

Luiz Fernando Spillere de Souza

**CORREÇÃO DOS ERROS DE PREVISÃO DE CARGA
ELÉTRICA DE CURTO PRAZO DECORRENTES DE
VARIÇÕES DE TEMPERATURA NA ILHA DE SANTA
CATARINA UTILIZANDO REDE NEURAL**

Dissertação submetida ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Santa Catarina para a obtenção do Grau de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Raul Sidnei Wazlawick

Florianópolis
2013

Ficha de identificação da obra elaborada pelo autor através do
Programa de Geração Automática da Biblioteca Universitária da UFSC.

Souza, Luiz Fernando Spillere de

CORREÇÃO DOS ERROS DE PREVISÃO DE CARGA ELÉTRICA DE CURTO
PRAZO DECORRENTES DE VARIAÇÕES DE TEMPERATURA NA ILHA DE SANTA
CATARINA UTILIZANDO REDE NEURAL / Luiz Fernando Spillere de
Souza ; orientador, Raul Sidnei Wazlawick - Florianópolis, SC,
2013.

85 p.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Centro Tecnológico. Programa de Pós-Graduação em
Ciência da Computação.

Inclui referências

1. Ciência da Computação. 2. Redes Neurais. 3. Redes
Elétricas. 4. Previsão de Carga Elétrica. 5. Efeitos
Climatográficos em Cargas Elétricas. 6. Sistemas de Potência.
I. Wazlawick, Raul Sidnei . II. Universidade Federal de Santa
Catarina. Programa de Pós-Graduação em Ciência da Computação.
III. Título.

Luiz Fernando Spillere de Souza

**CORREÇÃO DOS ERROS DE PREVISÃO DE CARGA
ELÉTRICA DE CURTO PRAZO DECORRENTES DE
VARIACIONES DE TEMPERATURA NA ILHA DE SANTA
CATARINA UTILIZANDO REDE NEURAL**

Esta Dissertação foi julgada adequada para obtenção do Título de Mestre em Ciência da Computação, e aprovada em sua forma final pelo Programa de Pós-Graduação em Ciência da Computação.

Florianópolis, 23 de agosto de 2013.

Prof. Ronaldo dos Santos Mello, Dr.
Coordenador do Curso

Banca Examinadora:

Prof. Raul Sidnei Wazlawick, Dr.
Orientador
Universidade Federal de Santa Catarina

Cláudio Magalhães de Oliveira, Dr.
Instituto de Capacitação, Pesquisa e Desenvolvimento Institucional em
Gestão Social de Tecnologia de Informação

Prof. Mario Antonio Ribeiro Dantas, Dr.
Universidade Federal de Santa Catarina

Prof. Fernando Alvaro Ostuni Gauthier, Dr.
Universidade Federal de Santa Catarina

Este trabalho é dedicado ao meu filho,
à minha esposa, aos meus pais e ao
meu irmão, por terem participado
efetivamente de minha educação
durante todos esses anos.

AGRADECIMENTOS

À Deus pela minha existência e capacidade de raciocinar.

Ao orientador Dr. Raul Sidnei Wazlawick pela oportunidade de compartilhar conhecimentos e possibilitar meu crescimento pessoal.

Aos membros da banca, Professor Dr. Mario Antonio Ribeiro Dantas, Professor Dr. Fernando Alvaro Ostuni Gauthier e Dr. Cláudio Magalhães de Oliveira por aceitarem o convite para avaliar este trabalho e pelas contribuições que auxiliaram a melhorar sua qualidade.

Ao Me. Luiz Ângelo Daros de Lucca pela participação efetiva no andamento do trabalho, compartilhando toda sua experiência profissional no assunto.

À Eletrosul Centrais Elétricas pelo fornecimento de dados para a pesquisa, especialmente ao Eng. Cassiano Aires Teixeira, integrante do Setor de Estudo e Proteção do Sistema e ao Chefe do Setor Paulo Luiz de Souza.

Aos meus familiares pelo apoio e incentivo, em especial à minha esposa Jane Schnaider de Souza e ao meu filho Igor Schnaider de Souza pela paciência nos momentos de minha ausência e pela motivação sempre positiva.

A todos aqueles não citados que de forma direta ou indireta me ajudaram na construção desta dissertação.

“Não existe nada de completamente errado no mundo, mesmo um relógio parado, consegue estar certo duas vezes por dia.”

(Paulo Coelho, 1990)

RESUMO

Este trabalho apresenta primeiramente uma pesquisa que tem como foco a investigação da relação da carga elétrica com a temperatura ambiente para a Ilha de Santa Catarina, e a influência da temperatura na precisão da previsão de carga elétrica de curto prazo, em diferentes faixas de temperatura. A partir dos dados históricos de carga e temperatura, foi construída uma aproximação polinomial de terceiro grau da relação carga versus temperatura, onde a curva resultante mostra a influência da temperatura sobre o comportamento da carga e o relacionamento não linear entre estas variáveis.

Foi verificado, para a região estudada, que existe uma faixa central de temperatura com pouca influência no consumo, enquanto que acima ou abaixo desta faixa, existem, respectivamente, relações significativas direta e inversa com o comportamento da carga. Ainda que, a precisão da previsão da carga horária por uma rede neural é afetada pela faixa de temperatura considerada. Outra contribuição desta dissertação é a proposta de um método de correção para a rede neural que minimiza o erro de previsão gerado pelas faixas de temperatura que mais afetam a previsão de carga.

Os estudos experimentais indicaram que uma rede neural que inicialmente apresentava instabilidade quando submetida a variações de temperatura, após sua correção, conseguiu diminuir seus erros de previsão a índices muito próximos a dias normais.

Palavras-chave: Influencia da Temperatura, Previsão de Carga Elétrica, Redes Neurais.

ABSTRACT

This work first presents a research that has focused on the investigation of the relationship between electric load and temperature in the Island of Santa Catarina and the influence of the temperature on short-term load forecasting regarding different temperature intervals. Based on historic data of load and temperature, it is built a *load over temperature* curve from a third-degree polynomial approximation, which is used to estimate the influence of the temperature on the load and the nonlinear relationship between these variables.

For the studied region it has been shown that there is a central temperature interval with minimum influence on demand, while above and below that interval, respectively, direct and inverse relationships with the behavior of the load is observed. Furthermore, the load prediction accuracy of a neural network is affected by the temperature range considered. This study may produce as result a better scaling on load demand, resulting in financial gain to the distributors. Based on this knowledge we propose a correction method for the neural network that minimizes the prediction error generated by the temperature ranges that most affect the load forecasting.

Experimental studies suggested that a neural network which initially showed instability when subjected to temperature changes after correction, managed to reduce forecast error to rates very similar to the normal days.

Keywords: Temperature Influence, Electric Load Forecasting, Neural Networks.

LISTA DE FIGURAS

Figura 1 – Arquitetura da rede <i>Multilayer Perceptron</i>	36
Figura 2 - Linhas de transmissão que chegam à ilha de Santa Catarina atualmente.....	44
Figura 3 – Carga horária e tendência estimada por polinômio de primeiro grau, para a ilha de Santa Catarina, período de janeiro de 2007 a abril de 2012.....	46
Figura 4 – Carga horária sem tendência, para a ilha de Santa Catarina, no período de janeiro de 2007 a abril de 2012.	47
Figura 5 - Curva de carga média diária sem a componente de tendência X temperatura média diária.	48
Figura 6 – Curva de carga para dias úteis, na semana de 16 a 20 de abril de 2012.	50
Figura 7 – Curva de carga média do período entre 0 hora a 5 horas sem a componente de tendência X temperatura média do período entre 0 hora a 5 horas.	51
Figura 8 – Curva de carga média do período entre 6 horas a 11 horas sem a componente de tendência X temperatura média do período entre 6 horas a 11 horas.	52
Figura 9 – Curva de carga média do período entre 12 horas a 17 horas sem a componente de tendência X temperatura média do período entre 12 horas a 17 horas.	53
Figura 10 – Curva de carga média do período entre 18 horas a 23 horas sem a componente de tendência X temperatura média do período entre 18 horas a 23 horas.	54
Figura 11- Arquitetura da rede neural utilizada	57
Figura 12 – Variação de temperatura na curva de carga entre os dias 26 e 27 de janeiro de 2010, no horário das 17 horas.	60
Figura 13 - Histograma das variações de temperatura na curva de carga nas últimas 24 horas.....	61
Figura 14 – Diagrama em blocos do sistema de previsão com correção.....	68
Figura 15 - Variação de temperatura na curva de carga ocorrida entre os dias 07/02/2010 e 08/02/2010 às 15 horas.	69
Figura 16 - Temperatura, cargas e erros no dia 08/02/2010.....	70
Figura 17 - Variação de temperatura na curva de carga ocorrida entre os dias 03/02/2011 e 04/02/2011 às 11 horas.	72
Figura 18 - Temperatura, cargas e erros no dia 04/02/2011.....	73

LISTA DE TABELAS

Tabela 1 - Erros MAPE médio diário por zona.....	58
Tabela 2 - Estatística descritiva das variações de temperatura na curva de carga nas últimas 24 horas.....	61
Tabela 3 – Erros MAPE médio horário por zona.....	62
Tabela 4 – Resultados MAPE diários da aplicação do método de correção.	74
Tabela 5 – Comparação dos erros MAPE médio diário por zona.	75

SUMÁRIO

1 INTRODUÇÃO	21
1.1 CONTEXTUALIZAÇÃO	21
1.2 OBJETIVOS	24
1.3 MÉTODO	24
1.4 ESTRUTURA DO TRABALHO	26
2 PREVISÃO DE CARGA	29
2.1 INTRODUÇÃO	29
2.2 METODOS DE PREVISÃO DE CARGA	29
2.3 FATORES QUE AFETAM A PREVISÃO DE CARGA	32
2.4 CONSIDERAÇÕES SOBRE O CAPÍTULO	34
3 REDES NEURAIS ARTIFICIAIS	35
3.1 INTRODUÇÃO	35
3.2 REDE MULTILAYER PERCEPTRON	36
3.3 REDES NEURAIS APLICADAS NA PREVISÃO DE CARGA	38
3.4 CONSIDERAÇÕES SOBRE O CAPÍTULO	41
4 PREVISÃO DE CARGA E O EFEITO DA TEMPERATURA.....	43
4.1 DESCRIÇÃO DO SISTEMA EM ESTUDO	43
4.2 INFLUÊNCIA DA TEMPERATURA NA CARGA PARA A ILHA DE SANTA CATARINA	47
4.3 A INFLUÊNCIA DA TEMPERATURA NA PREVISÃO DE CARGA.....	55
4.4 CONSIDERAÇÕES SOBRE O CAPÍTULO	63
5 PROPOSTA DE CORREÇÃO NA REDE NEURAL PARA CONDIÇÃO DE VARIÇÃO DE TEMPERATURA QUE RESULTE VARIÇÃO DE CURVA DE CARGA NA ZONA ELÁSTICA	65
5.1 INTRODUÇÃO	65

<i>5.2 APRESENTAÇÃO DA PROPOSTA</i>	66
<i>5.3 ESTUDO DE CASOS</i>	68
5.3.1 Entrada de frente fria no verão	69
5.3.2 Término de frente fria no verão	71
<i>5.4 ANÁLISE DO MÉTODO DE CORREÇÃO</i>	74
6 CONCLUSÕES E TRABALHOS FUTUROS	77
6.1 CONCLUSÕES	77
6.2 SUGESTÕES PARA TRABALHOS FUTUROS	78
REFERÊNCIAS	80
ANEXO A – One-way ANOVA: Média versus Período	85

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

A demanda futura de energia elétrica no curto, médio e longo prazos precisa ser prevista pelos agentes do sistema elétrico. Ela é utilizada para auxiliar na tomada de decisão em diversas atividades, em áreas como planejamento, mercado, manutenção e operação. A baixa precisão das previsões pode levar a indisponibilidade ou a baixa qualidade do serviço e implica em prejuízos financeiros e sociais. Por outro lado, a energia elétrica possui a característica de não poder ser facilmente armazenada em larga escala, sendo simultaneamente ao consumo, gerada e transportada. A responsabilidade no bom uso deste insumo envolve a geradora, transmissora, distribuidora e consumidor final. Qualquer desperdício está em desacordo com questões ambientais e de eficiência energética. Multas também são aplicadas às empresas concessionárias de energia pela energia provisionada e não utilizada. “As concessionárias deverão formalizar os respectivos contratos de uso do sistema de transmissão e distribuição considerando os montantes de demanda de potência pactuados nos contratos iniciais de compra e venda de energia elétrica. As ultrapassagens verificadas, em base mensal, serão cobradas quando o montante de energia for superior a vinte por cento do contratado e será aplicado o valor correspondente à média mensal do preço do Mercado Atacadista de Energia Elétrica - MAE para o submercado no qual a concessionária compradora está localizada. Quando o montante de demanda for superior a dez por cento ao contratado será aplicado, sobre toda a ultrapassagem, o valor correspondente a três vezes a respectiva tarifa contratual” (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2001).

