

UM MÉTODO DE PREVISÃO DE PREÇO DA CARGA, UTILIZANDO REDES NEURAI DE REGRESSÃO GENERALIZADA E PERCEPTRON MULTICAMADAS.

PATRÍCIA F. DA S. FREITAS¹, ANNA D. P. LOTUFO¹, NATÁLIA ALGUACIL², MARIA DO C. G. DA SILVEIRA¹.

1. *Laboratório de Sistemas Inteligentes, Departamento de Engenharia Elétrica, Universidade Estadual Paulista - UNESP, 13385-000 Ilha Solteira, SP, Brasil*

E-mails: patriciapbat@gmail.com, annadiva@dee.feis.unesp.br, carmo@adm.feis.unesp.br

2. *E.T.S. de Ingenieros Industriales, Universidad de Castilla – La Mancha, Campus Universitario s/n, 13071 Ciudad Real, Spain*

E-mail: Natalia.Alguacil@uclm.es

Abstract— Electric energy becomes a commodity that can be bought and sold after the reorganization of the electric companies. This new behavior generates the developing of new algorithms and tools to predict load and prices. Neural networks have been used for price forecasting, besides other statistical methods and some hybrids. This work presents a method for price forecasting using Perceptron multilayer neural network (MLP) and Generalized Regression neural network (GRNN) where the prices LMP (Locational Marginal Prices) are calculated by a DC-OPF (optimal power flow) randomly varying the loads to obtain several scenarios load-price to train the neural networks. Results are evaluated by analyzing the MAPE (mean absolute perceptual error) which are in accordance with those found in the literature. IEEE 24 RTS is the electrical system used.

Keywords— Multilayer Perceptron Neural Network, Generalized Regression Neural Network, Load Price Forecasting.

Resumo— A energia elétrica passou a ser uma mercadoria a ser comprada e vendida após a reestruturação do setor elétrico. A desregulamentação gerou o interesse no desenvolvimento de novos algoritmos e ferramentas para previsão de carga e preço. Redes neurais vêm sendo utilizadas consideravelmente para previsão de preço, além de métodos estatísticos e alguns híbridos. Este trabalho apresenta um método de previsão de preço utilizando redes neurais Perceptron multicamadas (MLP) e de Regressão Generalizada (GRNN), em que os preços LMP (Locational Marginal Prices), são calculados através de um DC-OPF (Optimal Power Flow), variando aleatoriamente a carga para gerar diversos cenários carga-preço para o treinamento das redes neurais. A avaliação dos resultados é feita através dos MAPES (erro percentual médio absoluto) cujos resultados estão de acordo com os encontrados na literatura. O sistema elétrico utilizado é o IEEE 24 RTS.

Palavras-chave— Rede neural Perceptron Multicamadas, Rede Neural de Regressão Generalizada, Previsão de Preço da carga

1 Introdução

No mercado elétrico a estrutura de preço possui uma oscilação caracterizada pelas altas frequências, variância não constante, sazonalidades, volatilidade, época do ano e percentual do preço, sendo atribuído ao não armazenamento energético natural, equilíbrio entre demanda e oferta e entre outros fatores (Schweppe et. al 1988). Desta forma é importante a previsão de preço para o planejamento e operação do sistema elétrico (Aggarwal et. al 2009).

O mercado elétrico desregulamentado pode ser classificado em oferta competitiva (pool) e contrato bilateral. A oferta competitiva é realizada nos mercados de energia elétrica a vista, através da realização de leilões, onde os compradores e vendedores apresentam suas propostas. No mercado bilateral o comprador e vendedor limitam os preços contra a volatilidade diária. Desta forma tornou-se fundamental a previsão de preço, dentre os quais o LMP (Locational Marginal Price) que está associado também às restrições físicas de segurança da rede elétrica (Gómez-Expósito et. al. 2009).

O LMP é um dos mais populares modos para a avaliação de preços de eletricidade no mercado competitivo, demonstrando o valor da eletricidade em cada barra e podendo ser diferente em diversas barras do sistema. Os LMP são associados às restrições de igualdade do fluxo de potência, são preços nodais calculadas como multiplicadores de Lagrange de um OPF (Optimal Power Flow) (Lotufo, 2012).

