0	0,33	0	0	0	0,00	0,33	
			60min	0	0	1	0,33	1	0	0	0,33	1	0	0	0,33	0,33	
			90min	0	1	1	0,67	1	1	0	0,67	0	1	1	0,67	0,67	
		derivada	0min	1	0	0	0,33	1	1	1	1,00	0	1	1	0,67	0,67	
			30min	0	0	0	0,00	0	0	1	0,33	1	1	1	1,00	0,44	
			60min	0	1	0	0,33	1	0	0	0,33	1	1	1	1,00	0,56	
		derivada2	0min	0	0	1	0,33	0	0	1	0,33	0	1	1	0,67	0,44	
			30min	0	1	0	0,33	1	0	1	0,67	1	0	0	0,33	0,44	
		umidade relativa do ar	absoluto	0min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
				30min	1	1	1	1,00	1	0	0	0,33	1	1	0	0,67	0,67
				60min	1	1	0	0,67	0	0	1	0,33	1	0	0	0,33	0,44
	90min			0	1	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22	
	derivada	0min	1	0	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22		
		30min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11		
		60min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11		
	derivada2	0min	1	1	0	0,67	0	0	1	0,33	1	0	0	0,33	0,44		
		30min	1	1	0	0,67	0	0	1	0,33	0	0	0	0,00	0,33		
umidade relativa do ar	máximo	0min	0	1	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22		
		0min	0	0	1	0,33	0	0	1	0,33	1	0	0	0,33	0,33		
		0min	0	0	0	0,00	1	0	0	0,33	0	1	1	0,67	0,33		
		0min	0	1	1	0,67	0	0	1	0,33	0	0	0	0,00	0,33		

semana	radiación solar	absoluto	0min	1	1	1	1,00	0	0	0	0,00	0	1	0	0,33	0,44
			30min	0	1	1	0,67	0	0	0	0,00	1	0	1	0,67	0,44
			60min	1	1	0	0,67	0	0	0	0,00	1	0	0	0,33	0,33
			90min	0	1	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22
		derivada	0min	0	1	1	0,67	0	0	0	0,00	1	1	0	0,67	0,44
			30min	0	0	1	0,33	1	0	0	0,33	1	1	0	0,67	0,44
			60min	0	1	1	0,67	0	0	0	0,00	1	1	0	0,67	0,44
		derivada2	0min	0	1	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22
			30min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22
		máximo	0min	1	0	0	0,33	0	1	0	0,33	0	0	0	0,00	0,22
		média	0min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
		mínimo	0min	0	1	0	0,33	0	1	0	0,33	1	0	0	0,33	0,33
	presión atmosférica	absoluto	0min	1	0	0	0,33	1	0	1	0,67	1	1	1	1,00	0,67
			30min	0	0	0	0,00	0	1	1	0,67	1	1	1	1,00	0,56
			60min	0	0	1	0,33	0	1	0	0,33	0	1	1	0,67	0,44
			90min	0	1	0	0,33	0	1	1	0,67	1	1	1	1,00	0,67
		derivada	0min	1	0	0	0,33	1	1	1	1,00	1	1	1	1,00	0,78
			30min	0	0	1	0,33	1	0	0	0,33	0	1	1	0,67	0,44
			60min	0	1	1	0,67	0	0	0	0,00	1	1	1	1,00	0,56
		derivada2	0min	1	1	1	1,00	1	0	1	0,67	0	1	1	0,67	0,78
			30min	0	1	0	0,33	0	0	1	0,33	1	1	0	0,67	0,44
		máximo	0min	0	1	0	0,33	0	1	0	0,33	1	1	1	1,00	0,56
		média	0min	0	1	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22
		mínimo	0min	0	0	0	0,00	1	1	0	0,67	0	0	0	0,00	0,22
	velocidade e direção do vento	absoluto	0min	1	0	0	0,33	0	1	0	0,33	0	0	1	0,33	0,33
			30min	0	0	0	0,00	1	0	0	0,33	1	0	1	0,67	0,33
			60min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11
			90min	1	1	1	1,00	0	0	0	0,00	0	0	1	0,33	0,44
		derivada	0min	1	1	1	1,00	1	1	0	0,67	1	0	0	0,33	0,67
			30min	0	0	0	0,00	0	1	1	0,67	0	0	1	0,33	0,33
			60min	0	0	1	0,33	0	1	0	0,33	0	0	0	0,00	0,22
		derivada2	0min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
			30min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11
		máximo	0min	0	0	0	0,00	1	1	1	1,00	0	0	1	0,33	0,44
		média	0min	0	1	1	0,67	0	1	0	0,33	0	0	1	0,33	0,44
		mínimo	0min	0	0	0	0,00	0	1	1	0,67	0	0	1	0,33	0,33
cosseno	0min	0	1	0	0,33	0	1	1	0,67	0	0	1	0,33	0,44		
seno	0min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11		
carga	absoluto	0min	0	1	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22	
		30min	1	0	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22	
		60min	0	0	0	0,00	0	1	0	0,33	1	0	0	0,33	0,22	
		90min	1	1	0	0,67	0	0	0	0,00	1	0	1	0,67	0,44	
	derivada	0min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00	
		30min	0	0	1	0,33	1	1	0	0,67	0	1	1	0,67	0,56	
		60min	1	0	0	0,33	0	1	1	0,67	0	1	1	0,67	0,56	
	derivada2	0min	1	0	1	0,67	1	0	1	0,67	0	1	1	0,67	0,67	
		30min	1	1	1	1,00	0	1	1	0,67	0	0	1	0,33	0,67	
	máximo	0min	1	1	0	0,67	1	0	1	0,67	0	0	1	0,33	0,56	
	média	0min	1	0	1	0,67	1	1	0	0,67	1	0	1	0,67	0,67	
	mínimo	0min	0	1	0	0,33	0	0	1	0,33	0	1	0	0,33	0,33	

temperatura ambiente	absoluto	0min	0	0	1	0,33	1	1	0	0,67	0	0	0	0,00	0,33
		30min	0	1	0	0,33	0	0	1	0,33	1	0	0	0,33	0,33
		60min	0	0	0	0,00	1	1	0	0,67	0	1	0	0,33	0,33
		90min	1	0	0	0,33	0	0	1	0,33	1	1	1	1,00	0,56
	derivada	0min	0	1	0	0,33	0	1	1	0,67	0	1	0	0,33	0,44
		30min	1	0	0	0,33	0	1	1	0,67	0	1	0	0,33	0,44
		60min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
	derivada2	0min	0	1	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22
		30min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
	máximo	0min	1	1	1	1,00	0	0	0	0,00	0	0	1	0,33	0,44
	média	0min	1	1	1	1,00	0	0	0	0,00	1	0	0	0,33	0,44
	mínimo	0min	0	1	0	0,33	0	0	0	0,00	1	1	1	1,00	0,44
umidade relativa do ar	absoluto	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		30min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22
		60min	0	0	0	0,00	1	1	1	1,00	0	0	0	0,00	0,33
		90min	1	0	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22
	derivada	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		30min	1	0	0	0,33	0	0	1	0,33	1	0	0	0,33	0,33
		60min	0	0	0	0,00	0	1	0	0,33	1	0	1	0,67	0,33
	derivada2	0min	1	1	0	0,67	1	0	0	0,33	0	0	0	0,00	0,33
		30min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
	máximo	0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
	média	0min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11
	mínimo	0min	0	1	1	0,67	1	0	1	0,67	0	0	0	0,00	0,44
radiação solar	absoluto	0min	0	0	0	0,00	0	1	0	0,33	1	0	0	0,33	0,22
		30min	0	1	0	0,33	1	1	0	0,67	0	0	0	0,00	0,33
		60min	0	0	0	0,00	1	0	1	0,67	0	0	0	0,00	0,22
		90min	1	1	0	0,67	0	1	0	0,33	0	0	0	0,00	0,33
	derivada	0min	0	1	0	0,33	0	1	0	0,33	0	0	1	0,33	0,33
		30min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
		60min	1	1	0	0,67	0	0	0	0,00	0	0	1	0,33	0,33
	derivada2	0min	0	1	0	0,33	0	1	0	0,33	0	0	0	0,00	0,22
		30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
	máximo	0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
	média	0min	0	0	0	0,00	0	0	0	0,00	1	1	1	1,00	0,33
	mínimo	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
pressão atmosférica	absoluto	0min	1	1	0	0,67	0	0	1	0,33	0	1	1	0,67	0,56
		30min	1	0	1	0,67	1	1	0	0,67	0	1	0	0,33	0,56
		60min	1	0	1	0,67	0	1	0	0,33	0	0	1	0,33	0,44
		90min	1	0	0	0,33	1	1	0	0,67	0	0	1	0,33	0,44
	derivada	0min	0	1	0	0,33	1	0	0	0,33	1	0	1	0,67	0,44
		30min	0	0	1	0,33	0	0	1	0,33	1	0	0	0,33	0,33
		60min	1	0	0	0,33	0	0	0	0,00	1	1	1	1,00	0,44
	derivada2	0min	1	1	0	0,67	1	1	1	1,00	0	0	0	0,00	0,56
		30min	1	0	0	0,33	0	0	1	0,33	1	1	1	1,00	0,56
	máximo	0min	1	0	0	0,33	1	0	0	0,33	1	1	1	1,00	0,56
	média	0min	0	0	1	0,33	0	1	1	0,67	0	0	0	0,00	0,33
	mínimo	0min	1	0	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22

ano	velocidade e direção do vento	absoluto	0min	1	0	1	0,67	0	0	1	0,33	1	0	0	0,33	0,44
			30min	0	1	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22
			60min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22
			90min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		derivada	0min	0	0	0	0,00	0	1	0	0,33	0	0	1	0,33	0,22
			30min	0	1	0	0,33	0	1	1	0,67	0	0	1	0,33	0,44
			60min	0	0	0	0,00	1	1	1	1,00	0	0	0	0,00	0,33
		derivada2	0min	0	1	0	0,33	1	0	0	0,33	0	0	1	0,33	0,33
			30min	0	0	0	0,00	1	1	1	1,00	1	0	1	0,67	0,56
		máximo	0min	0	1	1	0,67	1	0	0	0,33	1	0	0	0,33	0,44
0min	0		0	0	0,00	1	0	0	0,33	1	0	1	0,67	0,33		
mínimo	0min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11		
	0min	0	1	0	0,33	1	0	1	0,67	1	0	1	0,67	0,56		
cosseno	0min	0	1	0	0,33	1	0	1	0,67	1	0	1	0,67	0,56		
	0min	0	0	0	0,00	0	0	1	0,33	1	0	0	0,33	0,22		