Os métodos de previsão de carga elétrica vêm sendo estudados e aperfeiçoados ao longo do tempo, com a finalidade de se obter um modelo que

minimize os desperdícios e aumente a confiabilidade da distribuição. Uma previsão de carga se baseia em dados históricos da própria carga para prever condições que ainda não ocorreram. Em dias normais, a carga é similar, devido aos fatores que a influenciam seguirem normalmente uma rotina. Porém, ocorrendo qualquer tipo de alterações, como um fim de semana ou um feriado, o perfil do consumidor muda e conseqüentemente a demanda de carga também, exigindo então uma previsão dedicada. Um especialista humano teria a tarefa de pesquisar o banco de dados histórico para encontrar dias semelhantes à condição ocorrida e então refinar a sua previsão de carga. Da mesma forma, o agrupamento de padrões de carga diários semelhantes permite que algoritmos de previsão possam processar e dar bons resultados nestas situações (CHICCO; NAPOLI; PIGLIONE, 2001).

As previsões de curto prazo são capazes de projetar a carga elétrica de uma hora até uma semana à frente, e são utilizadas pela operação do sistema elétrico na tomada de decisão em situações de manutenção, transferência e corte de carga (METAXIOTIS, et al., 2003), (OLIVEIRA, 2004). Segundo Chan et al. (2011) os métodos de previsão de carga de curto prazo podem ser classificados em duas categorias: métodos estatísticos (baseados em regressão, filtro de Kalman, etc.) e métodos de inteligência artificial (sistema especialista, redes neurais, algoritmos genéticos, sistemas baseados em *wavelets*, lógica *fuzzy*, etc.). Os métodos de inteligência artificial, quando comparados com os métodos estatísticos, apresentam algumas vantagens como maior capacidade em captar as relações de não linearidade entre as variáveis, trabalhar com grandes quantidades de dados e processar as condições atípicas como finais de semana, feriados, variações climáticas, etc. (METAXIOTIS, et al., 2003),(ERKMEN, 2003). Outra vantagem no uso de métodos de inteligência artificial é que seu desempenho pode ser continuamente monitorado e, em caso de degradação, uma adaptação poderá ser acionada para corrigir o procedimento em tempo real (FIDALGO; LOPES, 2005).

O relacionamento entre a carga e fatores exógenos ao sistema elétrico é complexo e não linear (CARPINTEIRO; SILVA, 2000), (CARPINTEIRO; SILVA; FEICHAS, 2000), (OLIVEIRA, 2004). O valor da carga futura possui relação 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. Outro fato a ser considerado é um constante aumento na demanda por energia, bem como uma alteração no comportamento desta demanda. Este aumento se deve, dentre outros fatores, ao crescimento populacional, a trocas na organização e uso de espaços e alteração nos hábitos de consumo causados por mudanças nas bases tecnológica e cultural das comunidades. Assim, a construção de modelos que explicitem esta relação enfrenta a dificuldade da modelagem de relacionamentos complexos e não lineares (OLIVEIRA, 2004).

Trabalhos como o de Valor et al. (2001) e Giannakopoulos e Psiloglou (2006) estudaram especificamente a relação entre a temperatura ambiente e a energia. Para o sistema elétrico grego, a modelagem da relação entre a energia diária e a temperatura ambiente média diária, construída através de uma aproximação polinomial de grau 3, mostra uma relação não linear entre as variáveis. Nesta, há um intervalo central onde a energia é pouco sensível a variações da temperatura. Para temperaturas acima deste intervalo, existe uma relação direta entre as variáveis, onde o consumo de energia aumenta com o aumento da temperatura. Para temperaturas abaixo do intervalo, a relação é inversa e mais suave, com aumento do consumo à medida que a temperatura diminui. Ainda neste estudo, a relação modelada foi utilizada na construção de modelos de regressão para a previsão das energias diária e mensal.

Por outro lado, os estudos de Fidalgo e Lopes (2005), demonstraram que a temperatura não afetou a previsão de carga de curto prazo. A razão atribuída foi que a região em estudo, Portugal, é um país com clima

mediterrâneo, onde as mudanças bruscas de temperatura são raras. Para este, o sistema de previsão teve a capacidade de se moldar e adaptar às pequenas mudanças de temperatura em um curto espaço de tempo. Os testes mostraram que havia um ganho insignificante quando o fator temperatura estava sendo utilizado como entrada do sistema previsor, por isso optou-se pela realização de previsão de carga sem considerar esta grandeza.

1.2 OBJETIVOS

O objetivo geral deste trabalho é estudar a relação da temperatura ambiente média diária, com a carga elétrica média diária para a Ilha de Santa Catarina, e a influência de diferentes faixas de temperatura na precisão da previsão da carga horária em curto prazo.

Os objetivos específicos deste trabalho são:

1. Estimar a relação da temperatura média diária com a carga elétrica média diária.
2. Verificar a influência da temperatura na precisão da previsão de carga de curto prazo realizada por uma rede neural artificial.
3. Propor um método de correção na rede neural que diminua os erros de previsão de carga de curto prazo ocasionados pela influência de temperatura.

1.3 MÉTODO

A influência da temperatura sobre a carga não é a mesma para os diferentes tipos de consumidores. No Brasil, as unidades consumidoras são classificadas em dois grupos tarifários: Grupo A, que tem tarifa binômica e

Grupo B, que tem tarifa monômnia. O agrupamento é definido em função do nível de tensão em que são atendidos e também em função da demanda (kW). As unidades consumidoras atendidas em tensão abaixo de 2.300 volts são classificadas no Grupo B (baixa tensão). Estão nesta classe os consumidores residências, rurais, comerciais, industriais e serviços públicos, uma vez que, na sua maioria são atendidos nas tensões de 127 ou 220 volts. Os consumidores atendidos em alta tensão, acima de 2.300 volts, são classificados no Grupo A. Nesta classe estão as indústrias de grande porte, shopping centers e grandes centros comerciais (ELETROBRAS, 2012). Cada tipo de consumidor por sua vez assume um comportamento diferente no consumo de energia frente a diferentes condições climáticas, especialmente quanto à temperatura. Portanto, o tipo de consumidor deve ser levado em consideração quando se estuda a influência da temperatura sobre a carga.

Os consumidores residenciais e comerciais são sensíveis às variações climáticas. Em contrapartida, consumidores industriais são pouco influenciados pelas flutuações climáticas (MASOOD et al., 2010). Com base nesta informação foi escolhida uma região para estudo em que a carga predominantemente é relativa a consumidores residenciais e comerciais, as classes mais afetadas por mudanças climáticas. A Ilha de Santa Catarina é uma região com esta característica e os dados de temperatura e carga reais eram acessíveis. Outro ponto que levou a escolha da região foi o fato de por ser uma ilha, possibilita a contabilização da carga que é consumida, sendo um sistema pouco suscetível a remanejamento de carga.

Um fato que também deve ser considerado é que a carga sofre influência de outros fatores além dos climáticos. A previsão de carga para dias especiais como feriados e dias consecutivos a feriados são diferentes entre si, dependendo de que dia da semana são situados os feriados em questão. A época do ano em que ocorre o feriado também influencia na curva de consumo (KIM; YUON; KANG, 2000). Eventos anômalos também podem adulterar os

resultados da previsão de carga a níveis inaceitáveis. Entre esses eventos, os mais comuns são: erros de gravação nos históricos de dados, operações de comutação de carga e modificações nos hábitos de consumo (FIDALGO; LOPES, 2005). Desta forma optou-se por não utilizar dias como feriados e finais de semana para realização do treinamento e previsão da rede neural.

Após escolhida a região, fez-se necessário conhecer como a temperatura influencia na carga. Para isto, foi traçado um gráfico da relação entre a temperatura e a carga que serviu de base para a análise das faixas de influência da temperatura sobre a carga. A seguir estes dados foram submetidos a uma rede neural para verificar o comportamento dos erros de previsão da rede mediante as regiões do gráfico que a carga sofre maior influência da temperatura. Os resultados foram separados em zonas de influência da temperatura, permitindo análises a respeito da influencia da temperatura sobre a carga. Os resultados das análises serviram de base para a elaboração de um método de correção que minimiza os erros provenientes dos efeitos da temperatura na previsão de carga.

1.4 ESTRUTURA DO TRABALHO

O trabalho está organizado em seis capítulos. O primeiro capítulo, Introdução, apresenta uma contextualização do problema, questões, hipóteses e os objetivos estabelecidos. Apresenta também a metodologia adotada para atingir tais objetivos, a abrangência estabelecida para o trabalho e sua organização. O segundo capítulo, Previsão de Carga, faz uma revisão bibliográfica das técnicas de previsão de carga e relaciona os fatores que afetam a previsão de carga. O terceiro capítulo, Redes Neurais Artificiais, faz uma revisão bibliográfica das redes neurais artificiais, enfatizando a rede utilizada no estudo e relaciona o uso das redes neurais com a previsão de carga. No quarto capítulo é feito uma descrição detalhada do sistema em estudo. Neste também é mostrado como a temperatura influencia no consumo de carga da ilha de Santa

Catarina, bem como a sua influência na previsão da carga. No quinto capítulo é proposta uma correção na rede neural para a condição de variação de temperatura que ocasiona também variação na curva de carga. São ilustrados casos específicos da influência da temperatura na previsão de carga. O capítulo seis, Conclusões e Trabalhos Futuros, compreendem as conclusões finais e possibilidades de estudos futuros não abordados neste trabalho.

2 PREVISÃO DE CARGA

2.1 INTRODUÇÃO

A eletricidade, sob o ponto de vista econômico, é uma mercadoria a ser vendida e comprada e gera uma grande competição no mercado, no qual o risco de perda tem de ser mínimo. Logo, a previsão de cargas exerce um papel importante para os sistemas de potência e afeta de forma significativa os preços das tarifas elétricas (HIPPERT; PEDREIRA; SOUZA, 2001), (VEHVILÄINEN; KEPPO, 2003), (SFETSOS, 2003).

Segundo Almeida, Fishwich e Tang (1991) os métodos de previsão de carga necessitam de duas condições fundamentais: as informações sobre o passado quantificadas em forma de dados, e assumir que o comportamento ocorrido no passado irá se repetir no futuro. Porém carga elétrica é influenciada por fatores que interferem no seu comportamento. Para efetuar a previsão, primeiramente, é necessário que seja feita uma análise desses fatores.

A literatura propõe uma variedade de métodos para realização de previsão de carga, de modo a estabelecer previsões com grau aceitável de precisão. Desde sistemas mais simples baseados em conhecimento até ferramentas computacionais, resultando em diversos trabalhos em computação aplicada. A seguir será feita uma classificação geral dos métodos de previsão e a apresentação dos fatores que influenciam na qualidade de previsão.

2.2 METODOS DE PREVISÃO DE CARGA

Os métodos de previsão podem ser classificados de acordo com o horizonte de previsão. Segundo Metaxiotis et. al. (2003) existem quatro tipos de previsão de cargas: previsão de carga de longo prazo, previsão de carga de

médio prazo, previsão de carga de curto prazo e previsão de carga de curtíssimo prazo.

A previsão de carga de longo prazo é realizada principalmente na operação de planejamento de sistemas de potência. Essa previsão envolve um período de 10 a 20 anos e não considera os dados de carga elétrica diária ou semanal, somente a tendência do consumo de carga ao longo dos anos. É aplicada na provisão de equipamentos elétricos, preços de eletricidade, preços de fontes alternativas de energia, etc. A previsão de carga de médio prazo abrange o período de poucas semanas ou até mesmo alguns anos. É aplicada no planejamento de suprimento de combustível, programas de manutenção e planejamento de produção em médio prazo. A previsão de carga de curto prazo é realizada no intervalo de tempo de meia hora a poucas horas, ou até mesmo de 1 dia a 1 semana. Esta estima a carga para cada hora do dia, pico de carga diária ou geração de energia diária ou semanal. É aplicada no planejamento e operações econômicas e de segurança diária dos sistemas de potência. A previsão de carga de curtíssimo prazo ocorre entre poucos segundos e pouco menos de 15 minutos. É essencialmente usada para o planejamento de produção e controle.

Há uma diversidade de modelos propostos para solução do problema de previsão de carga para o horizonte de curto prazo. Dentre as abordagens encontradas podem ser citados os modelos baseados em regressão múltipla, análise de séries temporais, modelos de *Box-Jenkins*, alisamento exponencial, modelos de espaço de estados, sistemas caóticos, sistemas computacionais, onde estão inseridos modelos de redes neurais, sistemas especialistas, lógica *fuzzy*, programação evolucionária e modelos híbridos (FERREIRA, 2005).

