

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS À PREVISÃO DE CARGA EM LONGO PRAZO CONSIDERANDO A ELASTICIDADE-PREÇO DA DEMANDA DE ENERGIA ELÉTRICA

SANDY T. MIRANDA*, MOISES M. SANTOS†, MAURICIO DE CAMPOS‡, ALZENIRA DA ROSA ABAIDE§, MAURICIO SPERANDIO¶

*Endereço Sandy Miranda, Moises Santos e Mauricio de Campos
DeCEEEng - UNIJUI
Ijuí, RS, Brasil

†Endereço de Alzenira da Rosa e Mauricio Sperandio
UFSM
Santa Maria, RS, Brasil

Emails: sandy.miranda@unijui.edu.br, moises.santos@unijui.edu.br,
campos@unijui.edu.br, alzenira@ufsm.br, mauricio.sperandio@ufsm.br

Abstract— In recent decades, the consumption behaviour is changing and tends to be strongly affected with the innovations introduced by Smart Grids. The use of micro generation and provision of electricity prices in real time, provide consumers with the ability to modulate their consumption or generation, according to market conditions. This way, the electricity demand starts to react in more effective manner to the price, signalling the need to adjust the load forecasting models. In this context, this work aims at presenting a load prediction model, in the long-term, focusing on the electricity tariffs. The model uses Artificial Neural Networks (ANNs), with Multilayer Perceptron (MLP) architecture. The computational tests are performed using historical data from New England system (ISO-NE). The results show good performance and potential of the proposed methodology, demonstrating a strong trend in electricity demand becomes elastic, from a historical analysis of price elasticity curve.

Keywords— Long Term Load Forecast, Artificial Neural Network, Price Elasticity.

Resumo— Nas últimas décadas, o comportamento do consumo vem se modificando e tende a ser fortemente impactado com as inovações introduzidas pelas *Smart Grids*. O uso de microgeração e a disponibilização de preços da energia elétrica em tempo real, propiciam aos consumidores a possibilidade de modular o seu nível de consumo, ou geração, de acordo com as condições de mercado. Desta forma, a demanda de energia elétrica passa a reagir de forma mais efetiva ao preço, sinalizando a necessidade de readequar os modelos de previsão de carga. Neste contexto, o presente trabalho tem por objetivo apresentar um modelo de previsão de carga, em longo prazo, com enfoque para as tarifas de energia elétrica. O modelo adotado utiliza Redes Neurais Artificiais (RNAs), com arquitetura *Multilayer Perceptron* (MLP). Os testes computacionais são realizados utilizando dados históricos do sistema de New England (ISO-NE). Os resultados obtidos evidenciam o bom desempenho e as potencialidades da metodologia proposta, demonstrando uma forte tendência de a demanda de energia elétrica tornar-se elástica, a partir de uma análise histórica da curva elasticidade-preço.

Palavras-chave— Previsão de Carga à longo prazo, Redes Neurais Artificiais, Elasticidade- Preço.

1 Introdução

O desenvolvimento de modelos de previsão de carga se caracterizam como um problema de extrema complexidade, porém indispensáveis no que diz respeito a eficiência e segurança operacional dos sistemas de energia elétrica. O objetivo central desses modelos é representar de modo eficiente a natureza estocástica do comportamento de consumo e as suas variáveis correlacionadas, de forma a obter estimativas de cargas robustas. Tais estimativas permitem fazer um melhor uso dos recursos disponíveis, subsidiando o planejamento e a operação do sistema elétrico (Phimphachanh et al., 2004).