Redes neurais artificiais vêm sendo utilizadas consideravelmente para obtenção de previsões de preço, caracterizado pelo fato de dispensar um modelo matemático ao tratar as não linearidades (Lotufo, 2012). A utilização de método híbrido tal como o clássico ARIMA de Box e Jenkins (Box et. al., 2004) associado a redes neurais vem se destacando neste cenário. Diversos outros métodos estatísticos e de redes neurais estão sendo usados para esta finalidade destacando-se entre outras redes neurais as MLP (multi layer perceptron) com treinamento por back-propagation utilizando as vantagens de um e de outro (Lotufo, 2012).

Este artigo apresenta uma série temporal simulada através de um DC-OPF, onde será aplicada em duas redes neurais artificiais: Perceptron multi-

camadas (MLP) com o algoritmo de treinamento Levenberg Marquardt (Haykin, 1999) e rede neural de Regressão Generalizada (GRNN), através das toolboxes do MATLAB (Nose Filho 2011, Specht et. al. 1991), em que estes modelos mapeiam a relação entre a entrada e saída. Uma característica destacada pelas redes neurais artificiais é aprender as relações não lineares e complexas, quando for difícil efetuar a modelagem em métodos convencionais.

No presente artigo o sistema elétrico utilizado é o IEEE-RTS 24 barras. A carga é variada aleatoriamente para gerar diferentes cenários carga-preço durante a execução do DC-OPF, e o caso base é considerado o resultado original sem esta variação.

O critério de avaliação consiste no desempenho das redes neurais utilizadas neste artigo através dos MAPES (erro Percentual Absoluto Médio), comparando com o caso base obtido através da execução do DC-OPF e com artigos da literatura especializada.

2 Redes Neurais de Regressão Generalizada e Rede Neural Perceptron Multicamadas

2.1 Rede Neural de Regressão Generalizada - GRNN

A GRNN realiza a estimação de uma variável chamada dependente partindo de uma variável independente considerando um conjunto de variáveis finito. O seu treinamento é supervisionado, ou seja, possui uma saída desejada com estrutura do tipo não recorrente, constituída por uma estrutura fixa com uma camada de entrada, duas intermediárias e uma de saída. A quantidade de neurônios de cada camada é dependente da quantidade de padrões de treinamento (F. Heimes et. al 1998, Niu et. al. 2005).

A regressão generalizada caracteriza-se por uma variável dependente y e uma variável independente x , através de um conjunto de variáveis finito X e Y . O sistema identifica que a variável dependente y será a saída e a variável independente x será a entrada (Nose Filho 2011, Specht 1991), demonstrada na figura 1.

Declarando os conjuntos finitos de X variável independente e Y variável dependente. A variável \hat{x} denomina a entrada desconhecida e \hat{y} a estimativa pela regressão de \hat{x} , através das variáveis no conjunto X e Y (Nose Filho 2011, Specht et. al. 1991), é calculada por:

$$E(Y | \hat{x}) = \frac{\int_{-\infty}^{+\infty} y f(\hat{x}Y) dy}{\int_{-\infty}^{+\infty} f(\hat{x}, Y) dy} \quad (1)$$

em que $f(\hat{x}, Y)$ é a função de densidade de probabilidade que corresponde a estimação de Kernel ou janela de Parzen. As aferições da variável \hat{y} são

obtidas através de uma variável desconhecida (Specht et. al. 1991), representada por:

$$\hat{y}(\hat{x}) = \frac{\sum_{i=1}^n y_i \exp\left(\frac{-a_i^2}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(\frac{-a_i^2}{2\sigma^2}\right)} \quad (2)$$

O numero de amostras dos conjuntos X e Y é n , y_i representa a variável independente e é associada com x_i variável independente e a_i representa o valor da i -ésima distancia euclidiana de \hat{x} variável desconhecida, juntamente com a variável x_i (Specht et. al. 1991), de acordo com:

$$a_i = (\hat{x} - x_i)^T (\hat{x} - x_i) \quad (3)$$

A GRNN consiste em uma função de transferência do tipo Gaussiana determinada por:

$$f(a_i) = \exp\left(\frac{-a_i^2}{2\sigma^2}\right) \quad (4)$$

A variável (σ) representa o *spread*, função que define a abertura da função. A toolbox de redes neurais do MATLAB considera a função Gaussiana (*radbas*), (Nose Filho, 2011), que é representada por:

$$f(a_i) = \exp\left(\frac{-0.8326^2 a_i^2}{\sigma^2}\right) \quad (5)$$

2.1.1 Arquitetura

A arquitetura da GRNN se caracteriza por quatro camadas, uma camada de entrada, duas camadas intermediárias e uma camada de saída, representada na figura 1.