O emprego de sistemas computacionais de previsão reduz a sobrecarga do especialista e permite ainda aumentar a quantidade das previsões, tanto reduzindo os intervalos entre as mesmas quanto aumentando os pontos do

sistema de potência a serem acompanhados. Desta forma o especialista se reserva a tarefas mais nobres tais como a avaliação crítica, correção e controle do próprio sistema de previsão (LUCCA, 2008).

Para conhecer o estado da arte na previsão de carga elétrica, foi realizada uma revisão bibliográfica no assunto apresentando algumas das técnicas mais utilizadas nos últimos 15 anos.

O trabalho de Changyin, Ping e Linfeng (2006) utiliza uma modelagem *fuzzy* com uma técnica de computação evolutiva denominada *Particle Swarm Optimization*. A técnica consiste em um mecanismo de seleção de dados de entrada onde as entradas mais significativas de um dia anterior são selecionadas para prever a carga do dia seguinte. Um modelo difuso resultante é uma estrutura que possui um pequeno número de parâmetros e pode ser utilizado como entrada de qualquer estimador de carga. O resultado final é uma redução no tempo de seleção das entradas e um sistema de previsão mais eficiente.

O trabalho de Bo e Li (2009) apresenta uma abordagem probabilística para determinação da carga futura. Com a suposição de que a carga real possui uma distribuição normal, o conceito proposto assume que a carga prevista não corresponde a um valor determinado único. Ao invés disso a carga prevista representa um conjunto de intervalos de carga, cada qual associado a uma probabilidade de ocorrência.

Outra abordagem interessante é apresentada por Fay e Ringwood (2010) que sugere o uso de um modelo a partir da combinação de vários previsores de entrada. Estes geram uma saída combinada a partir de um algoritmo que minimiza a variância da previsão. A previsão combinada da carga é obtida a partir da média ponderada das previsões individuais dos previsores. Os resultados mostraram a eficiência do algoritmo para condições normais.

Hong et. al. (2011) aplica a Teoria do Caos para modelar o comportamento de cargas elétricas. Segundo ele, o caos frequentemente ocorre em um sistema não linear dinâmico, onde algumas variáveis tendem a assumir um comportamento instável, semelhante ao aleatório. Ao mapear essas variáveis, o sistema passa a conhecer o seu comportamento e, portanto, passa a ser capaz de prever a carga com maior precisão.

2.3 FATORES QUE AFETAM A PREVISÃO DE CARGA

Existem fatores que apresentam um efeito significativo na evolução da demanda de energia elétrica, pelo qual devem ser incorporados ao modelo de previsão de forma a melhorar a sua precisão. Estes fatores podem ser divididos em quatro categorias principais: fatores climáticos, fatores econômicos e demográficos, fatores cíclicos e sazonais e fatores aleatórios.

Os fatores climáticos são os fatores que ocorrem em curto prazo e, portanto influenciam nas previsões de curto prazo. São exemplos de fatores climáticos a temperatura, a velocidade do vento, a neblina, a umidade relativa do ar, as descargas atmosféricas, as chuvas, etc. Dentre todos os fatores mencionados a temperatura é o fator de maior influência no consumo de energia elétrica. Os fatores econômicos e demográficos são os fatores que ocorrem em longo prazo e que influenciam na previsão de carga de longo prazo. Tem-se como exemplo a região demográfica (rural, residencial, industrial), o crescimento industrial, as tendências econômicas, a variação nos preços de eletricidade, etc. Os fatores cíclicos e sazonais influenciam na carga em acontecimentos ocorridos em determinados períodos do ano, tais como: estações de ano, férias, feriados, início do ano escolar, natal, ano novo, dias próximos a feriados, etc. Os fatores aleatórios são eventos que causam perturbações na carga de forma atípica tais como: eventos esportivos, programas de televisão, paralisação das indústrias, apagões, etc. Os fatores cíclicos e sazonais e os fatores aleatórios influenciam na previsão de médio, curto e curtíssimo prazo

(SWARUP; SATISH, 2002), (HIPPERT; PEDREIRA; SOUZA, 2001), (MURTO, 1998).

Conhecendo os fatores que influenciam na previsão, estudos foram dedicados no dimensionamento que cada fator tem sobre a carga, bem como a utilização de métodos que realizam a correção destas previsões. Uma revisão bibliográfica ilustra alguns destes estudos.

Em Kim, Yuon e Kang (2000) é proposto um método de previsão de carga em curto prazo para condições anormais como feriados e dias consecutivos a feriados. Esses dias especiais são classificados em cinco tipos diferentes e uma rede neural artificial especializada para cada condição é utilizada como previsor. Depois de feita a previsão, dois modelos difusos são usados para prever a carga máxima e mínima, realizando uma combinação entre os resultados das redes. A dificuldade encontrada é a existência de poucos casos semelhantes para treinamento da rede neural.

Para melhorar a previsão de carga para dias anormais é necessária a utilização de dados históricos precisos. Uma combinação das técnicas mineração de dados, algoritmos genéticos e um sistema de classificação de padrões baseado em regras *fuzzy* foram utilizadas para esta finalidade no trabalho de Feng e Liu (2006).

Os métodos de regressão foram utilizados para modelar a influência da temperatura sobre a carga do Irã, no trabalho de Moghaddas-Tafreshi e Farhadi (2008). A análise de regressão linear reconhece que o padrão de carga é fortemente dependente da temperatura e encontra uma função linear entre estas grandezas.

Bodyanskiy, Popov e Rybalchenko (2008) propõem uma arquitetura de rede neural que consiste em duas camadas escondidas para formar o módulo

para a estimação da relação entre temperatura e carga e duas últimas camadas para realizar a previsão de carga propriamente dita. Apesar das diferentes condições climáticas testadas, a influência da temperatura sobre a carga observada foi menor na mesma faixa de temperatura, que é em torno de 15 a 20 °C. Isto pode ser atribuído a uma sensação de conforto térmico humano, independentemente da localização geográfica.

2.4 CONSIDERAÇÕES SOBRE O CAPÍTULO

Este capítulo faz uma breve apresentação das técnicas de previsão de carga elétrica e a sua importância para os sistemas de potência. Mostra também a classificação da previsão de carga de acordo com o horizonte de previsão e a relação dos fatores que influenciam na previsão da carga.

Esta análise serviu para a tomada de decisão na escolha do tipo de previsão utilizado no modelo em estudo, de forma a enfatizar o efeito da temperatura sobre a carga. A revisão bibliográfica permitiu a comparação dos métodos utilizados nos últimos anos, formando base para a construção do modelo de previsão, que no caso foi a previsão de carga de curto prazo utilizando redes neurais.

3 REDES NEURAIIS ARTIFICIAIS

3.1 INTRODUÇÃO

As redes neurais artificiais são sistemas conexionistas que fornecem um método para aprendizado de diversos tipos de funções a partir da inspiração biológica de um neurônio. Elas se assemelham ao cérebro pela capacidade de armazenar conhecimento adquirido, através de um processo de aprendizagem onde as forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Uma rede neural pode ser descrita computacionalmente como um processador paralelo e distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso (HAYKIN, 2001).

As redes neurais são métodos utilizados para aproximação de funções, que se destacam por apresentar capacidade de aprendizado e generalização. Podem ser empregadas no reconhecimento de padrões, no processamento de sinais digitais e imagens, em visão computacional, robótica e para previsão de séries temporais (BRAGA; CARVALHO; LUDERMIR, 1998).

Uma rede neural pode ser classificada de acordo com a sua topologia e seu algoritmo de aprendizagem. Não é o foco desse estudo descrever as topologias nem os algoritmos de aprendizado existentes atualmente. Por isso será apresentado apenas as características da rede utilizada, a rede *perceptron* múltiplas camadas (*Multilayer Perceptron*).

3.2 REDE MULTILAYER PERCEPTRON

As redes *Multilayer Perceptron* (MLP) possuem uma ou mais camadas de neurônios entre as camadas de entrada e saída, chamada de camada oculta. Esta camada do tipo *perceptron* adiciona um poder maior que as redes de camada única, que são capazes de classificar apenas padrões linearmente separáveis. A inserção de uma camada de neurônios ocultos é responsável por capturar a não linearidade dos dados. Neste modelo todos os neurônios são ligados aos neurônios da camada subsequente, não havendo ligação de neurônios da mesma camada e também não ocorre realimentação.

Esta rede possui a topologia alimentada adiante (*Feed-forward networks*) onde o fluxo de informação é sempre da camada de entrada para a camada de saída. A figura (1) mostra uma rede *Multilayer Perceptron*:




Figura 1 – Arquitetura da rede *Multilayer Perceptron*

O passo para frente é chamado de propagação, onde as saídas dos neurônios de entrada são aplicadas aos neurônios ocultos e as saídas dos neurônios ocultos são aplicadas como entradas dos neurônios da camada final, obtendo então a resposta da rede. O passo para trás tem a finalidade de ajustar os pesos sinápticos, por meio do cálculo do erro realizado na camada de saída.

Uma rede MLP pode ser considerada como um método prático para realização de um mapeamento não linear, de natureza geral, entre entrada e saída que propiciam um método para modelar 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. As redes neurais artificiais 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 a respeito do comportamento do problema em questão não podem ser facilmente formuláveis (OLIVEIRA, 2004).

A principal desvantagem da MLP é a lentidão do processo de aprendizagem, onde os parâmetros a serem estimados estão relacionados de forma não linear com a saída. O desempenho da rede (sucesso do treinamento) é altamente dependente da atribuição inicial de valores aos pesos, normalmente realizada de forma aleatória, sendo também uma desvantagem. Estes fatores dificultam, porém não inviabilizam a aplicação da arquitetura MLP em sistemas de tempo real (HAYKIN, 2001).

O processo da aprendizagem de uma rede MLP mais utilizado é a aprendizagem supervisionada, onde é fornecido à rede os conjuntos de valores de entrada e de saída esperados para cada entrada. O treinamento consiste em um problema de ajuste dos parâmetros da rede (seus pesos sinápticos) para que possam responder às entradas e extrapolar o mesmo comportamento para outras entradas não previstas no treinamento (HAYKIN, 2001). Dentre os algoritmos mais utilizados para aprendizagem supervisionada serão citados os quatro principais.

O algoritmo *Backpropagation* estabelece valores iniciais aleatórios para os pesos sinápticos da rede e, iterativamente, insere um valor de entrada na

rede propagando-o camada a camada, até obter o valor de sua saída. O erro entre a saída e a entrada é então calculado e propagado no sentido contrário ao da rede para ajuste dos pesos. Sua principal desvantagem é que facilmente leva a função de erro para um mínimo local.

O algoritmo do Gradiente Descendente procura corrigir o problema do algoritmo *Backpropagation* modificando a regra utilizada para atualização do vetor de pesos. Ao invés de se utilizar um fator de aprendizagem fixo, escolhe-se a cada iteração, um novo fator através de uma busca linear. A sua desvantagem é que para calcular as direções conjugadas, em cada passo é necessária a resolução de um sistema linear complexo.

Na busca de uma solução para o problema do algoritmo do Gradiente Descendente, o algoritmo de *Quasi-Newton* propõe uma direção de busca conhecida como direção de Newton e tem como propriedade principal apontar para um extremo local da função erro. Este algoritmo requer a avaliação e inversão da matriz *Hessiana* com operações computacionais de complexidade dois e três, tornando-o muito lento.

Finalmente o algoritmo de *Levenberg-Marquardt* foi desenvolvido para resolver iterativamente problemas de minimização de funções não-lineares pelo método de mínimos quadrados. Este é o algoritmo mais utilizado hoje em dia, superando outros algoritmos em uma grande variedade de problemas. O objetivo do algoritmo é encontrar o melhor ajuste para um conjunto de dados de tal modo que a soma dos quadrados das distâncias entre o modelo e cada um dos pontos dados seja a menor possível (método de *Gauss-Newton*).

3.3 REDES NEURAI APLICADAS NA PREVISÃO DE CARGA

As redes neurais aprendem por meio de exemplos, e isso possibilita entender e modelar um determinado problema a partir dos dados disponíveis a

respeito do mesmo. Para um 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 atribuída uma rede neural com parâmetros e ajustes específicos para o dado nó. Nos vários modelos baseados em redes neurais empregados para previsão de carga, observa-se que, independente do modelo 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. 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. (OLIVEIRA, 2004)

Na literatura há muitos casos bem sucedidos de redes neurais aplicadas a previsão de carga. Desta forma foi dada maior ênfase aos trabalhos publicados nos últimos 10 anos e de forma resumida, seus resultados são discutidos abaixo.

Jain e Satish (2009) utilizam uma técnica de *clusterização* dos dados de treinamento da rede neural, de forma a agrupar padrões de carga semelhantes. São utilizados os valores de carga média e carga de pico, e a carga prevista é obtida pelo resultado da rede neural treinada com esses padrões de *clusters*.

