

A INFLUÊNCIA DA TEMPERATURA NO COMPORTAMENTO DA CARGA ELÉTRICA DE CURTO PRAZO E NA PRECISÃO DA SUA PREVISÃO

LUIZ FERNANDO SPILLERE DE SOUZA¹, RAUL SIDNEI WAZLAWICK¹, CLAUDIO MAGALHÃES DE OLIVEIRA², LUIZ ANGELO DAROS DE LUCA².

1. *Programa de Pós-Graduação em Ciência da Computação, Universidade Federal de Santa Catarina*
Cx. P. 476, 88040-900 – Florianópolis, SC - Brasil

E-mails: spillere@gmail.com, raul@inf.ufsc.br.

2. *Instituto de Capacitação, Pesquisa e Desenvolvimento Institucional em Gestão Social de Tecnologia de Informação (IDESTI)*
Rua Dr. Alfredo Daura Jorge, 194, 88062-220. Florianópolis, SC - Brasil

E-mails: claudio@idesti.org, luizluca@gmail.com.

Abstract — This work presents the relationship of electric load to the ambient temperature to the Island of Santa Catarina and the influence of temperature in short-term load forecasting in different temperature ranges. Based on the historic data load and temperature, it is built a *load over temperature* curve, which is used to measure the influence of the temperature on the load. It has been shown for the studied region, which is a central temperature with little influence on consumption, while above and below this range are, respectively, forward and reverse relationship with the behavior of the load. Still, the prediction accuracy of the load by a neural network is affected by the temperature range considered. The results of this study are a better scaling in load demand, resulting in financial gain to the distributors. Consumers can expect a better service; and a good scaling of the natural resource energy contributes to good environmental practices.

Keywords — Temperature Influence, Load Forecasting, Neural Networks.

Resumo — Este trabalho estuda a 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 grau 3 da relação carga versus temperatura. A curva resultante mostra a influência da temperatura sobre o comportamento da carga e o relacionamento não linear entre estas variáveis. Foi demonstrado, 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. Uma previsão de carga eficiente resulta em ganhos financeiros para as distribuidoras, um serviço de melhor qualidade para os consumidores e um melhor dimensionamento do recurso natural contribuindo com boas práticas ambientais.

Palavras-chave — Influência da Temperatura, Previsão de Carga Elétrica, Redes Neurais.

1 Introdução

A demanda futura de energia elétrica no curto, médio e longo prazo 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. Os consumidores estão se tornando cada vez mais exigentes e os requisitos mínimos de qualidade e continuidade de fornecimento estabelecido pela legislação são cada vez mais restritos. “A distribuidora é obrigada a fornecer energia elétrica aos interessados cujas unidades consumidoras, localizadas na área concedida ou permitida, sejam de caráter permanente e desde que suas instalações elétricas satisfaçam às condições técnicas de segurança, proteção e operação adequadas, ressalvadas as exceções previstas na legislação

aplicável.” (Agência Nacional de Energia Elétrica, 2010).

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, 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 climá-

ticas, 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 e Lopes, 2005).

O relacionamento entre a carga e fatores exógenos ao sistema elétrico é complexo e não linear (Carpinteiro e Alves da Silva, 2000; Carpinteiro *et.al.* 2000). 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 à alteração nos hábitos de consumo causados pelas alterações 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 Gianakopoulos 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 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, com aumento do consumo à medida que a temperatura diminui. Ainda neste estudo, a relação modelada foi utilizada na construção de modelos de previsão da energia diária e mensal.

Por outro lado, os estudos de Fidalgo e Lopes (2005), demonstraram que a temperatura não afetou a previsão de carga. A razão atribuída foi que a região em estudo, Portugal, um país com clima mediterrâneo, onde as mudanças bruscas de temperatura são raras. Para esta, 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 da rede, por isso optou-se pela realização de previsão de carga sem considerar este fator.

Este trabalho estuda a relação da carga média diária com a temperatura ambiente média diária, para a Ilha de Santa Catarina, e a precisão da previsão da carga horária para diferentes faixas de temperatura ambiente.