Cada camada de entrada possui uma determinada quantidade de neurônios, esta quantidade de neurônio esta associada diretamente ao número de entradas, saídas e aos dados de treinamento. A entrada da rede é determinada por X (vetor coluna) com p dimensão, e a saída é determinada por Y (Vetor coluna) com s dimensão.




Figura 1. Arquitetura GRNN

2.2 Perceptron Multicamadas - MLP

A rede neural Perceptron Multicamada vem sendo muito utilizada para a previsão de preço juntamente com o algoritmo de treinamento Levenberg Marquardt. O algoritmo de treinamento utiliza a técnica iterativa localizando o mínimo global de funções não lineares e no caso do treinamento por Levenberg Marquardt este é baseado no algoritmo de Newton. (Haykin et.al. 1999).

A rede neural Perceptron multicamadas se caracteriza por ter mais de uma camada escondida. A primeira camada efetua a ligação dos dados de entrada com a primeira camada escondida posteriormente interligada com as demais camadas escondidas. A camada de saída apresenta o resultado esperado (Haykin et.al 1999). A estrutura da MLP é apresentada na figura 2.

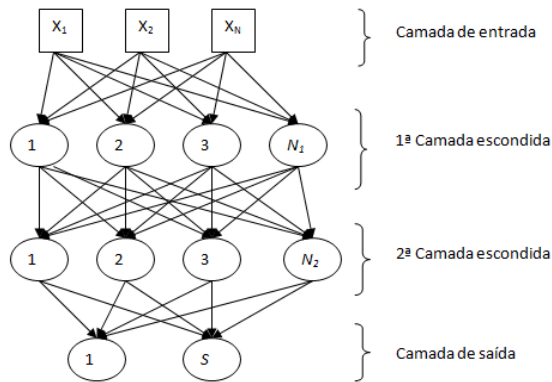


Figura 2. Arquitetura MLP

A rede neural perceptron é composta por no mínimo duas camadas intermediárias, com n dimensão. As entradas $\{X_1, X_2, \dots, X_n\}$, são as amostras do conjunto de treinamento, ou seja, são as entradas para a rede neural, em seguida são propagadas camada por camada até a camada de saída, para obter as respectivas saídas. A camada de saída tem dimensão s . As saídas produzidas pela rede neural são comparadas com a saída desejada. Para realizar a comparação da saída da rede neural e a saída desejada é efetuado o cálculo de desvio (erro), os quais são utilizados para ajustar os pesos e limiares dos neurônios da rede neural (Haykin, 1999).

3 Metodologia

O método consiste primeiramente em executar um DC- OPF uma simplificação de um OPF convencional, onde as restrições são de forma linear e de função custo quadrática, de acordo com as seguintes equações:

$$\begin{aligned} & \min \sum_i^n C_i(P_{G_i}) \\ & \text{s.a.} \\ & P_G^{\min} \leq P_G \leq P_G^{\max} \\ & P_G - P_D = P(\delta) \\ & |P_F(\delta)| \leq P_F^{\max} \end{aligned} \quad (7)$$

Em que P_G é a potência gerada, P_D a demanda, $C(P_G)$ o custo da produção, P_F fluxos nas linhas e δ ângulo de tensão.

Os LMPs são definidos após serem satisfeitas as condições de otimização de primeira ordem que são os multiplicadores de Lagrange associados ao fluxo, demonstrada por:

$$\lambda_i = \frac{\partial C}{\partial P_{D_i}} \quad (8)$$

Ou também descrito como a máxima variação do ganho social representado por SW relacionado a demanda, representada por:

$$\lambda_i = \frac{\partial SW}{\partial P_{D_i}} \quad (9)$$

Os LMPs são a forma mais popular de determinar os preços nos mercados elétricos, sendo estes, portanto frequentemente utilizados.