Lee e Du (2009) utilizaram uma arquitetura de rede neural que realiza a decomposição da previsão em dois grupos: um deles extrai as características fundamentais de previsão de carga diária e o outro extrai a dependência da carga em função da temperatura e outros fatores desconhecidos. O método de regressão é aplicado para reduzir os efeitos de outros fatores desconhecidos e se

possível eliminá-los. Os resultados foram satisfatórios, porém o sistema deve ser melhorado para as condições de carga em dias especiais.

Chen et. al. (2010) realizaram um estudo onde o objetivo é selecionar dias de cargas semelhantes avaliando o coeficiente de correlação entre os dias. Em seguida, aplicam redes neurais *wavelet* para decompor a entrada em uma componente de baixa frequência e outra de alta frequência. Com esses dados, utilizam duas redes neurais independentes para calcular o resultado de previsão.

O método de Amjady e Keynia (2011) consiste em utilizar uma rede neural treinada com um algoritmo de busca harmônica, que pesquisa o espaço de solução em várias direções, evitando assim ficar preso em mínimos locais.

Dongxiao, Ling e Jie (2011) utilizaram redes neurais *wavelet* como método de previsão e verificaram que alguns fatores relacionados como o clima e a temperatura foram desconsiderados pelo método. No entanto, o impacto destes fatores meteorológicos sobre a carga é fundamental, principalmente nos casos de mudanças de temperatura. Portanto, o processo de rede neural *wavelet* não é o ideal para este tipo de análise.

O trabalho de Valero et. al. (2012) faz um estudo comparativo entre uma rede *Multilayer Perceptron* (MLP) e redes neurais com mapas auto-organizáveis (SOM) para realização da previsão de carga elétrica. Com a rede MLP, foi possível prever com precisão a curva de carga global de um dia com o histórico de dados de carga e da temperatura dos meses anteriores. Este algoritmo teve uma rápida convergência e a sua desvantagem é o risco de queda em um mínimo local que resulta em erro na curva de carga. As redes SOM apresentaram um desempenho superior, porém com uma redução no histórico de dados, limitado a um ano.

3.4 CONSIDERAÇÕES SOBRE O CAPÍTULO

Este capítulo mostra a importância da abordagem das redes neurais aplicadas à previsão de carga. Pela sua característica de captação das relações não lineares entre a entrada e a saída, capacidade de aprendizado e generalização, justifica-se sua aplicação bem sucedida na previsão de carga.

Os trabalhos publicados tiveram sua importância em definir a melhor arquitetura a ser utilizada no sistema em estudo. A utilização de técnicas de separação em casos semelhantes, tipo de algoritmo de treinamento, ênfase da influência de fatores climáticos sobre a carga elétrica serviram de base para a construção da rede neural utilizada como previsor.

Foi escolhida a rede do tipo *Multilayer Perceptron* como rede utilizada na realização das previsões de carga deste trabalho. O algoritmo de treinamento da rede MLP foi o *Levenberg-Marquadt*, muito utilizado quando se deseja ajustar um modelo a um conjunto de dados experimentais por realizar aproximações globais e confiáveis.

4 PREVISÃO DE CARGA E O EFEITO DA TEMPERATURA

4.1 DESCRIÇÃO DO SISTEMA EM ESTUDO

Neste estudo, foram utilizados o histórico de cargas e temperaturas horárias relativas à ilha de Santa Catarina por dois motivos principais:

- a) Havia disponibilidade de dados.
- b) A carga na ilha é majoritariamente composta de clientes residenciais e comerciais, classes de clientes mais sensíveis às condições climáticas.

As linhas que alimentam a ilha de Santa Catarina, até 28/02/2009 eram a linha *Palhoça – Trindade*, com tensão de 138 kV e potência máxima de 86,94 MW e a linha *Palhoça – Ilha Centro*, com tensão de 138 kV e potência máxima de 82,8 MW. Ambas passam por cabos colocados no interior da ponte Colombo Salles, que liga a ilha ao continente. Em 01/03/2009 entrou em operação o transformador 1 da Subestação *Desterro*, e a ilha de Santa Catarina passou a ter mais uma linha de alimentação, denominada linha *Biguaçu – Desterro*, com tensão de 230 kV e potência máxima 179,4 MW. Esta linha é uma linha submarina que foi construída para minimizar os riscos de um apagão como o que ocorreu em outubro de 2003. A figura (2) mostra as linhas que chegam a ilha de Santa Catarina.




Figura 2 - Linhas de transmissão que chegam à ilha de Santa Catarina atualmente.

A base de dados da carga foi cedida pela Eletrosul Centrais Elétricas S.A., e é referente ao período de janeiro de 2007 a abril de 2012, exceto pelos meses entre fevereiro a agosto do ano de 2009 que estão ausentes. A base de dados de temperatura foi obtida do site Weather Underground (2013) e refere-se as medições de temperatura do aeroporto Hercílio Luz, localizado na região sul da ilha de Santa Catarina.

Preliminarmente, foi realizada um pré-processamento dos dados para minimizar problemas nos estudos em virtude de erros no histórico. O procedimento levou em consideração que a correção de dados em excesso pode atrapalhar o estudo tornando-o excessivamente otimista (FIDALGO; LOPES, 2005). O histórico de dados utilizado apresentava dados incompletos (ausência de leituras) e valores considerados muito altos, acima da capacidade das linhas de transmissão que abastecem a ilha. Também, aumentos de carga superiores a 40% ou reduções maiores que 30% em um intervalo de uma hora não representam o comportamento esperado para este sistema. Desta maneira optou-se por excluir do histórico as leituras de carga que apresentavam estas características.

A temperatura ambiente média diária pode ser considerada como uma série temporal estacionária dentro do intervalo de estudo, pois sua média não é alterada significativamente de um ano para outro. Já a carga pode ser entendida como uma série temporal não estacionária, pois apresenta uma tendência de crescimento persistente ao longo dos anos do intervalo de estudo (MORETIN; TOLOI, 2006). A tendência pode ser definida como o movimento de longo prazo que caracteriza a evolução do nível médio da série, isto é, se ela cresce, decresce ou permanece estável e qual a velocidade destas mudanças (SOUZA; SAMOHYL; MIRANDA, 2008). A tendência de crescimento da carga reflete o aumento no consumo de energia em função do crescimento populacional, do aumento na utilização de eletrodomésticos, pela melhoria das condições socioeconômicas e pelo desenvolvimento tecnológico, dentre outros. Este crescimento, entretanto, pode prejudicar o estudo da relação entre a temperatura e a carga, pois, ao longo dos anos, teremos a mesma temperatura para leituras de cargas cada vez maiores. Assim, faz-se necessário retirar a componente da tendência da série de carga, tornando-a estacionária. Sem a influência do aumento do consumo devido aos fatores socioeconômicos, ficará evidenciada a relação entre a carga e a temperatura.

O método utilizado para cálculo da componente de tendência da série de carga foi a interpolação polinomial de primeiro grau dos dados no intervalo de tempo de uma hora. A interpolação polinomial utiliza o ajuste por mínimos quadrados de polinômios ortogonais (dados regularmente distribuídos) e não ortogonais (dados irregularmente distribuídos). Estes, geralmente, são utilizados em uma modelagem preliminar para a verificação, e remoção, se necessário for, de uma tendência sistemática nos dados atribuída a causas naturais (no caso de variáveis geológicas ou meteorológicas) (LANDIM, 1997). A figura (3) mostra os dados de carga horária, no período de janeiro de 2007 a abril de 2012 e a curva de tendência estimada por um polinômio de primeiro grau, através de mínimos quadrados.




Figura 3 – Carga horária e tendência estimada por polinômio de primeiro grau, para a ilha de Santa Catarina, período de janeiro de 2007 a abril de 2012.

A aproximação polinomial de primeiro grau da carga com a componente de tendência é descrita na equação (1).

$$C = 0,0005754 \cdot t + 100,94 \quad (1)$$

Onde C é a carga em MW e t é o tempo em horas, onde o tempo 0 corresponde à data de 01/01/2007 às 0 horas e o tempo final à data de 30/04/2012 às 23 horas.

A figura (4) mostra os dados da carga horária após retirar a componente de tendência. A tendência foi considerada como multiplicativa e o método utilizado para retirada de tendência foi a divisão dos dados de carga pela sua componente de tendência.




Figura 4 – Carga horária sem tendência, para a ilha de Santa Catarina, no período de janeiro de 2007 a abril de 2012.

Conforme apresentado (figura 4), a transformação aplicada (retirada da tendência pela divisão - tendência multiplicativa) transformou a série original em uma série estacionária.

4.2 INFLUÊNCIA DA TEMPERATURA NA CARGA PARA A ILHA DE SANTA CATARINA

A temperatura do ar é a variável climática mais importante que afeta o consumo de energia. Uma mudança de temperatura influencia as condições de conforto térmico de uma determinada região, produzindo mudanças de comportamento no consumidor final e, conseqüentemente, mudanças no consumo de energia (LEE; DU, 2009). Outras variáveis climáticas, como a umidade e a velocidade dos ventos, influenciam a sensação de conforto térmico e podem ser consideradas como condições para corrigir a influência da temperatura no comportamento da carga (CANCELO; ESPASA, 1996).

Para estudar a influência da temperatura no comportamento da carga da ilha de Santa Catarina, foi construída a curva da carga média diária, sem tendência, em função da temperatura média diária, apresentada na figura (5). A curva foi obtida através de uma interpolação polinomial de terceiro grau ajustada por mínimos quadrados. A figura 5 apresenta ainda uma aproximação dos dados por uma interpolação polinomial de primeiro grau, ilustrando como seria mapeada a relação caso fosse considerada como linear.




Figura 5 - Curva de carga média diária sem a componente de tendência X temperatura média diária.

A interpolação polinomial de terceiro grau apresentada na figura (5) é dada pela equação (3).

$$C_{MST} = 0,000035.T^3 + 0,00135.T^2 - 0,07203.T + 0,53836 \quad (2)$$

Na (2), C_{MST} é a carga média diária sem tendência e T é a temperatura média diária.

A aproximação polinomial de terceiro grau apresentada na figura (5) mostra, para o sistema em estudo, a relação não linear entre temperatura ambiente e carga média diária. O ponto de mínimo da aproximação polinomial de terceiro grau é 16,2°C. Para valores de temperatura média diária próximos ao ponto de mínimo, a carga é pouco sensível a temperatura. Esta região, entre 15°C e 22°C, pode ser considerada inelástica em relação à temperatura. Valores de temperatura acima de 22°C caracterizam uma região de forte relação direta entre temperatura e carga (sistemas de refrigeração). Valores de temperatura abaixo de 15°C caracterizam uma região de relação inversa e mais suave entre temperatura e carga (calefação). Observa-se que na região acima de 22°C a maior quantidade de dados e inclinação da curva maior que a da região abaixo de 15°C, mostrando uma maior presença e influência das temperaturas mais altas na carga, que das temperaturas mais baixas, para a ilha de Santa Catarina.

A relação entre temperatura ambiente e carga também pode ser diferente para os diferentes horários no dia. É esperado que os hábitos de consumo em uma madrugada sejam diferentes do consumo em uma manhã ou uma tarde, proporcionando variação no consumo de energia de hora em hora durante um período de 24 h. O primeiro pico máximo perto do meio-dia é devido ao uso intensivo de energia elétrica, tanto para uso doméstico (aquecimento, refrigeração, eletrodomésticos) quanto para o uso comercial (aquecimento e refrigeração do escritório, servidores e uso de computadores, iluminação). O segundo pico máximo é devido ao uso do sistema de iluminação e aquecimento ou refrigeração, que utiliza aquecedores ou condicionadores de ar durante o final da tarde e início da noite (GIANNAKOPOULOS; PSILOGLOU, 2006). A figura 6 mostra o comportamento da carga para dias úteis e os dois picos de energia que ocorrem nos horários próximos de meio dia e final de tarde.

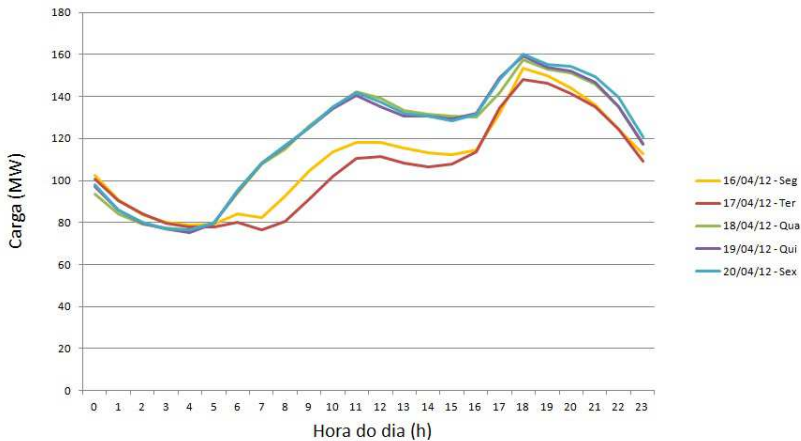


Figura 6 – Curva de carga para dias úteis, na semana de 16 a 20 de abril de 2012.

