UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de Ilha Solteira

Programa de Pós-Graduação em Engenharia Elétrica

PATRÍCIA FERNANDA DA SILVA FREITAS

Previsão de Preços (LMP) por redes GRNN

Ilha Solteira
2013

PATRÍCIA FERNANDA DA SILVA FREITAS

Previsão de Preço (LMP) por Redes GRNN

Dissertação apresentada à Faculdade de Engenharia do Campus de Ilha Solteira - UNESP, como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica. Área de conhecimento: Automação.

Profª.Drª. Anna Diva Plasencia Lotufo
Orientadora.
Profª. Drª. Maria do C. G. da Silveira
Coorientadora

Ilha Solteira
2013

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

F866p

Freitas, Patrícia Fernanda da Silva.
Previsão de preços (LMP) por redes GRNN / Patrícia Fernanda da Silva Freitas. -- Ilha Solteira: [s.n.], 2013
78 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2013

Orientador: Anna Diva Plasencia Lotufo
Co-orientador: Maria do C. G. da Silveira
Inclui bibliografia

1. Rede neural perceptron multicamadas. 2. Rede neural de regressão generalizada. 3. Previsão de preço - Locational Marginal Prices – LMP.

unesp **UNIVERSIDADE ESTADUAL PAULISTA**

CAMPUS DE ILHA SOLTEIRA

FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

CERTIFICADO DE APROVAÇÃO

TÍTULO: Previsão de preços (LMP) por redes GRNN

AUTORA: PATRÍCIA FERNANDA DA SILVA FREITAS

ORIENTADORA: Profa. Dra. ANNA DIVA PLASENCIA LOTUFO

CO-ORIENTADORA: Profa. Dra. MARIA DO CARMO G DA SILVEIRA

Aprovada como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica , Área: AUTOMAÇÃO, pela Comissão Examinadora:

Profa. Dra. ANNA DIVA PLASENCIA LOTUFO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

Profa. Dra. LILIAN YULI ISODA
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira

Profa. Dra. MARIA DE FÁTIMA RIBEIRO RAIA
Departamento de Eletrotécnica / Universidade Tecnológica Federal do Paraná

Data da realização: 02 de setembro de 2013.

Dedico

A minha família em especial minha mãe Nélia, minha avó Aparecida e a Profª. Valdioni por me educarem e que me possibilitaram mais essa conquista, apoiando-me em toda minha jornada acadêmica e também a meus irmãos Paulo e Marcelo.

“O tempo é algo que não volta atrás.
Por isso, plante seu jardim e decore sua alma,
Ao invés de esperar que alguém lhe traga flores. "
William Shakespeare

Agradecimentos

Agradeço primeiramente a Deus, por me conceder a oportunidade pela realização deste trabalho.

À minha família, minha mãe Nélia, minha avó Aparecida e meus irmãos Marcelo e Paulo, por estarem presentes em todas as minhas conquistas.

À Profª Esp. Valdioni Godoi, por ter me acompanhado em toda minha jornada acadêmica, pelo apoio financeiro e estar sempre ao meu lado em todos os momentos, acompanhando cada vitória desde as pequenas até as grandes, pela cumplicidade, pelo exemplo e garra, amizade, companheirismo, enfim uma grande mulher admirável. Eternamente grata.

Agradeço especialmente minha orientadora Profª. Drª. Anna Diva, por ter me concedido a oportunidade da realização deste projeto, pela confiança depositada e pelo acompanhamento de toda trajetória da pesquisa. Agradeço também à Profª. Drª. Maria do Carmo pela co-orientação.

A Profª. Drª. Natália Alguacil pela colaboração e sugestões das quais foram extremamente importantes para finalização do projeto de pesquisa.

Aos meus amigos, que tiveram uma grande importância na minha trajetória, pela colaboração, cumplicidade e amizade, tais como: Naryanne, Elaine, Mauro, Lucas Teles, Juliana Fonseca, Kenji, Marlon, Fernando. As companheiras de república e em especial ao Rodrigo Souza e Ana Claudia.

Agradeço o apoio financeiro concedido pela CAPES.

Meus sinceros agradecimentos.

RESUMO

Após a reestruturação da indústria de eletricidade, a energia elétrica tornou-se uma mercadoria que pode ser comprada e vendida nos mercados de eletricidade.

Dentro deste contexto, novas ferramentas para previsão de cargas e preços de eletricidade ainda são objetos de estudo. Redes Neurais Artificiais são bastante usadas para previsão de preços juntamente com outras técnicas estatísticas. Nesta pesquisa apresenta-se um método para a previsão de preço do dia seguinte, usando uma Rede Neural de Regressão Generalizada (GRNN) e Perceptron Multicamadas (MLP) com algoritmo de treinamento Levenberg – Marquardt. Os preços nodais são determinados resolvendo um DC-OPF (fluxo de potência ótimo), gerando os preços para todas as barras do sistema elétrico, denominado *Locational Marginal Prices* (LMP). Para treinar a rede neural, foram gerados vários cenários carga-preço e variando aleatoriamente a carga em cada barra do sistema elétrico. Os resultados são analisados através do erro percentual médio absoluto, uma medida muito comum encontrada na literatura. Os resultados foram comparados com literatura especializada com o caso base bem como com o Erro Máximo que varia de 3% a 8 %. Os resultados obtidos foram satisfatórios, dentro das margens encontradas na literatura, conforme apresentado na seção de resultados. A presente proposta foi aplicada no sistema teste IEEE 24- RTS.

Palavras-chave: Rede neural perceptron Multicamadas.Rede neural de regressão generalizada,Previsão de preço.*Locational Marginal Prices* – LMP.

ABSTRACT

After the electricity industry restructuring, electric energy has become a commodity that can be bought or sold in electricity markets. Within this context, new tools to predict loads and electricity prices are yet to be devised. Neural networks have been typically used for price forecasting, among other statistical-based techniques. This work presents a method for day-ahead price forecasting using a generalized regression neural network where nodal prices are determined by solving a DC optimal power flow. In order to train the neural network several load-price scenarios are generated by randomly varying the loads in each bus of the electric energy system. The results are validated by analyzing the mean absolute percentage error, a common measure adopted in the technical literature as well as the base case and the maximum error which are within those found in the literature. The proposed methodology has been successfully applied to the IEEE 24-RTS system.

Keywords: Neural networks,MLP (Multilayer Perceptron).GRNN (generalized regression neural network).Price forecasting,LMP (locational marginal prices).

LISTA DE FIGURAS

FIGURA 1 – CONJUNTOS FINITOS X E Y. 28
FIGURA 2 - ARQUITETURA DA REDE GRNN. 31
FIGURA 3 – ALGORITMO GRNN 32
FIGURA 4 – ARQUITETURA MLP 33
FIGURA 5 – MÉTODO LEVENBERG – MARQUARDT 36
FIGURA 6 - PROJEÇÃO DO SISTEMA ELÉTRICO IEEE 24 RTS 40
FIGURA 7 - ARQUITETURA DA PROJEÇÃO DA REDE NEURAL GRNN 40
FIGURA 8 - ARQUITETURA DA PROJEÇÃO DA REDE NEURAL MLP 41
FIGURA 9 - ENTRADAS DA REDE NEURAL MLP 42
FIGURA 10 - SISTEMA ELÉTRICO IEEE 24 RTS 43
FIGURA 11 - PREVISÃO DO DIA SEGUINTE GRNN 45
FIGURA 12 - MAPES OBTIDOS ATRAVÉS DA REDE GRNN 46
FIGURA 13 - ERRO MÁXIMO - GRNN 47
FIGURA 14 - LMP ($/MWH) CALCULADO E PREVISÃO - MLP 49
FIGURA 15 - MAPES - MLP 51
FIGURA 16 - ERRO MÁXIMO MLP 52
FIGURA 17 – LMP CALCULADO ($/MWH) E PREVISÃO – MLP (ADIÇÃO DE TIPO DE BARRA) 54
FIGURA18 - MAPES -MLP (ADIÇÃO DE TIPO DE BARRA) 55
FIGURA 19 – ERRO MÁXIMO - MLP (ADIÇÃO DE TIPO DE BARRA) 57
FIGURA 20 - EVOLUÇÃO NA PREVISÃO DE PREÇO DA REDE MLP 60
FIGURA 21 – PREVISÃO DE PREÇO DO DIA SEGUINTE GRNN E MLP (ADIÇÃO DE TIPO DE BARRA) 61
FIGURA 22 - MAPES GRNN E MLP (ADIÇÃO DE TIPO DE BARRA) 62

LISTA DE TABELAS

TABELA 1 – *SPREAD* APLICADOS EM CADA BARRA 44
TABELA 2 - LMP ($/MWH) CALCULADO E PREVISÃO COM GRNN 45
TABELA 3 - MAPES OBTIDOS-GRNN 47
TABELA 4 – ERRO MÁXIMO POR BARRAMENTO - GRNN 48
TABELA 5 - PREVISÃO GLOBAL - GRNN 49
TABELA 6 - PREVISÃO DO DIA SEGUINTE– MLP 50
TABELA 7 - MAPES - MLP 51
TABELA 8 – ERROS MÁXIMOS ENCONTRADOS - MLP 52
TABELA 9 - PREVISÃO GLOBAL - MLP 53
TABELA 10 – LMP CALCULADO ($/MWH) E PREVISÃO – MLP (ADIÇÃO DE TIPO DE BARRA) 54
TABELA 11 – MAPES - MLP (ADIÇÃO DE TIPO DE BARRA) 56
TABELA 12 – ERRO MÁXIMO - MLP (ADIÇÃO DE TIPO DE BARRA) 57
TABELA 13 - PREVISÃO GLOBAL SEM AS BARRAS 24, 11 E 12 - GRNN 58
TABELA 14 - PREVISÃO GLOBAL SEM AS BARRAS 24, 11 E 12 – MLP 59

LISTA DE ABREVIATURAS E SIGLAS

ARIMA	*Auto Regressive Integrated Moving Average*
OPF	*Optimal Power Flow*
GRNN	Rede Neural de Regressão Generalizada
MLP	Perceptron Multicamadas
MAPE	Erro Percentual Médio Absoluto
LMP	*Locational Marginal Price*
LM	Levenberg-Marquardt
BP	*Backpropropagation*
MCP	*Market Clearing Price*
IEEE	*Institute of Electrical and Electronics Engineers*
RNA	Rede Neural Artificial

SUMÁRIO

1 INTRODUÇÃO 13

1.1 OBJETIVO DO TRABALHO 15

1.2 CONTRIBUIÇÕES DO TRABALHO 15

1.3 ORGANIZAÇÃO DO TRABALHO 15

2 ESTADODA ARTE 17

2.1 INTRODUÇÃO 17

2.2 PRINCIPAIS REFERÊNCIAS BIBLIOGRÁFICAS 17

3 CONCEITOS SOBRE MERCADOS ELÉTRICOS 20

3.1 INTRODUÇÃO 20

3.2 AGENTES DO MERCADO DE ELETRICIDADE 21

3.3 PROCEDIMENTOS DE *MARKET CLEARING* 22

3.4 PREÇOS 23

3.5 LEILÕES DE UM ÚNICO PERÍODO 23

3.6 MERCADOS ELÉTRICOS NO BRASIL 24

4 REDES NEURAIS 27

4.1 INTRODUÇÃO 27

4.2 REDE NEURAL DE REGRESSÃO GENERALIZADA (GRNN) 28

4.3 REDE NEURAL PERCEPTRON MULTICAMADAS (MLP) 33

4.3.1 Algoritmo de treinamento Levenberg – marquardt (LMA) 34

5 METODOLOGIA 37

6 EXPERIMENTOS E RESULTADOS 44

6.1 INTRODUÇÃO 44

6.2 APLICAÇÃO 1 44

6.3 APLICAÇÃO 2 49

6.4 APLICAÇÃO 3 53

6.5 APLICAÇÃO 4 58

6.6 DISCUSSÕES 60

7 CONCLUSÕES E TRABALHOS FUTUROS 63

7.1 SUGESTÕES PARA TRABALHOS FUTUROS 64

REFERÊNCIAS 65

APÊNDICE A 71

1 INTRODUÇÃO

A energia elétrica tornou-se fundamental no desenvolvimento econômico-social da população. O crescimento do poder econômico proporcionou um consumo significantemente elevado de energia elétrica, consequentemente as fontes de energia primária (recursos naturais) tornaram-se escassas e com altos valores (GÓMEZ-EXPÓSITO, 2009).

Com a reestruturação do mercado de energia elétrica, houve a necessidade de discussão em relação aos preços da eletricidade, unindo consumidores e empresas energéticas em torno do tema. Desta forma, desenvolveu-se um número considerável de pesquisas nessa área, criando algoritmos, ferramentas e modelos com o objetivo de auxiliar organizações em tomadas de decisões, para possíveis medidas estratégicas e por ser uma área ainda a ser explorada (SCHWEPPE, 1988; BUNN, 2000).

Para a determinação do preço no mercado elétrico, vários fatores são levados em consideração, tais como: altas frequências, variância não constante, sazonalidades, volatilidade, época do ano e percentual do preço, sendo atribuído ao não armazenamento energético natural, equilíbrio entre a demanda e a oferta entre outros fatores (SCHWEPPE et al., 1988). Portanto, a previsão de preço da eletricidade vem se tornando fundamental para o planejamento e operação do sistema elétrico (AGGARWAL, 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, nos quais os compradores e vendedores apresentam suas propostas. No mercado bilateral, o comprador e vendedor estão envolvidos, e os valores dos preços são limitados contra a volatilidade diária. Desta forma, tornou-se fundamental a previsão de preço, associados às restrições físicas de segurança da rede elétrica (GÓMEZ-EXPÓSITO, 2009).

O preço do dia seguinte é definido como custo mínimo em uma determinada barra específica, mantendo o fluxo de energia seguro e sem violação dos limites físicos da rede. (GOMEZ-EXPÓSITO, 2009; LOTUFO, 2012).

Um dos métodos que vem sendo adotado para a previsão de preço é a utilização de redes neurais artificiais, destacando o tratamento das não-linearidades sem a necessidade de um modelo matemático (LOTUFO, 2012; PANDEY, 2008). É utilizada uma série temporal

para a realização da previsão de preço, sendo baseada em um histórico passado de série de preços. Dentre os métodos estatísticos destacando-se o clássico ARIMA de Box e Jenkins (BOX, 2004) e redes neurais artificiais podendo-se citar Perceptron Multicamadas (MLP) com treinamento por backpropagation (BP) ou Levenberg – Marquardt (LM).

Neste trabalho, apresenta-se uma serie temporal simulada através de *um Optimal Power Flow* (OPF), ferramenta que possibilita a otimização de uma função objetivo sujeita às restrições de igualdade do fluxo de potência, capacidade de transmissão nas linhas e posteriormente efetuando o cálculo do preço do dia seguinte.

Após a obtenção dos dados, os mesmos serão apresentados à Rede Neural de Regressão Generalizada (GRNN) e Perceptron Multicamadas (MLP) com o algoritmo de treinamento Levenberg - Marquardt. As redes neurais artificiais se caracterizam por sua capacidade de realizar o mapeamento da relação entre a entrada e saída, através da aprendizagem das relações complexas e não-lineares, as quais são difíceis de modelar em métodos convencionais (HAYKIN, 1999).

A motivação para a utilização da rede neural artificial GRNN é por possuir uma característica versátil, sem limitações de números de padrões de entrada e de fácil convergência, pois é baseada na função densidade de probabilidade (LOTUFO, 2012; SPECHT, 1991) e a rede neural Perceptron Multicamadas devido a sua versatilidade em aplicações especificamente em previsão de series temporais juntamente com o algoritmo de treinamento Levenberg – Marquardt (LMPA).

Os dados foram gerados através de um DC-OPF uma simplificação do OPF padrão, cujas restrições são lineares e uma função de custo quadrático, contendo, portanto, somente cargas ativas. As cargas foram perturbadas aleatoriamente para a obtenção das respectivas amostras carga-preço. Para cada perturbação foi executado um OPF diferente e calculado os respectivos LMP (*Locational Marginal Price*) os quais serão apresentados à rede neural. As entradas são as cargas ativas e as saídas são os LMP, ou seja, a saída da previsão é o preço do dia seguinte. Esta etapa foi realizada utilizando o Software MATPOWER ferramenta SMARTMARKET, o qual gerou as amostras carga-preço para a realização das previsões do dia seguinte (ZIMMERMAN, 2011).

O diferencial deste trabalho é a utilização do DC OPF para a solução do problema e cálculo do LMP contendo somente cargas ativas para todas as barras do sistema. Para a

realização da previsão de preço foi utilizado um leilão de um único período. Considera-se um único período de tempo, desprezando acoplamentos intertemporais.

Os critérios de avaliação dos resultados serão através dos MAPES (erro percentual médio absoluto), comparação com o caso base, sem a variação da carga, gerados através do DC OPF e comparativo com a referência de (PANDEY et al., 2008).