Nos trabalhos encontrados na literatura técnica, encontram-se inúmeras pesquisas sobre modelos de previsão de carga em longo prazo, que utilizam além da própria demanda histórica, diferentes variáveis que influenciam no consumo. Em Kermanshahi (1998) é apresentado um mo-

delo de previsão de carga utilizando Rede Neural Recorrente (RNR), considerando como principais dados históricos o PIB (Produto Interno Bruto) e a quantidade de condicionadores de ar. Carmona et al. (2002) aplicaram o método de Redes Neurais Artificiais (RNAs), considerando no modelo apenas demanda histórica. Outro trabalho que considerou apenas a demanda foi do AlRashidi and El-Naggar (2010), que aplicou o método baseado em *Particle Swarm Optimization* (PSO). Em Phimphachanh et al. (2004) também é adotado RNAs, considerando variáveis como velocidade do vento, umidade máxima, dados econômicos e taxa de crescimento do consumidor, fatores climáticos, entre outros. Em Daneshi et al. (2008) é aplicado três metodologias: RNAs, Regressão Linear e Neuro-Fuzzy considerando as variáveis para o modelo: Temperaturas máximas e mínimas, índice de população, número de domicílios e GSP (do inglês, *Gross State Product*). Mais

recentemente, em Hong et al. (2014) propõe-se o uso de regressão linear múltipla, utilizando além da própria demanda histórica, as variáveis climáticas.

Não obstante as diversas pesquisas sobre o tema, nota-se que o desenvolvimento de modelos de previsão de carga, que levem em conta a resposta da demanda ao preço da energia elétrica, ainda, encontra-se em fase incipiente de pesquisa (Sperandio et al., 2014).

O advento das redes elétricas inteligentes (*Smart Grids*) traz novas oportunidades e desafios para os programas de Resposta à Demanda com Base em Tarifas (RDBT). O uso de microgeração e a disponibilização de preços da energia elétrica, em tempo real, possibilita aos consumidores modular o seu nível de consumo ou de geração, de acordo com as condições do mercado. Desse modo, as *Smart Grids* propiciam um ambiente favorável para que a demanda de energia elétrica possa reagir de forma mais efetiva ao preço, sinalizando uma profunda mudança no comportamento do consumo de energia elétrica.

Neste contexto, o presente trabalho apresenta o desenvolvimento de um sistema inteligente para previsão de carga em longo prazo, com enfoque nas tarifas de energia elétrica. O modelo proposto se baseia em uma RNA, utilizando a arquitetura *MLP*, com duas camadas ocultas e uma camada de saída. Os testes computacionais são realizados utilizando dados históricos do sistema de New England (ISO-NE). A metodologia proposta é avaliada em termo do erro médio quadrático (MSE), do erro percentual absoluto médio (MAPE) e da curva Elasticidade-preço.

Este trabalho está organizado como descrito a seguir. A Seção 2 discute a teoria acerca da Elasticidade-preço da Demanda de Energia Elétrica. A Seção 3 apresenta em detalhes a metodologia proposta. A Seção 4 mostra os resultados obtidos de acordo com os testes realizados. Na Seção 5, as conclusões obtidas são apresentadas.

2 Elasticidade-preço da demanda de energia elétrica

Os conceitos inovadores introduzidos pelas *Smart Grids* prospectam uma evolução nos sistemas de energia elétrica, trazendo consigo grandes desafios, em especial a necessidade de reformulação dos modelos de previsão de carga. Neste cenário, o comportamento da elasticidade-preço da demanda de energia elétrica tende a ser fortemente impactado. A elasticidade-preço da demanda (EPD), trata-se de um conceito econômico que apresenta a elasticidade da quantidade demandada de um bem, em relação às mudanças de seu preço (Esteves and Reggiani, 2014). Em termos matemáticos é a razão entre a mudança de demanda e a mudança percentual do preço, à me-

didada que se move ao longo da curva da demanda, expressa na equação(1).

$$PED = \left(\frac{Q_x - Q_v}{\frac{Q_x + Q_v}{2}} \right) / \left(\frac{P_x - P_v}{\frac{P_x + P_v}{2}} \right) \quad (1)$$

onde, Q_x : Quantidade Inicial; Q_v : Quantidade Final; P_x : Preço Inicial; P_v = Preço Final.

A quantidade demandada se refere à máxima demanda anual e o preço da mesma corresponde às tarifas de energia elétrica. Salienta-se que os determinantes do grau de elasticidade podem ser qualificados em quatro casos:

- Perfeitamente Elástica: A demanda muda infinitamente com uma alteração nos preços ($|PED| \cong \infty$).
- Elástica: A demanda muda muito em relação a uma alteração nos preços ($|PED| > 1$).
- Elástica unitária: A demanda muda na mesma proporção que os preços ($|PED| = 1$).
- Inelástica: A demanda muda pouco em relação a uma alteração nos preços ($|PED| < 1$).