Com a finalidade de observar o comportamento da carga para os diferentes períodos do dia, foi feita a divisão do dia em quatro períodos de seis horas: entre 0 hora a 5 horas e 59 minutos, entre 6 horas e 11 horas e 59 minutos, entre 12 horas e 17 horas e 59 minutos e entre 18 horas e 23 horas e 59 minutos. Para cada faixa de horário foi construída a curva da carga média por período, sem tendência, em função da temperatura média por período, apresentada nas figuras (7), (8), (9) e (10).

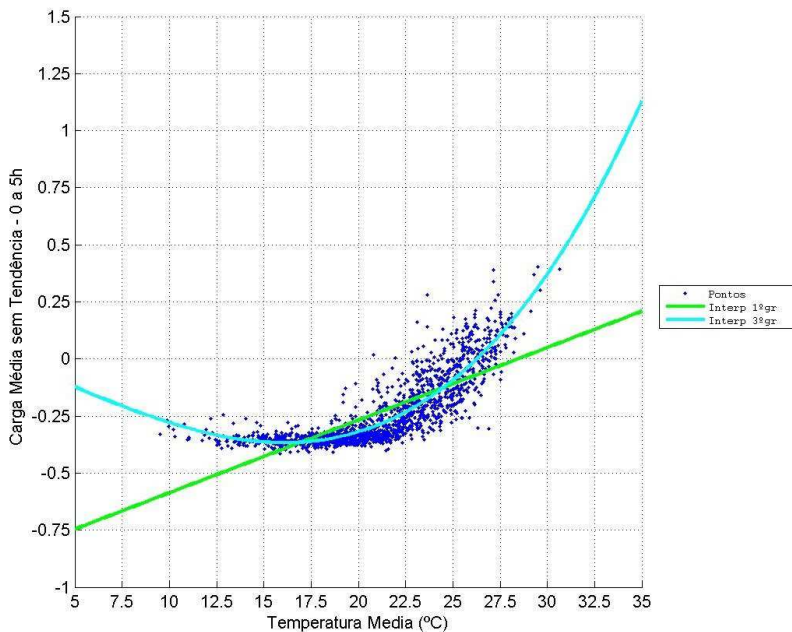


Figura 7 – Curva de carga média do período entre 0 hora a 5 horas sem a componente de tendência X temperatura média do período entre 0 hora a 5 horas

A interpolação polinomial de terceiro grau apresentada na figura (7) é dada pela equação (3).

$$C_{MsT-0a5h} = 0,000073.T^3 - 0,000743.T^2 - 0,03309.T + 0,052268 \quad (3)$$

Na (3), $C_{MsT-0a5h}$ é a carga média do período entre 0 hora a 5 horas sem tendência e T é a temperatura média do período entre 0 hora a 5 horas.

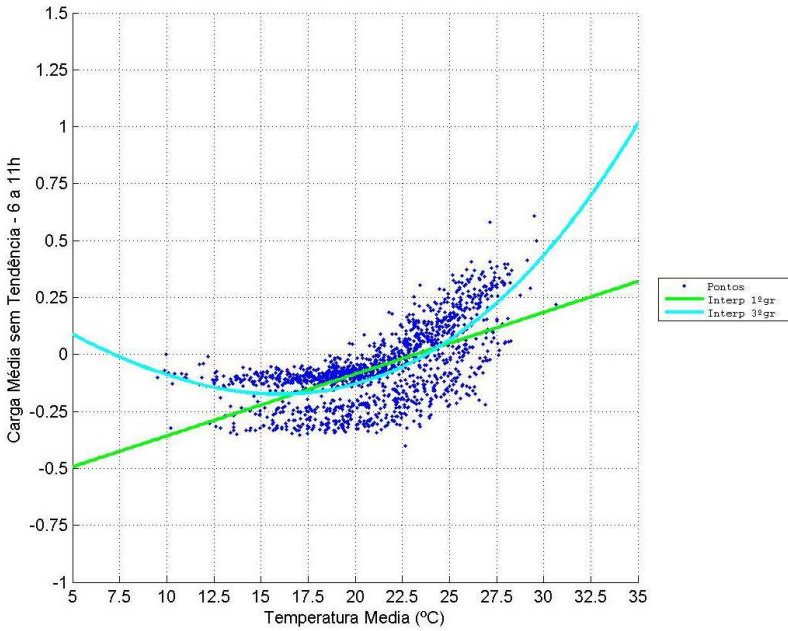


Figura 8 – Curva de carga média do período entre 6 horas a 11 horas sem a componente de tendência X temperatura média do período entre 6 horas a 11 horas.

A interpolação polinomial de terceiro grau apresentada na figura (8) é dada pela equação (4).

$$C_{MsT-6a11h} = 0,000036.T^3 + 0,000817.T^2 - 0,054384.T + 0,33553 \quad (4)$$

Na (4), $C_{MsT-6a11h}$ é a carga média do período entre 6 horas a 11 horas sem tendência e T é a temperatura média do período entre 6 horas a 11 horas.




Figura 9 – Curva de carga média do período entre 12 horas a 17 horas sem a componente de tendência X temperatura média do período entre 12 horas a 17 horas.

A interpolação polinomial de terceiro grau apresentada na figura (9) é dada pela equação (5).

$$C_{MST-12a17h} = -0,0000198T^3 + 0,004907.T^2 - 0,138479.T + 0,986009 \quad (5)$$

Na (5), $C_{MST-12a17h}$ é a carga média do período entre 12 horas a 17 horas sem tendência e T é a temperatura média do período entre 12 horas a 17 horas.




Figura 10 – Curva de carga média do período entre 18 horas a 23 horas sem a componente de tendência X temperatura média do período entre 18 horas a 23 horas.

A interpolação polinomial de terceiro grau apresentada na figura (10) é dada pela equação (6).

$$C_{MsT-18a23h} = 0,000049.T^3 + 0,000449.T^2 - 0,062186.T + 0,77966 \quad (6)$$

Na (6), $C_{MsT-18a23h}$ é a carga média do período entre 18 horas a 23 horas sem tendência e T é a temperatura média do período entre 18 horas a 23 horas.

Com a finalidade de verificar se existe diferença estatística entre as curvas foi realizado um teste ANOVA e um teste de *Turkey* com intervalo de confiança de 95% entre os valores das ordenadas das curvas. Considerou-se 4 tratamentos separados por períodos, onde o período 1 corresponda a 0 a 5 horas, o período 2 corresponda a 6 a 11 horas, o período 3 corresponda a 12 a 17 horas

e o período 4 corresponda a 18 a 23 horas. O resultado de cada tratamento era a o resultado das curvas $C_{MsT-0a5h}$, $C_{MsT-6a11h}$, $C_{MsT-12a17h}$ e $C_{MsT-18a23h}$ calculadas a partir de uma temperatura T variando de 5 a 35 graus, com incremento de 0,5 graus.

Os resultados do teste de *Turkey* (Anexo A) demonstram que existe diferença estatística ente o período 1 e 3, entre o período 1 e 4, entre o período 2 e 3 e entre os períodos 2e 4. Cabe também observar que existem diferenças nas densidades das curvas. Nas figuras (7) e (8) existe maior dispersão entre as médias e diferenças nos formatos da carga dos períodos entre 6 a 11 horas e entre 12 a 17 horas. Isto pode ser explicado por outro fator, não temperatura, que neste caso, não é o foco do estudo.

4.3 A INFLUÊNCIA DA TEMPERATURA NA PREVISÃO DE CARGA

Os modelos de previsão modelam a relação entre a carga e as variáveis explicativas pela minimização de um erro médio. Com isso, espera-se que as variações de temperatura, pouco representativas no histórico, sejam pouco consideradas na otimização do modelo. Para estudar a influência da temperatura na precisão da previsão da carga elétrica de curto prazo, foi construído um modelo de previsão baseado em redes neurais artificiais. Uma das vantagens da utilização das redes neurais na previsão de carga está na sua capacidade de modelar relacionamentos complexos entre as variáveis de entrada e sua saída. Além disso, as redes neurais artificiais são capazes de mapear a relação não linear entre as variáveis (METAXIOTIS, 2003), (FELICCE; YAO, 2011).

A topologia de rede neural empregada foi a Perceptron Múltiplas Camadas (MLP - *MultiLayer Perceptron*) com uma camada oculta. A entrada, consistindo de 36 nós, foi composta das seguintes variáveis:

- Dia_bin: dia codificado em 7 bits (7 neurônios), onde cada dia de semana corresponde a um único neurônio da rede ativado. Exemplo: domingo = 0000001, segunda feira = 0000010, etc.

- Hora_bin: hora do dia codificada em 24 bits (24 neurônios), onde cada hora do dia corresponde a um único neurônio da rede ativado. Exemplo: 00:00h = 00000000 00000000 00000001, 01:00h = 00000000 00000000 00000010, etc.

- Ch-1h: carga na hora anterior (1 neurônio).

- Ch-168h: carga na mesma hora da semana anterior, ou seja, 168 horas atrás (1 neurônio).

- Th: temperatura na hora atual (1 neurônio).

- Th-1h: temperatura na hora anterior (1 neurônio).

- Th-168h: temperatura na mesma hora da semana anterior, ou seja, 168 horas atrás (1 neurônio).

A saída com 1 nó (1 neurônio) representa a carga prevista na hora atual “h”, denominada Ch_Prev(h). A figura 11 mostra a arquitetura da rede neural utilizada.

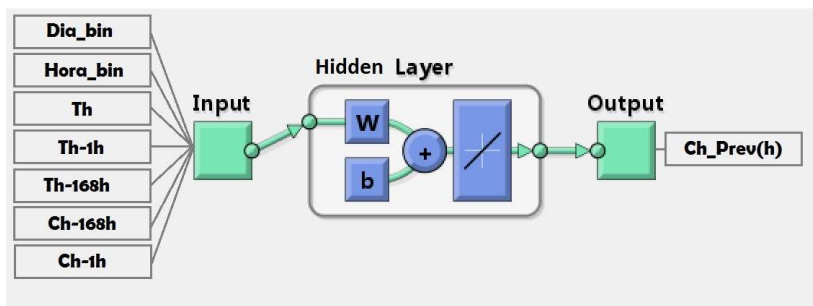


Figura 11- Arquitetura da rede neural utilizada

O treinamento da MLP foi feito utilizando-se o algoritmo *Levenberg-Marquadt*, minimizando o erro quadrático médio (MSE – *Mean Squared Error*) e utilizando para o histórico de treino somente dias com leituras horárias completas. Foi utilizado o software *Matlab* versão 7.10 para a construção do modelo. O critério de parada do treino do algoritmo de *Levenberg-Marquadt* no *Matlab* se dá quando é estabelecida uma destas condições: o número máximo de épocas é alcançado, a quantidade máxima de tempo for excedida, o erro quadrático desejável é minimizado, o gradiente de desempenho é minimizado, os parâmetros *Marquardt* excedem o valor máximo ou a validação de desempenho aumentou determinadas vezes desde a última vez que diminuiu (última validação). Para a rede neural implementada, os critérios de parada ocorridos foram: o gradiente de desempenho é minimizado (77%) e os parâmetros *Marquardt* excedem o valor máximo (23%).

O treinamento utilizou dados históricos da carga horária de 10 dias anteriores, saltando dias sem as 24 leituras horárias disponíveis. A janela de dados de treino foi limitada a 1 mês pois, a partir deste intervalo a rede degradava significativamente o seu desempenho. Depois de treinada, a rede faz a previsão para 24 horas à frente através de uma saída com uso realimentado. A qualidade da previsão foi mensurada pela média absoluta dos erros percentuais (MAPE – *Mean Absolute Percentual Error*).

Após a rede treinada e realizadas as previsões 24 horas à frente, foi feito um estudo da precisão da previsão da carga em diferentes condições de temperatura. Sabendo que a curva de carga média sem a componente de tendência versus temperatura média (figura 5) apresenta regiões distintas onde a temperatura possui maior ou menor influência na carga, separou-se os casos analisados em dois grupos: na zona inelástica, onde a temperatura possui pouca influência no comportamento da carga e na zona elástica onde a temperatura possui uma maior influência no comportamento da carga. Os intervalos foram definidos a partir da curva de relacionamento entre a carga média diária e temperatura, sendo a zona inelástica compreendida entre 15°C e 22°C e a zona elástica compreendida nos valores abaixo de 15°C (zona elástica inferior) ou acima de 22°C (zona elástica superior). Embora se tenha optado pela realização da previsão de carga somente para dias com histórico de carga completo, a análise das variações de temperatura contemplou todo o período em estudo.