O sistema elétrico utilizado é o IEEE 24 RTS contendo 24 barras (Reliability Test System Task Force, IEEE 1999).

O DC-OPF foi executado no software MATPOWER algoritmo SMARTMARKET (Zimmerman, 2011). As restrições físicas da rede elétrica estão contempladas no cálculo do OPF, considerando um leilão de um único período. As cargas ativas foram perturbadas aleatoriamente, em cada perturbação foi executado um OPF para formar o cenário carga-preço e, posteriormente utilizados para o treinamento nas redes neurais, considerando então o padrão de entrada as cargas ativas e o padrão de saída o LMP.

Foram simuladas 200 amostras diferentes de cargas variadas aleatoriamente para obter os preços, que serão apresentadas as redes neurais para efetuar o treinamento. Serão utilizados para o treinamento 70% das amostras, para efetuar o teste 30% das amostras e uma amostra diferente para fazer o diagnóstico.

Os dados foram normalizados utilizando a divisão do valor máximo, para que fiquem entre 0 e 1, conforme a exigência das redes neurais.

A configuração utilizada na rede neural perceptron multicamada foi: uma camada de entrada, duas camadas intermediárias e uma camada de saída e o algoritmo de treinamento Levenberg-Marquardt com função de ativação tangente hiperbólica. Foi também utilizada a GRNN (Rede neural de regressão generalizada) via *toolbox* no MATLAB.

A figura 3 abaixo apresenta um resumo do procedimento proposto, em que $P = [P_1, P_2, P_3, \dots]$

P24] são as entradas da rede, representando as cargas e o LMP = [LMP1, LMP2, LMP3... LMP24] representando as saídas dos LMPs.




Figura 3. Projecção do sistema elétrico IEEE 24 RTS

Os testes nas redes são realizados separadamente, ou seja, uma rede neural por vez, após a realização da previsão em ambas as redes neurais são realizadas as comparações de suas respectivas saídas.

Foi realizada também a previsão de preço global, em ambas as redes, utilizando como entrada todo sistema elétrico com suas respectivas saídas (preços-LMP).

A figura 4 apresenta o desenvolvimento da previsão pela rede neural GRNN.

Ao realizar o mesmo procedimento com a rede neural Perceptron Multicamadas com treinamento por Levenberg-Marquardt, os resultados não foram promissores, uma vez que nas barras em que a carga é zero (barras de geração), mas com preços, ela não consegue convergir fornecendo um preço zero também, não condizendo com a realidade.

Para sanar este problema foi realizado um novo teste introduzindo mais informações na entrada da rede neural MLP e desta forma foi possível obter resultados. A figura 5 apresenta o procedimento adotado para a realização da previsão adicionando nas entradas a barra e o tipo de barra.

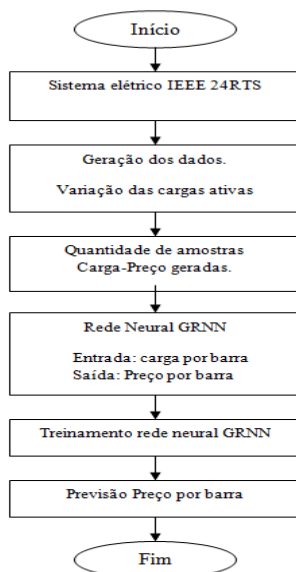


Figura 4. Etapas para a realização das previsões GRNN




Figura 5- Projecção do sistema elétrico IEEE 24 RTS com a rede MLP

Em que a matriz de entrada $P = [P1, P2, \dots, P24]$ é apresentada a rede neural e foi adicionado o tipo ao qual pertence a barra, representado por G_x . Após a definição das entradas foram realizados os testes, posteriormente foi possível obter a previsão em todas as barras do sistema elétrico. Portanto, desta forma obtiveram-se os resultados esperados de preço por barra e com erros percentuais de acordo com os encontrados na literatura.

A figura 6 representa as etapas para a realização da previsão de preço do dia seguinte, utilizando as redes neurais MLP.