1.1 OBJETIVO DO TRABALHO

O objetivo deste trabalho consiste em desenvolver um novo método para a realização da previsão de preço da carga do dia seguinte. Para a realização da previsão foi utilizada a Rede Neural de Regressão Generalizada pela facilidade de convergência e a rede neural Perceptron Multicamadas por sua versatilidade em aplicações especificamente em previsão de séries temporais.

1.2 CONTRIBUIÇÕES DO TRABALHO

A contribuição deste trabalho consiste no desenvolvimento de metodologias para a realização de previsão de preço da eletricidade do dia seguinte, utilizando sistemas inteligentes baseados em redes neurais artificiais GRNN e MLP. Os dados utilizados são dados simulados a partir da execução de um DC-OPF variando aleatoriamente as cargas.

1.3 ORGANIZAÇÃO DO TRABALHO

A seguir será apresentada, de forma sucinta, a organização do trabalho.

No capítulo 2 é apresentado um estudo da arte, contendo alguns trabalhos relacionados à previsão de preço de eletricidade.

No capítulo 3 são abordados os principais conceitos de Mercados Elétricos, a importância da previsão de preço da eletricidade, os métodos adotados para comercializar energia.

No capítulo 4 é feito uma apresentação das redes neurais artificiais utilizadas para a realização da previsão de preço que são: Rede Neural de Regressão Generalizada e a rede neural Perceptron Multicamadas.

O capítulo 5 apresenta a metodologia aplicada na solução da previsão de preço da eletricidade.

No capítulo 6 são apresentados os resultados das aplicações obtidos através das redes neurais e a comparação dos resultados das redes neurais.

No capítulo 7 são apresentadas as conclusões e sugestões para trabalhos futuros.

Apêndice: São relacionados os artigos publicados no período de desenvolvimento da pesquisa.

2 ESTADODA ARTE

2.1 INTRODUÇÃO

A Previsão de Preços, para o dia seguinte, segue basicamente duas grandes linhas: Métodos estatísticos e Inteligência Artificial, os quais são enfatizados principalmente quanto as Redes Neurais Artificiais.

Dentre os artigos analisados, pode-se citar que os preços também seguem duas grandes linhas, ou seja, em alguns artigos serão tratados como uma série temporal de preços passados e em outros como preços nodais. Cabe enfatizar que este trabalho em particular tratará de preços nodais.

2.2 PRINCIPAIS REFERÊNCIAS BIBLIOGRÁFICAS

Existem vários artigos relacionados à previsão de preço, utilizando redes neurais artificiais. Através deste cenário, serão apresentados alguns artigos e a metodologia adotada para a realização de previsão de preço da eletricidade.

Ambazhagan et al. (2012-1 e 2012-2) utilizam uma MLP com treinamento por LM (Levenberg-Marquardt) com algumas pequenas modificações. Utilizam também uma GRNN, mas em contexto diferente do utilizado neste trabalho, uma vez que são tratados como série temporal.

Catalão et al. (2011) usam uma ANFIS (neuro-fuzzy) para previsão auxiliada por uma transformada wavelet, que funcionando como uma espécie de filtro, divide a série em sub-séries de acordo com as estações do ano.

Singhal et al. (2011) fazem uso de uma MLP com treinamento por BP considerando, entre outros dados de entrada, dias da semana, demanda prevista, preços anteriores.

A influência da produção eólica, além da carga horária, é considerada no trabalho de Cruz et al. (2011), cuja rede neural de previsão é uma MLP.

Para Ming Tsai et al. (2010), a rede neural da mesma forma é uma MLP com treinamento por BP modificado incluindo, entre outros dados, os de carga e de temperatura.

Zhang Caiqing et al. (2010), escolheram um modelo híbrido entre PSO (Particle Swarm Optimization) e RBF (Radial Basis Function) em que o PSO otimiza os pesos iniciais com cargas e preços como dados de entrada.

Comprovando ainda a popularidade da MLP com treinamento por LM, pode-se citar o trabalho de Bigdeli et al. (2010) que utiliza como dados de entrada cargas e preços médios dos mesmos períodos das cargas.

Dentre os modelos híbridos, cita-se o trabalho de Shafie-Khan et al. (2011) decompondo a série original por transformada wavelet, um ARIMA (Auto Regressive Integrated Moving Average) trata a parte linear. Uma rede neural RBF é responsável pela parte não-linear além, de um PSO para otimizar o centro e a largura (spread) da RBF.

Giri et al. (2010) decompõem a série por transformada wavelet para servir de entrada da rede neural e o treinamento é por IWO (Invasive Weed Optimization).

Duarte et al. (2009) também utilizam uma MLP com treinamento por LM incluindo outras informações como dia da semana, do mês e do ano.

Segundo trabalho de Aggarwal et al. (2009), que realizam uma avaliação do estado da arte, as redes neurais, principalmente a MLP (multilayer perceptron) com treinamento por BP (backpropagation), são as mais utilizadas.

Os trabalhos de Bashir e El-Hawary (2009), além dos preços, realizam previsões de cargas que são também utilizadas como entradas para a rede neural juntamente com outros fatores como temperatura, estações do ano, auxiliados por uma transformada wavelet, que é uma MLP com treinamento por PSO (Particle Swarm Optimization).

Pindoryia et al. (2008) além dos preços também utilizam a demanda como variável exógena e a rede neural é AWNN (Adaptive Wavelet Neural Network) com treinamento por BPLM (backpropagation Levenberg-Marquardt).

Os diversos artigos de Mandal et al. (2007, 2008, 2009) utilizam a norma Euclidiana para determinar similaridade entre dias anteriores e os preços bem como entre preços e cargas e a rede neural é treinada por BP.

Vahidinasab et al. (2008), escolheram uma MLP com treinamento por LM em que consideram também correlações de horas anteriores entre os preços, bem como entre preços e cargas, além de um algoritmo Fuzzy C-means para agrupar as características semelhantes entre dias úteis e fins de semanas.

Arciniegas et al. (2008) utilizam um sistema de inferência *fuzzy* de Takagi-Sugeno para previsão dos preços com dados de entrada sendo: ponta diária, carga média e temperatura.

Em Zarazadeh et al. (2008) os preços são separados, de acordo com a temperatura e com a hora da carga (baixa, normal, ponta). A rede neural escolhida é uma MLP com treinamento por BP em que os critérios acima são combinados de diversas formas e seis redes neurais são executadas, considerando os preços do histórico e as cargas previstas por algum método de previsão.

Em Qi Tang et al. (2007), o treinamento da rede neural é também por LM, além do gradiente conjugado escalonado.

A linha de previsão que utiliza preços nodais, ao contrário de uma série temporal, é baseada principalmente nos trabalhos de Pandey et al. (2008a, 2008b, 2009 e 2010) e Lalitha e Sydulu (2011) em que os preços do dia seguinte são obtidos a partir de um OPF perturbando aleatoriamente a carga para o treinamento da rede neural. Nestes trabalhos, o OPF executado é um fluxo de potência AC (cargas ativas e reativas) e, no caso Pandey et al., ainda é utilizado um método de clusterização para determinar quais os nós mais sensíveis para diminuir o número de entradas da rede neural. O sistema elétrico é o IEEE RTS 24 barras. Lalitha e Sydulu utilizaram um sistema elétrico de seis barras considerando todas as cargas ativas e reativas como entradas da rede neural, sem prejudicar o desempenho, além de utilizar também um algoritmo híbrido de redes neurais com algoritmos genéticos.

Estas referências foram o ponto de partida deste trabalho, com as devidas modificações apresentadas no capítulo de metodologia.

3 CONCEITOS SOBRE MERCADOS ELÉTRICOS

3.1 INTRODUÇÃO

Após a desregulamentação do setor elétrico, ocorrido em diversos países por volta de 20 anos atrás, surgiu uma nova área de pesquisa (ARANGO, 2011). A ideia básica da desregulamentação foi separar serviços e infraestrutura.

O mercado de eletricidade passou de uma estrutura vertical (geralmente monopólio) para uma estrutura liberalizada e competitiva. Nesta última, a competição foi uma das principais mudanças introduzidas, neste modelo em que os participantes têm a oportunidade de escolha para comercializar eletricidade e serviços, e também por reduzir custos (ARANGO, 2011). Assim, os preços são de fundamental importância, uma vez que a eletricidade passou a ser uma mercadoria que pode ser comprada e vendida, mas como se sabe, não pode ser armazenada. Portanto, as restrições de estabilidade requerem um balanço entre produção e consumo (ARANGO, 2011).

A previsão de carga é essencial neste cenário de mercados elétricos. Desta forma, a previsão de preços auxilia os fornecedores a ajustarem suas estratégias de oferta para um máximo benefício e os consumidores a maximizarem suas vantagens (AGGARWAL, 2009).

Os fatores que influenciam os preços são vários. Os mais importantes são as características do mercado, índices de comportamento da população, efeitos temporais, sazonais, entre outros (AGGARWAL, 2009).

Os mercados desregulamentados podem ser classificados em: oferta competitiva (*pool*) e contrato bilateral. Além destes, também existem alguns mercados híbridos (GOMEZ-EXPÓSITO, 2009).

A oferta competitiva acontece nos mercados de energia a vista (*spot*), com os leilões em que compradores e vendedores submetem suas ofertas de hora em hora para suprir a demanda prevista, e o contrato bilateral envolve o comprador e o vendedor em que os participantes limitam os preços contra a volatilidade diária (GOMEZ-EXPÓSITO, 2009). Os pregões do mercado spot são funções dos custos marginais dos geradores movidos a combustíveis fósseis. A cada intervalo de tempo, as ofertas com preços mais baixos saem vitoriosas e que somadas atendem ao consumo previsto. O preço da oferta mais cara aceita

determina o preço da energia no período que é o *Uniform Price Auction* (UPA) (GOMEZ-EXPÓSITO, 2009).

Um contrato bilateral requer um acordo entre o vendedor e o comprador num horizonte de vigência do contrato.

A importância da previsão de preços se reforça mais uma vez. Como já enfatizado anteriormente, as restrições físicas da rede elétrica também influenciam, as quais são consideradas quando do cálculo dos preços, aqui destacando particularmente, o LMP (*Locational Marginal Price*). Os LMP são os preços associados às restrições de igualdade, são os preços nodais tipicamente calculados como multiplicadores de Lagrange de um OPF (*Optimal Power Flow*) (GOMEZ-EXPÓSITO, 2009).

Define-se LMP como o custo mínimo para atender a carga numa determinada barra, mantendo o fluxo de energia seguro e sem violar os limites físicos (GOMEZ-EXPÓSITO, 2009). O LMP é um dos mais populares modos de avaliar o preço da energia no mercado competitivo e pode demonstrar o valor da eletricidade em uma barra, podendo ser diferente em diferentes barras do sistema.

Um dos métodos mais utilizados, atualmente, para realizar previsão de preços é o de Redes Neurais Artificiais, principalmente pela vantagem em tratar as não-linearidades sem a necessidade de um modelo matemático. Com um bom banco de dados históricos é possível captar o comportamento do mercado caracterizado entre outras coisas por: sazonalidade diária e semanal, efeitos de fim de semana, feriados, entre outros.

3.2 AGENTES DO MERCADO DE ELETRICIDADE

Os participantes de um mercado elétrico competitivo podem ser classificados em: empresas de geração, comercializadores, de consumo, operador do sistema independente (ISO) e operador de mercado (MO) (GOMEZ-EXPÓSITO, 2009).

As empresas geradoras são as que possuem as unidades geradoras, as operam e as mantém e também vendem eletricidade para consumidores.

Os consumidores são aqueles que compram das geradoras para suprirem as suas demandas.

As empresas comercializadoras compram e vendem eletricidade, mas não possuem unidades geradoras, principalmente compram das geradoras para vender aos consumidores.

O Operador do Sistema Independente (ISO) é uma entidade independente sem interesses comerciais e responsáveis pelo gerenciamento técnico do sistema. Deve garantir o balanço geração-consumo dentro das restrições técnicas de segurança. Também é responsável pela manutenção da confiabilidade e programação de manutenção.

O Operador de Mercado (MO) é responsável pela administração financeira do sistema. Gerencia a compra e a venda de eletricidade. Estabelece preços, determina a energia para cada geradora, consumidor e mercado. O operador de mercado colabora com o ISO para gerenciar mercados de serviços ancilares, AGC (controle automático de geração), controle de tensão entre outros.

O operador de mercado dispõe de um procedimento conhecido como Market clearing para determinar as offers (ofertas dos geradores) e as bids (ofertas de demanda) aceitas e os MCP (market clearing price), ou seja, o operador gerencia o mercado do dia seguinte que é aclarado um dia antes.

Em alguns mercados, o ISO e o MO são entidades distintas, enquanto em outros são a mesma.

Pool Market é o tipo de marcado mais utilizado e inclui geradores, consumidores e ISO.

Neste mercado, as geradoras submetem suas ofertas (offers) ao pool, consistindo de blocos de energia com os seus correspondentes preços mínimos de venda e os consumidores submetem (bids) blocos de energia e seus correspondentes preços máximos de compra. ISO recebe as propostas de compra e venda procurando maximizar os benefícios sociais, resultando em preços horários e programação de consumo e geração através de procedimentos adequados.

3.3 PROCEDIMENTOS DE *MARKET CLEARING*

Define-se Market clearing, como um algoritmo usado pelo operador de mercado que determina: offers aceitas, bids aceitas e clearing prices, os quais são os conhecidos leilões (GOMEZ-EXPÓSITO, 2009).

Offers de produtores são geralmente consideradas monotonicamente crescentes, enquanto bids de consumidores, monotonicamente decrescentes.

3.4 PREÇOS

Dois critérios de preços são geralmente usados: marginal e pay as bid.

Sob preços marginais, as unidades geradoras e as demandas são pagas e pagam o preço marginal, respectivamente. Isto é o mesmo que dizer, se as restrições da rede são consideradas no processo de Market clearing, as unidades geradoras e as demandas são pagas e pagam LMP.

No pay as bid, as offers aceitas pelos geradores são pagas pelo preço oferecido e as bids aceitas pela demanda pagam o preço ofertado. Este é equivalente ao custo médio dos geradores programados sob o ponto de vista dos consumidores.

O preço marginal é o mais aceito por fornecer uma resposta econômica mais apropriada do que o pay as bid (GOMEZ-EXPÓSITO, 2009).

3.5 LEILÕES DE UM ÚNICO PERÍODO

É o procedimento que considera restrições de rede em um único período de tempo desprezando ou simplificando acoplamentos intertemporais.

O operador de mercado recebe offers de produtores e bids de consumidores e aclara o mercado maximizando o bem estar social (SW), apresentado pela equação (1):

$$
\begin{aligned}
&Max \\
&SW = \sum_{j=1}^{N_D}\sum_{k=1}^{N_{D_j}} \lambda_{D\,jk} P_{D_{jk}} - \sum_{i=1}^{N_G}\sum_{b=1}^{N_{G_i}} \lambda_{G\,ib} P_{G_{ib}} \\
&s.a \\
&0 \le P_{D_{jk}} \le P_{D_{jk}}^{\max} \\
&0 \le P_{G_{ib}} \le P_{G_{ib}}^{\max} \\
&\sum_{j=1}^{N_D}\sum_{k=1}^{N_{D_j}} P_{D_{jk}} = \sum_{i=1}^{N_G}\sum_{b=1}^{N_{G_i}} P_{G_{ib}} + \sum_{n\in\Omega_n} \frac{1}{X_{nm}}(\delta_m - \delta_n) : LMP \\
&-P_{F_{nm}}^{\max} \le \frac{1}{X_{nm}}(\delta_m - \delta_n) \le P_{F_{nm}}^{\max}
\end{aligned}
\tag{1}
$$

em que:

$P_{D_{jk}}$: Bid de demanda j do bloco de potência k;

$P_{G_{ib}}$: offer de geração da unidade i e bloco b;

$\lambda_{D_{jk}}$: é o preço da bid de demanda j do bloco k;

$\lambda_{G_{ib}}$: preço da offer de geração da unidade i, bloco b;

N_{D_j} : número de blocos de bid de demanda j;

N_{G_i} : número de blocos de offers de geração da unidade i;

N_D : número de cargas;

N_G : número de unidades geradoras;

δ : ângulo de tensão;

X : reatância das linhas;

$P_{F_{nm}}^{\max}$: limite máximo de fluxo nas linhas.

O MCP (Market Clearing Price) é uma variável dual da terceira restrição do problema de maximização acima descrito, equação (1), que pode ser tanto o preço do bloco gerador mais dispendioso que foi aceito como o preço do bloco de demanda mais econômico que foi aceito. Estes preços correspondem ao custo incremental da demanda adicional em cada barra. Numa rede de transmissão não congestionada, estes preços serão uniformes e iguais ao preço da última unidade aceita ou marginal. Este é um problema de programação linear que foi resolvido usando o software MATPOWER (ZIMMERMAN, 2011). Esta etapa foi desenvolvida em trabalho anterior (LOTUFO, 2012). Aqui, neste trabalho, são utilizados somente o banco de dados gerado.