A tabela 1 apresenta as zonas em estudo onde foram contabilizados os dias do período em estudo (dias), os dias previstos pela rede neural (previsões) e a os erros MAPE médios diários entre a carga real e a carga prevista.

Tabela 1 - Erros MAPE médio diário por zona.

	Zona Elástica Inferior	Zona Inelástica	Zona Elástica Superior	TOTAL
Dias	153	888	786	1827
Previsões	44	263	151	458
MAPE (%)	2,71	2,38	2,84	2,56

Os dados da tabela 1 mostram que a rede neural apresentou erros maiores na zona elástica, onde existe uma maior influência da temperatura ambiente no comportamento da carga. Isso significa que o modelo tem sua precisão diminuída à medida que aumenta a influência da temperatura no comportamento da carga. A perda de precisão entre a zona inelástica e elástica

inferior foi de 0,33 pontos percentuais e entre a zona inelástica e elástica superior foi de 0,46 pontos percentuais. A representatividade dos dados da zona elástica sobre o total é 51,4% indicando a região em que a carga é influenciada pela temperatura (SOUZA et.al., 2013).

Foi aplicado um teste t de *Student* para duas amostras independentes para verificar se as médias dos erros na zona inelástica e as médias dos erros na zona elástica são estatisticamente diferentes. Por hipótese inicial considerou-se que os erros na região elástica não são maiores que os erros na região inelástica. Para um nível de significância de 1% a hipótese inicial foi rejeitada com *p-valor* de 0,0001. Desta forma, conclui-se que as médias dos erros na zona elástica são maiores que na zona inelástica.

Um ponto a ser considerado além da classificação por zona é saber se houve uma variação de temperatura que possa explicar um aumento nos erros de previsão. Para isto, foi necessário estabelecer uma métrica de medição que pudesse caracterizar uma variação de temperatura levando em consideração a sua influência sobre a carga. Pela dificuldade da existência na literatura de uma definição de variação de temperatura, optou-se por comparar um valor de temperatura com o dia anterior, para cada intervalo horário. Mas esta informação não é o suficiente, pois dependendo da região na curva de carga, uma variação de temperatura pode ocasionar diferentes variações na carga. Para caracterizar então uma variação de temperatura na curva de carga (ΔCc), foi feito o cálculo da carga média do período considerando temperatura horária atual ($C_{MST-periodo}(T_h)$) e a temperatura no mesmo horário do dia anterior ($C_{MST-periodo}(T_{h-24})$) a partir das suas respectivas equações de terceiro grau na curva de carga por período. A variação de temperatura na curva de carga de um determinado horário é definida como a diferença entre estes valores calculados:

$$\Delta Cc = C_{MST-periodo}(T_h) - C_{MST-periodo}(T_{h-24}) \quad (7)$$

Exemplificando, no dia 26/01/2010 a temperatura era de 26°C e no dia 27/01/2010 a temperatura era de 31°C. Na interpolação polinomial de terceiro grau da curva de carga do período de 12 as 17 horas (equação 5), os valores de carga média do período calculadas são: 0,353 e 0,816, ocasionando uma variação de temperatura na curva de carga de 0,463. Embora uma variação de temperatura 5°C não parece ser uma variação considerável, há uma grande variação de temperatura na curva de carga que talvez possa ocasionar erros de previsão.

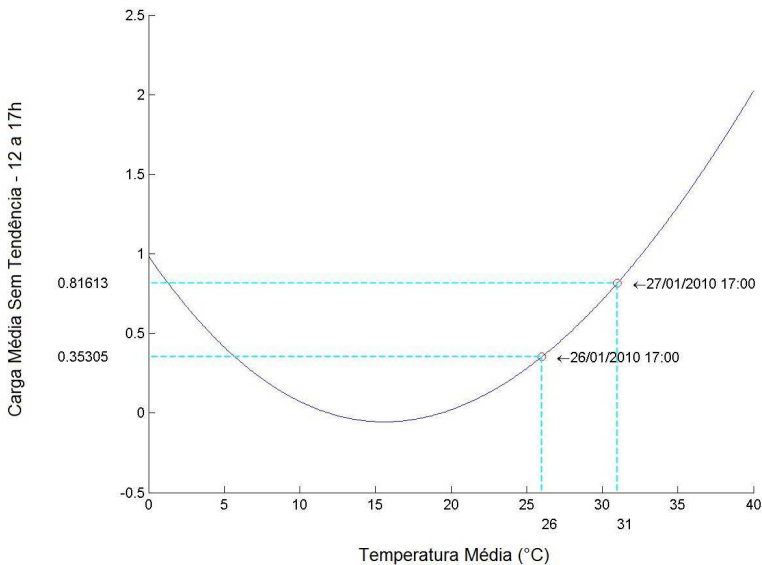


Figura 12 – Variação de temperatura na curva de carga entre os dias 26 e 27 de janeiro de 2010, no horário das 17 horas.

O mesmo cálculo foi feito para todos os valores horários de temperatura e construído o histograma das variações de temperatura na curva de carga, mostrado na figura 13. Na tabela 2 é apresentada a estatística descritiva das variações de temperatura na curva de carga, das últimas 24 horas.

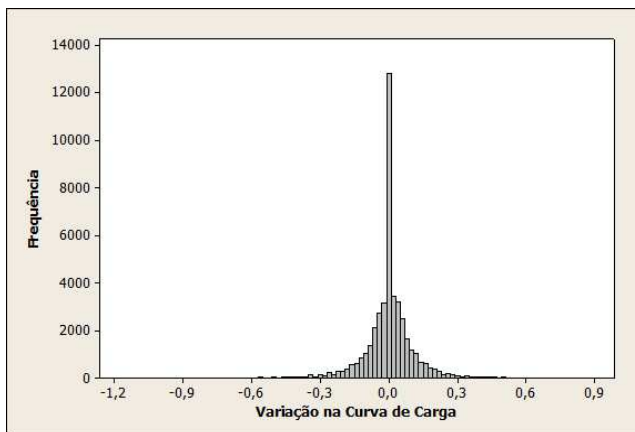


Figura 13 - Histograma das variações de temperatura na curva de carga nas últimas 24 horas.

Tabela 2 - Estatística descritiva das variações de temperatura na curva de carga nas últimas 24 horas.

Média	0,000166
Desvio Padrão	0,1052
Variância	0,01327
Mínimo	-1,2192
Quartil 1	-0,03394
Mediana	0
Quartil 3	0,04173
Maximo	0,94234
Total de Leituras	43800

Para separar os casos onde houve uma variação significativa de temperatura na curva de carga nas últimas 24 horas, foi definido o limite de 3 desvios padrão acima ou abaixo da média.

Com os dados da tabela 1 é possível verificar que a zona elástica apresenta os maiores erros. Porém, não há uma análise considerando as variações de temperatura na curva de carga nas últimas 24 horas comparadas com os erros das zonas. Para isto foi feita uma classificação dos erros por horário do dia, não mais utilizando os valores médios diários, e sim as leituras individuais horárias. A tabela 3 apresenta esta nova organização onde foi contabilizado o número de leituras horárias e os erros *MAPE* médio horário entre a carga real e a carga prevista por zona.

Tabela 3 – Erros MAPE médio horário por zona.

		Zona Elástica Inf.	Zona Inelástica	Zona Elástica Sup.	TOTAL
Sem Variação ΔCc	Leituras horárias	1343	5236	4259	10838
	Erro MAPE (%)	2,38	2,35	2,85	2,55
Com Variação ΔCc	Leituras horárias	10	11	133	154
	Erro MAPE (%)	3,51	2,69	3,06	3,06
Total	Leituras horárias	1353	5247	4392	10992
	Erro MAPE (%)	2,39	2,35	2,86	2,56

Através deste detalhamento dos erros mostrados na tabela 3 verifica-se que existe um aumento nos erros de previsão quando a variação de temperatura produz uma variação na curva de carga maior que três desvios padrão, para todas as zonas, independente do fato da carga permanecer ou mudar de zona. E este aumento nos erros é maior quando a temperatura encontra-se em uma das zonas elásticas (superior ou inferior).

4.4 CONSIDERAÇÕES SOBRE O CAPÍTULO

Este capítulo mostrou o efeito da temperatura sobre a previsão de carga elétrica de curto prazo. Inicialmente foi apresentada a justificativa da escolha de região em estudo e como os dados de carga foram pré-processados antes da sua entrada na rede neural. O método de construção da curva de carga média diária sobre a temperatura média diária foi utilizado com êxito para mostrar o comportamento da carga para as diferentes faixas de temperatura. Com a divisão da curva de carga em períodos, foi possível verificar as diferenças no comportamento dos consumidores para cada período, bem como permitiu a classificação mais detalhada dos erros de previsão da rede.

Os resultados apresentados comprovaram que houve um aumento dos erros de previsão quando a rede é submetida a variações de temperatura que resultem em variações na curva de carga, mais significativas nas zonas elásticas. Partindo desta constatação, houve a motivação em adicionar uma entrada à rede neural que pudesse informar a rede uma condição de existência de variação de temperatura na curva de carga estando na zona elástica, para verificar se existe melhora nos erros de previsão.

5 PROPOSTA DE CORREÇÃO NA REDE NEURAL PARA CONDIÇÃO DE VARIAÇÃO DE TEMPERATURA QUE RESULTE VARIAÇÃO DE CURVA DE CARGA NA ZONA ELÁSTICA

5.1 INTRODUÇÃO

Para que fosse possível a construção de uma proposta de correção na rede neural para dias em condições especiais de temperatura, foi necessária uma revisão bibliográfica. Na literatura foram encontradas duas formas distintas de abordagem do problema: o estudo da curva de carga sobre a temperatura e o tratamento de erros de previsão ocasionados por fatores climáticos.

Os trabalhos de Giannakopoulos e Psiloglou (2006) e Valor, Meneu e Caselles (2001) fazem a construção da curva de carga sobre a temperatura para dias, meses e estações do ano, mostrando a relação não linear entre estas grandezas e a região de conforto térmico. Também é identificado um crescimento linear ocasionando um aumento no consumo anual de energia, justificado pelo crescimento econômico. Em Moghaddas-Tafreshi e Farhadi (2008) é utilizada uma rede neural para captar a relação entre temperatura e carga e os resultados são semelhantes aos anteriores, mostrando uma região central de conforto térmico, pouco influenciado pela temperatura.

A utilização de técnicas para o tratamento de erros de previsão ocasionados por fatores climáticos é mostrada em trabalhos como Lee e Du (2009) e Fidalgo e Lopes (2005). Nestes trabalhos são mostrados métodos de correção geral, que captam relações entre dias anormais e melhoram a previsão de carga para esses dias. Sendo que um dos fatores que influencia e torna o dia anormal é a temperatura, e as técnicas utilizadas são a regressão linear e as redes neurais.

Porém, trabalhos específicos que a partir da curva de carga sobre a temperatura, tratem e corrijam dos erros de previsão ocasionados pela influência da temperatura, não foram encontrados. Este estudo bibliográfico justifica então a importância da apresentação de uma proposta de correção dos erros de previsão ocasionados pela temperatura.

5.2 APRESENTAÇÃO DA PROPOSTA

A partir da análise do comportamento da rede neural para as zonas elásticas e considerando as ocorrências de variações de temperatura que resultem em uma variação significativa na curva de carga, foi proposto um método de correção na previsão de rede, que pudesse adaptar o sistema a estas situações.

Inicialmente separou-se os dias de ocorrência destas condições e, ao estudar detalhadamente o comportamento da rede para estes dias, verificou-se que a rede se comporta de uma maneira diferente para cada situação. Como não é o foco deste estudo classificar estas situações, vamos detalhar apenas duas situações que ocorreram com maior frequência para a região em estudo.

A primeira delas é a situação onde a estação do ano era o verão e há a ocorrência de uma frente fria. Como a previsão da rede possui dependência com a temperatura, a ocorrência de uma queda na mesma resulta, por consequência, em uma queda na previsão da rede neural. Porém, na prática, o comportamento dos consumidores é de manter os mesmos hábitos de consumo por algumas horas ou dias. E a rede, que interpreta esta mudança de temperatura, imediatamente começa a estimar a carga com valores mais baixos. Por isso há uma subestimação da carga pela rede neural, que deve ser corrigida.

A outra situação ocorre quando a estação do ano também é verão e há o fim de uma frente fria, retornando as temperaturas médias normais para a

estação. Neste caso o comportamento dos consumidores, que diminuíram o consumo de carga por alguns dias, em virtude da frente fria e da não utilização tão constante de sistemas de refrigeração, passa a ser maior com este aumento de temperatura. Diferentemente do comportamento anterior, a rede neste caso não é capaz de interpretar o aumento de temperatura imediatamente, continuando a fazer previsões abaixo do consumo real. E da mesma forma que a situação anterior, há uma subestimação da carga pela rede neural, que deve ser corrigida.