Em geral, avaliar a elasticidade dos preços é uma tarefa complexa. Estudos mostram que a elasticidade se comporta diferente, de acordo com o período de tempo adotado (Thimmapuram et al., 2010). Geralmente análises de EPD à curto prazo, possuem comportamento inelástico, por outro lado, estudos a longo prazos são relativamente sensíveis ao preço.

A análise da EPD é de extrema importância para o mercado de energia elétrica. Na literatura técnica encontram-se, principalmente, estudos da EPD para curto e médio prazo (Mohajeryami et al., 2015; Motamedi et al., 2012). Neste trabalho, a partir do uso de inteligência artificial, pretende-se apresentar uma estimativa da evolução histórica da Elasticidade-Preço através de dados históricos.

3 Metodologia

O modelo de previsão de carga proposto baseia-se no utilização de RNAs. As mesmas têm sido aplicadas em diversos campos da tecnologia, como modelagem, reconhecimento de padrões e previsões. O amplo emprego, é proveniente de sua habilidade de aprender a partir de dados de entrada com ou sem professor (Haykin, 1994). Além disso, cita-se o alto poder de generalizar informações após uma fase de aprendizagem, possibilitando capturar relações funcionais entre os dados.

Em termos matemáticos é possível descrever seu modelo básico através das equações (2) e (3).

$$U_n = \sum_{i=0}^m w_i \times x_i \quad (2)$$

$$Y_n = \varphi(U_n + B_n) \quad (3)$$

onde, w_i representa os pesos sinápticos, x_i representa as variáveis de entrada, φ é a função de ativação e o b_n representa o bias.

De acordo com as equações apresentadas, os pesos são ajustados de acordo com os padrões aplicados na entrada. A saída resultante é calculada a partir da função de ativação. Função matemática que, aplica à combinação linear entre as variáveis de entrada e pesos, determinando a relação entre entradas e saídas de cada neurônio da rede.

Dentre as diversas arquiteturas das RNAs adotadas em previsões de longo prazo (Daneshi et al., 2008; Kermanshahi, 1998; Xu et al., 2014), optou-se por utilizar a arquitetura MLP.

A MLP pode ser aplicada para resolver diversos problemas (Haykin, 1994). É formada por um conjunto de nós, divididos em camadas de entrada (*input layer*), camadas escondidas (*hidden layer*) e camadas de saídas (*output layer*). Para especificação dos pesos sinápticos propõe-se o algoritmo de treinamento Levenberg-Marquardt (LM). Tal algoritmo é muito utilizado em trabalhos da literatura técnica (Xu et al., 2014). Possui maior convergência e eficiência, entretanto, utiliza significativamente a memória do computador.

A arquitetura do sistema composta pela MLP é apresentada na Figura 1.




Figura 1: RNA- multilayer perceptron (MLP).

Adotou-se aprendizagem supervisionada para a realização do treinamento. Através desta, é possível adquirir um grande poder computacional para a realização de previsões. Além disto, a arquitetura seguida possui característica *feed-forward*, ou seja, as saídas dos neurônios se conectam unicamente às entradas dos neurônios da camada seguinte, sem a necessidade de realimentação.

Salienta-se que para a determinação do número de camadas escondidas, adotou-se um esquema de tentativa e erro, através do aumento do número de camadas e neurônios, gradualmente, calculando seu respectivo erro (Kermanshahi, 1998). Como resultado, obteve-se uma RNA constituída de duas camadas escondidas com 21 e 12 neurônios, respectivamente.

3.1 Variáveis de Entrada

A metodologia de previsão da demanda à longo prazo, implica em avaliar os fatores que influenciam no consumo de energia elétrica anual. Neste trabalho, foram considerados os dados históricos de: máxima demanda anual; índice de população anual; temperaturas máximas e mínimas; produto bruto do estado (GSP); e em especial, tarifas de energia elétrica. Para as tarifas realizou-se a média do preço entre os três setores principais (residencial, comercial e industrial).