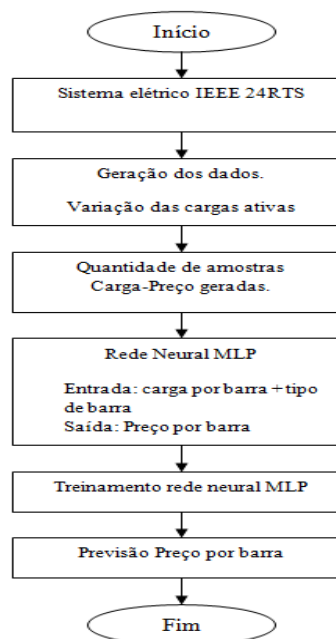


Figura 6 – Etapas para a realização das previsões MLP

Os critérios de avaliação serão através do caso base obtidos através do DC-OPF sem variação da carga e comparando com a literatura especializada principalmente com o trabalho de Pandey et. al. 2008, e através do MAPE (erro percentual absoluto médio) apresentado na equação 10.

$$MAPE = \frac{1}{N_a} \sum_{n=1}^{N_a} \frac{100 \cdot |C^R(n) - C^P(n)|}{C^R(n)} \quad (10)$$

Em que

C^R é o valor do preço real, C^P valor do preço previsto e N_a o numero de amostras previstas.

3 Resultados

Neste artigo realizou-se a previsão de preço da carga do dia seguinte, utilizando os dados gerados no software MATPOWER (Zimmerman, 2011) através de um DC-OPF. Os testes foram realizados através dos treinamentos das redes neurais, visando comparar as respectivas saídas LMP e MAPES (Erro Percentual Absoluto Médio).

Para a realização da previsão de preço do dia seguinte foi apresentada as redes neurais duas matrizes contendo 24 vetores cada, uma matriz de carga apresentada na entrada das redes e uma matriz de preço apresentado na saída. Posteriormente estes dados são apresentados as redes neurais GRNN e MLP, desenvolvidas no MATLAB via *toolbox*.

3.1 Aplicação 1 - GRNN

Na primeira aplicação realizou-se a previsão de preço com a rede neural GRNN comparando com o caso base, conforme a figura 7.




Figura 7 – Previsão de preço rede GRNN

Na figura 8 são apresentados os MAPES extraídos da rede neural GRNN.




Figura 8 – MAPE rede neural de regressão generaliza

Ao analisar o gráfico na figura 8 foi constatado que os MAPES obtidos através da rede GRNN estão de acordo com os encontrados pelos trabalhos realizados por Pandey et. al., 2008, entre outros.

3.2 Aplicação 2 - MLP

Na segunda aplicação foi utilizada para realizar a previsão de preço a rede neural MLP e comparado com o caso base, conforme figura 9.




Figura 9 – Previsão de preço rede MLP

Os MAPES de cada barra do sistema elétrico estão apresentados na figura 10.




Figura 10 – MAPE rede neural perceptron multicamadas

3.2 Aplicação 3 - Previsão global GRNN e MLP

Foi realizada a previsão global de preço do dia seguinte, envolvendo as 24 barras do sistema elétrico, utilizando a rede neural de regressão generaliza – GRNN.

Tabela 1. Previsão global GRNN

GRNN	LMP	MAPE%	E _{max} %	spread
13,461	13,866	0,0101	2,9142	0,0005

Foi realizado o mesmo procedimento para a rede neural perceptron multicamadas – MLP.

Tabela 2. Previsão global MLP

MLP	LMP	MAPE%	E _{max} %	Interações
13,539	13,866	0,0082	2,3524	42

3.3. Comparação das previsões das redes GRNN e MLP.

Através dos resultados apresentados nas aplicações 1 e 2 é possível fazer uma análise geral das saídas das previsões obtidas através das redes neurais GRNN e MLP, conforme a figura 11.




Figura 11 – Previsão de preço das redes GRNN e MLP

Através da análise da figura 12, observa-se as previsões com as duas redes neurais e o caso base. Em algumas barras é possível observar que a rede GRNN obteve uma previsão de preço mais próxima do caso base (\$ / MWh), porém ambas as redes forneceram previsões satisfatórias quando comparadas com resultados semelhantes encontrados na literatura.