3.6 MERCADOS ELÉTRICOS NO BRASIL

A partir da década de 90, o Brasil iniciou o processo de desverticalização, ou seja, a separação do bloco geração, transmissão e distribuição de energia elétrica, atividades das quais passariam a ser desenvolvidas autonomamente e independente (MEDEIROS, 2003).

A transmissão e distribuição ficaram definidas monopolistas naturais e a geração de energia foi destinada a comercialização, permitindo a concorrência, privatizando assim uma boa parte das empresas de distribuição e geração (MEDEIROS, 2003).

Para regularizar esta situação, foram necessárias mudanças na legislação, de modo a transferir, do estado à iniciativa privada, as responsabilidades de investimento e operação e também realizando as tarefas de fiscalizar e regulamentar (MEDEIROS, 2003).

Foram aprovados vários decretos/leis para a regularização do setor elétrico no Brasil. Porém, algumas medidas não foram suficientes para sanear as empresas e superar os problemas enfrentados pelo setor elétrico (DAVID, 2004; MEDEIROS, 2003).

Em 1996 a 1998, foi desenvolvido um grande projeto de reestruturação do setor elétrico brasileiro (SEB) com participantes de consultores da RE-SEB (ELETROBRÁS, 1998). Foi sugerido um mercado atacadista de energia elétrica, substituindo o modelo de sistemas de preços regulamentados de geração e contratos renováveis de suprimento. Desta forma, as empresas negociariam a maior parcela de seu mercado, por meio de contrato bilateral, especificando o montante e o valor. Estes contratos protegem as partes contra a exposição ao risco determinado pelo potencial de volatilidade do preço de energia (DAVID, 2004; MEDEIROS, 2003).

Em 1996, foi criado um agente que regulasse e fiscalizasse o mercado elétrico brasileiro pela lei no 9.427, de 26/12/1996 e o decreto no 2.335 instituindo a agência nacional de energia elétrica (ANEEL), em que o principal objetivo é a definição de normas e procedimentos para o funcionamento do sistema elétrico brasileiro (DAVID, 2004; MEDEIROS, 2003).

Várias medidas, em formas de portarias e regulamentações, tal como a ANEEL vem buscando melhorias na estrutura do mercado elétrico brasileiro. Dentre elas, a regulamentação do acesso e uso do sistema de transmissão e distribuição determinado pelas resoluções nos 281, 282 e 286, de outubro de 1999 entre outras (DAVID, 2004; MEDEIROS, 2003).

A determinação da ANEEL é que no mínimo 50% da energia elétrica comercializada pelas concessionárias geradoras de serviço público sob controle federal, determinada pela lei no 10.438 em 2002, incluindo o montante reduzido em contratos iniciais, sejam negociadas em leilões públicos. Esta lei enquadra também determinados riscos hidrológicos, se o contrato não cumprido é assumido pelas concessionárias e a geradora (vendedora de energia) (DAVID, 2004; MEDEIROS, 2003).

O modelo adotado para os mercados no Brasil é um modelo misto seguindo o conceito de mercado atacadista ou mercado spot que são uma espécie de leilão de energia, e as empresas participando de contratos bilaterais. Neste tipo de mercado, os agentes de mercado realizam as transações de compra e venda. Estes contratos bilaterais, também chamados de contratos de longo prazo, preveem riscos financeiros associados à compra e venda pelo preço do mercado atacadista. Este modelo adotado, permite um único comprador ou agência compradora e, também, permite que qualquer geradora independente venda sua energia a qualquer distribuidora. O caso brasileiro ainda é considerado um mercado regulado, isto é, o equilíbrio de mercado é determinado indiretamente pela otimização dos recursos de geração. Isto porque o sistema é basicamente hidrelétrico com a geração fortemente dependente do quanto de energia armazenada na forma de água existe nos reservatórios e da afluência que é incerta e sazonal e dependente de fatores climáticos. (DAVID, 2004; MEDEIROS, 2003).

4 REDES NEURAIS

4.1 INTRODUÇÃO

As redes neurais artificiais (RNAs) são baseadas nos neurônios do ser humano. Sendo assim, foram desenvolvidos modelos computacionais seguindo modelos matemáticos. Sendo constituído por um sistema que possui um circuito que faça a simulação de um cérebro humano, inclusive também seu comportamento. As RNA são formadas por vários neurônios artificiais interconectados através de interconexões denominadas *sinapses* artificiais. O conhecimento é adquirido pela rede, através de um processo de aprendizagem, em que as conexões entre os neurônios, pesos sinápticos, são utilizadas para armazenar este conhecimento (HAYKIN, 1999).

Warren McCulloch (neuroanatomista e psiquiatra) e Walter Pitts (matemático) foram responsáveis pelas primeiras pesquisas referentes às RNA's iniciadas em 1943. A princípio, propôs o primeiro modelo de neurônio artificial, possuindo a base estrutural de um cérebro humano (BRAGA, 1998).

Segundo Braga et al. (1998), Hebb (1949) foi um dos primeiros pesquisadores a desenvolver algoritmos de aprendizado das RNA's, mostrando que a aprendizagem das RNA's é obtida através da variação dos pesos de entrada dos nós, baseado no reforço das ligações sinápticas entre os nós excitados, sendo ainda utilizada em vários algoritmos de aprendizagem conhecido como *Regra de Hebb*.

A técnica retropropagação (*backpropagation*), para o treinamento de redes multicadas, foi proposta por Werbos (WERBOS, 1974) e notabilizada por Rumelhart et al. (Rumelhart et al., 1986). Este algoritmo tornou-se rapidamente o mais utilizado para o treinamento de *perceptrons* de múltiplas camadas (HAYKIN, 1999).

Ao longo dos anos foi desenvolvida uma variedade de redes neurais, algoritmos de treinamento, modelos híbridos, tal como rede neural GRNN (General Regression Neural Network) desenvolvida por Specht em 1991 (SPECHT, 1991), entre outras.

Para a realização da previsão de preço da carga do dia seguinte foram utilizadas as Redes Neurais: GRNN e MLP que serão apresentadas detalhadamente nas seções 4.2 e 4.3 respectivamente.

4.2 REDE NEURAL DE REGRESSÃO GENERALIZADA (GRNN)

Rede neural de regressão generalizada (GRNN) foi desenvolvida por Donald Specht, (SPECHT, 1991). A regressão generalizada foi introduzida como uma memória baseada em rede neural onde são armazenados todos os dados de treinamento independentes e dependentes disponíveis para um mapeamento particular. Quando apresentada por um novo vetor de entrada, a regressão generalizada utiliza uma função de distância para calcular a média ponderada dos dados de treinamento dependentes, cujos parâmetros independentes estão em estreita proximidade com o vetor de entrada (HEIMES, 1998).

O treinamento da GRNN é supervisionado, ou seja, possui uma saída desejada com estrutura do tipo não-recorrente, constituída por uma estrutura fixa contendo 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, (HEIMES, 1998).

Sejam os conjuntos finitos X e Y, ilustrados na figura 1, em que x são variáveis independentes e y variáveis dependentes. A regressão é efetuada de uma variável dependente y a partir de uma variável independente x. As variáveis x e y são apresentadas como vetores, onde a variável independente x é a entrada e variável dependente y é a saída. São utilizadas para a aproximação de função, possuindo uma camada base radial e uma camada linear espacial (NOSE-FILHO, 2011; SPECHT, 1991).

Figura 1 – Conjuntos finitos X e Y.

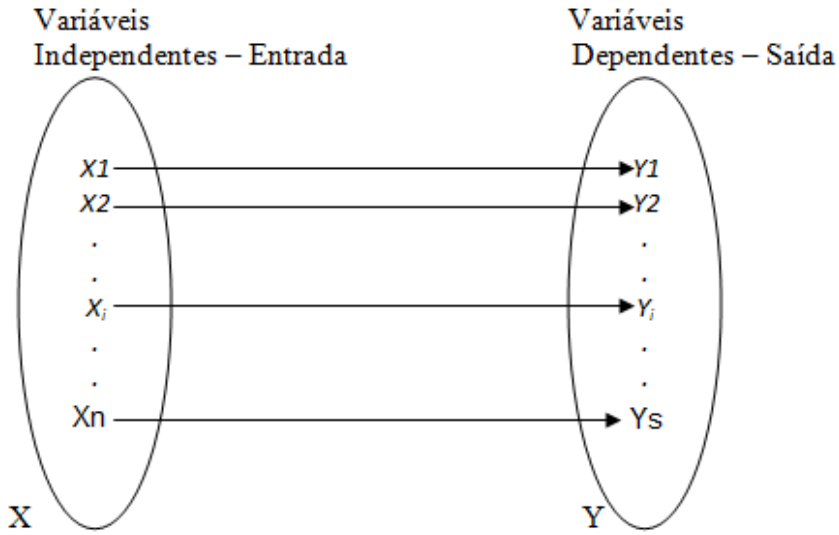

Fonte: própria autora

Considere f(x, y) uma função densidade de probabilidade de uma variável aleatória de entrada x e uma variável de saída aleatória y. A regressão da variável aleatória y é estimada, pela regressão da variável aleatória x, variáveis das quais estão inseridas nos conjuntos finitos X e Y, (SPECHT, 1991) conforme equação (2):

$$E[y \mid X] = \frac{\int_{-\infty}^{\infty} y f(X, y) dy}{\int_{-\infty}^{\infty} f(X, y) dy} \qquad (2)$$

A função densidade de probabilidade f(X,y) desconhecida pode ser obtida pelos conjuntos X e Y. A rede neural de regressão generalizada adota como estimativa da função densidade de probabilidade é a estimação de Kernel proposta por Parzen (PARZEN, 1962) conhecida também como janela de Parzen, conforme definida pela equação 3. A probabilidade estimada $\hat{f}$ (X, Y) é baseada em amostras de valores Xi e Yi das variáveis aleatórias x e y, (SPECHT, 1991) dada pela equação (3).

$$\hat{f}(X,Y) = \frac{1}{(2\pi)^{(p+1)/2}\,\sigma^{(p+1)}} \cdot \frac{1}{n} \cdot \sum_{i=1}^{n} \exp\left[-\frac{(X - X^i)^T (X - X^i)}{2\sigma^2}\right] \cdot \exp\left[-\frac{(Y - Y^i)^2}{2\sigma^2}\right] \qquad (3)$$

Em que,

n : número de amostras;

p : dimensão dos vetores da variável x.

σ : função de abertura, estimada por Kernel.

Yi : saída desejada dada pela entrada Xi.

A estimativa função densidade de probabilidade $\hat{f}$ (***X, Y***), é determinada pela função de abertura σ (*spread*) para cada amostra do conjunto finito X^i e Y^i (SPECHT, 1991).

A estimativa $\hat{Y}(X)$ utiliza a média ponderada de todas as amostras Y^i, em que cada amostra é ponderada exponencialmente de acordo com a distância euclidiana de X (SPECHT, 1991), determinada pela equação (4).

$$\hat{Y}(X) = \frac{\sum_{i=1}^{n} Y^i \exp\left(\frac{-D_i^2}{2\sigma^2}\right)}{\sum_{i=1}^{n} \exp\left(-\frac{D_i^2}{2\sigma^2}\right)} \tag{4}$$

Seja a função escalar D_i^2, a distância Euclidiana da variável desconhecida *X* juntamente com as variáveis aleatórias X^i (SPECHT, 1991), determinada por (5):

$$D_i^2 = (X - X^i)^T (X - X^i) \tag{5}$$

A rede neural de regressão generaliza utiliza a função de transferência do tipo gaussiana determinado pela equação (6).

$$f(a_i) = \exp\left(\frac{-a_i^2}{2\sigma^2}\right) \tag{6}$$

A variável sigma (σ) representa o *spread*, função que define sua abertura. As redes neurais do MATLAB toolbox consideram a função Gaussiana, apresentada pela equação (7).

$$f(a_i) = \left(\frac{-0.8326^2 a_i^2}{\sigma^2}\right) \tag{7}$$

A arquitetura da rede GRNN é composta por quatro camadas fixas: uma camada de entrada, duas intermediárias e uma de saída, conforme apresentado na figura 2.

A figura 2 - Arquitetura da rede GRNN.

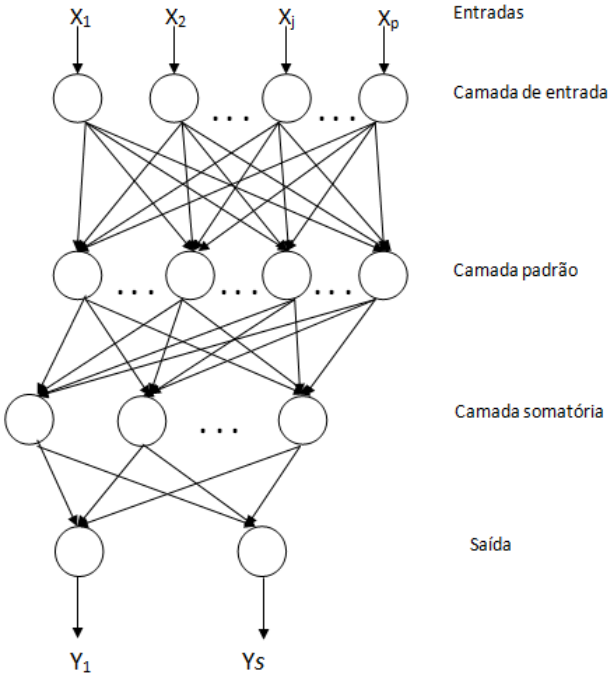

Fonte: própria autora

Os padrões de entradas são determinados por um vetor X com p dimensão e os padrões de saída são determinados por Y com s dimensão.

O algoritmo de treinamento da GRNN (SPECHT, 1991) é apresentado através da figura 3.

Figura 3 – Algoritmo GRNN

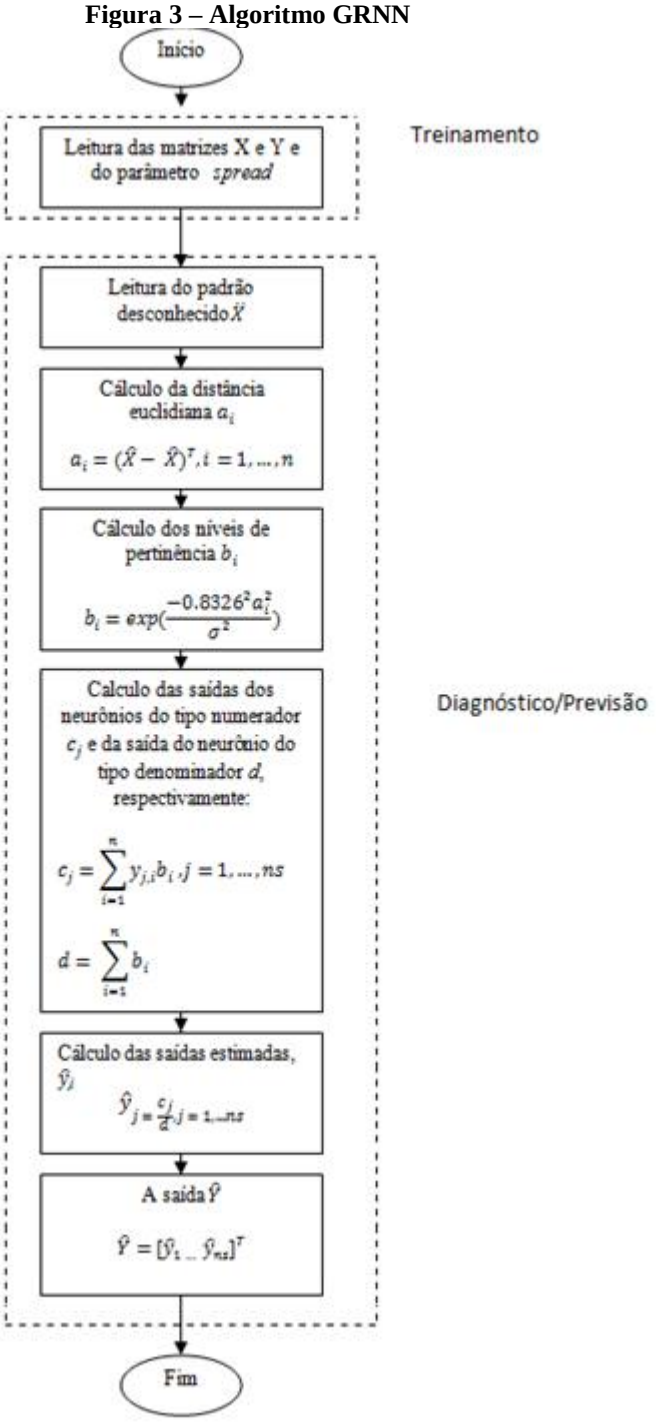

Fonte: Nose Filho (2011).

4.3 REDE NEURAL PERCEPTRON MULTICAMADAS (MLP)

A rede neural Perceptron Multicamadas (MLP), desenvolvida por HEBB em 1949, tem sido muito utilizada para a solução de problemas em diversas áreas de conhecimento tais como: aproximação de função, previsão utilizando séries temporais, otimização e entre outros.