3.2 Normalização dos dados

Na estrutura das RNAs é necessário normalizar os dados a serem aplicados na entrada (Carmona et al., 2002). A normalização impede que uma dimensão se sobreponha em relação às outras e evita que o aprendizado seja estagnado.

Para o sistema proposto, a partir de testes realizados, aplicou-se a função de ativação tangente hiperbólica nas camadas escondidas e função linear na camada de saída.

O método de normalização, apresentada na equação (4), implica em transformar os dados numa mesma faixa de valores.

$$x = \left[\left(\frac{D_{original} - D_{minimum}}{D_{maxim} - D_{minimum}} \right) \times 2 \right] - 1 \quad (4)$$

Neste caso, adotou-se a faixa de -1:1, limite da função tangente hiperbólica aplicada na camada escondida.

4 Aplicação prática e resultados

Para avaliar os resultados e o desempenho do modelo de previsão proposta são utilizados os dados obtidos do sistema New England (ISO-NE) (*New England Operation (ISO-NE)*, n.d.). O histórico da demanda máxima (MW) no período de 1980 a 2014 é representado na Figura 2.




Figura 2: Histórico da demanda máxima anual

O desenvolvimento do modelo de previsão, bem como os testes foram realizados utilizando o software Matlab. As simulações foram feitas em um computador com processador Intel Core

i7 Haswell, memória RAM de 8 GB HyperX Impact DDR3 e com placa de vídeo NVIDIA GeForce GTX 950M GPU.

4.1 Treinamento

Para o treinamento da RNA utilizaram-se dados históricos do sistema New England (ISO-NE), referente ao ano 1980 a 2000. O erro do treino foi calculado através do erro quadrático médio (do inglês, *Mean Squared Error*(MSE)), expresso na equação (5).

$$MSE = \frac{1}{N} \sum_{j=1}^N (a_j - y_j)^2 \quad (5)$$

onde a_j significa o valor real, y_j o valor resultante, N é o número de período das previsões.

A partir de uma série de treinamentos, com 17 iterações obteve-se o MSE de 3,5%. A rede atingiu bom aprendizado, como demonstrado na Figura 3.




Figura 3: Resultado do treinamento da rede

4.2 Validação

A realização da simulação para validação do sistema de previsão, contou com a análise do erro percentual absoluto (APE) e erro percentual absoluto médio (MAPE) (Shahidehpour et al., 2002) obtido através da equação(6) e equação(7), respectivamente.

$$APE(\%) = \left(\frac{D_o - D_r}{D_o} \right) \times 100 \quad (6)$$

$$MAPE(\%) = \frac{1}{N} \sum_{j=1}^N APE(j) \quad (7)$$

onde, D_o significa o valor da demanda original, D_r o valor da demanda real e N o período analisado.

Para a validação, foi utilizado nos testes os dados históricos do período dos anos de 2001 a 2010. A Figura 4 apresenta os resultados obtidos do treinamento e posteriormente a validação. O sistema, como pode-se analisar, obteve bons resultados na validação. O MSE da validação resultou 2,76 %.




Figura 4: Previsão de demanda

Realizou-se a previsão para os anos de 2011 a 2014, com novos dados apresentados à estrutura. A tabela1 apresenta os valores em termos de demanda de potência.

Tabela 1: Previsão da Demanda (MW).

Ano	Demanda original	Demanda resultante	APE (%)
2011	27,707	27.246,50	1,66%
2012	25,880	24.866,17	3,90%
2013	27,379	27.236,50	0,52%
2014	24,443	23.702,97	3,02%

A partir da tabela I é possível verificar que o sistema proposto obteve resultados positivos, com um erro máximo de 3,9%. A partir do erro resultante é possível afirmar que o sistema possui tão bom desempenho quanto a maioria (Phimphachanh et al., 2004; Daneshi et al., 2008).

4.3 Análise comparativa

No trabalho de Daneshi et al. (2008), aplicaram-se três métodos para a previsão de longo prazo: Regressão Linear (RL), RNAs (baseado em Perceptron com treinamento *backpropagation*) e Modelo Híbrido (RNA+Fuzzy). Onde também, foi utilizado os dados da ISO-NE para validar seus modelos. O MAPE resultante para o sistema proposto é apresentado na tabela2, comparando os resultados obtidos neste trabalho.