2 Descrição do Sistema em Estudo

Neste estudo, foram utilizados o histórico de carga e temperaturas horárias relativas à Ilha de Santa Catarina. A influência da temperatura ambiente no consumo pode variar para os diferentes tipos de consumidores. Os consumidores residenciais e comerciais são sensíveis às variações climáticas. Em contrapartida, consumidores industriais são pouco influenciados pelas flutuações climáticas (Masood *et al.*, 2010). Os consumidores da região em estudo são principalmente residenciais e comerciais onde, por hipótese, a influência da temperatura sobre a carga deve ser significativa. 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 (2011).

Preliminarmente, foi realizada uma filtragem dos dados para minimizar problemas nos estudos em virtude de erros no histórico. O procedimento levou em consideração que uma filtragem de dados em excesso pode atrapalhar o estudo tornando-o excessivamente otimista (Fidalgo e Lopes, 2005). O histórico de dados utilizado apresentava dados incompletos (leituras zeradas) e valores considerados muito altos, acima da capacidade da linha de transmissão que abastece a cidade. 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 qualquer leitura de carga e temperatura evidentemente incorreta.

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 & Toloí, 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 e Miranda, 2008). A tendência de crescimento da carga reflete o aumento no consumo de carga de energia em função do crescimento populacional, do aumento na utilização de eletrodomésticos, pela melhoria das condições sócio econômicas 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 1 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 grau 1, através de mínimos quadrados.




Figura 1. Carga horária e tendência estimada por polinômio de grau 1, para a ilha de Santa Catarina, período de janeiro de 2007 a abril de 2012.

A aproximação polinomial de grau 1 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 2 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 2. Carga horária sem tendência, para a Ilha de Santa Catarina, no período de janeiro de 2007 a abril de 2012.

Conforme apresentado (figura 2), a transformação aplicada (retirada da tendência pela divisão - tendência multiplicativa) transformou a série original em uma série estacionária.

3 Influência da Temperatura na Carga Elétrica 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 e Du, 2009). Outras variáveis climáticas, como a umidade e a velocidade dos ventos, influenciam a refrigeração e sensação de conforto térmico e podem ser consideradas como condições para corrigir a influência direta da temperatura no comportamento da carga (Cancelo e 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 (3). A curva foi obtida através de uma interpolação polinomial de grau 3 ajustada por mínimos quadrados. A figura 3 apresenta ainda uma aproximação dos dados por uma interpolação polinomial de grau 1, ilustrando como seria mapeada a relação caso fosse considerada como linear.




Figura 3. Curva de carga média diária sem a componente de tendência X temperatura média diária.

A interpolação polinomial de grau 3 apresentada na figura 3 (curva em azul claro) é dada pela equação (2).

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

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

A aproximação polinomial de grau 3 apresentada na figura 3 mostra, para o sistema em estudo, a relação não linear entre temperatura ambiente e carga média diárias. O ponto de mínimo da aproximação polinomial de grau 3 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 inclinação da curva é maior que a da região abaixo de 15°C, mostrando uma maior influência em variações das temperaturas mais altas na carga, que das temperaturas mais baixas, para a ilha de Santa Catarina.

4 Influência da Temperatura na Previsão de Carga Elétrica

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 previsão da carga, 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 relaciona-

mentos 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 codificado em 7 bits, hora do dia codificada em 24 bits, carga na hora anterior, carga na mesma hora da semana anterior, temperatura na hora atual, temperatura na hora anterior e temperatura na mesma hora da semana anterior. A saída com um nó representa a carga prevista uma hora à frente. 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. O critério de parada do treino é 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). Foi utilizado o software Matlab versão 7.10 para a construção modelo.

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 mes pois, a partir deste intervalo a rede degradava significativamente o seu desempenho. Após 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 3) 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 (zona elástica fria) ou acima (zona elástica quente) destes valores. 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 (previstos) e o erro MAPE entre a carga real e a carga prevista.

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

Tabela 1. MAPE dos erros de previsão por zona.

Os dados da tabela 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. Foi aplicado um teste t de Student para duas amostras independentes para verificar se a média dos erros na zona inelástica e a média 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 a média dos erros na zona elástica são maiores que na zona inelástica.