ano	carga	absoluto	0min	1	0	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22
			30min	0	1	0	0,33	0	1	0	0,33	0	1	0	0,33	0,33
			60min	0	0	0	0,00	1	0	1	0,67	0	1	0	0,33	0,33
			90min	1	1	1	1,00	0	0	0	0,00	1	0	0	0,33	0,44
		derivada	0min	1	1	1	1,00	0	1	1	0,67	1	1	1	1,00	0,89
			30min	0	0	0	0,00	1	1	1	1,00	0	0	1	0,33	0,44
			60min	1	0	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22
		derivada2	0min	0	0	0	0,00	1	1	1	1,00	0	0	1	0,33	0,44
			30min	0	0	0	0,00	1	0	0	0,33	0	0	1	0,33	0,22
		máximo	0min	1	0	0	0,33	0	0	0	0,00	1	0	1	0,67	0,33
0min	0		1	1	0,67	0	1	0	0,33	1	0	1	0,67	0,56		
mínimo	0min	1	0	1	0,67	0	1	1	0,67	0	0	0	0,00	0,44		
	0min	0	1	0	0,33	0	0	1	0,33	0	1	0	0,33	0,33		

ano	temperatura ambiente	absoluto	0min	0	1	0	0,33	0	0	1	0,33	0	1	0	0,33	0,33
			30min	0	0	1	0,33	0	1	1	0,67	1	1	0	0,67	0,56
			60min	0	1	1	0,67	0	0	1	0,33	0	0	0	0,00	0,33
			90min	0	1	0	0,33	0	0	1	0,33	0	1	0	0,33	0,33
		derivada	0min	0	0	0	0,00	1	0	1	0,67	1	1	0	0,67	0,44
			30min	0	0	0	0,00	1	1	0	0,67	1	0	0	0,33	0,33
			60min	1	1	0	0,67	1	1	0	0,67	1	0	0	0,33	0,56
		derivada2	0min	0	1	0	0,33	0	0	0	0,00	0	1	1	0,67	0,33
			30min	0	1	0	0,33	0	1	0	0,33	1	0	1	0,67	0,44
		máximo	0min	1	0	1	0,67	0	1	1	0,67	0	1	1	0,67	0,67
0min	0		1	0	0,33	0	0	1	0,33	0	1	0	0,33	0,33		
mínimo	0min	0	0	1	0,33	0	0	1	0,33	0	0	1	0,33	0,33		
	0min	0	0	1	0,33	0	0	1	0,33	0	0	1	0,33	0,33		

ano	umidade relativa do ar	absoluto	0min	1	1	0	0,67	0	0	1	0,33	0	0	0	0,00	0,33
			30min	1	1	0	0,67	1	0	0	0,33	0	1	0	0,33	0,44
			60min	1	0	1	0,67	1	1	0	0,67	0	0	0	0,00	0,44
			90min	1	1	1	1,00	0	0	1	0,33	0	0	0	0,00	0,44
		derivada	0min	0	0	1	0,33	0	1	0	0,33	0	0	0	0,00	0,22
			30min	1	1	1	1,00	0	1	0	0,33	0	0	0	0,00	0,44
			60min	0	0	1	0,33	0	0	1	0,33	0	0	0	0,00	0,22
		derivada2	0min	0	0	0	0,00	0	1	0	0,33	0	1	0	0,33	0,22
			30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		máximo	0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
0min	1		1	0	0,67	0	1	1	0,67	0	1	0	0,33	0,56		
mínimo	0min	1	0	0	0,33	0	1	0	0,33	0	0	0	0,00	0,22		
	0min	1	0	0	0,33	0	1	0	0,33	0	0	0	0,00	0,22		

	radiação solar	absoluto	0min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22
			30min	1	0	0	0,33	0	1	0	0,33	0	0	0	0,00	0,22
			60min	0	1	1	0,67	0	1	0	0,33	1	0	0	0,33	0,44
			90min	0	1	1	0,67	0	1	0	0,33	0	0	0	0,00	0,33
		derivada	0min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			30min	0	1	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22
			60min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22
		derivada2	0min	1	0	0	0,33	0	1	0	0,33	0	0	0	0,00	0,22
			30min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11
		máximo	0min	1	0	1	0,67	0	0	0	0,00	0	0	1	0,33	0,33
		média	0min	0	1	0	0,33	0	1	0	0,33	0	0	1	0,33	0,33
		mínimo	0min	1	1	1	1,00	0	0	0	0,00	0	0	1	0,33	0,44
	pressão atmosférica	absoluto	0min	0	0	0	0,00	1	1	1	1,00	0	0	0	0,00	0,33
			30min	1	0	0	0,33	0	1	1	0,67	0	1	0	0,33	0,44
			60min	1	1	0	0,67	0	0	1	0,33	0	0	0	0,00	0,33
			90min	1	0	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22
		derivada	0min	0	1	0	0,33	0	0	0	0,00	0	1	1	0,67	0,33
			30min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11
			60min	0	1	0	0,33	1	0	0	0,33	1	0	1	0,67	0,44
		derivada2	0min	0	1	1	0,67	0	0	1	0,33	1	1	1	1,00	0,67
			30min	0	1	1	0,67	1	0	1	0,67	0	0	0	0,00	0,44
		máximo	0min	0	1	1	0,67	1	0	0	0,33	0	1	0	0,33	0,44
		média	0min	1	0	0	0,33	0	1	0	0,33	0	0	1	0,33	0,33
		mínimo	0min	0	0	0	0,00	1	0	0	0,33	0	1	1	0,67	0,33
	velocidade e direção do vento	absoluto	0min	0	1	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22
			30min	0	0	0	0,00	1	1	1	1,00	0	0	0	0,00	0,33
			60min	0	1	0	0,33	1	1	1	1,00	0	1	1	0,67	0,67
			90min	0	1	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22
		derivada	0min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11
30min			0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
60min			0	1	0	0,33	0	1	0	0,33	0	1	0	0,33	0,33	
derivada2		0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11	
		30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
máximo		0min	1	0	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33	
média		0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11	
mínimo		0min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11	
cosseno		0min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
seno		0min	0	1	1	0,67	0	0	0	0,00	0	1	0	0,33	0,33	

Tabela 43 - Grupo A – ISS: Carga e Todas as Variáveis Climáticas

Época	Tipo	Classe	Deslocamento	Estação												Total uso (%)
				Inverno				Outono				Verão				
				exp1	exp2	exp3	Uso (%)	exp1	exp2	exp3	Uso (%)	exp1	exp2	exp3	Uso (%)	
tempo	dia semana	cosseno	0min	1	0	0	0,33	0	0	1	0,33	0	0	1	0,33	0,33
		seno	0min	0	1	0	0,33	0	1	0	0,33	0	1	1	0,67	0,44
	meia hora dia	cosseno	0min	0	0	1	0,33	1	1	0	0,67	1	0	0	0,33	0,44
		seno	0min	0	0	0	0,00	1	1	0	0,67	1	1	1	1,00	0,56
	semana do ano	cosseno	0min	1	1	1	1,00	1	0	0	0,33	1	0	0	0,33	0,56
		seno	0min	0	1	1	0,67	1	0	1	0,67	0	0	1	0,33	0,56
agora	Carga	absoluto	30min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00
			60min	1	1	1	1,00	1	1	1	1,00	0	1	0	0,33	0,78
			90min	1	0	0	0,33	1	1	1	1,00	1	1	1	1,00	0,78
		derivada	30min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00
			60min	1	0	1	0,67	1	0	1	0,67	1	1	0	0,67	0,67
			derivada2	30min	1	0	1	0,67	1	1	1	1,00	0	1	1	0,67
	temperatura ambiente	absoluto	0min	0	0	0	0,00	0	0	1	0,33	0	1	0	0,33	0,22
			30min	0	0	0	0,00	0	0	1	0,33	1	1	0	0,67	0,33
			60min	0	0	0	0,00	1	0	1	0,67	1	0	0	0,33	0,33
			90min	0	0	0	0,00	1	1	1	1,00	0	0	0	0,00	0,33
		derivada	0min	0	0	0	0,00	1	0	1	0,67	0	1	0	0,33	0,33
			30min	0	0	0	0,00	0	1	1	0,67	1	0	0	0,33	0,33
			60min	0	0	0	0,00	1	1	1	1,00	0	1	0	0,33	0,44
		derivada2	0min	1	0	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22
			30min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11
		máximo	0min	0	1	0	0,33	0	0	0	0,00	1	1	1	1,00	0,44
			30min	0	0	0	0,00	1	0	1	0,67	1	0	1	0,67	0,44
			60min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11
	90min		0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11	
	umidade relativa do ar	absoluto	0min	0	0	0	0,00	1	1	1	1,00					0,50
			30min	0	0	0	0,00	1	1	1	1,00					0,50
			60min	0	0	0	0,00	1	0	1	0,67					0,33
			90min	0	1	0	0,33	1	0	0	0,33					0,33
		derivada	0min	0	0	0	0,00	0	0	0	0,00					0,00
			30min	0	1	0	0,33	0	0	0	0,00					0,17
			60min	0	1	1	0,67	0	0	0	0,00					0,33
		derivada2	0min	1	0	0	0,33	0	0	0	0,00					0,17
			30min	0	0	0	0,00	0	1	0	0,33					0,17
		máximo	0min	0	0	0	0,00	0	0	0	0,00					0,00
			30min	0	0	0	0,00	1	1	0	0,67					0,33
60min			0	0	0	0,00	0	0	0	0,00					0,00	
90min	0		1	1	0,67	1	0	0	0,33					0,50		

