

PREVISÃO DA DEMANDA DE ENERGIA ELÉTRICA NO CURTÍSSIMO PRAZO BASEADA EM REDES NEURAS ARTIFICIAIS RECORRENTES NARX

Luciano Carli Moreira de Andrade
Athila Quaresma Santos
Mário Oleskovicz
Denis Vinicius Coury

Universidade de São Paulo- USP
Escola de Engenharia de São Carlos- EESC
Departamento de Engenharia Elétrica e de Computação
e-mails: {[lucarli](mailto:lucarli@sc.usp.br), [olesk](mailto:olesk@sc.usp.br), [coury](mailto:coury@sc.usp.br)}@sc.usp.br, athila.santos@usp.br
Av. Trabalhador São-carlense, 400 - CEP 13566-590, São Carlos, SP.

Abstract – Time series forecasting is an important aspect in many fields such as science, economics, engineering and other segments that use historical data to forecast future problems. There are numerous techniques that can be used to do forecasting. Among them, artificial neural networks can be used as they present promising results when compared to traditional statistical techniques. Therefore, this study aims to evaluate the performance of NARX recurrent neural networks for the purpose of performing very-short term load demand forecasting in distribution substations. The best topologies of NARX recurrent neural networks were determined by using the tool known as cross-validation for the case studies with time series of very short term load demand measured in three Brazilian substations. The results were presented in graphs and tables and compared to those obtained with the use of feed forward and Elman neural networks, widely used in forecasting tasks. Additionally the performance of NARX recurrent neural networks was evaluated for forecasting horizons of up to five steps ahead. The results showed the superiority of NARX recurrent neural networks when compared to feed forward and Elman neural networks, and also to other approaches presented in the literature.

Keywords – Time series forecasting, load demand forecasting, NARX recurrent artificial neural networks.

Resumo – Previsão de séries temporais é um aspecto importante em vários campos da ciência, passando por economia, engenharia e outros segmentos que fazem uso de dados históricos para prever problemas futuros. Existem inúmeras técnicas que podem ser empregadas para realizar previsão. Dentre estas, têm-se as Redes Neurais Artificiais (RNA), que têm apresentado resultados promissores quando comparadas com técnicas estatísticas tradicionais. Neste sentido, esta pesquisa tem por objetivo avaliar o desempenho de RNAs recorrentes NARX (*Nonlinear Autoregressive Model with Exogenous Input*) com o propósito de executar uma previsão para a demanda de energia elétrica em curtíssimo prazo em subestações de distribuição. As melhores topologias das RNAs recorrentes NARX foram determinadas com o uso da ferramenta padrão conhecida por validação cruzada. As topologias foram avaliadas e empregadas no estudo de casos com séries temporais de demanda de energia elétrica no curtíssimo prazo mensurado em três subestações brasileiras. Os resultados observados foram apresentados de forma gráfica e por tabelas, sendo comparados com os obtidos pelo uso de RNA *feed forward* e de Elman, amplamente empregadas em tarefas de previsão. Adicionalmente foi avaliado o desempenho das RNAs recorrentes NARX para previsão de horizontes de até cinco passos à frente. Os resultados obtidos demonstram a superioridade das RNAs recorrentes NARX quando comparadas às RNAs *feed forward* de Elman, como também, à de outras abordagens encontradas na literatura correlata.

Palavras Chaves – Previsão de séries temporais, previsão de demanda de energia elétrica, redes neurais artificiais recorrentes NARX.

1. INTRODUÇÃO

Para que sistemas elétricos de potência (SEP) possam realizar operações confiáveis e econômicas é imprescindível o uso da previsão de demanda de energia elétrica em horizontes de curtíssimo prazo, ou seja, de alguns minutos à frente. Um dos objetivos fundamentais do controle do sistema é manter o balanço entre a demanda e o fornecimento de energia elétrica. O controle primário usado para atender este objetivo é chamado de Controle Automático de Geração (CAG). Este atualiza

periodicamente a carga conectada aos geradores utilizando exemplos de carga-frequência do SEP. Em sistemas típicos, os exemplos da taxa de controle utilizados variam de horizontes de um a dez minutos [1,2]. Com o objetivo de aprimorar seu desempenho, novos algoritmos do CAG têm sido empregados e requerem previsões em horizontes de trinta a cento e vinte minutos, em uma taxa de um a dez minutos [3].

Previsões de curtíssimo prazo, integradas às informações como programação de transações de compra e venda de energia por meio de redes de terceiros, disponibilidade de transmissão, custo de geração, preço da energia no mercado de pronta entrega e exigências de reserva girante impostas por operadores de sistemas independentes, são utilizadas para determinar a melhor estratégia no uso dos recursos das concessionárias de energia [4,5].

Diferentemente dos trabalhos com horizontes de previsão mais distantes, onde são considerados fatores que influenciam a demanda por energia elétrica, tais como, condições meteorológicas e socioeconômicas, a previsão de demanda de energia no curtíssimo prazo (cujos horizontes são inferiores à uma hora) requer uma abordagem onde o objetivo é voltado exclusivamente para a observação do comportamento das medidas recentes de carga [4,6]. Em [7] é também constatado que essa estratégia apresenta os melhores resultados para previsão de demanda de energia elétrica para horizontes inferiores à uma hora.