Esta rede possui uma arquitetura feedforward, caracterizada por mais de uma camada intermediária, localizada entre a camada de entrada e a camada de saída. O tipo de treinamento é de forma supervisionado com algoritmo de treinamento Levenberg – Marquardt.

A arquitetura da rede neural MLP na figura 4 ilustra a estrutura da rede neural, tendo início na camada de entrada percorrendo logo após as camadas intermediárias, em seguida finalizando na camada de saída.

Figura 4 – Arquitetura MLP

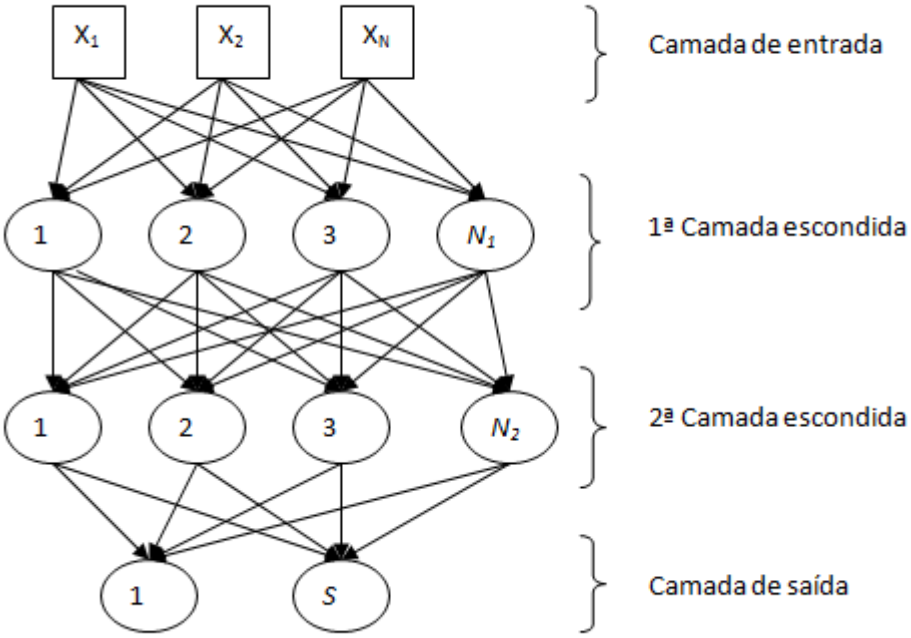

Fonte: Silva, (2010).

A rede neural MLP é constituída por, no mínimo, duas camadas intermediárias (chamadas de camada ocultas) com *n* dimensão. As entradas $\{X_1, X_2,..., X_n\}$, são as amostras do conjunto de treinamento, que são apresentadas nas entradas da rede neural. Em seguida são propagadas camada por camada até a camada de saída, para obter as respectivas saídas. A

camada de saída com 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).

4.3.1 Algoritmo de treinamento Levenberg – marquardt (LMA)

O algoritmo de treinamento Levenberg – Marquardt se caracteriza pela rapidez ao executar o treinamento em redes neurais com quantidades moderadas de pesos sinápticos, determinados pela derivada de segunda ordem do erro quadrático. Através dessas características, a convergência é desenvolvida com menos iterações. Porém, realizando mais cálculos, por iteração, em virtude do cálculo das matrizes inversas. Isto requer um esforço computacional considerável. Destaca-se como um algoritmo de treinamento ágil, adequado para redes neurais, considerando uma quantidade moderada de parâmetros apresentados à rede neural (ARAÚJO, 2011; ZHANG, 2011).

O algoritmo Levenberg – Marquardt é baseado em um método de otimização de aproximação de matriz, dado pela equação (8), apresentado em uma função da matriz Jacobiana, contendo as primeiras derivadas de pesos em função dos pesos sinápticos (ARAÚJO, 2011; ZHANG, 2011), expresso pela equação (9):

$$H = \frac{\partial^2 E_R\,(W)}{\partial W^2} \tag{8}$$

$$J = \frac{\partial\, e(W)}{\partial\,(W)} \tag{9}$$

Em que: $e(W)$ é definido através da equação (10):

$$e(W) = \sum_{i=1}^{n} (y_1 - y_{ei}) \tag{10}$$

O desempenho de treinamento de uma rede neural é apresentado em função da soma dos erros quadráticos determinados pela matriz Hessiana, dado pela equação (11).

$$H = J^T(W)\,J(W) \tag{11}$$

A atualização dos pesos é definida através do método de Newton, expresso pela equação (12):

$$W(k+1) = W(k) - H^{-1}\,g_k \tag{12}$$

Em que g_k é determinado pela equação (13):

$$g_k = 2J^T(W)e(W) \tag{13}$$

Após a atualização de pesos (método de Newton), efetuando as modificações para a determinação da matriz Hessiana, é expressa por (14):

$$W(k+1) = W(k) - [J^T(W)J(W) + \mu_k I]^2 J^T(W)e(W) \tag{14}$$

sendo:

I : Matriz identidade.

μk : fator de estabilidade de treinamento ajustando a aproximação de modo a tornar uma convergência ágil (método de Newton), desta forma, evitando pesos muito grandes, podendo levar a um erro de convergência.

Realizada a atualização, se o valor do desempenho diminuir, consequentemente o μ_k deverá ser diminuído, reduzindo a influência do gradiente descendente. O mesmo ocorre se o valor do desempenho seja aumentado, a utilização do gradiente descendente será ideal e o valor de μ_k deverá ser aumentado. A determinação de μ influencia diretamente na atualização de W. Se μ torna-se grande, determinado pela matriz Hessiana, não haverá utilidade no cálculo da atualização de W. Para solucionar o problema, Marquardt substitui a matriz identidade pela matriz $diag[H]$ (matriz diagonal de H). Assim, foram definidas as regras de atualização (ARAÚJO, 2011; ZHANG, 2011), apresentadas na figura 5.

Figura 5 – Método Levenberg – Marquardt

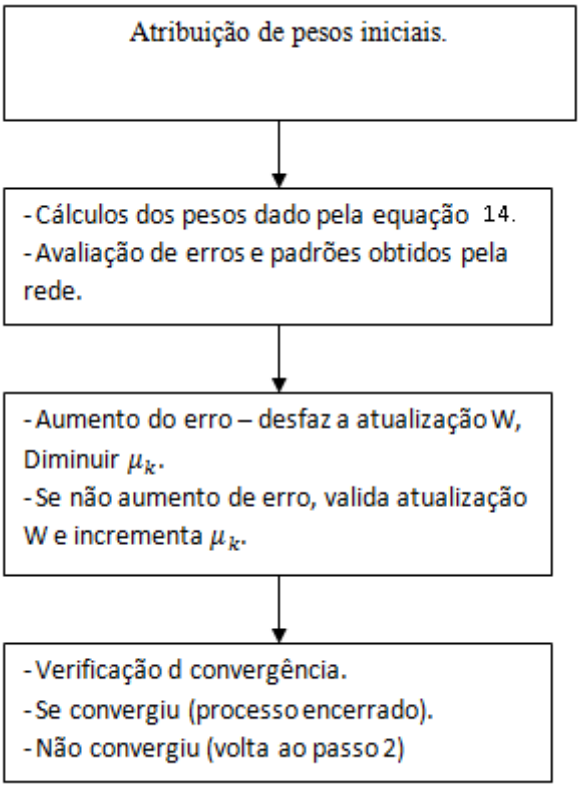

Fonte: Araújo (2011).

Um dos critérios de convergência utilizados pelo método Levenberg – Marquardt, (ARAÚJO, 2011; ZHANG, 2011), é determinado por:

- o valor preestabelecido ser maior que a norma do gradiente;
- o valor preestabelecido ser maior que a soma dos erros quadráticos;
- atingir uma quantidade de iterações pré estabelecidas.

5 METODOLOGIA

O método consiste primeiramente em executar um OPF (*Optimal Power Flow*) que é definido pela minimização dos custos totais sujeitos aos limites de geração, restrições de igualdade do fluxo de potência e capacidade de transmissão em todas as linhas e determinar o LMP (*Locational Marginal Price*), representado por (15):

$$\text{Min } f(x, u)$$

s.a.

$$\begin{aligned} h\,(x, u) &= 0 \\ g\,(x, u) &\geq 0 \end{aligned} \tag{15}$$

Em que:

f : função objetivo;

u :variáveis de decisão;

x : variáveis dependentes;

h : equações da rede;

g : restrições operacionais.

Um OPF padrão é um problema de otimização não-linear com custos e restrições não-lineares (GOMES-EXPÓSITO 2009).

O diferencial deste trabalho, em relação a outros encontrados na literatura (Pandey et at., 2008), é a utilização de um DC-OPF para simulação dos dados. O DC-OPF é uma simplificação do OPF padrão no qual as restrições são lineares e a função objetivo é aproximada por uma quadrática ou linear por partes. Além destas simplificações, consideram-se as tensões de barras iguais à unidade, os cossenos das diferenças angulares por serem muito pequenos são aproximados da unidade e os senos iguais ao próprio ângulo. A resistência de cada ramo é considerada desprezível, quando comparada com a reatância e, portanto, pode ser considerada igual a zero.

Neste caso, as magnitudes de tensão e de potência reativa são eliminadas do problema. Os fluxos de potência são modelados como funções lineares dos ângulos de tensão (GOMEZ-EXPÓSITO, 2009).

Um DC-OPF sem consideração de perdas é modelado como um problema de minimização do custo total sujeito às restrições do balanço de energia e transmissão, podendo incluir contingências, expresso na equação (16).

$$\begin{aligned} & Min \ \sum_{i}^{n} C_i(P_{G_I}) \\ & s.a. \\ & P_G^{\min} \le P_G \le P_G^{\max} \\ & P_G - P_D = P_F(\delta) \quad (\lambda) \\ & |P_F(\delta)| \le P_F^{\max} \end{aligned} \tag{16}$$

Em que

P_G : potência gerada;

P_D : demanda;

$C(P_G)$: custo da produção;

P_F : fluxos nas linhas;

δ : ângulo de tensão.

Os LMPs são calculados após as condições de otimização de primeira ordem serem satisfeitas e são os multiplicadores de Lagrange associados ao fluxo, demonstrada pela equação (17):

$$\lambda_i = \frac{\partial C}{\partial P_{D_i}} \tag{17}$$

Escrevendo de outra forma, mais generalizada, os LMP podem ser descritos como a máxima variação do benefício social em relação à demanda, em que SW é o benefício social, o qual é apresentado pela equação (18):

$$\lambda_i = \frac{\partial SW}{\partial P_{D_i}} \tag{18}$$

cuja unidade está em $/MWh.

Estas simplificações de um DC-OPF fazem com que não se tenham potências reativas, o que também diferencia dos demais trabalhos encontrados na literatura (PANDEY et.al., 2008), uma vez que, desta forma, diminuem-se os parâmetros de entrada para a rede neural. Nesta referência, Pandey et al. (2008) utilizam um método de seleção de variáveis mais sensíveis para diminuir o número de variáveis de entrada e, assim, ser possível executar a rede neural escolhida que foi uma perceptron multicamadas com treinamento por gradiente descendente (retropropagação), além de Levenberg – Marquardt e a rede neural de base radial (RBF).

Portanto, a metodologia, utilizada neste trabalho, consiste em variar aleatoriamente as cargas gerando diferentes cenários carga-preço, da mesma forma que a referência acima considerando os limites físicos da rede elétrica de tal forma que não sejam ultrapassados e executar um DC-OPF ao contrário daquela que executa um OPF convencional.

Comparando com outros trabalhos encontrados na literatura, conforme estado da arte apresentado no capítulo 2, a maioria considera os preços como uma série temporal global, isto é, como se fosse uma única barra, ao contrário deste trabalho que considera os preços por barra do sistema elétrico.

O software MATPOWER (ZIMMERMAN, 2011) algoritmo SMARTMARKET foi utilizado para gerar estes dados considerando leilões de um único período, ou seja, as restrições de rede são para um único período de tempo desprezando ou simplificando acoplamentos intertemporais.

A representação matemática desta função objetivo foi apresentada no capítulo 3 conforme equação (1).

Dentre os métodos apresentados no MATPOWER para resolver o problema de programação matemática, o método escolhido para solucionar o problema foi o de Pontos Interiores, uma vez que apresentou os melhores resultados. Cabe salientar aqui que esta parte do trabalho foi desenvolvida na referência (LOTUFO, 2012), sendo que aqui neste trabalho foi desenvolvida somente a execução da rede neural, isto é, o treinamento, diagnóstico e a análise dos resultados assim obtidos.

Considerando o banco de dados através do MATPOWER num total de 200 pares carga-preço, foram utilizados 70% (primeiros) dos dados para treinamento e 30% (restantes) para diagnóstico e, posteriormente, um valor ainda diferente para realizar a previsão.

As redes neurais propostas para a realização da previsão de preço são as redes neurais: GRNN e MLP, para fazer uma comparação dos respectivos desempenhos. A figura 6 apresenta um resumo do procedimento proposto, em que P = [P1, P2, P3,... P24] são as entradas da rede, representando as cargas, e LMP [LMP1, LMP2, LMP3, ... LMP24] são as saídas, representando os LMPs.

Figura 6 - Projeção do sistema elétrico IEEE 24 RTS

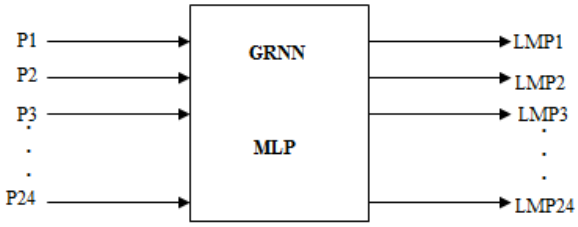

Fonte: Dados da própria autora

A figura 6 representa as entradas apresentada as redes neurais e suas saídas. Os testes nas redes neurais 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.

Na figura 7, apresenta-se o desenvolvimento da rede neural GRNN, após a obtenção dos dados. São apresentadas as etapas para a realização da previsão de preço.

Figura 7 - Arquitetura da projeção da rede neural GRNN

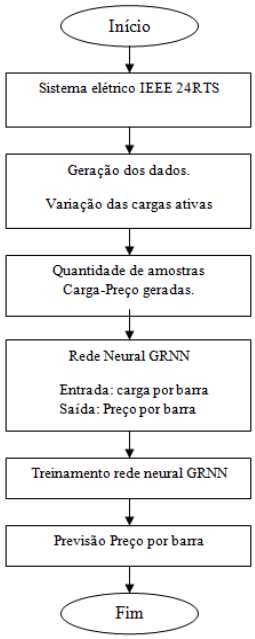

Fonte: Dados da própria autora

A rede neural escolhida foi a rede neural GRNN, que, também, segundo a literatura, ainda não foi usada para esta finalidade. Esta rede neural apresenta vantagens principalmente por ser baseada em densidade de probabilidade e não cair em mínimos locais, além de não ter problemas quanto ao número de variáveis de entrada. Sendo assim, sempre forneceu um resultado.

Alguns testes foram feitos com a rede neural MLP com treinamento por Levenberg – Marquardt, mas os resultados não foram promissores, uma vez que nas barras em que a carga é zero, mas com preços, ela não consegue convergir fornecendo um preço zero também, o que não condiz com a realidade.

Para contornar este problema, foi feito um teste considerando como dados de entrada e saída todo o banco carga-preço e comparando com uma média dos preços nas barras, como se fosse um valor global. Desta forma, a rede neural convergiu e foram obtidos resultados considerados satisfatórios, porém não com preços por barra.

Foi adotado um novo procedimento para a realização da previsão de preço na rede neural MLP, apresentando informações adicionais na entrada da rede. Desta forma, foi possível obter resultados satisfatórios. Este procedimento está representado conforme a figura 8.

Figura 8 - Arquitetura da projeção da rede neural MLP

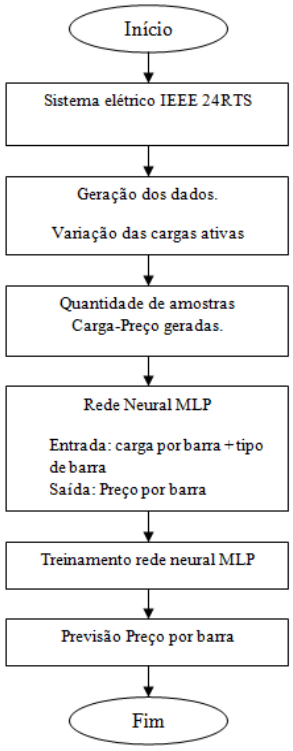

Fonte: Dados da própria autora

Assim, para obter preços por barra com a rede neural MLP com treinamento por Levenberg – Marquardt foi necessário fornecer mais informações em sua entrada. Estas informações consistem em fornecer à rede neural o tipo de barra do sistema elétrico de acordo com:

- tipo 1: São as barras que contém cargas. As barras de carga são: 3, 4, 5, 6, 8, 9, 10, 11, 12, 17, 19, 20, 24.
- tipo 2: São as barras de geração. As barras associadas a este grupo são: 1, 2, 7, 14, 15, 16, 18, 21, 22, 23.
- tipo 3: São barras de referências. A barra que compõe este grupo é: 13.