semana	radiação solar	absoluto	0min	1	0	0	0,33	0	1	1	0,67	0	0	0	0,00	0,33
			30min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			60min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11
			90min	0	1	0	0,33	0	1	0	0,33	0	0	0	0,00	0,22
		derivada	0min	1	1	0	0,67	0	1	1	0,67	0	0	0	0,00	0,44
			30min	1	1	0	0,67	0	1	0	0,33	0	0	0	0,00	0,33
			60min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
		derivada2	0min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			30min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
		máximo	0min	0	0	0	0,00	1	1	0	0,67	1	0	0	0,33	0,33
		média	0min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11
		mínimo	0min	0	0	0	0,00	0	0	0	0,00	1	1	0	0,67	0,22
	pressão atmosférica	absoluto	0min	1	0	1	0,67	1	1	0	0,67	1	1	0	0,67	0,67
			30min	1	0	0	0,33	1	0	1	0,67	1	0	0	0,33	0,44
			60min	1	0	0	0,33	1	1	0	0,67	1	0	0	0,33	0,44
			90min	0	0	1	0,33	1	1	1	1,00	1	1	0	0,67	0,67
		derivada	0min	0	0	0	0,00	0	0	0	0,00	0	1	1	0,67	0,22
			30min	0	0	1	0,33	1	0	0	0,33	1	0	0	0,33	0,33
			60min	0	0	1	0,33	1	0	0	0,33	1	0	0	0,33	0,33
		derivada2	0min	1	0	1	0,67	1	1	0	0,67	1	0	0	0,33	0,56
			30min	1	0	1	0,67	1	0	0	0,33	1	0	0	0,33	0,44
		máximo	0min	1	0	0	0,33	1	0	0	0,33	1	0	0	0,33	0,33
		média	0min	0	0	0	0,00	1	0	0	0,33	1	0	1	0,67	0,33
		mínimo	0min	1	0	1	0,67	1	0	0	0,33	1	0	1	0,67	0,56
	velocidade e direção do vento	absoluto	0min	1	0	0	0,33	1	0	0	0,33					0,33
			30min	1	0	0	0,33	0	0	0	0,00					0,17
			60min	1	1	0	0,67	0	0	0	0,00					0,33
			90min	1	1	0	0,67	0	0	0	0,00					0,33
		derivada	0min	0	0	0	0,00	0	0	0	0,00					0,00
			30min	0	0	0	0,00	0	0	0	0,00					0,00
			60min	1	1	0	0,67	0	0	0	0,00					0,33
		derivada2	0min	0	1	0	0,33	0	0	0	0,00					0,17
			30min	0	0	0	0,00	0	0	0	0,00					0,00
		máximo	0min	1	0	0	0,33	0	0	0	0,00					0,17
		média	0min	1	1	0	0,67	1	0	0	0,33					0,50
		mínimo	0min	0	0	0	0,00	0	0	0	0,00					0,00
cosseno	0min	0	0	1	0,33	1	1	0	0,67					0,50		
seno	0min	0	0	0	0,00	0	1	0	0,33					0,17		
carga	absoluto	0min	1	1	0	0,67	0	0	1	0,33	0	1	0	0,33	0,44	
		30min	1	1	1	1,00	0	1	0	0,33	0	0	0	0,00	0,44	
		60min	0	0	1	0,33	0	1	0	0,33	1	0	1	0,67	0,44	
		90min	1	0	1	0,67	1	1	1	1,00	0	1	1	0,67	0,78	
	derivada	0min	1	1	1	1,00	1	0	1	0,67	1	1	1	1,00	0,89	
		30min	1	0	0	0,33	1	1	1	1,00	1	1	0	0,67	0,67	
		60min	1	1	0	0,67	1	0	1	0,67	1	1	0	0,67	0,67	
	derivada2	0min	1	1	0	0,67	1	1	1	1,00	1	1	0	0,67	0,78	
		30min	1	1	1	1,00	1	0	1	0,67	1	1	1	1,00	0,89	
	máximo	0min	0	0	1	0,33	1	1	0	0,67	0	0	1	0,33	0,44	
	média	0min	1	0	1	0,67	0	0	0	0,00	0	1	0	0,33	0,33	
	mínimo	0min	0	0	0	0,00	0	1	0	0,33	1	0	0	0,33	0,22	

temperatura ambiente	absoluto	0min	0	0	0	0,00	0	1	0	0,33	1	0	0	0,33	0,22
		30min	0	0	0	0,00	1	0	0	0,33	1	0	0	0,33	0,22
		60min	0	0	0	0,00	1	0	0	0,33	1	0	0	0,33	0,22
		90min	0	0	0	0,00	1	1	0	0,67	1	0	0	0,33	0,33
	derivada	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		30min	0	0	0	0,00	0	1	0	0,33	1	0	0	0,33	0,22
		60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
	derivada2	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		30min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
	máximo	0min	1	0	0	0,33	0	1	0	0,33	1	0	0	0,33	0,33
	média	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
	mínimo	0min	0	0	0	0,00	1	1	0	0,67	1	0	0	0,33	0,33
umidade relativa do ar	absoluto	0min	1	0	1	0,67	1	1	0	0,67				0,67	
		30min	0	1	0	0,33	1	0	0	0,33				0,33	
		60min	0	0	1	0,33	1	0	0	0,33				0,33	
		90min	0	0	1	0,33	1	0	0	0,33				0,33	
	derivada	0min	0	0	1	0,33	1	0	0	0,33				0,33	
		30min	0	1	1	0,67	0	0	0	0,00				0,33	
		60min	0	1	0	0,33	0	0	0	0,00				0,17	
	derivada2	0min	0	1	0	0,33	0	0	0	0,00				0,17	
		30min	0	0	0	0,00	0	0	0	0,00				0,00	
	máximo	0min	0	1	0	0,33	0	0	0	0,00				0,17	
	média	0min	0	0	0	0,00	1	0	0	0,33				0,17	
	mínimo	0min	0	1	0	0,33	0	0	0	0,00				0,17	
radiação solar	absoluto	0min	1	1	0	0,67	0	0	0	0,00	0	1	0	0,33	0,33
		30min	0	0	0	0,00	1	0	1	0,67	0	1	0	0,33	0,33
		60min	0	0	1	0,33	1	1	1	1,00	0	0	0	0,00	0,44
		90min	1	0	0	0,33	1	1	0	0,67	0	1	0	0,33	0,44
	derivada	0min	0	1	0	0,33	1	1	0	0,67	0	0	0	0,00	0,33
		30min	0	0	0	0,00	1	0	0	0,33	1	0	0	0,33	0,22
		60min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11
	derivada2	0min	0	1	0	0,33	0	1	1	0,67	0	0	0	0,00	0,33
		30min	1	0	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22
	máximo	0min	0	0	1	0,33	1	0	0	0,33	0	0	0	0,00	0,22
	média	0min	1	0	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22
	mínimo	0min	1	0	0	0,33	0	1	1	0,67	1	0	1	0,67	0,56
pressão atmosférica	absoluto	0min	1	0	1	0,67	1	0	1	0,67	1	0	0	0,33	0,56
		30min	1	1	0	0,67	1	0	1	0,67	0	0	0	0,00	0,44
		60min	1	1	1	1,00	0	0	0	0,00	0	0	1	0,33	0,44
		90min	1	0	1	0,67	0	0	0	0,00	0	0	1	0,33	0,33
	derivada	0min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
		30min	0	0	1	0,33	1	1	0	0,67	0	0	0	0,00	0,33
		60min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11
	derivada2	0min	1	1	1	1,00	0	0	0	0,00	0	0	0	0,00	0,33
		30min	0	0	1	0,33	0	1	1	0,67	0	0	0	0,00	0,33
	máximo	0min	0	1	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
	média	0min	0	1	1	0,67	0	1	1	0,67	0	0	0	0,00	0,44
	mínimo	0min	1	0	1	0,67	1	1	1	1,00	0	0	0	0,00	0,56

	velocidade e direção do vento	absoluto	0min	1	0	0	0,33	1	0	0	0,33					0,33	
			30min	0	0	0	0,00	0	0	0	0,00						0,00
			60min	0	1	0	0,33	1	0	0	0,33						0,33
			90min	1	1	0	0,67	0	0	0	0,00						0,33
		derivada	0min	1	1	0	0,67	0	0	0	0,00						0,33
			30min	1	0	0	0,33	0	0	0	0,00						0,17
			60min	0	0	0	0,00	0	0	0	0,00						0,00
		derivada2	0min	1	0	0	0,33	0	0	0	0,00						0,17
			30min	1	1	0	0,67	0	0	0	0,00						0,33
		máximo	0min	0	0	0	0,00	1	1	0	0,67						0,33
			0min	0	0	0	0,00	1	0	0	0,33						0,17
		mínimo	0min	0	0	0	0,00	1	0	0	0,33						0,17
0min	1		0	0	0,33	1	0	0	0,33						0,33		
cosseno	0min	1	0	1	0,67	0	1	0	0,33						0,50		
	0min	1	0	1	0,67	0	1	0	0,33						0,50		
ano	carga	absoluto	0min	0	1	1	0,67	1	1	1	1,00	1	0	1	0,67	0,78	
			30min	0	1	1	0,67	1	0	0	0,33	0	0	0	0,00	0,33	
			60min	1	0	1	0,67	0	0	1	0,33	1	1	0	0,67	0,56	
			90min	0	0	0	0,00	1	0	1	0,67	0	0	1	0,33	0,33	
		derivada	0min	1	1	0	0,67	1	1	1	1,00	0	1	1	0,67	0,78	
			30min	0	1	0	0,33	1	1	0	0,67	1	1	1	1,00	0,67	
			60min	1	0	1	0,67	0	0	0	0,00	0	1	1	0,67	0,44	
		derivada2	0min	0	1	1	0,67	1	1	1	1,00	1	0	0	0,33	0,67	
			30min	1	1	1	1,00	0	0	1	0,33	0	0	0	0,00	0,44	
		máximo	0min	1	1	1	1,00	0	0	0	0,00	1	0	1	0,67	0,56	
			0min	0	0	1	0,33	0	0	0	0,00	0	1	0	0,33	0,22	
		mínimo	0min	0	0	0	0,00	1	0	0	0,33	1	0	0	0,33	0,22	
0min	0		0	0	0,00	1	0	0	0,33	1	0	0	0,33	0,22			
ano	temperatura ambiente	absoluto	0min	0	0	1	0,33	1	0	0	0,33	1	0	0	0,33	0,33	
			30min	0	0	1	0,33	0	1	1	0,67	0	0	0	0,00	0,33	
			60min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11	
			90min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11	
		derivada	0min	0	0	1	0,33	1	0	0	0,33	0	0	0	0,00	0,22	
			30min	0	0	0	0,00	1	1	1	1,00	0	0	0	0,00	0,33	
			60min	0	0	1	0,33	0	0	1	0,33	0	0	0	0,00	0,22	
		derivada2	0min	0	0	1	0,33	1	1	0	0,67	0	0	0	0,00	0,33	
			30min	0	0	0	0,00	1	0	1	0,67	0	0	0	0,00	0,22	
		máximo	0min	0	1	0	0,33	0	1	1	0,67	0	0	0	0,00	0,33	
			0min	0	1	0	0,33	0	1	1	0,67	0	0	0	0,00	0,33	
		mínimo	0min	0	0	1	0,33	1	0	0	0,33	0	0	0	0,00	0,22	
0min	0		0	1	0,33	1	0	0	0,33	0	0	0	0,00	0,22			
ano	umidade relativa do ar	absoluto	0min	0	1	0	0,33	1	0	0	0,33					0,33	
			30min	1	1	0	0,67	1	1	0	0,67					0,67	
			60min	0	0	0	0,00	1	0	1	0,67					0,33	
			90min	0	1	0	0,33	1	1	1	1,00					0,67	
		derivada	0min	0	1	0	0,33	0	1	0	0,33					0,33	
			30min	0	1	0	0,33	1	1	0	0,67					0,50	
			60min	0	0	0	0,00	0	1	0	0,33					0,17	
		derivada2	0min	0	0	0	0,00	0	1	1	0,67					0,33	
			30min	0	0	0	0,00	0	0	0	0,00					0,00	
		máximo	0min	0	1	0	0,33	0	0	0	0,00					0,17	
			0min	0	1	0	0,33	0	0	1	0,33					0,33	
		mínimo	0min	0	1	0	0,33	0	1	0	0,33					0,33	
0min	0		1	0	0,33	0	1	0	0,33					0,33			