Diante destes fatos, surgiram questionamentos de como realizar a correção destes erros de previsão. A ideia consiste em adicionar a informação à rede do exato momento que está ocorrendo uma variação na temperatura. Na prática, tendo o histórico da temperatura da semana atual e conhecendo-se o valor de temperatura previsto para as próximas 24 horas, pode ser realizado o cálculo dos valores na curva de carga e calculada a diferença entre os valores. Como havia disponibilidade dos dados reais, os mesmos foram utilizados, não havendo necessidade da utilização de valores de temperatura previstos.

Para o sistema em estudo, foi adicionada uma entrada na rede neural (*Var_cc*) contendo a diferença na curva de carga entre o valor atual de temperatura e o valor de temperatura no dia anterior, ou seja, a mesma variável cujo histórico foi traçado na figura 13 e definida como variação de temperatura na curva de carga (*ΔCc*).

A figura 14 mostra um diagrama em blocos do sistema de previsão com correção.

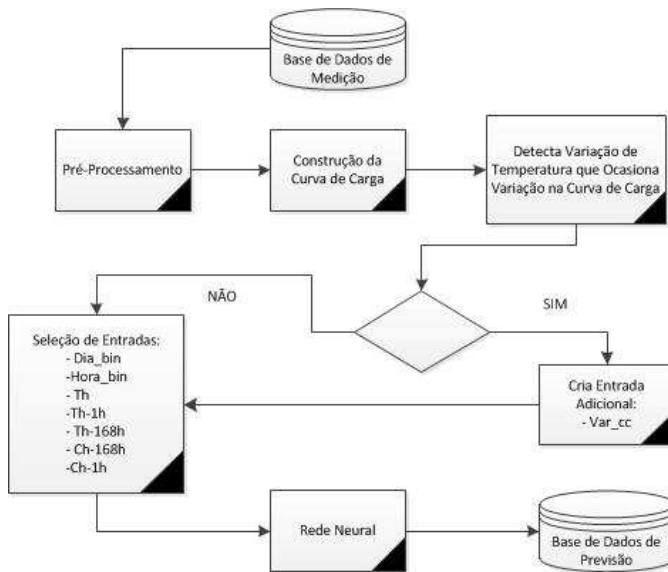


Figura 14 – Diagrama em blocos do sistema de previsão com correção

A partir da base de dados de medição é realizado um pré-processamento, a construção da curva de carga e o teste de detecção de variação de temperatura que ocasiona variação na curva de carga. Se o resultado do teste for negativo, que é a condição normal, as entradas da rede são calculadas e a rede neural faz a previsão da carga elétrica. Se o resultado do teste for positivo, que é a condição de variação de temperatura que ocasiona variação na curva de carga, a entrada adicional é inserida às outras entradas da rede, para então realizar a previsão da carga elétrica.

5.3 ESTUDO DE CASOS

Nesta secção são mostrados casos que ilustram a diminuição do erro MAPE obtido com as previsões da rede neural corrigida, que contém informações de condições da mudança de temperatura na sua entrada. O

primeiro caso mostra uma queda de temperatura em virtude da chegada de uma frente fria e o segundo mostra um aumento de temperatura em virtude do final de uma frente fria, ambos ocorridos no verão.

5.3.1 Entrada de frente fria no verão

No dia 08/02/2010, segunda feira, ocorreu uma queda na temperatura, que se iniciou por volta das 15 horas e se prolongou por três dias. Neste horário a temperatura era de 26°C, diferenciando-se 10°C abaixo do dia anterior. Esta variação de temperatura na zona elástica superior provocou uma variação de -1,07895 na curva de carga, conforme figura 15.

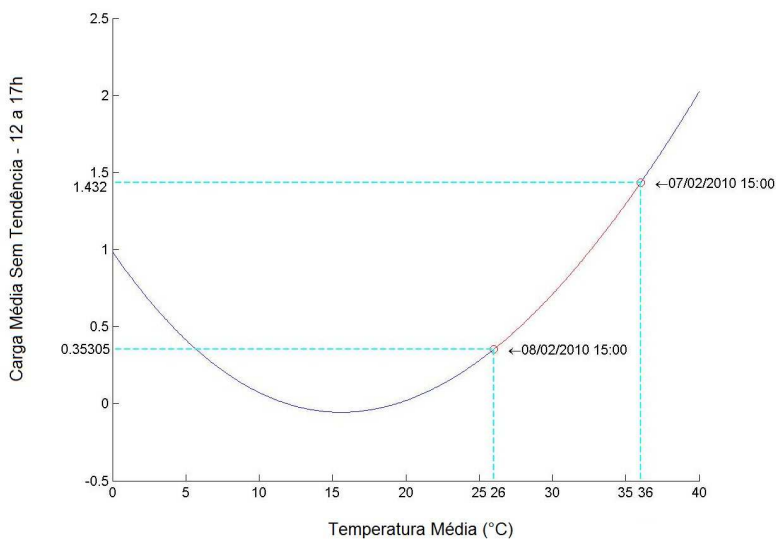


Figura 15 - Variação de temperatura na curva de carga ocorrida entre os dias 07/02/2010 e 08/02/2010 às 15 horas.

Devido ao comportamento atípico da temperatura neste dia, o erro médio MAPE de previsão da rede foi de 3,92%. Após a correção na rede, o

novo erro MAPE de previsão corrigida passou a ser de 1,73%. As curvas de temperatura, carga real, carga prevista, carga corrigida e erros são mostradas na figura 16.




Figura 16 - Temperatura, cargas e erros no dia 08/02/2010.

Em (16) a curva “Carga Prev” mostra a previsão inicial da rede, que está abaixo da condição de carga real “Carga Real”. Neste dia houve uma queda de temperatura e a rede neural fez a previsão adequando o consumo de

carga à queda de temperatura. Porém, o comportamento real dos consumidores neste dia foi semelhante aos anteriores, que apresentavam temperaturas altas. E isto causou uma situação atípica para a rede neural, pois a queda de temperatura neste dia não provocou uma queda no consumo, como deveria ter ocorrido. No dia anterior a temperatura média foi de 30,6°C, no dia da chegada da frente fria a temperatura média foi de 27,1°C e no dia posterior a temperatura média foi de 24°C. A implementação da correção na rede e a nova previsão “*Carga Corr*” aproxima-se mais da carga real.

5.3.2 Término de frente fria no verão

No dia 04/02/2011, sexta feira, ocorreu um aumento na temperatura, que se iniciou por volta das 11 horas e se estendeu até às 19 horas. Às 11 horas a temperatura era de 29°C, diferenciando-se 4°C acima do dia anterior. Esta variação de temperatura, embora pareça pequena, por estar na zona elástica superior provocou uma variação de 0,33164 na curva de carga, conforme figura 17.




Figura 17 - Variação de temperatura na curva de carga ocorrida entre os dias 03/02/2011 e 04/02/2011 às 11 horas.

Devido ao comportamento atípico da temperatura neste dia, o erro médio MAPE de previsão da rede foi de 5,42%. Após a correção na rede, o novo erro MAPE de previsão corrigida passou a ser de 1,73%. As curvas de temperatura, carga real, carga prevista, carga corrigida e erros são mostradas na figura 18.

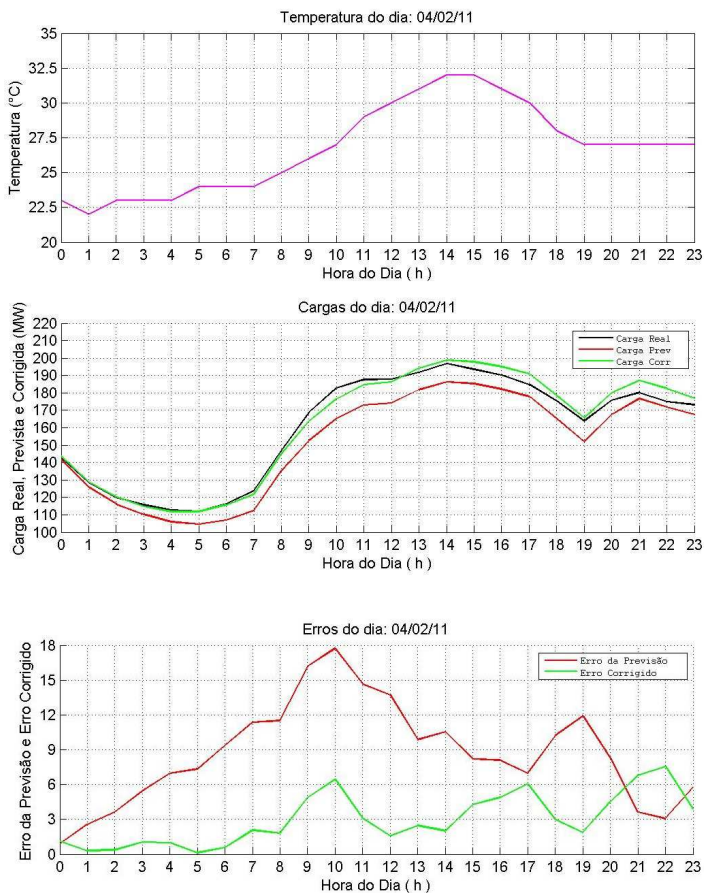


Figura 18 - Temperatura, cargas e erros no dia 04/02/2011.

Em (19) a curva “Carga Prev” mostra a previsão inicial da rede, que está abaixo da condição de carga real “Carga Real”. A rede neural fez a previsão abaixo do consumo de carga, similar aos dias anteriores que estavam sob o efeito de uma frente fria. Porém, o aumento repentino na temperatura causou uma situação atípica. No dia anterior a temperatura média foi de 24,5°C, no dia do término da frente fria a temperatura média foi de 26,75°C e no dia

posterior a temperatura média foi de 28,21°C. A implementação da correção na rede e a nova previsão “*Carga Corr*” aproxima-se mais da carga real.

5.4 ANÁLISE DO MÉTODO DE CORREÇÃO

Analisando o método de correção, verifica-se que o mesmo foi capaz de reduzir os erros de 21 dias com variação de temperaturas com variação na curva de carga. A tabela 4 mostra os resultados dos erros MAPE diários, dos dias em que foi aplicado o método de correção.

Tabela 4 – Resultados MAPE diários da aplicação do método de correção.

Data	MAPE Rede Normal (%)	MAPE Rede Corrigida (%)	Diferença (%)
29/03/2007	5,11	2,70	2,41
27/10/2009	3,16	2,42	0,74
01/12/2009	2,15	2,05	0,10
02/12/2009	3,55	2,76	0,78
17/12/2009	3,81	3,01	0,80
01/02/2010	3,23	2,61	0,62
08/02/2010	3,92	1,73	2,19
12/02/2010	2,07	1,83	0,24
14/07/2010	3,52	3,44	0,09
30/11/2010	3,92	3,90	0,02
08/12/2010	4,52	2,88	1,64
10/12/2010	5,34	4,62	0,73
21/12/2010	2,40	1,98	0,42
25/01/2011	2,32	1,72	0,60
31/01/2011	1,34	1,29	0,05
04/02/2011	5,42	1,73	3,69
13/04/2011	4,05	4,02	0,03
15/04/2011	3,16	1,95	1,21
11/11/2011	4,03	3,04	0,99
25/01/2012	2,96	2,84	0,11
01/03/2012	3,32	2,49	0,83

Média	3,49	2,62	0,87
-------	------	------	------

A média de erros MAPE diários destes dias era de 3,49% e após aplicada a correção, a média de erros MAPE diários passou a ser 2,62%, ocasionando uma diminuição de 0,87 pontos percentuais.

A tabela 5 foi construída a partir da aplicação do método de correção, onde foi comparado o erro MAPE médio diário, entre a carga real e a carga prevista, com a implementação da correção (MAPE CORR) e o erro MAPE médio diário sem a implementação da correção (MAPE).

Tabela 5 – Comparação dos erros MAPE médio diário por zona.

	Zona Elástica Inferior	Zona Inelástica	Zona Elástica Superior	TOTAL
MAPE (%)	2,71	2,38	2,84	2,56
MAPE CORR. (%)	2,62	2,38	2,74	2,52

Este método de correção foi capaz de melhorar em 0,09 pontos percentuais os erros da zona elástica superior e 0,1 pontos percentuais do erro geral da rede. Em valores percentuais MAPE médios totais, o ganho obtido pela melhora na previsão de 21 dias não é muito afetado, tendo uma diminuição de 0,04 pontos percentuais, pois estes eventos são raros no histórico de dados. Porém o estudo apresenta sua importância em dimensionar e apresentar um método de correção nos erros de uma rede neural quando submetida a mudanças de temperatura.