Pode-se observar na figura 9, o procedimento adotado para a realização da previsão adicionando nas entradas a barra e o respectivo grupo na rede neural perceptron multicamadas.

Figura 9 - Entradas da rede neural MLP

Fonte: Dados da própria autora

A matriz de entrada [P1, P2,... P24] é apresenta a rede neural MLP e foi adicionado o grupo (tipo de barra) da qual pertence. G_x que representa o grupo em que a barra é associada. Após a definição das entradas, foram realizados os testes e em seguida foi possível obter a previsão em todas as barras do sistema elétrico. Portanto, deste modo, obtiveram-se os resultados esperados de preço por barra e com erros percentuais de acordo com os encontrados na literatura.

Uma vez que o objetivo aqui era usar a rede neural GRNN, a ênfase será dada a esta rede e os resultados com a rede neural MLP serão usados somente para efeito de comparação.

O sistema elétrico utilizado foi o IEEE 24RTS (Reliability Test System Task Force, 1999), com 24 barras conforme diagrama unifilar apresentado na figura 10.

Figura 10 - Sistema elétrico IEEE 24 RTS

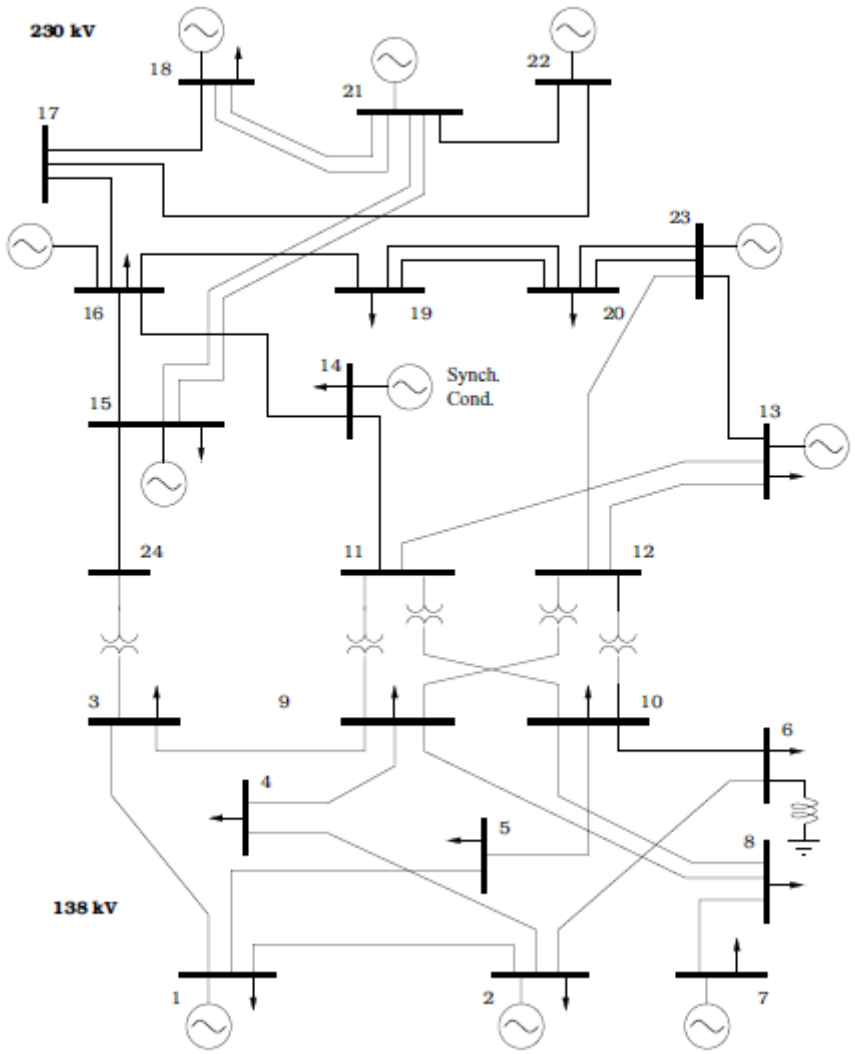

Fonte: Bertrand (2005).

Os critérios de avaliação são definidos através do MAPE (erro percentual médio absoluto) apresentado na equação (19), comparação com o caso base gerado pelo DC-OPF (sem variação da carga) e comparação com valores encontrados na literatura especializada principalmente com o trabalho de Pandey et al. 2008):

$$MAPE = \frac{1}{Na} \sum_{n=1}^{N_a} \frac{100.|C^R(n) - C^P(n)|}{C^R(n)} \tag{19}$$

em que:

C^R : valor do preço real;

C^p :valor do preço previsto;

N_a : número de amostras previstas.

6 EXPERIMENTOS E RESULTADOS

6.1 INTRODUÇÃO

Neste trabalho, foi realizada a previsão de preço da eletricidade para o dia seguinte, utilizando os dados gerados com o software MATPOWER algoritmo SMARTMARKET (ZIMMERMAN, 2011). Para a realização das previsões, em cada barra do sistema elétrico, foram utilizadas as Redes Neurais Artificiais GRNN e MLP, desenvolvidas no MATLAB via toolboxes. As realizações das simulações das redes neurais consistem em apresentar 24 vetores de carga atuando como entrada e 24 vetores de preço atuando na saída. Realizando assim o treinamento e, por último, são efetuados os cálculos das previsões.

Após a obtenção das saídas de ambas as redes neurais utilizadas que são os preços, são avaliados os MAPES e Erro Máximo, comparando com o caso base, ou seja, sem variação aleatória da carga, e também comparando-os com as referências da literatura especializada através de (PANDEY et al., 2008; LALITHA; SYDULU, 2011). O Erro Máximo varia de 3% a 8% nas referências consultadas.

6.2 APLICAÇÃO 1

A primeira aplicação consiste na utilização da rede neural GRNN para a realização da previsão de preço da eletricidade do dia seguinte.

Foi utilizado *spread* diferente em determinadas barras do sistema elétrico, conforme apresentados na tabela 1.

Tabela 1 – *Spread* aplicados em cada barra

Barra	***Spread***
1, 2, 4, 5, 9, 14, 21, 22, 23 e 24	0,03
3, 6 e 20	0,04
7, 8, 10, 13, 16,e 19	0,01
11, 12, 17e 18	0,02

Fonte: Dados da própria autora

Os valores apresentados na Tabela 1 foram encontrados por tentativa e erro, sendo escolhidos, portanto, aqueles que apresentaram os melhores resultados com relação ao menor erro.

Os padrões de teste são ilustrados na figura 11, apresentando a previsão de preço das 24 barras do sistema elétrico, pela rede neural GRNN, comparada com o caso base. O caso base se entende como o resultado do fluxo de potência ótimo sem variação da carga, isto é com as cargas reais em cada barra.

Figura 11 - Previsão do dia Seguinte GRNN

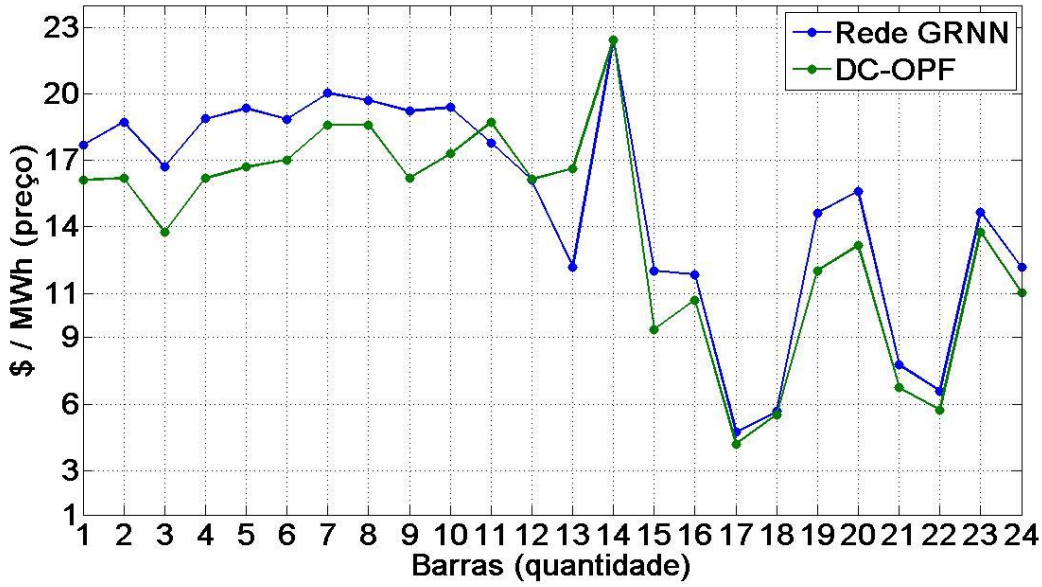

Fonte: Dados da própria autora

A Tabela 2 fornece os valores calculados pelo DC – OPF e os valores dos LMPs que são as saídas das previsões por barramento projetadas pela GRNN.

Tabela 2 - LMP ($/MWh) Calculado e previsão com GRNN

Barra	DC-OPF	Previsão
1	16,12	17,69
2	16,18	18,73
3	13,75	16,69
4	16,19	18,87
5	16,93	19,36
6	17,02	18,85
7	18,60	20,03
8	18,60	19,72

9	16,19	19,22
10	17,29	19,39
11	18,71	17,80
12	16,14	16,11
13	16,64	12,20
14	22,45	22,45
15	9,36	12,01
16	10,68	11,85
17	4,19	4,73
18	5,53	5,66
19	12,01	14,63
20	13,15	15,60
21	6,73	7,77
22	5,73	6,58
23	13,77	14,66
24	11,01	12,16

Fonte: Dados da própria autora

Na figura 12 são apresentados os MAPES obtidos através da rede GRNN nas 24 barras do sistema elétrico.

Figura 12 - MAPES obtidos através da rede GRNN

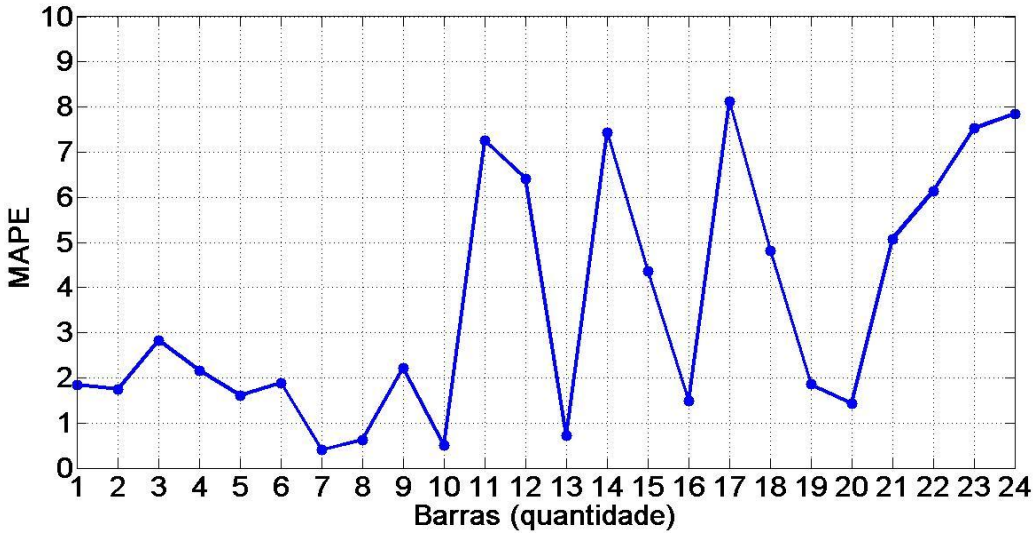

Fonte: Dados da própria autora

Ao realizar a análise do gráfico apresentado na figura 12, foi constatado que os MAPE, obtidos através da rede neural GRNN, estão de acordo com os encontrados pelos trabalhos realizados por (PANDEY et al., 2008; AMJADY et al., 2008, LALITHA; SYDULU, 2011). Através da tabela 3 é possível observar os MAPES mais detalhadamente.

Tabela 3 - MAPES obtidos-GRNN

Barra	MAPES %
1	1,848
2	1,742
3	2,827
4	2,164
5	1,609
6	1,889
7	0,402
8	0,622
9	2,216
10	0,510
11	7,248
12	6,412
13	0,7151
14	7,4399
15	4,358
16	1,48
17	8,119
18	4,816
19	1,852
20	1,4276
21	5,074
22	6,140
23	7,524
24	7,847

Fonte: Dada da própria autora

Na figura 13 são apresentados os erros máximos da previsão de preço em cada barra.

Figura 13 - Erro máximo - GRNN

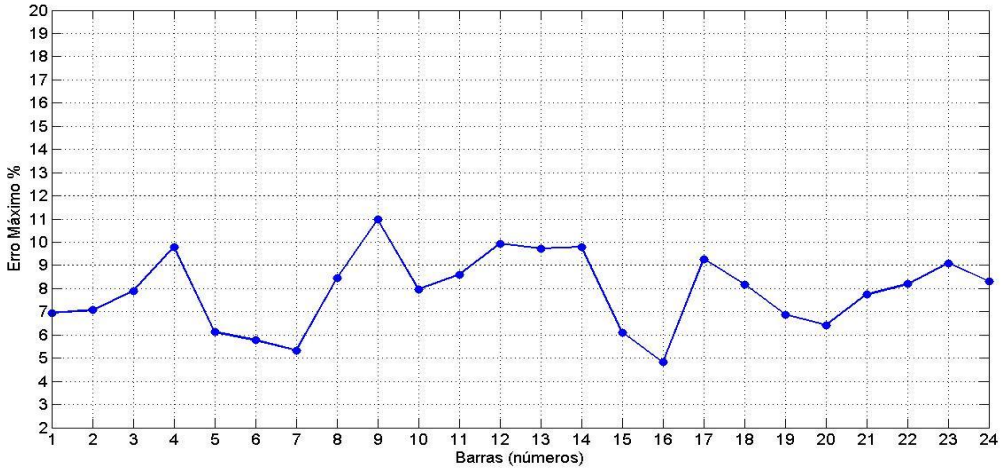

Fonte: Dados da própria autora

O gráfico da figura 13 representa claramente o erro percentual máximo após a realização da previsão de preço em todas as barras do sistema elétrico. A margem de erros máximos também está de acordo com a literatura especializada, quando comparado com a referência (AMJADY et al., 2008).

Na Tabela 4 apresenta-se o desempenho de cada barra do sistema elétrico com relação ao erro máximo.

Tabela 4 – Erro máximo por barramento - GRNN

Barra	ERRO MAX %
1	6,950
2	7,073
3	7,889
4	9,801
5	6,125
6	5,764
7	5,326
8	8,449
9	10,97
10	7,975
11	8,599
12	9,941
13	9,721
14	9,799
15	6,104
16	4,814
17	9,275
18	8,176
18	6,868
20	6,426
21	7,747
22	8,199
23	9,098
24	8,310

Fonte: Dados da própria autora

Os erros encontrados variam entre 4,814 e 10,97 %, sendo uma margem de erro considerada satisfatória e dentro das porcentagens encontradas na literatura especializada.

Foi realizada a previsão de preço global do sistema elétrico, que é apresentada na Tabela 5 para simulação com a rede GRNN.

Tabela 5 - Previsão global - GRNN

GRNN	DC-OPF	MAPE%	ERRO MAX %	*spread*
13,461	13,866	0,0101	2,914	0,0005

Fonte: Dados da própria autora

Para obter uma previsão global, foram envolvidas todas as barras do sistema elétrico com suas respectivas entradas e saídas, isto é, todo o banco de dados do sistema elétrico foi utilizado com as respectivas entradas e saídas.

A Tabela 5 apresenta o resultado fornecido pela rede neural GRNN e sua configuração. A previsão obtida pela rede neural é satisfatória, chegando a uma margem de erro muito pequena. As comparações foram efetuadas com uma média dos preços nas barras.

6.3 APLICAÇÃO 2

A segunda aplicação para a realização da previsão de preço foi a utilização da rede neural MLP contendo uma camada de entrada, duas intermediárias e uma camada de saída com algoritmo de treinamento Levenberg – Marquardt utilizando a função de ativação tangente hiperbólica.

O primeiro método adotado para efetuar a previsão de preço. Consiste na previsão de preço em cada barra, fornecendo somente na entrada a carga e a saída o preço, respectivamente.

Na figura 14 é apresentada a previsão do dia seguinte, utilizando a rede neural MLP.