	radiação solar	absoluto	0min	1	0	0	0,33	1	1	0	0,67	1	0	1	0,67	0,56	
			30min	1	1	0	0,67	1	1	0	0,67	1	0	1	0,67	0,67	0,67
			60min	0	1	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22	0,22
			90min	0	1	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22	0,22
		derivada	0min	0	1	0	0,33	0	0	0	0,00	0	0	1	0,33	0,22	0,22
			30min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11	0,11
			60min	0	1	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22	0,22
		derivada2	0min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11	0,11
			30min	0	0	1	0,33	1	0	0	0,33	0	0	0	0,00	0,22	0,22
		máximo	0min	0	0	1	0,33	0	0	1	0,33	0	0	0	0,00	0,22	0,22
		média	0min	0	1	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22	0,22
		mínimo	0min	1	1	0	0,67	0	1	0	0,33	0	0	1	0,33	0,44	0,44
	pressão atmosférica	absoluto	0min	0	0	0	0,00	1	1	0	0,67	0	0	0	0,00	0,22	0,22
			30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	0,00
			60min	0	1	1	0,67	0	0	1	0,33	0	0	1	0,33	0,44	0,44
			90min	0	1	0	0,33	1	1	1	1,00	0	0	0	0,00	0,44	0,44
		derivada	0min	0	0	1	0,33	0	1	0	0,33	0	0	0	0,00	0,22	0,22
			30min	0	1	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22	0,22
			60min	0	1	1	0,67	0	0	0	0,00	1	0	0	0,33	0,33	0,33
		derivada2	0min	0	0	1	0,33	1	0	0	0,33	0	0	0	0,00	0,22	0,22
			30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	0,00
		máximo	0min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11	0,11
		média	0min	0	1	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22	0,22
		mínimo	0min	0	1	0	0,33	1	0	0	0,33	1	0	0	0,33	0,33	0,33
	velocidade e direção do vento	absoluto	0min	0	1	0	0,33	1	0	0	0,33					0,33	0,33
			30min	1	0	0	0,33	1	1	0	0,67					0,50	0,50
			60min	0	1	0	0,33	1	0	0	0,33					0,33	0,33
			90min	1	1	0	0,67	1	0	0	0,33					0,50	0,50
		derivada	0min	0	0	0	0,00	1	0	0	0,33					0,17	0,17
			30min	0	1	0	0,33	1	1	0	0,67					0,50	0,50
60min			0	0	0	0,00	1	1	0	0,67					0,33	0,33	
derivada2		0min	1	0	0	0,33	0	0	0	0,00					0,17	0,17	
		30min	0	0	0	0,00	1	0	0	0,33					0,17	0,17	
máximo		0min	0	0	1	0,33	0	1	0	0,33					0,33	0,33	
média		0min	1	0	1	0,67	0	0	0	0,00					0,33	0,33	
mínimo		0min	0	1	1	0,67	1	1	0	0,67					0,67	0,67	
cosseno		0min	0	0	1	0,33	1	1	0	0,67					0,50	0,50	
seno		0min	0	0	0	0,00	0	0	0	0,00					0,00	0,00	

Tabela 44 - Grupo A – SAD: Carga e Todas as Variáveis Climáticas

Época	Tipo	Classe	Deslocamento	Estação												Total uso (%)
				Inverno				Outono				Verão				
				exp1	exp2	exp3	Uso (%)	exp1	exp2	exp3	Uso (%)	exp1	exp2	exp3	Uso (%)	
tempo	dia semana	cosseno	0min	0	0	1	0,33	0	0	0	0,00	0	1	0	0,33	0,22
		seno	0min	0	0	1	0,33	0	0	0	0,00	1	0	1	0,67	0,33
	meia hora dia	cosseno	0min	1	1	0	0,67	0	1	0	0,33	0	0	1	0,33	0,44
		seno	0min	1	1	1	1,00	0	1	1	0,67	0	1	0	0,33	0,67
	semana do ano	cosseno	0min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
		seno	0min	0	1	1	0,67	1	0	0	0,33	0	0	0	0,00	0,33
agora	Carga	absoluto	30min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00
			60min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00
			90min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00
		derivada	30min	1	1	1	1,00	1	1	1	1,00	1	1	0	0,67	0,89
			60min	0	1	0	0,33	1	1	1	1,00	1	1	1	1,00	0,78
			derivada2	30min	1	1	1	1,00	1	0	0	0,33	0	1	1	0,67
	temperatura ambiente	absoluto	0min	0	0	0	0,00	0	0	0	0,00	1	0	1	0,67	0,22
			30min	1	0	1	0,67	0	0	1	0,33	0	1	0	0,33	0,44
			60min	1	0	0	0,33	0	0	0	0,00	0	1	1	0,67	0,33
			90min	0	0	1	0,33	0	0	0	0,00	0	1	1	0,67	0,33
		derivada	0min	1	0	1	0,67	0	0	0	0,00	1	1	0	0,67	0,44
			30min	1	0	1	0,67	0	0	0	0,00	1	1	1	1,00	0,56
			60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		derivada2	0min	0	0	1	0,33	1	0	1	0,67	0	0	0	0,00	0,33
			30min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
		máximo	0min	0	0	1	0,33	0	0	0	0,00	0	1	0	0,33	0,22
			30min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
	90min		0	0	1	0,33	1	0	0	0,33	0	0	1	0,33	0,33	
	umidade relativa do ar	absoluto	0min	0	0	0	0,00	0	0	1	0,33	1	0	0	0,33	0,22
			30min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11
			60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
			90min	0	0	1	0,33	1	0	0	0,33	0	0	1	0,33	0,33
		derivada	0min	1	0	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22
			30min	0	1	0	0,33	0	0	0	0,00	1	1	0	0,67	0,33
			60min	0	0	0	0,00	0	0	0	0,00	0	0	1	0,33	0,11
		derivada2	0min	0	0	0	0,00	0	0	0	0,00	1	1	1	1,00	0,33
	30min		0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
máximo	0min	0	1	0	0,33	0	0	1	0,33	1	0	1	0,67	0,44		
	30min	0	0	0	0,00	0	0	1	0,33	1	1	0	0,67	0,33		
mínimo	0min	0	1	0	0,33	0	0	1	0,33	1	1	1	1,00	0,56		
	30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00		

semana	radiación solar	absoluto	0min															
			30min															
			60min															
			90min															
			derivada	0min														
				30min														
				60min														
				derivada2	0min													
					30min													
				máximo	0min													
				média	0min													
				mínimo	0min													
			presión atmosférica	absoluto	0min	0	1	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22
				30min	0	1	1	0,67	0	0	0	0,00	0	1	0	0,33	0,33	
				60min	0	1	1	0,67	0	0	0	0,00	0	1	0	0,33	0,33	
				90min	0	0	0	0,00	0	0	0	0,00	1	0	1	0,67	0,22	
				derivada	0min	0	1	1	0,67	1	0	0	0,33	0	0	0	0,00	0,33
					30min	0	1	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22
					60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
				derivada2	0min	0	1	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
					30min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
				máximo	0min	0	0	0	0,00	0	1	1	0,67	1	0	1	0,67	0,44
				média	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
				mínimo	0min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11
		velocidade e direção do vento		absoluto	0min	0	0	1	0,33	0	1	0	0,33	0	0	1	0,33	0,33
				30min	0	0	1	0,33	0	1	0	0,33	0	0	0	0,00	0,22	
				60min	0	0	1	0,33	1	1	0	0,67	0	0	0	0,00	0,33	
				90min	0	0	1	0,33	0	1	0	0,33	0	0	1	0,33	0,33	
				derivada	0min	0	0	0	0,00	0	1	1	0,67	0	0	1	0,33	0,33
					30min	0	0	0	0,00	1	1	1	1,00	1	0	1	0,67	0,56
					60min	0	0	1	0,33	0	1	0	0,33	1	0	1	0,67	0,44
				derivada2	0min	0	0	1	0,33	0	1	1	0,67	1	1	1	1,00	0,67
					30min	0	0	0	0,00	1	1	1	1,00	1	0	0	0,33	0,44
				máximo	0min	0	0	0	0,00	0	1	0	0,33	0	1	1	0,67	0,33
				média	0min	0	0	1	0,33	1	1	0	0,67	0	0	0	0,00	0,33
				mínimo	0min	0	0	0	0,00	0	0	1	0,33	1	0	1	0,67	0,33
				cosseno	0min	0	0	0	0,00	0	1	1	0,67	0	0	0	0,00	0,22
			seno	0min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
		carga	absoluto	0min	1	1	1	1,00	1	0	1	0,67	0	1	1	0,67	0,78	
				30min	1	1	1	1,00	0	1	1	0,67	0	0	0	0,00	0,56	
			60min	1	1	1	1,00	0	0	0	0,00	1	1	0	0,67	0,56		
			90min	0	1	0	0,33	0	1	1	0,67	0	1	0	0,33	0,44		
			derivada	0min	1	1	0	0,67	1	1	1	1,00	1	1	1	1,00	0,89	
				30min	0	1	1	0,67	0	1	0	0,33	1	0	0	0,33	0,44	
				60min	1	1	1	1,00	0	1	0	0,33	0	0	1	0,33	0,56	
			derivada2	0min	0	1	1	0,67	1	1	1	1,00	0	1	0	0,33	0,67	
				30min	1	1	1	1,00	0	1	0	0,33	1	0	1	0,67	0,67	
			máximo	0min	0	0	0	0,00	1	0	1	0,67	1	1	1	1,00	0,56	
			média	0min	1	1	0	0,67	1	1	0	0,67	1	0	0	0,33	0,56	
			mínimo	0min	1	0	0	0,33	1	1	0	0,67	1	0	1	0,67	0,56	