5 Conclusão

Este artigo mostra a relação não linear da carga com a temperatura ambiente para a Ilha de Santa Catarina e sua importância em estudos da influência da temperatura no comportamento da carga elétrica e na sua previsão. 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 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 curva resultante da relação entre carga e temperatura é característica para cada região e pode sofrer alterações dependendo do tipo de consumidor. 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. As alterações na precisão da carga prevista frente às diferentes faixas de temperatura indicam que essa informação deve ser conhecida na construção de modelos de previsão de carga elétrica.

Agradecimentos

Este projeto é parte integrante de pesquisa realizada junto ao Laboratório de Sistemas de Conhecimento, Universidade Federal de Santa Catarina. Agradecemos ao apoio da Eletrosul Centrais Elétricas no fornecimento de dados para a pesquisa.

Referências Bibliográficas

- Agência Nacional de Energia Elétrica.(2010). “Estabelece as Condições Gerais de Fornecimento de Energia Elétrica de forma atualizada e consolidada. Resolução nº 414, de 9 de setembro de 2010”, Disponível em: <<http://www.aneel.gov.br/cedoc/ren2010414comp.pdf>>. Acesso em: 24 de fevereiro de 2012.
- Cancelo, J. R., and A. Espasa. (1996). Modelling and forecasting daily series of electricity demand. *Invest. Econ.*, v. 20, p. 359–376.
- Carpinteiro, O. A. S., Alves da Silva A. P. (2000). A hierarchical neural model in short-term load forecasting. *Sixth Brazilian Symposium on Neural Networks*, p. 120- 124.
- Carpinteiro, O. A. S., Alves da Silva, A. P., Feichas, C. H. L. (2000). A hierarchical neural model in short-term load forecasting. *IEEE-INNS-ENNS International Joint Conference on Neural Networks*, v. 6, p. 241 – 246.
- Chan, P.P.K. et al. (2011) Multiple classifier system for short term load forecast of Microgrid. *Machine Learning and Cybernetics International Conference*, v. 3, p. 1268-1273.
- Erkmen, I; Topalli, A. K. (2003). Four methods for short-term load forecasting using the benefits of artificial intelligence. *Springer Berlin on Electrical Engineering*, v. 85, p. 229-233.
- Felicce , Matteo de; Yao, Xin. (2011). Short-Term Load Forecasting with Neural Network Ensembles: A Comparative Study. *IEEE Computational Intelligence Magazine*, v. 6, n. 3, p. 47-56.
- Fidalgo, J.N.; Lopes, J.A. Peças. (2005). Load forecasting performance enhancement when facing anomalous events. *IEEE Transactions on Power Systems*, v. 20, p. 408-415.
- Giannakopoulos, Christos; Psiloglou, Basil E. (2006). Trends in energy load demand for Athens, Greece: weather and non-weather related factors. *Journal Article Climate Research*, v. 31, p. 97–108.
- Landim, P.M.B. (1997). *Análise Estatística de Dados Geológicos*. Rio Claro. Editora UNESP.

- Lee, K.Y.; Du, Shu Du. (2009). 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.
- Masood, Nahid-Al et al. (2010). Temperature sensitivity forecasting of electrical load. IEEE on Power Engineering and Optimization Conference, p .244-248.
- Metaxiotis, K.et al. (2003). 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.
- Morettin, Pedro A; Toloí, Clélia M. C. (2006). Análise de séries temporais. 2ª ed. São Paulo: Edgar Blucher.
- Oliveira, Claudio Magalhaes. (2004). Modelo Adaptativo para Previsão de Carga de Curto Prazo. Tese (Doutorado em Engenharia de Produção) – Universidade Federal de Santa Catarina. Florianópolis.
- Souza, Gueibi Peres; Samohyl, Robert Wayne; Miranda, Rodrigo Gabriel de. (2008). Métodos Simplificados de Previsão Empresarial. 1ª ed. Editora Ciencia Moderna. p. 59-123..
- Valor, Enric; Meneu, Vicente.; Caselles, Viente. (2001). Daily air temperature and electricity load in Spain. Journal of Applied Meteorology, v. 40, p.1413-1421.
- Weather Underground. (2011). Internet Weather Service. Disponível em: <<http://www.wunderground.com>>. Acesso em: 18 de fevereiro de 2011.