Figura 14 - LMP ($/MWh) Calculado e previsão - MLP

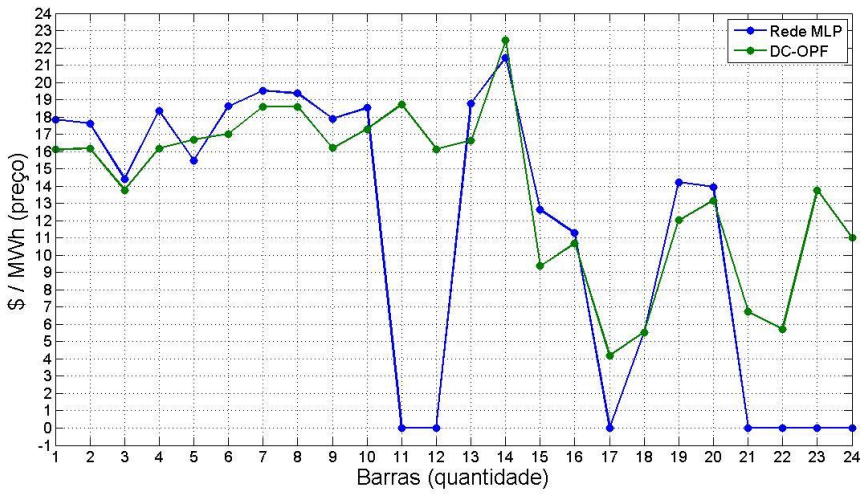

Fonte: Dados da própria autora

Ao observar a figura 14, é notado que em determinadas barras a rede neural não consegue nos fornecer uma previsão de preço. As barras 11, 12, 17, 21, 22, 23, 24 possuem carga com valores igual a zero, ou seja, são barras de geração ou barras de interconexão, porém, essas barras têm um preço. A rede neural MLP não consegue nos fornecer uma saída desejada em determinadas barras, provavelmente por não convergência do algoritmo de minimização do erro (Levenberg-Marquardt).

Através da tabela 6, podem-se observar detalhadamente as previsões obtidas com a rede MLP comparadas com o caso base gerado através do DC-OPF e a quantidade de iterações durante a realização da previsão de preço.

Tabela 6 - Previsão do dia seguinte– MLP

Barra	DC-OPF	Previsão	Iterações
1	16,12	17,86	12
2	16,18	17,63	17
3	13,75	14,41	16
4	16,19	18,35	12
5	16,9	15,46	15
6	17,02	18,61	13
7	18,60	19,53	12
8	18,60	19,37	13
9	16,19	17,91	18
10	17,29	18,53	17
11	18,714	ZERO	ZERO
12	16,14	ZERO	ZERO
13	16,64	18,76	19
14	22,45	21,42	21
15	9,36	12,63	25
16	10,68	11,28	39
17	4,19	ZERO	ZERO
18	5,53	5,53	14
19	12,01	14,23	12
20	13,15	13,96	12
21	6,73	ZERO	ZERO
22	5,73	ZERO	ZERO
23	13,77	ZERO	ZERO
24	11,014	ZERO	ZERO

Fonte: Dados da própria autora

A análise detalhada obtida pela Tabela 6, observando as barras que contêm carga. Estas tiveram resultados satisfatórios. Porém, as barras que não contêm carga, não obtiveram resultados satisfatórios, não fornecendo a previsão de preço do dia seguinte.

Os MAPES obtidos nas barras que contêm carga são apresentados na figura 15.

Figura 15 - MAPES - MLP

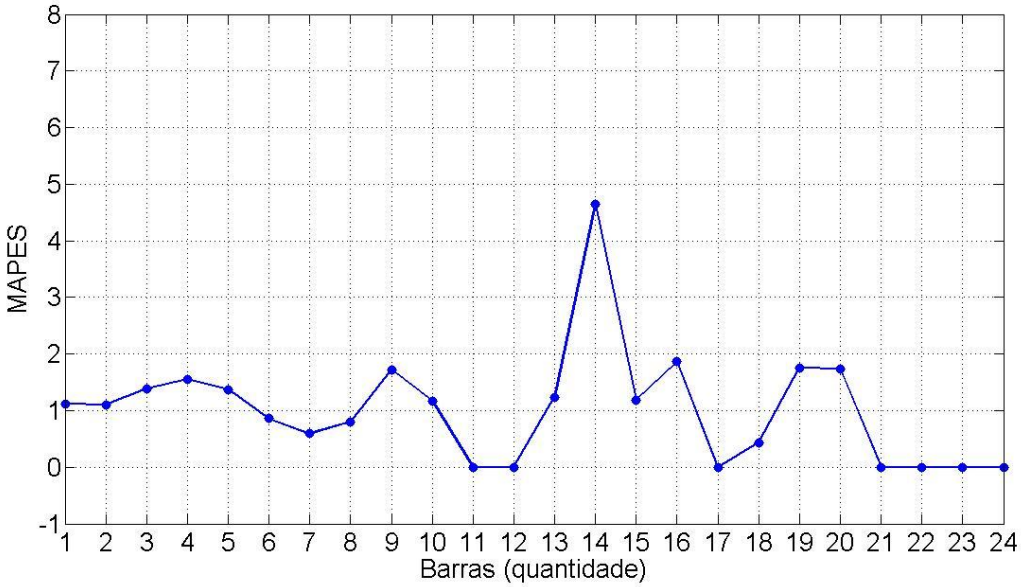

Fonte: Dados da própria autora

Os MAPES extraídos da rede neural MLP, desconsiderando as barras "zeradas", foram considerados satisfatórios, pois, como mencionado anteriormente, as barras que não contêm carga, não fornecem previsão, consequentemente não apresentam MAPE. Na Tabela 7, são apresentados os MAPES obtidos pela rede MLP em todas as barras do sistema elétrico.

Tabela 7 - MAPES - MLP

Barra	MAPE %
1	1,122
2	1,104
3	1,392
4	1,559
5	1,375
6	0,859
7	0,597
8	0,802
9	1,722
10	1,171
11	0
12	0
13	1,239
14	4,649
15	1,182

16	1,865
17	0
18	0,431
19	1,754
20	1,742
21	0
22	0
23	0
24	0

Fonte: Dados da própria autora

Em virtude das barras que não contêm carga, também não foi possível obter os MAPES, não satisfazendo por completo a previsão de preço.

São apresentados na figura 16 os Erros Máximos nas barras que contêm carga.

Figura 16 - Erro máximo MLP

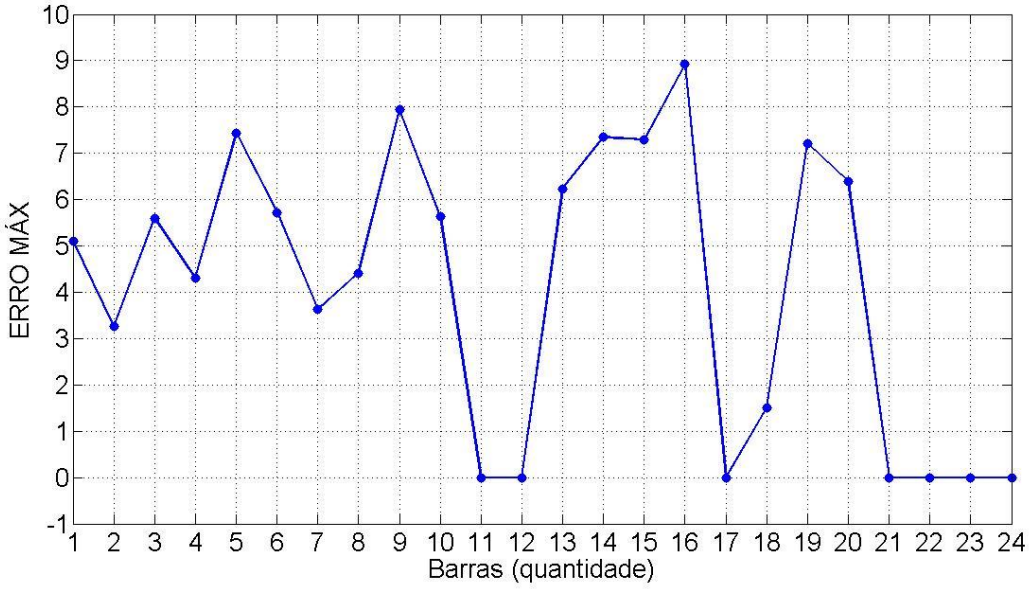

Fonte: Dados da própria autora

Pode se observar com mais exatidão os erros máximos da previsão obtidos pela rede neural MLP, conforme Tabela 8

Tabela 8 – Erros máximos encontrados - MLP

Barra	ERRO MÁX %
1	5,111
2	3,266
3	5,603

4	4,297
5	7,427
6	5,726
7	3,6288
8	4,412
9	7,945
10	5,641
11	0
12	0
13	6,232
14	7,350
15	7,298
16	8,925
17	0
18	1,498
19	7,217
20	6,397
21	0
22	0
23	0
24	0

Fonte: Dados da Própria autora

Foi realizada a previsão de preço global do sistema elétrico, de acordo com o procedimento feito anteriormente para a rede neural GRNN. A Tabela 9 apresenta a simulação na rede MLP para este caso.

Tabela 9 - Previsão global - MLP

MLP	DC-OPF	MAPE%	ERRO MAX %	Iterações
13,539	13,866	0,0082	2,352	42

Fonte: dados da própria autora

6.4 APLICAÇÃO 3

Para solucionar a previsão de preço da eletricidade do dia seguinte nas barras "zeradas" na rede neural MLP, foi necessário acrescentar mais informação na entrada para que pudesse fornecer uma saída desejada, ou seja, obter a previsão do preço. O fator escolhido para amenizar este problema foi informar o tipo de barra de acordo com a classificação dos sistemas elétricos os quais são (MONTICELLI; GARCIA, 1999):

- tipo 1 – são barras de carga, que são as de números: 3, 4, 5, 6, 8, 9, 10, 11, 12, 17, 19, 20, 24.
- tipo 2 – São barras de geração, representado pelas barras: 1, 2, 7, 14, 15, 16, 18, 21, 22, 23.
- tipo 3 – são barras de referência, dada pela barra 13.

Partindo deste princípio, foram apresentados como entrada da rede MLP a carga por barra e o tipo de barra da qual esta barra pertence e na saída o preço da barra correspondente à barra de entrada. Foram realizados novos testes em todas as barras do sistema elétrico, utilizando as mesmas configurações da rede MLP apresentadas na aplicação de número 2. Na figura 17 apresenta-se a previsão de preço da eletricidade do dia seguinte em todas as barras.

Figura 17 - LMP Calculado ($/MWh) e Previsão – MLP (adição de tipo de barra)

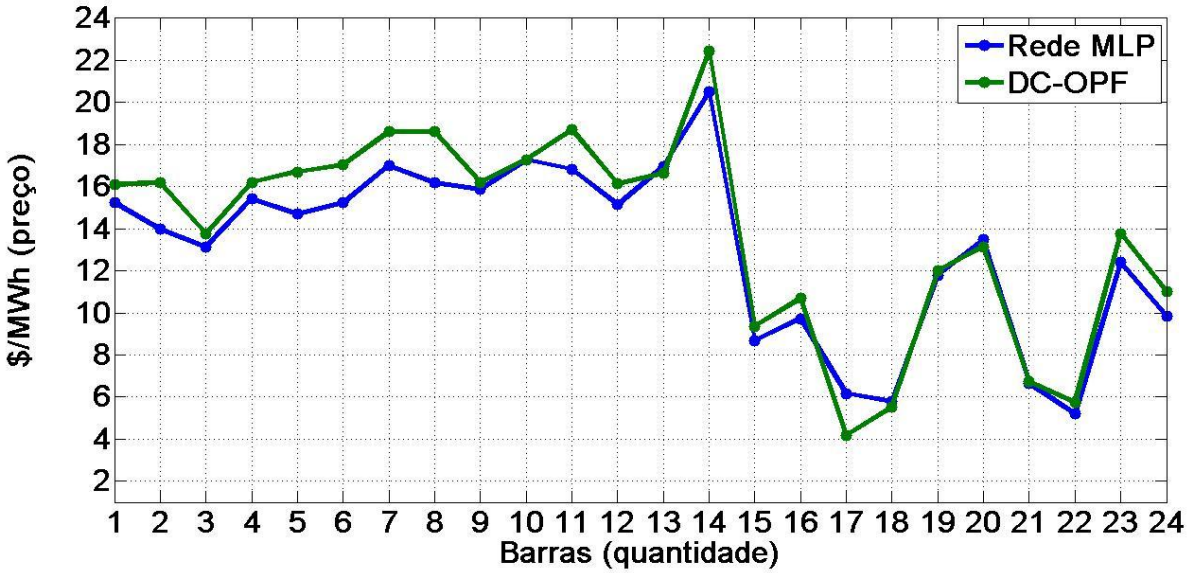

Fonte: Dados da própria autora

Com a adição de mais informação na entrada da rede neural MLP foi possível obter uma previsão de preço em todas as barras do sistema elétrico. Na Tabela 10, é possível observar com mais precisão a evolução nos resultados obtidos neste novo teste.

Tabela 10- LMP Calculado ($/MWh) e Previsão – MLP (adição de tipo de barra)

Barra	DC-OPF	Previsão	Iterações
1	16,12	15,24	17
2	16,183	13,99	11
3	13,755	13,13	36
4	16,191	15,42	14

5	16,93	14,68	13
6	17,025	15,23	15
7	18,60	17,00	38
8	18,60	16,16	27
9	16,19	15,88	13
10	17,29	17,27	13
11	18,71	16,83	13
12	16,14	15,15	15
13	16,64	16,95	12
14	22,45	20,50	23
15	9,36	8,67	28
16	10,68	9,72	10
17	4,19	6,17	13
18	5,53	5,77	40
19	12,01	11,79	13
20	13,15	13,47	20
21	6,73	6,65	14
22	5,73	5,18	9
23	13,77	12,39	12
24	11,01	9,83	16

Fonte: Dados da própria autora

Foram obtidos novos MAPE em todas as barras do sistema elétrico, dado pela Figura18.

Figura18 - MAPES -MLP (adição de tipo de barra)

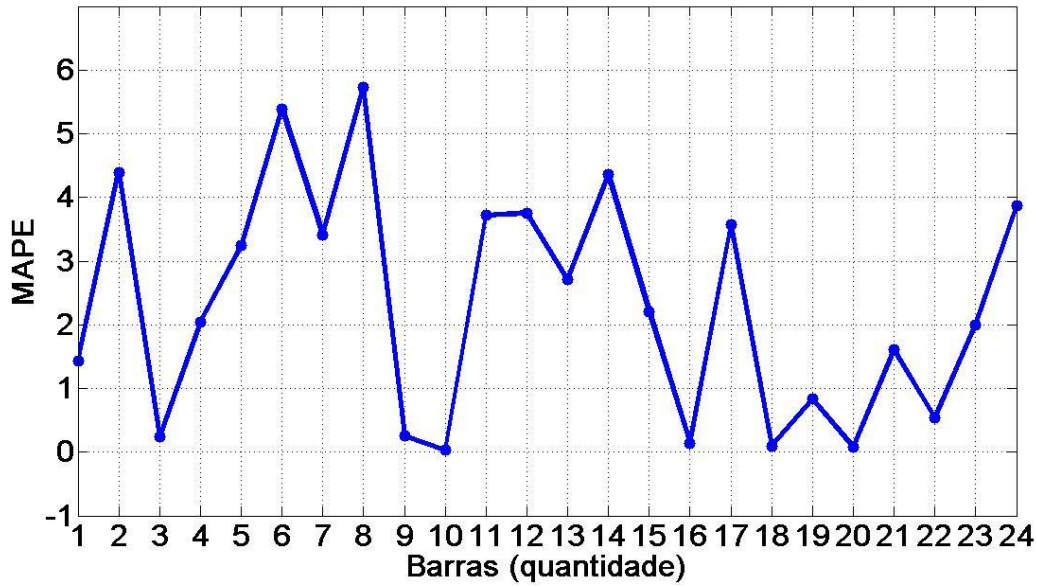

Fonte: Dados da própria autora

Os valores apresentado na figura 18, podem ser analisados de forma detalhada na Tabela 11.

Tabela 11 – MAPES - MLP (adição de tipo de barra)

Barra	MAPE %
1	1,437
2	4,391
3	0,247
4	2,039
5	3,242
6	5,388
7	3,410
8	5,731
9	0,253
10	0,0344
11	3,714
12	3,752
13	2,710
14	4,357
15	2,210
16	0,132
17	3,569
18	0,093
19	0,833
20	0,0839
21	1,603
22	0,539
23	2,001
24	3,873

Fonte: Dados da própria autora

Na Figura 19, são apresentados os erros máximos encontrados durante a realização da previsão de preço.