temperatura ambiente	absoluto	0min	0	0	0	0,00	0	0	0	0,00	0	1	1	0,67	0,22
		30min	0	1	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22
		60min	0	0	1	0,33	0	0	1	0,33	1	0	1	0,67	0,44
		90min	0	0	1	0,33	0	0	0	0,00	0	1	1	0,67	0,33
		derivada	0min	0	0	0	0,00	1	0	0	0,33	1	0	1	0,67
		30min	1	0	1	0,67	0	0	0	0,00	0	1	1	0,67	0,44
		60min	0	1	0	0,33	0	0	0	0,00	0	1	1	0,67	0,33
		derivada2	0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00
		30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		máximo	0min	1	1	0	0,67	1	0	0	0,33	0	1	0	0,33
média	0min	1	0	0	0,33	0	0	1	0,33	0	0	1	0,33	0,33	
mínimo	0min	0	0	1	0,33	0	1	0	0,33	0	0	0	0,00	0,22	
umidade relativa do ar	absoluto	0min	1	0	0	0,33	1	0	0	0,33	1	1	0	0,67	0,44
		30min	0	0	0	0,00	0	0	0	0,00	1	1	1	1,00	0,33
		60min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
		90min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
		derivada	0min	0	0	0	0,00	1	0	0	0,33	0	1	0	0,33
		30min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
		60min	1	0	0	0,33	0	0	0	0,00	0	0	1	0,33	0,22
		derivada2	0min	0	0	0	0,00	1	0	1	0,67	0	1	1	0,67
		30min	0	0	0	0,00	1	0	1	0,67	1	0	0	0,33	0,33
		máximo	0min	1	0	0	0,33	0	0	1	0,33	0	0	1	0,33
média	0min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11	
mínimo	0min	0	0	0	0,00	0	0	1	0,33	0	1	0	0,33	0,22	
radiação solar	absoluto	0min													
		30min													
		60min													
		90min													
		derivada	0min												
		30min													
		60min													
		derivada2	0min												
		30min													
		máximo	0min												
média	0min														
mínimo	0min														
pressão atmosférica	absoluto	0min	0	0	0	0,00	1	0	1	0,67	1	0	1	0,67	0,44
		30min	1	1	0	0,67	0	0	0	0,00	1	0	1	0,67	0,44
		60min	0	0	0	0,00	0	1	0	0,33	1	0	1	0,67	0,33
		90min	0	1	1	0,67	0	0	1	0,33	1	0	0	0,33	0,44
		derivada	0min	0	0	1	0,33	0	1	0	0,33	1	0	0	0,33
		30min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11
		60min	0	0	0	0,00	0	1	1	0,67	0	0	0	0,00	0,22
		derivada2	0min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00
		30min	0	1	1	0,67	0	0	1	0,33	0	0	1	0,33	0,44
		máximo	0min	1	0	1	0,67	0	0	1	0,33	0	0	1	0,33
média	0min	0	1	1	0,67	0	0	0	0,00	0	0	1	0,33	0,33	
mínimo	0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11	

ano	velocidade e direção do vento	absoluto	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
			30min	0	0	0	0,00	0	0	1	0,33	1	0	0	0,33	0,22
			60min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22
			90min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
		derivada	0min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
			30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
			60min	0	0	0	0,00	1	0	1	0,67	0	0	0	0,00	0,22
		derivada2	0min	0	0	1	0,33	1	0	1	0,67	1	0	0	0,33	0,44
			30min	0	0	1	0,33	1	0	1	0,67	0	0	0	0,00	0,33
		máximo	0min	0	0	0	0,00	0	1	1	0,67	0	0	0	0,00	0,22
			0min	0	0	0	0,00	0	0	0	0,00	1	0	1	0,67	0,22
		mínimo	0min	0	0	0	0,00	1	1	0	0,67	0	0	0	0,00	0,22
0min	0		0	0	0,00	0	0	0	0,00	0	1	1	0,67	0,22		
cosseno	0min	0	0	0	0,00	0	0	0	0,00	0	1	1	0,67	0,22		
	0min	0	1	1	0,67	0	0	1	0,33	1	1	0	0,67	0,56		

ano	carga	absoluto	0min	1	0	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22
			30min	0	0	0	0,00	0	1	1	0,67	1	0	0	0,33	0,33
			60min	0	1	0	0,33	0	0	0	0,00	0	0	1	0,33	0,22
			90min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11
		derivada	0min	1	1	1	1,00	1	0	1	0,67	0	1	1	0,67	0,78
			30min	1	0	1	0,67	0	1	1	0,67	0	0	1	0,33	0,56
			60min	1	0	0	0,33	0	1	1	0,67	1	1	1	1,00	0,67
		derivada2	0min	0	1	1	0,67	1	1	1	1,00	1	1	0	0,67	0,78
			30min	1	0	1	0,67	0	0	1	0,33	1	1	0	0,67	0,56
		máximo	0min	1	1	0	0,67	1	1	0	0,67	1	1	1	1,00	0,78
			0min	0	1	0	0,33	1	1	0	0,67	0	1	1	0,67	0,56
		mínimo	0min	1	0	1	0,67	0	0	1	0,33	1	0	0	0,33	0,44

ano	temperatura ambiente	absoluto	0min	0	0	0	0,00	0	0	1	0,33	0	1	1	0,67	0,33
			30min	0	0	0	0,00	0	0	1	0,33	0	0	1	0,33	0,22
			60min	0	1	0	0,33	1	0	1	0,67	0	1	0	0,33	0,44
			90min	0	1	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
		derivada	0min	1	1	0	0,67	0	0	0	0,00	0	1	0	0,33	0,33
			30min	1	1	1	1,00	1	0	1	0,67	0	1	1	0,67	0,78
			60min	0	1	0	0,33	0	0	1	0,33	1	1	0	0,67	0,44
		derivada2	0min	0	0	0	0,00	1	0	1	0,67	0	0	1	0,33	0,33
			30min	0	0	0	0,00	1	0	1	0,67	0	0	0	0,00	0,22
		máximo	0min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
			0min	1	0	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22
		mínimo	0min	1	0	1	0,67	1	0	0	0,33	0	0	0	0,00	0,33

ano	umidade relativa do ar	absoluto	0min	0	0	1	0,33	1	0	0	0,33	0	1	0	0,33	0,33
			30min	0	0	1	0,33	1	0	0	0,33	1	1	1	1,00	0,56
			60min	0	0	1	0,33	0	0	0	0,00	1	0	0	0,33	0,22
			90min	0	0	1	0,33	0	0	1	0,33	1	0	0	0,33	0,33
		derivada	0min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
			30min	0	0	1	0,33	0	0	0	0,00	0	0	1	0,33	0,22
			60min	0	0	1	0,33	0	0	0	0,00	1	0	0	0,33	0,22
		derivada2	0min	0	0	0	0,00	1	0	1	0,67	0	0	1	0,33	0,33
			30min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
		máximo	0min	0	0	0	0,00	0	0	1	0,33	1	1	0	0,67	0,33
			0min	0	0	1	0,33	0	0	1	0,33	0	0	1	0,33	0,33
		mínimo	0min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11

	radiação solar	absoluto	0min													
			30min													
			60min													
			90min													
		derivada	0min													
			30min													
			60min													
		derivada2	0min													
			30min													
		máximo	0min													
	média	0min														
	mínimo	0min														
	pressão atmosférica	absoluto	0min	0	0	1	0,33	1	0	0	0,33	1	1	0	0,67	0,44
			30min	1	0	1	0,67	1	0	0	0,33	1	0	0	0,33	0,44
			60min	1	1	1	1,00	1	0	0	0,33	1	0	0	0,33	0,56
			90min	0	0	1	0,33	0	0	0	0,00	1	0	1	0,67	0,33
		derivada	0min	1	0	1	0,67	0	0	0	0,00	0	0	1	0,33	0,33
			30min	0	0	1	0,33	0	0	0	0,00	0	1	0	0,33	0,22
			60min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
		derivada2	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
			30min	0	0	1	0,33	1	0	0	0,33	0	0	1	0,33	0,33
		máximo	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
	média	0min	0	0	0	0,00	0	0	1	0,33	0	1	1	0,67	0,33	
	mínimo	0min	0	0	1	0,33	1	0	0	0,33	1	0	1	0,67	0,44	
	velocidade e direção do vento	absoluto	0min	0	1	0	0,33	1	0	1	0,67	1	0	0	0,33	0,44
			30min	1	1	1	1,00	0	1	1	0,67	0	0	0	0,00	0,56
			60min	1	1	0	0,67	1	0	0	0,33	0	0	0	0,00	0,33
			90min	0	0	1	0,33	0	1	0	0,33	0	0	0	0,00	0,22
		derivada	0min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
		30min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11	
		60min	0	1	1	0,67	1	0	0	0,33	1	0	0	0,33	0,44	
derivada2		0min	0	0	1	0,33	0	0	0	0,00	0	0	1	0,33	0,22	
		30min	0	1	1	0,67	1	1	0	0,67	0	0	0	0,00	0,44	
máximo		0min	1	1	1	1,00	0	0	0	0,00	0	0	1	0,33	0,44	
média		0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
mínimo		0min	0	0	1	0,33	0	0	0	0,00	1	0	0	0,33	0,22	
coseno		0min	0	0	1	0,33	0	0	1	0,33	0	1	1	0,67	0,44	
seno		0min	0	1	1	0,67	0	1	1	0,67	1	0	1	0,67	0,67	

Tabela 45 - Grupo A – SRA: Carga e Todas as Variáveis Climáticas

Época	Tipo	Classe	Deslocamento	Estação												Total uso (%)
				Inverno				Outono				Verão				
				exp1	exp2	exp3	Uso (%)	exp1	exp2	exp3	Uso (%)	exp1	exp2	exp3	Uso (%)	
tempo	dia semana	cosseno	0min	1	1	1	1,00	0	1	0	0,33	0	1	0	0,33	0,56
		seno	0min	1	1	0	0,67	1	1	0	0,67	0	0	0	0,00	0,44
	meia hora dia	cosseno	0min	0	0	1	0,33	1	0	0	0,33	1	1	1	1,00	0,56
		seno	0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
	semana do ano	cosseno	0min	0	0	1	0,33	1	0	1	0,67	0	1	1	0,67	0,56
		seno	0min	0	1	1	0,67	0	0	1	0,33	1	0	0	0,33	0,44
agora	Carga	absoluto	30min	0	1	1	0,67	1	1	1	1,00	1	1	1	1,00	0,89
			60min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00
			90min	1	1	1	1,00	1	1	1	1,00	1	1	0	0,67	0,89
		derivada	30min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00
			60min	1	0	0	0,33	0	0	1	0,33	1	0	1	0,67	0,44
			derivada2	30min	1	1	1	1,00	1	1	0	0,67	0	1	1	0,67
	temperatura ambiente	absoluto	0min	0	0	0	0,00	1	0	1	0,67	1	1	0	0,67	0,44
			30min	0	1	1	0,67	1	1	1	1,00	1	0	0	0,33	0,67
			60min	0	1	1	0,67	1	0	0	0,33	1	1	0	0,67	0,56
			90min	1	1	0	0,67	1	0	0	0,33	1	0	1	0,67	0,56
		derivada	0min	1	0	0	0,33	0	0	0	0,00	0	0	1	0,33	0,22
			30min	1	0	1	0,67	0	1	0	0,33	0	1	0	0,33	0,44
			60min	0	0	1	0,33	0	0	0	0,00	1	0	1	0,67	0,33
			derivada2	0min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00
		30min	1	0	0	0,33	1	0	0	0,33	0	0	1	0,33	0,33	
		máximo	0min	1	0	1	0,67	0	1	0	0,33	0	0	1	0,33	0,44
			30min	0	0	1	0,33	0	0	1	0,33	0	0	0	0,00	0,22
			60min	0	0	0	0,00	1	0	0	0,33	0	0	1	0,33	0,22
	90min		0	0	0	0,00	1	0	0	0,33	0	0	1	0,33	0,22	
	umidade relativa do ar	absoluto	0min	0	0	1	0,33	0	0	0	0,00	0	0	1	0,33	0,22
			30min	0	0	0	0,00	0	1	0	0,33	1	1	1	1,00	0,44
			60min	0	0	1	0,33	0	0	0	0,00	1	1	1	1,00	0,44
			90min	0	0	1	0,33	0	0	0	0,00	1	0	0	0,33	0,22
		derivada	0min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
30min			0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
60min			0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
derivada2			0min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11
30min		1	0	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22		
máximo		0min	0	0	0	0,00	0	0	0	0,00	1	0	1	0,67	0,22	
		30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
		60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
	90min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00		
média	0min	0	0	0	0,00	1	0	0	0,33	0	1	0	0,33	0,22		
	30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00		
	60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00		
	90min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00		