Tabela 2: MAPE(%) comparisons for the years 2001:2002(Daneshi et al., 2008).

Ano	Metodologia proposta	RL	RNAs	Modelo híbrido
2001	1,07	24,78	4,59	4,91
2002	3,61	37,05	11,89	6,39

Ressalta-se que o período do MAPE é $N=1$, pois utilizou-se apenas variáveis anuais, enquanto no modelo comparado foi considerado demandas mensais, ou seja, $N = 12$. Pode-se observar que na metodologia proposta, as previsões são mais acuradas no sistema proposto, em relação aos obtidos em Daneshi et al. (2008). Acredita-se que a

proposta de previsão à longo prazo utilizando dados históricos anuais, possui maior precisão, que à metodologia utilizando dados mensais.

4.4 Estimativa do comportamento histórico da elasticidade-preço do sistema New England (ISO-NE)

A partir do desenvolvimento da RNA, apresentam-se neste item estimativas do comportamento histórico da EPD do sistema New England. Tais estimativas foram realizadas simulando variações na faixa de $\pm 15\%$ do valor da tarifa média anual, onde avaliou-se os impactos no comportamento da demanda, para os anos de 1980, 2000 e 2014. Os dados são apresentados em p.u., utilizando-se como valores de base, a tarifa média anual (fornecidos pelo próprio banco de dados da ISO-NE) e as demandas máximas dos respectivos anos, conforme Tabela 3.

Tabela 3: Valores de b		
Ano	Demanda base (MW)	Tarifa base (Cents/kWh)
1980	15.505,00	18,236
2000	22.005,00	13,465
2014	24.444,30	15,405

Na Figura 5, apresentam-se os resultados obtidos, onde é possível observar que a curva tende a torna-se elástica para o ano de 2014.




Figura 5: Elasticidade preço da demanda.

Os resultados da Figura 5 demonstram e confirmam, que o perfil de consumo vem se modificando nos últimos anos. Atribui-se a este comportamento diversos fatores, dentre os quais destacam-se: os avanços nas áreas de telecomunicações; novas tecnologias de medições e supervisão; aperfeiçoamento da regulação do setor elétrico; desenvolvimento de novos mecanismos de formação de preços energia elétrica; incentivo à inserção, à microgeração e à minigeração.

As Figuras 6 e 7 apresentam os resultados para o ano de 1980 e 2014, demonstrando a evolução da EPD. Através destes gráficos, é possível analisar que a EPD tende a aumentar, ou seja, tornar-se mais elástica com a diminuição da tarifa e aumento da demanda.




Figura 6: Elasticidade-preço do ano: 1980.




Figura 7: Elasticidade-preço do ano: 2014.

Observa-se que para o ano de 1980 a EPD máxima resultou em 2,55. Entretanto para o ano de 2014 a EPD máxima resultou em 10,5, possibilitando afirmar que a tarifa tem forte relação com a demanda no ano de 2014. Os gráficos demonstram a diferença da relação do preço de energia com a demanda hoje e há 34 anos atrás.

Além das simulações apresentadas, realizaram-se testes de comportamento da demanda, para um aumento percentual de 25% em relação à tarifa original. A simulação foi realizada no período de 1994 a 2010, Figura 8.




Figura 8: Elasticidade-preço do ano: 2014.

Nota-se que na faixa de 1994 a 1999, a variação do preço de energia elétrica não apresenta relação com a demanda. No entanto, a partir do ano 2000, à medida que a tarifa aumenta anualmente, a demanda começa a decrescer em relação aos valores originais. A análise demonstra o forte impacto do preço em relação à demanda, para os

últimos anos.