Figura 19 – Erro Máximo - MLP (adição de tipo de barra)

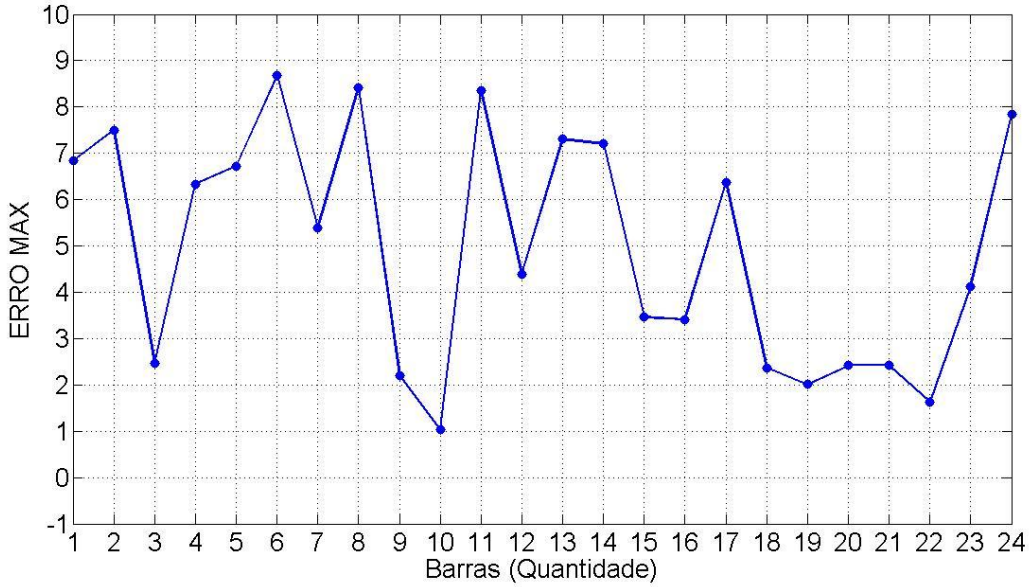

Fonte: Dados da própria autora

Outra forma de analisar os erros máximos obtidos por meio da rede MLP é através da Tabela 12 em que são apresentados os erros máximos.

Tabela 12 – Erro Máximo - MLP (adição de tipo de barra)

Barra	Erro max %
1	6,832
2	7,4951
3	2,4731
4	6,3391
5	6,7273
6	8,6896
7	5,3803
8	8,4183
9	2,21
10	1,0395
11	8,357
12	4,3873
13	7,31
14	7,2003
15	3,4591
16	3,4135
17	6,3654
18	2,3651
19	2,0139
20	1,9835
21	2,4183
22	1,631

23	4,131
24	7,835

Fonte: dados da própria autora

Com a adição de mais informações apresentada na entrada da rede neural MLP, foi possível obter resultados satisfatórios em todas as barras que compõe o sistema elétrico IEEE 24 RTS.

6.5 APLICAÇÃO 4

Para minimizar o problema da não convergência com a rede MLP para as barras em que não contêm carga com valores igual a zero, algumas tentativas foram realizadas para sanar o problema.

Foi realizada uma nova previsão global retirando as barras 24, 11 e 12 com carga igual a zero e seus respectivos preços. Estas barras podem ser retiradas do sistema elétrico, devido a não influenciarem em seu desempenho e transmissão, uma vez que são barras de interligação do sistema elétrico.

O sistema elétrico IEEE 24 RTS é composto por dois subsistemas: o subsistema 1 composto pelas barras 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23 e o subsistema 2 composto pelas barras 1, 2, 3, 4, 5, 6, 7, 8, 9 e 10. A retirada das barras 24, 11 e 12 não afeta o funcionamento do sistema elétrico.

A primeira rede neural utilizada foi a GRNN em que foi realizada uma nova previsão global, retirando as barras de interligação, desta forma pode-se observar o resultado através da Tabela 13.

Tabela 13 - Previsão global sem as barras 24, 11 e 12 - GRNN

GRNN	**DC-OPF**	**MAPE%**	**ERRO MAX %**	***Spread***
13,421	13,866	0,0254	3,203	0.2

Fonte: Dados da própria autora

Na tabela 5 (conforme página 48) apresenta-se a primeira previsão global do sistema elétrico, com todas as barras do sistema elétrico, totalizando 24, obtida pela aplicação 1.

Tabela 5 - Previsão global - GRNN

GRNN	DC-OPF	MAPE%	ERRO MAX %	*spread*
13,461	13,866	0,0101	2,914	0,0005

Fonte: Dados da própria autora

A segunda rede neural utilizada para a previsão global foi a MLP. Desta forma, pode-se observar os resultados relacionados na Tabela 14.

Tabela 14 - Previsão global sem as barras 24, 11 e 12 – MLP

MLP	DC-OPF	MAPE%	ERRO MAX %	Iterações
11,778	13,866	2,698	9,230	11

Fonte: Dados da própria autora

Na tabela 9 (conforme página 53) é apresentada a primeira previsão global utilizando a rede neural MLP, obtida pela aplicação 2, utilizando todas as barras do sistema elétrico.

Tabela 9 - Previsão global - MLP

MLP	DC-OPF	MAPE%	ERRO MAX %	Iterações
13,539	13,866	0,0082	2,352	42

Fonte: dados da própria autora

Estes testes foram realizados com a finalidade de fornecer um resultado melhor para a previsão global do sistema elétrico, de forma a não interromper e danificar o funcionamento do sistema elétrico. A comparação, da mesma forma, foi com uma média dos preços nas barras.

Na previsão global apresentada na aplicação 1, utilizando a rede neural GRNN, a diferença entre a previsão global da aplicação 1 e a previsão global da aplicação 4, é muito pequena, porém o desempenho da aplicação 1, demonstrou ser um pouco superior. Desta forma, as duas previsões globais estão dentro dos padrões encontrados na literatura especializada.

Na previsão global apresentada na aplicação 2, utilizando a rede neural MLP a diferença entre a previsão global da aplicação 2 e a previsão global da aplicação 4, indicam uma diferença considerável uma da outra. A previsão global da aplicação 2 ficou muito próxima do caso base (gerados através de um DC-OPF). Contudo, na aplicação 4 ficou, em média, 2 pontos de diferença do caso base. Portanto, a previsão global da aplicação 2 teve um

melhor desempenho em todos quesitos expostos na tabela 15. Embora a previsão global da aplicação 4 não supere a previsão global da aplicação 2, seu resultado ainda é satisfatório e levados em consideração ao ser comparada com os resultados encontrados na literatura.

A previsão global do sistema elétrico consiste na soma de todos os valores de todas as barras do sistema. Posteriormente, é calculada a média do sistema elétrico como um todo.

6.6 DISCUSSÕES

Diante dos resultados apresentados nas aplicações 1, 2 e 3, é possível efetuar A análise geral das saídas das previsões e MAPES, obtidos através das redes neurais GRNN e MLP.

Na figura 20, apresenta-se a evolução da rede MLP para obter a previsão do dia seguinte.

Figura 20 - Evolução na previsão de preço da rede MLP

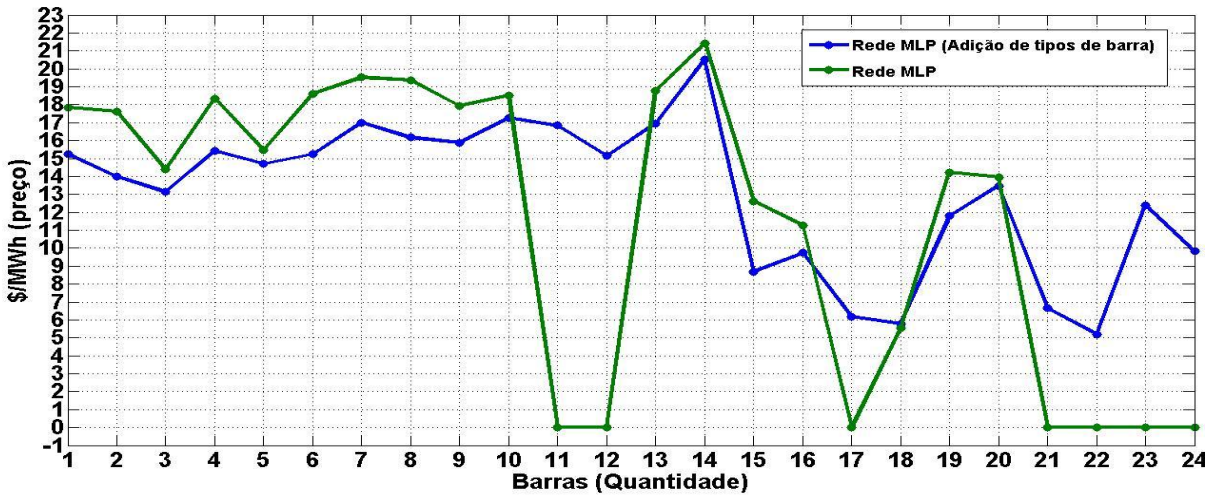

Fonte: Dados da própria autora

Na figura 20, é possível visualizar a melhora expressiva na previsão de preço pela rede MLP, obtida através da aplicação 2, em que foram apresentadas, às entradas da rede neural, somente as cargas ativas de cada barramento e seu respectivo preço na saída. Na aplicação 3, foram acrescentadas mais informações na entrada (tipo de barra).

Foram apresentadas, à rede neural MLP, como entrada, a barra e mais o tipo de barra no qual pertence e, na saída, o preço correspondente à barra de entrada. Desta forma, foi possível realizar a previsão de preço do dia seguinte da eletricidade em todas as barras do sistema elétrico sendo que os resultados foram considerados satisfatórios.

Conforme ilustrado na figura 21, pode se observar as previsões em todas as barras do sistema elétrico e comparando-as com o caso base – DC-OPF (sem variação aleatória da carga) das redes neurais GRNN e MLP apresentado na aplicação 3 com a adição dos tipos de barras à entrada da rede neural. Deste modo, obtendo as previsões de preço do dia seguinte em todas as barras do sistema elétrico.

Figura 21 – Previsão de preço do dia seguinte GRNN e MLP (adição de tipo de barra)

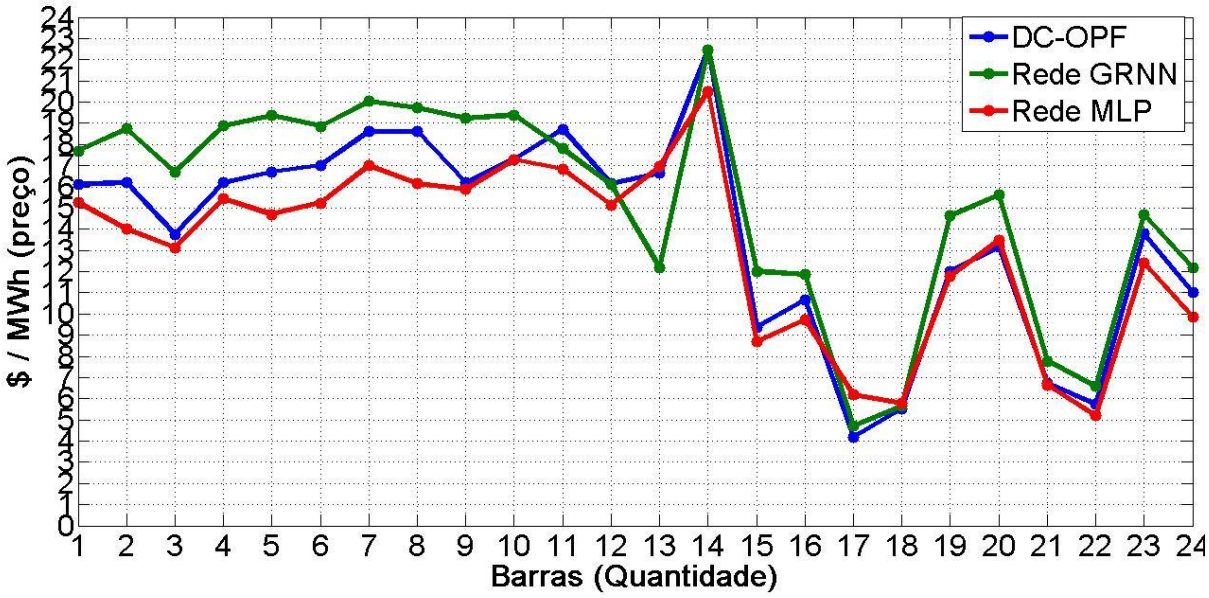

Fonte: Dados da própria autora

Pela análise da figura 21, obteve-se as previsões de preços em todas as barras, em uma visão geral das previsões fornecidas em ambas as redes, em algumas barras é possível observar que a rede GRNN obteve uma previsão de preço mais próximo do caso base ($ / MWh), porém ambas as redes forneceram previsões satisfatórias.

Na figura 22 são apresentados os MAPES obtidos através das redes neurais

Figura 22 - MAPES GRNN e MLP (adição de tipo de barra)

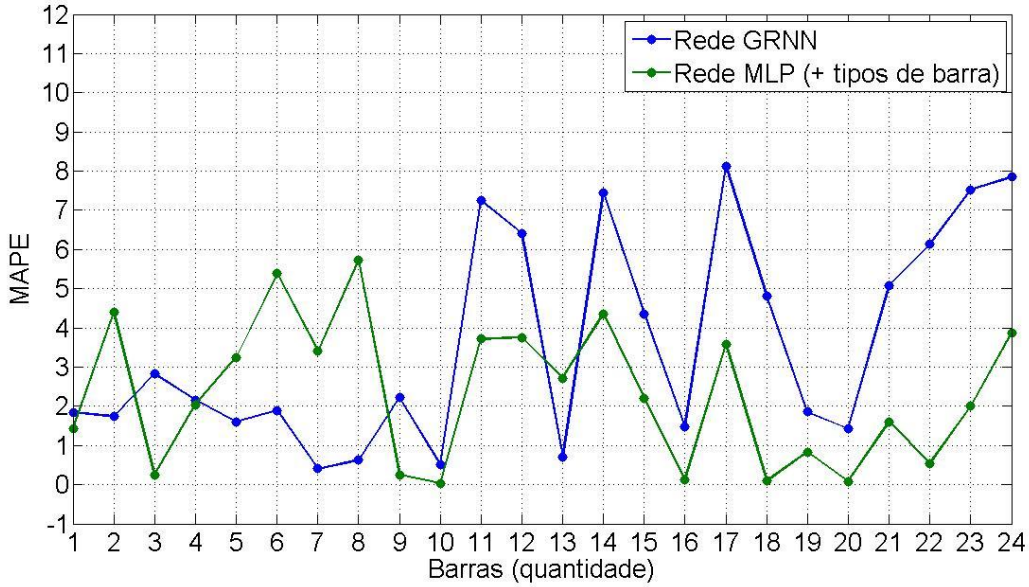

Fonte: Dados da própria autora

Analisando a figura 22, é possível observar o desempenho dos MAPES obtidos pelas redes neurais, visto que a rede neural MLP obteve MAPES menores, na maioria das barras, em relação à rede neural MLP. Porém, os MAPES extraídos de ambas as redes neurais são considerados satisfatórios, pois estão dentro dos padrões encontrados na literatura especializada.

7 CONCLUSÕES E TRABALHOS FUTUROS

As técnicas computacionais inteligentes, baseadas em redes neurais artificiais, vêm se destacando neste cenário de previsão de preço da carga em sistemas elétricos de potência, sendo eficaz para solucionar estes tipos de problemas, por causa de suas características, capacidade de generalização e aprendizagem.

Para a realização da previsão do preço da carga – LMP, foram utilizadas as redes neurais GRNN e MLP, das quais se apresentou uma abordagem sobre suas características e a projeção da previsão da eletricidade do dia seguinte em todo sistema elétrico IEEE 24RTS. As redes neurais utilizadas mostram-se rápidas nas respectivas simulações.

Foram utilizadas as redes neurais GRNN e MLP no software MATLAB, através das *toolboxes Neural Networks*.

As matrizes de entrada, para a realização do treinamento nas redes neurais, foram as cargas ativas e a matriz de saída os LMP gerados por um DC-OPF, os quais foram normalizados para que ficassem entre 0 e 1, forma a qual é exigida pelas redes neurais.

O sistema elétrico apresentado neste trabalho é o IEEE 24 RTS composto por 24 barras e cada barra contendo 200 amostras carga-preço. Obteve-se a previsão de preço do dia seguinte nas redes neurais GRNN e MLP. Posteriormente, realizou-se a análise das respectivas saídas comparando com o caso base, sem variação aleatória da carga, e com o artigo de Pandey et al.2008), onde o critério de avaliação adotado foi o erro máximo com uma margem variando ente 3% a 8%.

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 como consequência de suas características já apresentadas anteriormente.

No caso da rede MLP, não foi possível fornecer uma saída desejada, retornando um resultado igual à zero. Neste caso, foi necessária a adição de mais informação na entrada da rede neural, cujo parâmetro escolhido foi o tipo de barra, para fornecer a previsão em todas as barras do sistema elétrico. Desta forma, obtendo-se resultados satisfatórios, dentro dos padrões encontrados na literatura.

Ao efetuar a previsão global, utilizando com entrada todas as barras, nota-se que ambas as redes fornecem uma previsão, obtendo-se êxito nos resultados. Este resultado foi possível considerando-se todos os dados para treinamento independente da barra.