		mínimo	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00		
	radiação solar	absoluto	0min															
			30min															
			60min															
			90min															
		derivada	0min															
			30min															
			60min															
		derivada2	0min															
			30min															
			máximo	0min														
		média	0min															
	pressão atmosférica	absoluto	0min	1	1	1	1,00	0	0	0	0,00	0	0	0	0,00	0,33		
			30min	0	0	0	0,00	0	1	0	0,33	0	1	1	0,67	0,33		
			60min	1	1	0	0,67	1	1	0	0,67	1	0	0	0,33	0,56		
			90min	1	1	1	1,00	0	0	1	0,33	1	1	1	1,00	0,78		
		derivada	0min	0	0	1	0,33	1	0	0	0,33	0	1	1	0,67	0,44		
			30min	0	1	1	0,67	1	0	0	0,33	1	0	1	0,67	0,56		
			60min	0	1	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22		
		derivada2	0min	1	1	0	0,67	0	1	1	0,67	0	1	1	0,67	0,67		
			30min	0	1	0	0,33	0	0	0	0,00	0	0	1	0,33	0,22		
			máximo	0min	1	1	0	0,67	0	0	0	0,00	0	0	1	0,33	0,33	
		média	0min	0	0	0	0,00	1	0	0	0,33	0	1	0	0,33	0,22		
		mínimo	0min	0	0	0	0,00	0	0	1	0,33	1	1	0	0,67	0,33		
	velocidade e direção do vento	absoluto	0min	1	0	0	0,33	1	0	0	0,33	0	0	1	0,33	0,33		
			30min	0	0	1	0,33	1	0	0	0,33	1	0	1	0,67	0,44		
			60min	0	1	1	0,67	0	0	1	0,33	1	0	0	0,33	0,44		
			90min	1	0	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22		
		derivada	0min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11		
			30min	1	0	1	0,67	0	0	0	0,00	1	0	0	0,33	0,33		
			60min	0	0	0	0,00	0	0	1	0,33	0	0	1	0,33	0,22		
		derivada2	0min	0	1	1	0,67	1	0	1	0,67	0	0	0	0,00	0,44		
			30min	0	1	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22		
			máximo	0min	0	1	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22	
		média	0min	0	0	0	0,00	1	0	1	0,67	1	0	1	0,67	0,44		
		mínimo	0min	0	1	1	0,67	1	0	1	0,67	1	0	0	0,33	0,56		
		coseno	0min	0	0	0	0,00	0	0	1	0,33	1	0	0	0,33	0,22		
		seno	0min	1	0	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22		
semana	carga	absoluto	0min	0	1	1	0,67	0	0	0	0,00	1	0	1	0,67	0,44		
			30min	0	0	0	0,00	1	0	0	0,33	0	1	0	0,33	0,22		
			60min	0	1	0	0,33	1	1	0	0,67	0	0	0	0,00	0,33		
			90min	1	1	1	1,00	0	0	1	0,33	0	0	0	0,00	0,44		
		derivada	0min	1	1	1	1,00	0	1	0	0,33	1	1	1	1,00	0,78		
			30min	1	1	1	1,00	1	0	1	0,67	0	0	1	0,33	0,67		
			60min	1	1	0	0,67	1	1	1	1,00	1	0	0	0,33	0,67		
		derivada2	0min	0	1	0	0,33	1	0	1	0,67	1	0	1	0,67	0,56		
			30min	1	0	0	0,33	1	1	1	1,00	1	0	1	0,67	0,67		
			máximo	0min	0	0	1	0,33	1	0	1	0,67	1	0	1	0,67	0,56	
	média	0min	1	0	1	0,67	0	0	0	0,00	0	0	1	0,33	0,33			

	mínimo	0min	1	1	1	1,00	0	1	1	0,67	1	0	0	0,33	0,67	
temperatura ambiente	absoluto	0min	1	1	0	0,67	1	0	0	0,33	1	1	1	1,00	0,67	
		30min	1	0	0	0,33	0	0	1	0,33	0	1	0	0,33	0,33	
		60min	0	0	0	0,00	0	1	0	0,33	1	1	1	1,00	0,44	
		90min	1	1	0	0,67	0	0	1	0,33	1	1	0	0,67	0,56	
	derivada	0min	0	0	0	0,00	0	0	0	0,00	1	1	0	0,67	0,22	
		30min	0	1	0	0,33	1	0	0	0,33	0	0	1	0,33	0,33	
		60min	0	0	1	0,33	0	0	0	0,00	0	1	0	0,33	0,22	
	derivada2	0min	0	0	0	0,00	0	0	0	0,00	0	0	1	0,33	0,11	
		30min	1	0	1	0,67	1	0	1	0,67	0	0	0	0,00	0,44	
	máximo	0min	1	0	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22	
média	0min	0	0	1	0,33	1	0	1	0,67	0	1	1	0,67	0,56		
mínimo	0min	1	0	1	0,67	1	0	1	0,67	1	0	1	0,67	0,67		
umidade relativa do ar	absoluto	0min	1	1	1	1,00	1	0	1	0,67	0	1	1	0,67	0,78	
		30min	1	1	0	0,67	0	1	1	0,67	0	1	0	0,33	0,56	
		60min	1	0	0	0,33	1	1	1	1,00	1	1	0	0,67	0,67	
		90min	1	0	0	0,33	1	0	1	0,67	1	1	0	0,67	0,56	
	derivada	0min	1	0	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22	
		30min	0	1	1	0,67	1	1	1	1,00	0	0	1	0,33	0,67	
		60min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11	
	derivada2	0min	0	1	0	0,33	1	1	1	1,00	0	0	0	0,00	0,44	
		30min	0	0	0	0,00	0	0	0	0,00	1	0	1	0,67	0,22	
	máximo	0min	0	0	0	0,00	1	0	1	0,67	1	0	0	0,33	0,33	
média	0min	0	0	0	0,00	1	1	1	1,00	1	0	0	0,33	0,44		
mínimo	0min	0	1	0	0,33	1	0	0	0,33	0	1	1	0,67	0,44		
radiação solar	absoluto	0min														
		30min														
		60min														
		90min														
	derivada	0min														
		30min														
		60min														
	derivada2	0min														
		30min														
	máximo	0min														
média	0min															
mínimo	0min															
pressão atmosférica	absoluto	0min	0	0	1	0,33	0	0	0	0,00	1	1	1	1,00	0,44	
		30min	0	0	0	0,00	1	0	0	0,33	0	1	1	0,67	0,33	
		60min	0	0	0	0,00	0	0	1	0,33	1	0	0	0,33	0,22	
		90min	1	0	0	0,33	0	0	1	0,33	0	0	1	0,33	0,33	
	derivada	0min	1	0	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22	
		30min	0	0	0	0,00	0	0	0	0,00	0	0	1	0,33	0,11	
		60min	0	0	0	0,00	0	0	1	0,33	0	1	1	0,67	0,33	
	derivada2	0min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
		30min	0	0	0	0,00	0	0	0	0,00	1	1	0	0,67	0,22	
	máximo	0min	1	0	1	0,67	0	0	0	0,00	0	1	1	0,67	0,44	
média	0min	1	1	0	0,67	0	0	0	0,00	1	0	0	0,33	0,33		
mínimo	0min	0	1	0	0,33	0	0	0	0,00	0	1	1	0,67	0,33		

	velocidade e direção do vento	absoluto	0min	0	1	1	0,67	1	0	1	0,67	0	1	0	0,33	0,56
			30min	0	1	1	0,67	1	0	1	0,67	0	0	1	0,33	0,56
			60min	0	0	0	0,00	0	0	1	0,33	0	1	0	0,33	0,22
			90min	0	0	0	0,00	1	0	1	0,67	0	0	1	0,33	0,33
		derivada	0min	0	0	1	0,33	1	0	1	0,67	0	0	0	0,00	0,33
			30min	0	0	1	0,33	1	0	0	0,33	1	0	0	0,33	0,33
			60min	1	0	0	0,33	0	0	1	0,33	0	0	1	0,33	0,33
		derivada2	0min	0	0	1	0,33	1	0	0	0,33	0	0	0	0,00	0,22
			30min	0	1	1	0,67	1	0	1	0,67	0	0	1	0,33	0,56
		máximo	0min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
		média	0min	0	0	1	0,33	1	0	1	0,67	0	1	0	0,33	0,44
		mínimo	0min	1	0	0	0,33	0	0	1	0,33	0	1	0	0,33	0,33
cosseno	0min	0	0	0	0,00	0	1	1	0,67	0	0	0	0,00	0,22		
seno	0min	1	0	0	0,33	1	1	1	1,00	0	0	1	0,33	0,56		
ano	carga	absoluto	0min	1	0	1	0,67	1	1	1	1,00	0	0	0	0,00	0,56
			30min	1	1	0	0,67	0	1	0	0,33	0	0	0	0,00	0,33
			60min	1	0	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22
			90min	0	0	0	0,00	0	1	0	0,33	0	1	0	0,33	0,22
		derivada	0min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00
			30min	1	0	0	0,33	1	1	1	1,00	0	1	1	0,67	0,67
			60min	0	1	1	0,67	0	1	0	0,33	1	1	0	0,67	0,56
		derivada2	0min	1	1	1	1,00	1	1	1	1,00	0	1	1	0,67	0,89
			30min	1	0	0	0,33	0	0	1	0,33	1	0	1	0,67	0,44
		máximo	0min	0	0	0	0,00	1	0	0	0,33	1	0	0	0,33	0,22
		média	0min	0	1	0	0,33	1	0	0	0,33	1	1	1	1,00	0,56
		mínimo	0min	0	0	0	0,00	1	0	1	0,67	0	0	1	0,33	0,33
temperatura ambiente	absoluto	0min	1	0	0	0,33	0	0	0	0,00	1	1	0	0,67	0,33	
		30min	1	1	1	1,00	0	0	0	0,00	0	1	1	0,67	0,56	
		60min	0	1	0	0,33	0	1	0	0,33	1	1	1	1,00	0,56	
		90min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22	
	derivada	0min	1	1	0	0,67	1	0	1	0,67	1	0	0	0,33	0,56	
		30min	0	1	0	0,33	1	0	0	0,33	1	1	1	1,00	0,56	
		60min	0	0	0	0,00	0	0	0	0,00	1	0	1	0,67	0,22	
	derivada2	0min	0	0	1	0,33	1	1	1	1,00	0	1	0	0,33	0,56	
		30min	1	0	1	0,67	1	0	1	0,67	0	0	0	0,00	0,44	
	máximo	0min	1	0	0	0,33	1	0	0	0,33	1	0	0	0,33	0,33	
média	0min	0	0	1	0,33	1	0	0	0,33	1	1	1	1,00	0,56		
mínimo	0min	1	0	1	0,67	1	1	1	1,00	0	0	0	0,00	0,56		
umidade relativa do ar	absoluto	0min	0	0	1	0,33	0	0	0	0,00	0	1	1	0,67	0,33	
		30min	0	0	0	0,00	0	0	1	0,33	0	0	1	0,33	0,22	
		60min	0	1	1	0,67	0	0	0	0,00	0	1	1	0,67	0,44	
		90min	1	1	0	0,67	0	0	0	0,00	0	1	1	0,67	0,44	
	derivada	0min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22	
		30min	0	1	1	0,67	1	0	0	0,33	0	1	1	0,67	0,56	
		60min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11	
	derivada2	0min	0	1	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22	
		30min	0	1	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22	
	máximo	0min	1	0	0	0,33	1	1	0	0,67	1	1	1	1,00	0,67	
média	0min	0	0	0	0,00	0	0	0	0,00	1	1	1	1,00	0,33		
mínimo	0min	1	1	0	0,67	1	0	0	0,33	0	0	1	0,33	0,44		