A melhora do processo de previsão utilizando o paradigma de redes neurais comprovou sua eficiência através da proposta deste método de correção dos erros de previsão de carga de curto prazo, decorrentes de variações de temperatura, na ilha de Santa Catarina. Os testes comprovaram a eficiência do

método, que oferece uma alternativa prática e simplificada para a previsão de carga em sistemas de potência.

6 CONCLUSÕES E TRABALHOS FUTUROS

6.1 CONCLUSÕES

Este estudo propõe um método para minimização dos erros de previsão de uma rede neural artificial, utilizando uma aproximação polinomial de terceiro grau, para extrair a relação não linear da carga elétrica com a temperatura ambiente para a ilha de Santa Catarina. A curva que expressa esta relação mostra que existem duas zonas elásticas, onde a carga é mais sensível à temperatura, e uma zona inelástica central onde variações da temperatura tem pouca influência na carga. As zonas elásticas podem ser divididas em superior e inferior. A superior apresenta relação direta entre temperatura e carga e a zona inferior mostra que a relação é inversa e bem mais suave que na zona superior.

A aplicação do conhecimento resultante do mapeamento da relação não linear entre temperatura e carga em um sistema de previsão, mostra que o mesmo tem sua capacidade de previsão reduzida à medida que aumenta a influência da temperatura no comportamento da carga. A mudança na precisão da carga prevista frente às diferentes faixas de temperatura, indica que essa informação deve ser levada em consideração na construção de modelos de previsão de carga.

A curva resultante da relação entre carga e temperatura, é característica para cada região e pode sofrer alterações dependendo do tipo de consumidor e período do dia. Pelo fato do estudo ter sido feito na ilha de Santa Catarina onde os consumidores são, em sua maioria, residenciais e comerciais, esta curva pode ser utilizada como referência para outros estudos em regiões com clientes majoritariamente sensíveis ao conforto térmico.

6.2 SUGESTÕES PARA TRABALHOS FUTUROS

A limitação deste trabalho está na região em estudo. Embora tenha sido escolhida principalmente pelo motivo de tentar isolar uma área com pouca influência de consumidores industriais, seria interessante a realização do mesmo estudo para outras regiões com clientes majoritariamente sensíveis ao conforto térmico. Porém, deve-se procurar isolar a carga destas áreas com características climáticas semelhantes entre si, pois o estudo da curva de carga versus temperatura é mais eficiente nestes casos.

Com a divisão do dia em períodos, foi possível a verificação de um comportamento diferente para cada período. Nota-se que as madrugadas (0 a 5 horas) e as noites (18 a 23 horas) apresentam uma curva com pouca dispersão. Já as manhãs e tardes (6 a 17 horas) apresentam os dados mais dispersos, mostrando que há outro fator de forte influência. Um estudo interessante seria a verificação da causa desta dispersão, utilizando também técnicas de redes neurais ou análise estatística.

Outra abordagem interessante do problema seria construir a curva de influência para outros fatores climáticos como umidade do ar, velocidade dos ventos sobre a carga. Através da composição das várias influências, seria possível a construção de um modelo mais abrangente envolvendo conforto térmico, que possibilitaria uma correção mais apurada dos erros de previsão gerados por fatores climáticos.

REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Estabelece as diretrizes e condições para os contratos iniciais de compra e venda de energia elétrica entre as concessionárias que especifica. Resolução nº 44**, de 1 de fevereiro de 2001, Disponível em: <http://www.aneel.gov.br/cedoc/res2001044.pdf>. Acessado em: 24 de fevereiro de 2012.

ALMEIDA, C.; FISHWICH, P. A.; TANG, Z. **Time series forecasting using neural network vs. Box-Jenkins methodology**. Simulation Councies. p. 303-310, Nov. 1991.

AMJADY, N.; KEYNIA, F. **A New Neural Network Approach to Short Term Load Forecasting of Electrical Power Systems**. Energies 2011, v. 4, p. 488-503. Mar. 2011.

BARBETTA, Pedro Alberto. **Estatística aplicada às Ciências Sociais**. 6ª ed. Florianópolis: Editora da UFSC, 2006. p. 201-207.

BO, Rui; LI, Fangxing. **Probabilistic LMP Forecasting Considering Load Uncertainty**. IEEE Transactions on Power Systems, v. 24, n. 3, p. 1279 - 1289, Ago. 2009.

BODYANSKIY, Yevgeniy; POPOV, Sergiy; RYBALCHENKO, Taras. **Feedforward Neural Network with a Specialized Architecture for Estimation of the Temperature Influence on the Electric Load**. IEEE International Conference on "Intelligent Systems", v.1, p.7-14 - 7-18, Set. 2008

BRAGA, Antônio de Pádua; CARVALHO, André Ponce de Leon F.; LUDERMIR, Teresa Bernarda. **Fundamentos de Redes Neurais Artificiais**. Rio de Janeiro: UFRJ, 1998.

CANCELO, J. R., ESPASA, Antoni. **Modelling and forecasting daily series of electricity demand**. Investigaciones Economicas, v. 20, p. 359–376. Set. 1996.

CARPINTEIRO, O. A. S., SILVA A. P. A. **A hierarchical neural model in short-term load forecasting**. Sixth Brazilian Symposium on Neural Networks, p. 120- 124. 2000.

CARPINTEIRO, O. A. S., SILVA, A. P. A., FEICHAS, C. H. L. **A hierarchical neural model in short-term load forecasting**. IEEE-INNS-ENNS International Joint Conference on Neural Networks, v. 6, p. 241 – 246. 2000.

CHAN, P.P.K. et al. **Multiple classifier system for short term load forecast of Microgrid**. Machine Learning and Cybernetics International Conference, v. 3, p. 1268-1273, Jul. 2011.

CHANGYIN, Sun; PING, Ju; LINFENG, Li. **Fuzzy Modeling Technique with PSO Algorithm for Short-Term Load Forecasting**. Springer Berlin on Computer Science, v. 4223, n. 978-3-540-45916-3, p. 933-936, 2006.

CHEN, Ying et.al. **Short-term load forecasting: Similar day-based wavelet neural networks**. IEEE Transactions on Power Systems, v. 25 n. 1, p. 322 - 330, Fev. 2010.

CHICCO, G.; NAPOLI, R.; PIGLIONE, F. **Load pattern clustering for short-term load forecasting of anomalous days**. IEEE Porto on Power Tech Proceedings, v. 2, p. 6 -11, Set. 2001.

DONGXIAO, Niu; LING, Ji; JIE, Tian. **Wavelet neural network embedded expert system used in short-term load forecasting**. IEEE International Conference on Emergency Management and Management Sciences, p.190-193, Ago. 2011.

ELETRORBRAS. **Manual de Tarifação da Energia Elétrica**. 2012, Disponível em: <http://www.eletrorbras.com/elb/main.asp?TeamID=%7B60F8B9E9-77F5-4C5B-9E94-B1CC0CEF1EAB%7D#>. Acessado em: 30 de julho de 2013.

ERKMEN, I; TOPALLI, A. K. **Four methods for short-term load forecasting using the benefits of artificial intelligence**. Springer Berlin on Electrical Engineering, v. 85, p. 229-233, Set. 2003.

FAY, D.; RINGWOOD, J.V. **On the influence of weather forecast errors in short-term load forecasting models**. IEEE Transactions on Power Systems, v. 25, n. 3, p. 1751-1758, Ago. 2010.

FELICCE, Matteo de; YAO, Xin. **Short-Term Load Forecasting with Neural Network Ensembles: A Comparative Study**. IEEE Computational Intelligence Magazine, v. 6, n. 3, p. 47-56, Ago. 2011.

FENG, Li; LIU, Ziyang. **Effects of multi-objective genetic rule selection on short-term load forecasting for anomalous days**. IEEE on Power Engineering Society General Meeting, p. 7 -14, 2006.

FERREIRA, Vitor Hugo. **Técnicas de Regularização de Modelos Neurais Aplicadas à Previsão de Carga em Curto Prazo**. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Rio de Janeiro. Rio de Janeiro. 2005.

FIDALGO, J.N.; LOPES, J.A. Peças. **Load forecasting performance enhancement when facing anomalous events**. IEEE Transactions on Power Systems, v. 20, p. 408-415, Fev. 2005.

GIANNAKOPOULOS, CHRISTOS; PSILOGLOU, BASIL E. **Trends in energy load demand for Athens, Greece: weather and non-weather related factors**. Journal Article Climate Research, v. 31, p. 97–108. 2006.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. Tradução de Paulo Martins Engel. Porto Alegre: Bookman, 2001.

HIPPERT, H. S.; PEDREIRA, C. E.; SOUZA, R. C. **Neural networks for short term load forecasting: are view and evaluation**. IEEE Transactions on Power Systems, v. 16, n. 1, p. 44-55, Fev. 2001.

HONG, W.-C. et. al. **SVR with Hybrid Chaotic Immune Algorithm for Seasonal Load Demand Forecasting**. Energies 2011, v. 4, p. 960-977, Jun. 2011.

JAIN, A.; SATISH, B. **Short term load forecasting by clustering technique based on daily average and peak loads**. IEEE on Power & Energy Society General Meeting, n. 1944-9925, Jul. 2009.

KIM, Kwang-Ho; YUON, Hyoung-Sun; KANG, Yong-Cheol. **Short-term load forecasting for special days in anomalous load conditions using neural networks and fuzzy inference method**. IEEE Transactions on Power Systems, v. 15, n. 2, p. 559-565, Maio 2000.

LANDIM, P.M.B. **Análise Estatística de Dados Geológicos**. Rio Claro. Editora UNESP. 1997.

LEE, K.Y.; DU, Shu Du. **Short-Term Load Forecasting Using Semigroup Based System-Type Neural Network**. IEEE on Intelligent System Applications to Power Systems, n.978-1-4244-5098-5, p.1 - 6, Nov. 2009.

LUCCA, Luiz Angelo Daros de. **Previsão de Carga em Sistemas De Potência Durante Feriados Prolongados: Efeito do Feriado na Quinta-Feira Sobre a Carga da Sexta-Feira**. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Santa Catarina. Florianopolis. 2008.

MASOOD, Nahid-Al et. al. **Temperature sensitivity forecasting of electrical load**. IEEE on Power Engineering and Optimization Conference, p .244-248, Jun. 2010.

METAXIOTIS, K. et. al. **Artificial intelligence in short term electric load forecasting**: a state-of-the-art survey for the researcher, Energy Conversion and Management, v. 44, p. 1525-1534, Jun. 2003.

MOGHADDAS-TAFRESHI, S.M.; FARHADI, M. **A linear regression-based study for temperature sensitivity analysis of Iran electrical load**. IEEE International Conference on Industrial Technology, p. 1-7, Abr. 2008.

MORETTIN, Pedro A; TOLOI, Clélia M. C. **Análise de séries temporais**. 2ª ed. São Paulo: Edgar Blucher. 2006.

MURTO, Pauli. **Neural network models for short-term load forecasting**. Masters Thesis, Department of Engineering Physics and Mathematics, Helsinki University of Technology, 1998.

OLIVEIRA, Claudio Magalhães. **Modelo Adaptativo para Previsão de Carga de Curto Prazo**. Tese (Doutorado em Engenharia de Produção) – Universidade Federal de Santa Catarina. Florianópolis. 2004.

SFETSOS, A. **Short-term load forecasting with a hybrid clustering algorithm**. IEEE Proceedings Generation, Transmission, and Distribution. v. 150, n. 3, p. 257-262, Mai. 2003.

SOUZA, Luiz Fernando Spillere de et. al. **A Influência da Temperatura no Comportamento da Carga Elétrica de Curto Prazo e na Precisão da sua Previsão**. SBAI Simpósio Brasileiro de Automação Inteligente. Out. 2013.

SOUZA, Gueibi Peres; SAMOHYL, Robert Wayne; MIRANDA, Rodrigo Gabriel de. **Métodos Simplificados de Previsão Empresarial**. 1ª ed. Editora Ciência Moderna. p. 59-123. 2008.

SWARUP, K. S. and SATISH, B. **Integrated ANN approach to forecast load**. IEEE Computer Applications in Power, v. 15, n. 1, p. 46-51, Abr. 2002.

VALERO, Sergio et.al. **Comparison of Electric Load Forecasting between Using SOM and MLP Neural Network**. Journal of Energy and Power Engineering, v.6, p.411-417, Mar. 2012.

VALOR, Enric; MENEU, Vicente.; CASELLES, Vicente. **Daily air temperature and electricity load in Spain**. Journal of Applied Meteorology, v. 40, p.1413-1421, Ago. 2001.

VEHVILÄINEN, I.; KEPPO, J. **Managing electricity market price risk**. European Journal of Operational Research. v. 145, n. 1, p. 136-147, 2003.

WEATHER UNDERGROUND. **Internet Weather Service**. Disponível em: <<http://www.wunderground.com>>. Acesso em: 18 de fevereiro de 2013.