Na tentativa de melhorar a previsão global do sistema elétrico, foi realizado um novo teste retirando barras de interligação, unificando o sistema elétrico, uma vez que este sistema elétrico é formado por dois subsistemas, de modo a não interferir no desempenho do sistema, não obtendo resultados que superasse as redes MLP e GRNN, mesmo assim, a previsão global desta aplicação está dentro dos padrões encontrados na literatura especializa.

O objetivo deste trabalho é comparar o comportamento das respectivas redes, através das simulações deste sistema elétrico e comparando os resultados obtidos em cada rede neural.

Conclui-se que a proposta apresentada neste trabalho, tanto com a obtenção da série simulada, quanto com a escolha da rede neural foi adequada para realizar a previsão dos preços em função dos vários testes realizados, bem como com os erros encontrados.

Considerando os MAPES encontrados estes estão de acordo com aqueles encontrados na literatura. Sendo assim, a proposta apresentada neste trabalho demonstrou ser adequada em problemas de previsão de preço, tornando-se importante em tomadas de decisões em organizações do setor elétrico visando o benefício do consumidor final.

7.1 SUGESTÕES PARA TRABALHOS FUTUROS

Sugestões para possíveis trabalhos futuros são apresentadas a seguir:

- a utilização de um método estatístico como, por exemplo, ARIMA de Box e Jenkins juntamente com a rede neural formando um método híbrido;
- a realização de novos testes em outras redes neurais de forma a observar as respectivas saídas e a comparação com os valores obtidos nas redes utilizadas neste trabalho;
- realizar o mesmo procedimento feito com a rede MLP, adicionando os tipos de barras na entrada da rede neural GRNN;
- realizar leilões multi períodos;
- incluir previsão de carga como dado de entrada.

REFERÊNCIAS

AGGARWAL , S. K.; SAINI, L. M; KUMAR, A. Electricity price forecasting in deregulated markets: a review and evaluation. *Electrical Power and Energy Systems*, Haryana, v. 31, n. 2, p. 13–22, 2009.
Disponível em: < http://www.sciencedirect.com/science/article/pii/S0142061508000884>. Acesso em: 3 abr, 2013.

AMJADY, N.; KEYNIA, F. A new prediction strategy for price spike forecasting of day-ahead electricity markets, *Applied Soft Computing*, Semnan, v. 11, n.2, p. 4246–4256, 2011.
Disponível em: < http://www.sciencedirect.com/science/article/pii/S1568494611001207>. Acesso em: 15 mar 2013.

AMJADY, N.; KEYNIA, F. Day ahead price forecasting of electricity markets by a mixed data model and hybrid forecast method. *Electrical Power and Energy Systems*, Molavi, v. 30, n.1, p. 533–546, 2008.
Disponível em: < http://www.sciencedirect.com/science/article/pii/S0142061508000628 >. Acesso em: 18 nov 2012.

ANBAZHAGAN, S.; KUMARAPPAN, N. Day-ahead deregulated electricity market price classification using neural network input featured by DCT, *International Journal of Electrical Power & Energy Systems*, Cuddalore District, v. 37, n.2, p. 103-109, May 2012.
Disponível em: < http://www.sciencedirect.com/science/article/pii/S0142061511002948 >. Acesso em: 22 nov 2012.

ARANGO, S.; LARSEN, E. Cycles in deregulated electricity markets: empirical evidence from two decades *Energy Policy*, Lugano, v. 39, n.2, p. 2457-2466, 2011. Disponivel em: < http://www.sciencedirect.com/science/article/pii/S0301421511000863 >. Acesso em: 24 maio 2013.

ARAUJO, K. A. M. *Previsão de afluências por redes Neurais artificiais com diferentes treinamentos supervisionados utilizando o software MATLAB* 2011. 106 f, Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2011.

ARCINIEGAS, A. I.; ARCINIEGAS RUEDA, I. E. Forecasting short-term power prices in the Ontario Electricity Market (OEM) with a fuzzy logic based inference system. *Utilities Policy*, New York, v. 16, n.2, p. 39-48, 2008.
Disponível em: < http://www.sciencedirect.com/science/article/pii/S0957178707000719 >. Acesso em: 11 ago 2012.

BASHIR, Z. A.; EL-HAWARY, M. E. Load and locational marginal pricing prediction in competitive electrical power environment using computational intelligence. *Energy Conversion and Management***,** New York, v. 51, n.1, p. 490 – 495.
Disponível em: < http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=05090183 >.
Acesso em: 2 set 2012.

BERTRAND, R. G. *Multi-period equilibrium / near-equilibrium in electricity markets based on locational marginal prices*. 2005. 235 f. Tese (Doutorado) - Escuela Técnica Superior de Ingenieros Industriales, Universidad de Castilla-La Mancha, Madrid, 2005.

BIGDELI, N.; AFSHAR, K.; FOTUHI-FIRUZABAD, M. Bidding strategy in pay-as-bid markets based on supplier-market interaction analysis. *Energy Conversion and Management*, Qazvin, v. 51, n.2, p. 2419–2430, 2010.
Disponível em: < http://www.sciencedirect.com/science/article/pii/S0196890410001810 >.
Acesso em: 11 abr 2013.

BOX, G. E. P.; JENKINS, G. M.; REINSEL G. C. *Time series analysis:* forecasting and control. New York: Pearson Education, 2004. p. 598.

BRAGA, A. de P,; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. *Fundamentos de redes neurais artificiais*. Rio de Janeiro: UFRJ, 1998. p. 226.

BUNN, D. W. Forecasting loads and prices in competitive power markets. *Proc IEEE*, New York, v. 88, n.2, p. 163–169, 2000.
Disponível em: < http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=823996>.
Acesso em: 8 abr 2013.

CAIQING, Z.; PEIYU, M. Short-term electricity price forecasting based on pso algorithm and RBF neural network algorithm. *Energy Conversion and Management*, New York, v. 3,n.1, p.1-6, 2011. Disponível em: < http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=5459528 > Acesso em: 2 fev 2013.

CATALÃO, J. P. S.; POUSINHO, H. M. I.; MENDES, V. M. F. Short-term electricity prices forecasting in a competitive market by a hybrid intelligent approach. *Energy Conversion and Management*, Lisbon, v. 52, n.2, p. 1061–1065, 2011.
Disponível em: < http://www.sciencedirect.com/science/article/pii/S0196890410004012 >.
Acesso em: 22 jul 2012.

CRUZ, A.; MUÑOZ, A.; ZAMORA, J. L.; ESPINOLA, R. The effect of wind generation and weekday on Spanish electricity spot price forecasting, *Electric Power Systems Research*, Madrid, v. 81, n.1, p. 1924– 1935, 2011.
Disponível em: < http://www.sciencedirect.com/science/article/pii/S0378779611001313 >.
Acesso em: 25 jul 2012.

DAVID, P. A. M. S. Formação do preço, atração de investimentos e gerenciamento de risco no mercado brasileiro de energia elétrica. 2004 134 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Pontifica Universidade Católica – PUC, Rio de Janeiro, 2004. Disponível em: < http://www.lambda.maxwell.ele.puc-rio.br/Busca_etds.php?strSecao=resultado&nrSeq=5216@1 >. Acesso em: 18 ago 2013.

DUARTE, F.; FIDALGO, J. N.; SARAIVA, J. T. Forecasting electricity prices in spot markets – one week horizon approach. I*nstitute of electrical and electronics engineers*, New York, v. 51, n.2, p. 1-6, 2009 .
Disponível em: < http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=05282124 > Acesso em: 5 abr 2013.

GIRI, R.; CHOWDHURY, A.; GHOSH, A.; PANIGRAHI, B. K.; MOHAPATRA, A. Electricity price forecasting: a hybrid wavelet transform and evolutionary- ANN. approach, power electronics, drives and energy systems- pedes &. Power India. In: JOINT INTERNATIONAL CONFERENCE, 1., 2010, New York. *Anais...* New York: Harbra, 2010. Disponível em: < http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=5712575 >. Acesso em: 12 set. 2012.

GOMÉZ-EXPÓSITO, A; CONEJO, A. J.; CANIZARES, C. *Electric energy systems:* analysis and operation. New York: CRC, 2009. p. 664.

HAYKIN, S**.** *Neural networks:* a comprehensive foundation. New Jersey. Prentice-Hall , 1999. p. 696.

HEIMES F.; HEUVEL B. V. The normalized radial basis function neural network, *Institute of Electrical and Electronics Engineers*, New York, v. 2, n. 2, p. 1609-1614, 1998. Disponível em: < http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=728118 >. Acesso em: 9 out 2012.

LALITHA, S. V. N. L.; SYDULU, M., Hybrid neural network models for determination of locational marginal price, In IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS, 11., 2011, Malaca. *Conference...* Malacca: Hybrid Intelligent Systems - HIS, 2011. p. 424-429.
Disponível em: < http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=6122143 >. Acesso em: 5 out 2012.

LOTUFO, A. D. P. *Mercados elétricos e redes neurais*. Ciudad Real. Universidad de castilla la Mancha, 2012. (Processo CAPES BEX, 5665/11-6). Relatório final de estágio de Pós-Doutorado.

MANDAL, P.; SRIVASTAVA, A. K.; NEGNEVITSKY, A. K. Improving performance of nn based electricity price forecasting using sensitivity analysis. POWER SYSTEMS CONFERENCE AND EXPOSITION – PSCE, 9., 2011, Arizona. *Anais...* Arizona: Phoenix, 2011. Disponível em: < http://ieeexplore.ieee.org/xpls/a bs_all.jsp?arnumber=4840236 >. Acesso em: 13 maio 2012.

MEDEIROS, L. *Previsão do preço spot no mercado de energia elétrica*. 2003. 132 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, Pontifícia Universidade Católica – PUC, Rio de Janeiro, 2003. Disponível em: < http://fourier.lambda.ele.puc-rio.br/4777/4777_1.PDF >. Acesso em: 12 fev 2013.

MONTICELLI, A. E.; GARCIA, A. *Introdução a sistemas de energia elétrica*. Campinas: UNICAMP, 1999. p. 264.

NOSE-FILHO, K. *Previsão de carga multinodal utilizando redes neurais de regressão generalizada*. 2010. 81 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010. Disponível em: <http://www.acervodigital.unesp.br/handle/123456789/61505>. Acesso em: 10 out 2011.

PANDEY, S. N.; TAPASWI, S.; SRIVASTAVA, L. Growing RBFNN based soft computing approach for congestion management. *Neural Computing & Applications*, Gwalior, v. 18, n. 2, p. 945-955, 2009.
Disponível em: < http://www.researchgate.net/publication/220372373_Growing_RBFNN-based_soft_computing_approach_for_congestion_management >. Acesso em: 7 abr 2013.

PANDEY, S. N.; TAPASWI, S.; SRIVASTAVA, L. Integrated evolutionary neural approach with distributed computing for congestion management . *Applied Soft Computing*, Gwalior, v. 10,n. 2, p. 251-260, 2010.
Disponível em: < http://www.sciencedirect.com/science/article/pii/S1568494609001161 >. Acesso em: 7 abr 2013.

PANDEY, S. N.; TAPASWI, S.; SRIVASTAVA, L., Nodal congestion price estimation in spot power market using artificial neural network. *IET Generation Transmission and Distribution*, Gwalior, v. 2, n. 2, p. 280-290, 2008.
Disponível em: < http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=04459244 >. Acesso em: 7 abr 2013.

PANDEY, S. N.; VERMA, S.; SRIVASTAVA, L. ANN based approach for nodal congestion pricing. In: IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY – ICIT, 17., 2006, Munbai. *Conference...* Munbai: [s.n.], 2006. p. 15-17.
Disponível em: < http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4237654 >. Acesso em: 7 abr. 2013.

PARZEN, E. On estimation of a probability density function and mode, *Ann. Math. Statist.*, New York, v. 33, n. 2, p. 1065-1076, 1962.
Disponível em: < http://ssg.mit.edu/cal/abs/2000_spring/np_dens/density-estimation/parzen62.pdf >. Acesso em: 2 dez 2012.

PINDORIYA, N. M.; SINGH, S. N.; SINGH, S. K., An adaptive wavelet neural network based energy price forecasting in electricity markets. *IEEE Transactions on Power Systems*,New York, v. 23, n.2, p. 1423-1432, 2008.
Disponível em:
< http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4494757&userType=inst >.
Acesso em: 21 jan 2013.

SCHWEPPE, F. C.; CARAMINIS M. C.; TABLORS R. D.; BOHN R. E. **Spot pricing of electricity.** São Paulo: Springer, 1988. p. 384.

SHAFIE-KHAH, M.; MOGHADDAM, P. ; SHEIKH-EL-ESLAMI, M. K. Price forecasting of day-ahead electricity markets using a hybrid forecast method, *Energy Conversion and Management*, Tehran, v. 52, n. 2, p. 2165–2169, 2011.
Disponível em: < http://www.sciencedirect.com/science/article/pii/S0196890410005212 >
Acesso em: 3 jun 2013.

SILVA I. N.; SPATTI D. H.; FLAUZINO R. A. *Redes neurais artificiais*: para engenharia e ciências aplicadas. São Paulo: Artiber, 2010. p. 399.

SINGHAL, D.; SWARUP, K. S., Electricity price forecasting using artificial neural networks, *IEEE Electrical Power and Energy Systems*, New Delhi, v. 33,n. 2, p. 550–555, 2011.Disponível em: < http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4148001 >.
Acesso em: 23 mar 2013.

SPECHT, D. F. A generalized regression neural network. **IEEE Transactions on Neural Networks**, New York, v. 2, p. 568-576, 1991.
Disponivel em: < http://research.vuse.vanderbilt.edu/vuwal/Paul/Paper/References/grnn.pdf>
Acesso em: 13 nov 2011.

TANG, Q.; GU, D. Day-ahead electricity prices forecasting using artificial neural networks. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND COMPUTATIONAL INTELLIGENCE- AICI,1., 2009, Xangai. *Conference...* Xangai: Institute of Electrical and Electronics Engineers, 2009. p. 511 - 514
Disponível em: < http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5375895 >
Acesso em: 8 set. 2012

TSAI, M. T.; CHEN, C. H. A forecasting system of electric price using the refined backpropagation neural network. *IEEE Electrical Power and Energy Systems*, Hangzhou, v. 51, n. 2, p. 1-6, 2010.
Disponível em: < http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5666458 >
Acesso em: 12 out 2012.

VAHIDINASAB, V.; JADID, S.; KAZEMI, A. Day-ahead price forecasting in restructured power systems using artificial neural networks. *Electric Power Systems Research*, Tehran, v. 78, n.1, p. 133:2–1342, 2008.
Disponível em: < http://www.sciencedirect.com/science/article/pii/S0378779607002362 > Acesso em: 4 abr 2013.

WERBOS, P. J. *Beyond regression:* new tools for prediction and analysis in the behavioral sciences. 1975. 906 f. Thesis (Doctor) - Harvard University, Boston, 1974.

ZAREZADEH, M.; NAGHAVI, A.; GHADERI, S. F. Electricity price forecasting in Iranian electricity market applying artificial neural networks. In: IEEE ELECTRICAL POWER & ENERGY CONFERENCE EPEC, 2, 2008, Vancouver. *Conference…* Vancouver: Institute of Electrical and Electronics Engineers, 2008. p. 1 - 6.
Disponível em: < http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4763300 > Acesso em: 12 maio 2012.

ZHANG, N.; BEHERA, P. P. K. Solar radiation prediction based on recurrent neural networks trained by levenberg-marquardt backpropagation learning algorithm. In: IEEE ELECTRICAL POWER & ENERGY CONFERENCE,1, 2012, Whashington. *conference…* Whashington: Institute of Electrical and Electronics Engineers, 2012. p. 1 – 7. Disponível em: < http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6175757 >. Acesso em: 7 nov. 2012.

ZIMMERMAN, R. D.; MURILLO-SÁNCHEZ C. E. MATPOWER: steady-state operations, planning and analysis tools for power systems research and education, power systems. *IEEE Transactions on***,** New York, v. 26, n. 1, p. 12-19, 2011. Disponivel em: <http:/www.pserc.cornell.edu/matpower.> Acesso em: 15 dez 2011.

APÊNDICE A

TRABALHO PUBLICADO EM ANAIS DE CONGRESSO

FREITAS, Patrícia Fernanda da Silva; ALGUALCIL, Natalia; LOTUFO, Anna Diva Plasencia; SILVEIRA, Maria do Carmo Gomes. Rede neural de regressão generalizada para previsão de preço em mercados de eletricidade. In: LATIN-AMERICAN CONGRESS ON ELECTRICITY GENERATION AND TRANSMISSION- CLAGTEE, 10., 2013, Viña del Mar. *Conference…* . Viña del Mar:[s.n], 2013. p. 1-7.

FREITAS, P. F. S.; LOTUFO, A. D. P.; ALGUACIL, N; SILVEIRA, M. C. G. Um método de previsão de preço da carga, utilizando redes neurais de regressão generalizada e perceptron multicamadas. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE- SBAI, 11, 2013, Fortaleza. *Anais*... Fortaleza: [s.n], 2013. p.1-6