	radiação solar	absoluto	0min														
			30min														
			60min														
			90min														
		derivada	0min														
			30min														
			60min														
		derivada2	0min														
			30min														
		máximo	0min														
		média	0min														
		mínimo	0min														
	pressão atmosférica	absoluto	0min	0	1	1	0,67	0	0	0	0,00	0	1	1	0,67	0,44	
			30min	0	0	0	0,00	0	0	0	0,00	0	1	1	0,67	0,22	
			60min	0	0	0	0,00	1	0	0	0,33	1	1	0	0,67	0,33	
			90min	1	1	1	1,00	1	0	0	0,33	1	0	0	0,33	0,56	
		derivada	0min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
			30min	0	0	1	0,33	1	0	1	0,67	0	0	0	0,00	0,33	
			60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
		derivada2	0min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22	
			30min	0	1	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22	
		máximo	0min	0	0	0	0,00	0	0	1	0,33	0	1	1	0,67	0,33	
		média	0min	1	0	0	0,33	1	0	0	0,33	1	1	0	0,67	0,44	
		mínimo	0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11	
	velocidade e direção do vento	absoluto	0min	1	0	0	0,33	0	1	1	0,67	0	0	0	0,00	0,33	
			30min	1	1	0	0,67	0	1	0	0,33	0	0	0	0,00	0,33	
			60min	0	1	0	0,33	1	1	0	0,67	1	0	0	0,33	0,44	
			90min	0	0	0	0,00	1	0	1	0,67	1	0	1	0,67	0,44	
		derivada	0min	1	0	0	0,33	0	0	0	0,00	0	0	1	0,33	0,22	
		30min	1	0	0	0,33	0	1	0	0,33	0	1	0	0,33	0,33		
		60min	1	1	0	0,67	0	0	0	0,00	0	1	0	0,33	0,33		
derivada2		0min	1	0	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33		
		30min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11		
máximo		0min	0	0	0	0,00	0	0	1	0,33	0	1	0	0,33	0,22		
média		0min	1	0	0	0,33	1	1	0	0,67	0	0	0	0,00	0,33		
mínimo		0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11		
coseno		0min	1	0	1	0,67	0	0	1	0,33	0	1	0	0,33	0,44		
seno		0min	0	0	0	0,00	0	0	1	0,33	1	0	0	0,33	0,22		

Tabela 46 - Grupo A – TDE: Carga e Todas as Variáveis Climáticas

Época	Tipo	Classe	Deslocamento	Estação												Total uso (%)
				Inverno				Outono				Verão				
				exp1	exp2	exp3	Uso (%)	exp1	exp2	exp3	Uso (%)	exp1	exp2	exp3	Uso (%)	
tempo	dia semana	cosseno	0min	1	1	0	0,67	0	0	0	0,00	0	0	1	0,33	0,33
		seno	0min	1	1	1	1,00	0	1	1	0,67	0	0	0	0,00	0,56
	meia hora dia	cosseno	0min	0	1	0	0,33	0	0	1	0,33	1	0	1	0,67	0,44
		seno	0min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22
	semana do ano	cosseno	0min	1	1	1	1,00	0	1	0	0,33	1	0	0	0,33	0,56
		seno	0min	0	1	1	0,67	0	0	1	0,33	1	0	1	0,67	0,56
agora	Carga	absoluto	30min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00
			60min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00
			90min	1	1	1	1,00	1	0	0	0,33	1	1	1	1,00	0,78
		derivada	30min	1	1	1	1,00	0	1	1	0,67	1	1	1	1,00	0,89
			60min	1	1	1	1,00	1	0	0	0,33	1	1	1	1,00	0,78
		derivada2	30min	1	1	0	0,67	1	0	0	0,33	1	0	1	0,67	0,56
	temperatura ambiente	absoluto	0min	1	0	0	0,33	0	0	0	0,00	1	0	1	0,67	0,33
			30min	0	0	0	0,00	1	0	0	0,33	0	0	1	0,33	0,22
			60min	1	0	0	0,33	0	0	1	0,33	1	1	0	0,67	0,44
			90min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11
		derivada	0min	0	0	0	0,00	0	0	1	0,33	1	0	0	0,33	0,22
			30min	0	0	0	0,00	1	0	0	0,33	1	0	1	0,67	0,33
			60min	1	0	0	0,33	1	0	0	0,33	1	1	1	1,00	0,56
		derivada2	0min	0	0	1	0,33	0	0	1	0,33	1	0	0	0,33	0,33
			30min	1	0	0	0,33	1	0	0	0,33	1	1	1	1,00	0,56
		máximo	0min	0	0	0	0,00	1	0	1	0,67	0	1	0	0,33	0,33
			30min	0	0	0	0,00	1	0	1	0,67	1	0	0	0,33	0,33
			60min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
	90min		0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11	
	umidade relativa do ar	absoluto	0min	0	1	1	0,67	0	0	0	0,00	1	0	0	0,33	0,33
			30min	1	0	0	0,33	0	0	0	0,00	1	1	1	1,00	0,44
			60min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			90min	1	0	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22
		derivada	0min	0	1	0	0,33	0	0	0	0,00	1	0	1	0,67	0,33
			30min	1	0	0	0,33	0	0	0	0,00	0	0	1	0,33	0,22
			60min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
		derivada2	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
			30min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
		máximo	0min	0	0	1	0,33	0	0	0	0,00	1	1	1	1,00	0,44
			30min	1	0	1	0,67	0	0	1	0,33	1	1	1	1,00	0,67
60min			0	0	1	0,33	0	0	1	0,33	0	0	0	0,00	0,11	
90min	0		0	1	0,33	0	0	1	0,33	0	0	0	0,00	0,11		

semana	radiação solar	absoluto	0min	1	1	0	0,67	1	0	0	0,33	0	0	0	0,00	0,33
			30min	0	1	0	0,33	1	1	0	0,67	0	0	0	0,00	0,33
			60min	1	1	1	1,00	0	1	1	0,67	0	1	0	0,33	0,67
			90min	0	0	0	0,00	0	1	1	0,67	1	0	0	0,33	0,33
		derivada	0min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
			60min	1	0	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22
		derivada2	0min	1	1	0	0,67	0	0	0	0,00	1	0	0	0,33	0,33
			30min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11
		máximo	0min	0	1	0	0,33	0	0	1	0,33	1	0	1	0,67	0,44
		média	0min	0	1	0	0,33	0	0	1	0,33	0	0	1	0,33	0,33
		mínimo	0min	1	0	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22
	pressão atmosférica	absoluto	0min	0	0	1	0,33	0	0	0	0,00	0	0	1	0,33	0,22
			30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
			60min	0	0	0	0,00	0	1	1	0,67	0	0	0	0,00	0,22
			90min	0	0	1	0,33	1	1	0	0,67	0	0	0	0,00	0,33
		derivada	0min	0	1	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
			30min	1	0	0	0,33	1	0	0	0,33	0	0	1	0,33	0,33
			60min	0	1	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22
		derivada2	0min	1	0	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
			30min	0	1	0	0,33	0	0	1	0,33	0	0	1	0,33	0,33
		máximo	0min	0	1	1	0,67	0	0	1	0,33	0	0	1	0,33	0,44
		média	0min	0	0	0	0,00	0	1	1	0,67	0	0	1	0,33	0,33
		mínimo	0min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
	velocidade e direção do vento	absoluto	0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
			30min	0	1	0	0,33	0	1	0	0,33	0	0	0	0,00	0,22
			60min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
			90min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		derivada	0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
			30min	0	0	0	0,00	0	0	0	0,00	0	0	1	0,33	0,11
			60min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
		derivada2	0min	0	0	0	0,00	1	0	0	0,33	0	0	0	0,00	0,11
			30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		máximo	0min	0	0	0	0,00	0	1	0	0,33	1	1	0	0,67	0,33
		média	0min	1	0	0	0,33	0	1	0	0,33	0	1	0	0,33	0,33
		mínimo	0min	0	1	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22
cosseno	0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11		
seno	0min	0	1	0	0,33	0	1	0	0,33	0	1	0	0,33	0,33		
carga	absoluto	0min	0	1	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22	
		30min	0	0	1	0,33	0	0	0	0,00	0	1	1	0,67	0,33	
		60min	1	1	0	0,67	1	0	0	0,33	0	0	0	0,00	0,33	
		90min	1	1	1	1,00	0	0	0	0,00	1	1	0	0,67	0,56	
	derivada	0min	1	1	1	1,00	1	1	1	1,00	1	1	1	1,00	1,00	
		30min	0	1	1	0,67	0	0	0	0,00	0	0	1	0,33	0,33	
		60min	1	1	0	0,67	0	1	0	0,33	1	0	1	0,67	0,56	
	derivada2	0min	1	1	1	1,00	1	1	1	1,00	0	1	1	0,67	0,89	
		30min	1	0	1	0,67	1	1	0	0,67	0	0	1	0,33	0,56	
	máximo	0min	1	1	1	1,00	0	0	1	0,33	1	0	0	0,33	0,56	
	média	0min	0	1	1	0,67	1	0	0	0,33	0	0	1	0,33	0,44	
	mínimo	0min	1	0	1	0,67	1	1	1	1,00	1	0	1	0,67	0,78	