5 Conclusão

Neste artigo foi proposta a utilização das redes neurais GRNN e Perceptron multicamadas para a previsão de preço (LMP), utilizando o toolbox do MATLAB.

As redes neurais vêm se tornando pioneiras em solucionar problemas de previsão de preço em sistemas elétricos de potência, sendo muito eficientes para tal solução, em virtude da capacidade de generalização e aprendizagem.

O sistema elétrico apresentado neste artigo é o IEEE 24 RTS composto por 24 barras. Analisando os resultados obtidos através das simulações nas redes neurais GRNN e MLP observa-se que as barras sem carga (no total de sete barras) interferem na qualidade do treinamento das respectivas redes neurais.

Analisando este contexto através dos resultados obtidos em ambas as redes, cada rede obteve um comportamento diferente nas barras sem carga do sistema elétrico. A rede GRNN consegue fornecer uma saída (preço) em cada barra sem carga devido às suas características de aprendizagem. No caso da rede MLP, esta não consegue fornecer uma saída desejada, retornando um resultado igual à zero nas barras sem carga (geração). Para solucionar este problema foi necessário inserir mais informações na entrada da rede neural MLP, que foi o tipo de barra do sistema elétrico. Desta forma foi possível realizar a previsão de preço da carga do dia seguinte em todas as barras do sistema elétrico em ambas as redes e com resultados satisfatórios.

Portanto o método adotado e apresentado neste artigo demonstrou ser adequado em problemas de previsão de preço – LMP, desta forma tornando-se importante em tomadas de decisões em organizações do setor elétrico.

Agradecimentos

Agradeço Juliana Fonseca Antunes, Mauro de Souza Tonelli Neto, Kenji Nose Filho, e a CAPES pelo apoio financeiro.

Referências Bibliográficas

Aggarwal, S. K.; Saini, L. M. and Kumar, A. (2009). "Electricity price forecasting in deregulated markets: A review and evaluation", *Electrical Power and Energy Systems*, Vol. 31, pp. 13–22.

Box, G.E.P., Jenkins G.M. and Reinsel, G.C. (2004). *"Time series analysis: forecasting and control"*. Pearson Education.

Heimes, F. and Heuvel, B. V. (1998). "The Normalized Radial Basis Function Neural Network," *IEEE International Conference on Systems, Man, and Cybernetics*, Vol.2, pp. 1609-1614.

Gómez-Expósito, A; Conejo, A.J and Canizares, C. (2009). *"Electric Energy Systems: Analysis and Operation"*, CRC Press, USA.

Haykin, S. (1999). *"Neural Networks: A Comprehensive Foundation"*, Prentice-Hall, Upper Saddle River, New Jersey, USA.

Lotufo, A.D.P. (2012). *"Mercados Elétricos e Redes Neurais"*, Relatório Final de estágio de Pós-doutorado, Processo CAPES BEX 5665/11-6.

Niu, D. X.; Wang, H. Q. and Gu, Z. H. (2005). "Short-term load forecasting using general regression neural network". In: *Proceedings of International Conference on Machine Learning and Cybernetics*, Vol. 7, pp. 4076- 4082.

Nose Filho, K. (2011). *"Previsão de carga multino-dal utilizando redes neurais de regressão generalizadas"*, Dissertação de mestrado, UNESP, Campus de Ilha Solteira.

Pandey, S.N.; Tapaswi, S. and Srivastava, L. (2008). "Location Marginal Price Projection using a Novel RBFNN Approach in Spot Power Market", in *Joint International Conference on Power System Technology and IEEE Power India Conference, Powercon 2008*.

Reliability Test System Task Force, (1999). *The IEEE Reliability Test System 1996*, *IEEE Transactions on Power Systems*, Vol.14, No.3, pp. 1010-1020.

Schweppe, F.C.; Caraminis M.C.; Tablors R.D. and Bohn, R.E. (1988). *"Spot pricing of electricity"*. Kluwer Academic Publishers.

Specht, D. F. (1991). "A generalized regression neural network". *IEEE Transactions on Neural Networks*, Vol. 2, pp. 568-576.

Zimmerman, R.D. and Murillo-Sanchez, C.E. (2011). *"MATPOWER 4.1 user's manual"*, <http://www.pserc.cornell.edu/matpower>