5 Conclusões

Este trabalho apresentou um modelo de previsão de carga à longo prazo, com ênfase a elasticidade-preço da energia elétrica. A metodologia proposto contemplou o desenvolvimento de uma RNA, utilizando MLP, considerando como dados de entrada do modelo: Demanda, índice de população, tarifas, temperaturas máximas e mínimas e produto bruto do estado (GSP). Para validação do modelo foram utilizados dados do sistema New England (ISO-NE). Os resultados obtidos demonstram o bom desempenho da metodologia, com erros de previsão inferiores a 3,9%. Em relação à elasticidade-preço, constatou-se que do ano de 1980 a 2014 houve uma variação da $|EPD|$ de 0,0654 a 0,7014. Estes resultados demonstram que o comportamento do consumo vem se modificando de modo expressivo nas últimas décadas. Tal comportamento sinaliza uma forte tendência da elasticidade-preço da energia elétrica se tornar elástica, sobretudo à medida que os conceitos das redes elétricas inteligentes se disseminarem e tornarem-se realidade.

Agradecimentos

Os autores agradecem ao apoio financeiro recebido do Departamento Municipal de Energia de Ijuí (DEMEI), no âmbito do projeto Desenvolvimento de Sistemas de Automação e Controle para Sistemas Elétricos.

Referências

- AlRashidi, M. and El-Naggar, K. (2010). Long term electric load forecasting based on particle swarm optimization, *Applied Energy* **87**(1): 320–326.
- Carmona, D., Jaramillo, M. A., González, E. and Alvarez, J. A. (2002). Electric energy demand forecasting with neural networks, *IECON 02 [Industrial Electronics Society, IEEE 2002 28th Annual Conference of the]*, Vol. 3, IEEE, pp. 1860–1865.
- Daneshi, H., Shahidehpour, M. and Choobbari, A. L. (2008). Long-term load forecasting in electricity market, *2008 IEEE International Conference on Electro/Information Technology*, pp. 395–400.
- Esteves, R.-B. and Reggiani, C. (2014). Elasticity of demand and behaviour-based price discrimination, *International Journal of Industrial Organization* **32**: 46–56.
- Haykin, S. (1994). Neural networks: A comprehensive foundation: Macmillan college publishing company, *New York*.
- Hong, T., Wilson, J. and Xie, J. (2014). Long term probabilistic load forecasting and normalization with hourly information, *IEEE Transactions on Smart Grid* **5**(1): 456–462.
- Kermanshahi, B. (1998). Recurrent neural network for forecasting next 10 years loads of nine japanese utilities, *Neurocomputing* **23**(1): 125–133.
- Mohajeryami, S., Schwarz, P. and Baboli, P. T. (2015). Including the behavioral aspects of customers in demand response model: Real time pricing versus peak time rebate, *North American Power Symposium (NAPS), 2015*, IEEE, pp. 1–6.
- Motamedi, A., Zareipour, H. and Rosehart, W. D. (2012). Electricity price and demand forecasting in smart grids, *IEEE Transactions on Smart Grid* **3**(2): 664–674.
- New England Operation (ISO-NE)* (n.d.). <http://www.iso-ne.com/>. Accessed: 2016-04-30.
- Phimpachanh, S., Chammongthai, K., Kumhom, P. and Sangswang, A. (2004). Using neural network for long term peak load forecasting in vientiane municipality, *TENCON 2004. 2004 IEEE Region 10 Conference*, Vol. 100, IEEE, pp. 319–322.
- Shahidehpour, M., Yamin, H. and Li, Z. (2002). *Market Operations in Electric Power Systems: Forecasting, Scheduling, and Risk Management*, 1 edn, John Wiley Sons, Inc., New York.
- Sperandio, M., Bernardon, D., Bordin, G., Oliveira, M. and Bordignon, S. (2014). Probabilistic demand forecasting to minimize overtaking the transmission contract, *Electric Power Systems Research* **112**: 27–36.
- Thimmapuram, P. R., Kim, J., Botterud, A. and Nam, Y. (2010). Modeling and simulation of price elasticity of demand using an agent-based model, *Innovative Smart Grid Technologies (ISGT), 2010*, IEEE, pp. 1–8.
- Xu, Y., Cai, J. and Milanović, J. V. (2014). On accuracy of demand forecasting and its extension to demand composition forecasting using artificial intelligence based methods, *IEEE PES Innovative Smart Grid Technologies, Europe*, pp. 1–6.