temperatura ambiente	absoluto	0min	0	1	0	0,33	1	0	1	0,67	0	1	1	0,67	0,56
		30min	0	0	0	0,00	1	0	0	0,33	1	0	1	0,67	0,33
		60min	0	1	0	0,33	0	0	1	0,33	0	1	0	0,33	0,33
		90min	0	1	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22
	derivada	0min	0	1	1	0,67	0	0	0	0,00	0	0	0	0,00	0,22
		30min	0	0	0	0,00	1	0	0	0,33	0	1	0	0,33	0,22
		60min	0	0	0	0,00	0	0	1	0,33	0	1	0	0,33	0,22
	derivada2	0min	0	0	0	0,00	0	0	1	0,33	0	1	0	0,33	0,22
		30min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11
	máximo	0min	0	1	0	0,33	1	0	1	0,67	0	1	1	0,67	0,56
	média	0min	0	1	0	0,33	1	0	1	0,67	0	1	0	0,33	0,44
	mínimo	0min	0	0	0	0,00	1	1	0	0,67	0	1	1	0,67	0,44
umidade relativa do ar	absoluto	0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
		30min	0	0	0	0,00	0	1	0	0,33	0	1	0	0,33	0,22
		60min	0	0	0	0,00	1	0	0	0,33	0	1	0	0,33	0,22
		90min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
	derivada	0min	0	0	0	0,00	0	1	0	0,33	1	1	1	1,00	0,44
		30min	0	0	0	0,00	1	1	0	0,67	1	1	0	0,67	0,44
		60min	0	0	1	0,33	0	1	0	0,33	1	1	0	0,67	0,44
	derivada2	0min	0	0	0	0,00	0	1	0	0,33	1	0	0	0,33	0,22
		30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
	máximo	0min	0	0	0	0,00	0	0	0	0,00	0	1	1	0,67	0,22
	média	0min	0	0	0	0,00	1	1	0	0,67	1	0	0	0,33	0,33
	mínimo	0min	0	0	0	0,00	1	0	0	0,33	0	0	1	0,33	0,22
radiação solar	absoluto	0min	1	1	0	0,67	1	0	1	0,67	0	0	0	0,00	0,44
		30min	1	0	1	0,67	0	0	0	0,00	0	1	0	0,33	0,33
		60min	0	1	0	0,33	0	0	0	0,00	0	1	0	0,33	0,22
		90min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11
	derivada	0min	0	0	0	0,00	0	0	0	0,00	0	0	1	0,33	0,11
		30min	0	0	1	0,33	0	0	0	0,00	0	0	0	0,00	0,11
		60min	1	0	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22
	derivada2	0min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11
		30min	0	0	1	0,33	0	0	0	0,00	1	0	0	0,33	0,22
	máximo	0min	0	0	0	0,00	0	1	0	0,33	0	0	1	0,33	0,22
	média	0min	1	0	0	0,33	0	1	0	0,33	0	0	0	0,00	0,22
	mínimo	0min	0	1	1	0,67	0	0	1	0,33	1	0	1	0,67	0,56
pressão atmosférica	absoluto	0min	1	1	1	1,00	0	1	1	0,67	0	1	0	0,33	0,67
		30min	1	1	1	1,00	0	0	1	0,33	0	1	1	0,67	0,67
		60min	1	1	1	1,00	1	1	1	1,00	0	0	0	0,00	0,67
		90min	1	0	1	0,67	0	1	1	0,67	0	0	1	0,33	0,56
	derivada	0min	0	0	1	0,33	0	1	0	0,33	0	0	0	0,00	0,22
		30min	0	1	1	0,67	0	0	1	0,33	0	0	1	0,33	0,44
		60min	0	1	1	0,67	0	1	0	0,33	0	1	0	0,33	0,44
	derivada2	0min	0	0	1	0,33	0	0	0	0,00	1	1	1	1,00	0,44
		30min	0	0	0	0,00	0	1	1	0,67	0	1	1	0,67	0,44
	máximo	0min	1	0	1	0,67	1	0	0	0,33	0	0	0	0,00	0,33
	média	0min	1	1	1	1,00	0	0	1	0,33	0	1	0	0,33	0,56
	mínimo	0min	0	0	0	0,00	0	1	1	0,67	0	0	0	0,00	0,22

ano	velocidade e direção do vento	absoluto	0min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
			30min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			60min	1	1	0	0,67	0	0	1	0,33	0	0	1	0,33	0,44
			90min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		derivada	0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			30min	0	0	0	0,00	0	0	1	0,33	0	0	0	0,00	0,11
			60min	1	0	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22
		derivada2	0min	1	0	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
			30min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11
		máximo	0min	0	0	0	0,00	1	0	0	0,33	1	1	0	0,67	0,33
			0min	0	0	0	0,00	0	1	0	0,33	0	1	0	0,33	0,22
		mínimo	0min	0	0	0	0,00	0	0	1	0,33	1	0	0	0,33	0,22
0min	1		1	0	0,67	1	1	0	0,67	0	0	0	0,00	0,44		
cosseno	0min	1	1	0	0,67	1	1	0	0,67	0	0	0	0,00	0,44		
	0min	0	0	1	0,33	0	1	0	0,33	0	0	0	0,00	0,22		

ano	carga	absoluto	0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			30min	0	0	0	0,00	1	0	0	0,33	1	0	1	0,67	0,33
			60min	1	0	0	0,33	0	1	1	0,67	0	1	1	0,67	0,56
			90min	1	0	1	0,67	0	0	0	0,00	0	0	1	0,33	0,33
		derivada	0min	1	0	1	0,67	1	1	1	1,00	1	1	1	1,00	0,89
			30min	1	0	0	0,33	1	1	1	1,00	1	1	0	0,67	0,67
			60min	0	1	1	0,67	0	0	1	0,33	0	0	0	0,00	0,33
		derivada2	0min	0	1	0	0,33	1	1	1	1,00	1	0	1	0,67	0,67
			30min	1	1	1	1,00	0	0	0	0,00	0	0	0	0,00	0,33
		máximo	0min	1	0	0	0,33	0	0	1	0,33	0	1	0	0,33	0,33
			0min	1	0	0	0,33	0	1	1	0,67	0	0	0	0,00	0,33
		mínimo	0min	0	0	0	0,00	1	1	0	0,67	0	0	0	0,00	0,22
0min	1		0	0	0,33	1	1	1	1,00	0	1	0	0,33	0,56		

ano	temperatura ambiente	absoluto	0min	1	0	0	0,33	1	1	1	1,00	0	1	0	0,33	0,56
			30min	0	0	0	0,00	1	1	1	1,00	0	0	0	0,00	0,33
			60min	0	0	0	0,00	1	0	1	0,67	1	1	0	0,67	0,44
			90min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11
		derivada	0min	1	0	0	0,33	0	1	0	0,33	0	0	0	0,00	0,22
			30min	1	1	0	0,67	0	0	0	0,00	1	0	0	0,33	0,33
			60min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
		derivada2	0min	0	1	0	0,33	0	0	0	0,00	1	0	0	0,33	0,22
			30min	1	1	0	0,67	1	1	1	1,00	0	0	1	0,33	0,67
		máximo	0min	1	1	0	0,67	0	0	0	0,00	1	0	0	0,33	0,33
			0min	0	0	0	0,00	0	0	0	0,00	1	1	1	1,00	0,33
		mínimo	0min	1	0	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
0min	1		0	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33		

ano	umidade relativa do ar	absoluto	0min	0	0	0	0,00	0	1	0	0,33	1	0	1	0,67	0,33
			30min	0	0	1	0,33	0	1	0	0,33	0	0	0	0,00	0,22
			60min	0	0	1	0,33	0	1	0	0,33	1	0	0	0,33	0,33
			90min	0	0	0	0,00	0	1	0	0,33	1	1	0	0,67	0,33
		derivada	0min	0	0	0	0,00	0	1	0	0,33	0	1	0	0,33	0,22
			30min	0	0	0	0,00	1	1	0	0,67	1	0	0	0,33	0,33
			60min	0	0	0	0,00	0	0	0	0,00	1	0	0	0,33	0,11
		derivada2	0min	0	0	0	0,00	0	1	0	0,33	0	0	1	0,33	0,22
			30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		máximo	0min	1	0	1	0,67	0	1	0	0,33	0	1	1	0,67	0,56
			0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		mínimo	0min	0	0	0	0,00	0	0	0	0,00	1	1	0	0,67	0,22
0min	0		0	0	0,00	0	0	0	0,00	1	1	0	0,67	0,22		

	radiação solar	absoluto	0min	1	1	1	1,00	1	0	1	0,67	0	0	0	0,00	0,56
			30min	1	1	0	0,67	1	0	0	0,33	0	0	0	0,00	0,33
			60min	0	1	0	0,33	0	0	1	0,33	0	0	0	0,00	0,22
			90min	1	0	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
		derivada	0min	0	1	0	0,33	1	0	1	0,67	0	0	0	0,00	0,33
			30min	0	0	0	0,00	0	0	1	0,33	0	1	0	0,33	0,22
			60min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22
		derivada2	0min	0	1	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			30min	1	1	0	0,67	0	0	0	0,00	0	0	0	0,00	0,22
		máximo	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
		média	0min	0	0	0	0,00	0	1	0	0,33	0	0	0	0,00	0,11
		mínimo	0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
	pressão atmosférica	absoluto	0min	1	0	1	0,67	0	0	0	0,00	1	1	0	0,67	0,44
			30min	1	1	1	1,00	0	1	1	0,67	1	0	1	0,67	0,78
			60min	0	0	0	0,00	1	0	1	0,67	0	0	0	0,00	0,22
			90min	1	1	0	0,67	1	1	0	0,67	0	1	0	0,33	0,56
		derivada	0min	0	0	1	0,33	0	0	0	0,00	1	0	1	0,67	0,33
			30min	1	0	0	0,33	0	0	1	0,33	0	0	1	0,33	0,33
			60min	1	0	0	0,33	0	0	1	0,33	1	1	1	1,00	0,56
		derivada2	0min	0	0	1	0,33	0	1	0	0,33	0	0	0	0,00	0,22
			30min	1	0	0	0,33	0	0	0	0,00	1	1	1	1,00	0,44
		máximo	0min	1	1	1	1,00	0	0	1	0,33	1	0	0	0,33	0,56
		média	0min	1	1	0	0,67	0	1	0	0,33	1	1	1	1,00	0,67
		mínimo	0min	1	0	0	0,33	0	1	1	0,67	1	1	1	1,00	0,67
	velocidade e direção do vento	absoluto	0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
			30min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
			60min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00
			90min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
		derivada	0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11
			30min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
			60min	0	0	1	0,33	1	1	0	0,67	0	1	0	0,33	0,44
		derivada2	0min	0	0	0	0,00	0	1	0	0,33	0	1	0	0,33	0,22
			30min	1	0	0	0,33	0	0	0	0,00	0	0	0	0,00	0,11
máximo		0min	0	0	0	0,00	0	0	0	0,00	0	1	0	0,33	0,11	
média		0min	0	0	0	0,00	0	0	0	0,00	0	0	0	0,00	0,00	
mínimo		0min	0	0	0	0,00	1	0	0	0,33	0	1	0	0,33	0,22	
cosseno		0min	0	0	0	0,00	0	0	0	0,00	0	0	1	0,33	0,11	
seno	0min	1	0	0	0,33	1	0	0	0,33	0	0	0	0,00	0,22		