Em horizontes de previsão de curto prazo, ou seja, de uma hora até alguns dias à frente, existem inúmeros métodos que foram empregados nos últimos anos. Dentre os quais, está o alisamento exponencial Holt-Winters, a análise de componentes principais, o modelo ARIMA (*AutoRegressive Integrated Moving Average*) [8], sistemas *fuzzy* [9], sistemas híbridos [10]-[13] e Redes Neurais Artificiais (RNA) [14], [15].

Já os métodos para previsão de demanda de energia elétrica no curtíssimo prazo não são numerosos [4]-[6], [16]. Algumas técnicas incluem estimadores de Kalman [1], sistemas *fuzzy* [2], extrapolação exponencial de primeira e segunda ordem, modelos AR (*Autoregressive*) e ARMA (*Autoregressive Moving Average*), e RNA [4,5].

Os trabalhos relacionados com a previsão de séries temporais utilizando redes neurais NARX (*NonlinearAutoregressiveModelwithExogenous Input*) têm ganhado destaque. Em [17] propõe-se o uso da arquitetura recorrente NARX para a mitigação do baixo desempenho do gradiente descendente. Já em [18], os autores utilizam redes recorrentes para modelar a previsão de séries temporais discretas, onde a utilização de redes *feedforward* requereria uma quantidade infinita de observações. Os autores de [19] utilizam uma rede neural híbrida Elman-Narx para a previsão de séries temporais caóticas. Adicionalmente, em [20] avalia-se, em termos qualitativos e quantitativos, a habilidade preditiva das redes NARX-P e NARX-SP em séries temporais para horizontes de previsão de longo prazo.

Neste contexto, a pesquisa em questão tem como finalidade determinar os melhores parâmetros e topologias das RNA NARX para a previsão de demanda da energia elétrica no curtíssimo prazo. Neste sentido, a ferramenta estatística conhecida como validação cruzada será empregada por fornecer um princípio orientador e atraente para a solução desse tipo de problema [20].

O artigo está organizado nas seguintes seções: na Seção II é apresentada uma revisão da literatura relacionada à previsão de demanda de energia elétrica; na Seção III são apresentados os aspectos das séries temporais de demanda que foram considerados; na Seção IV são apresentados alguns aspectos das RNANARX empregadas para a previsão de demanda no curtíssimo prazo; a metodologia para a determinação das melhores topologias das RNA é apresentada na Seção V; os resultados da previsão decorrentes desta abordagem são apresentados na Seção VI; dados comparativos com outras abordagens frequentemente empregadas no problema são apresentados na Seção VII; sendo que a Seção VIII traz as conclusões a respeito deste trabalho.

2. PREVISÃO DE DEMANDA DE ENERGIA ELÉTRICA

Existem diversos trabalhos publicados sobre previsão de demanda de energia elétrica. Estes trabalhos são classificados em quatro grupos de acordo com os horizontes de previsão [24].

O primeiro horizonte é o de longo prazo, e se caracteriza por previsões de um a dez anos à frente. São empregados para apontar a necessidade de desenvolvimento de sistemas de transmissão e de distribuição, e também no planejamento da geração de energia [18,25].

O segundo horizonte é o de médio prazo que se caracteriza por previsões de alguns meses a um ano. São necessárias para garantir restrições de segurança, previsões de capacidade de demanda [24], realização de manutenção programada das unidades, compra de combustíveis, estimação de compra e venda de energia e exploração das reservas hidrológicas [26].

O horizonte de curto prazo (terceiro horizonte) é aquele que apresenta o maior número de trabalhos, tornando-se uma questão chave para a operação dos SEP. Assim, a previsão de demanda de energia elétrica no curto prazo é uma ferramenta importante para uma confiável e econômica operação, pois muitas decisões operacionais, tais como programação de despacho da capacidade de geração, análises de confiabilidade, avaliação da segurança e planejamento da manutenção dos geradores são tomadas a partir deste horizonte [24].

O quarto e último horizonte de previsão, foco desta pesquisa, é o de curtíssimo prazo, ou minutos à frente. Este é primordialmente empregado para permitir um CAG mais eficiente [3], que tem por função manter o equilíbrio (balanço) entre a demanda e o fornecimento de energia elétrica.

Existem poucos trabalhos publicados sobre esse horizonte de previsão.

A referência [2] propõe e discute três técnicas para a previsão de demanda de energia elétrica no curtíssimo prazo. As técnicas investigadas foram lógica *fuzzy* (LF), RNA e o modelo auto-regressivo (AR). Os resultados apresentados ilustraram a viabilidade do projeto de um simples e satisfatório previsor para tendências no curtíssimo prazo. O desempenho dos previsores baseados em LF e RNA foram superiores àquele baseado no modelo AR.

Já a referência [4] compara duas abordagens para previsão de demanda de energia elétrica no curtíssimo prazo por meio de RNA. Na primeira abordagem são adotadas como entradas as medidas de carga mais recentes para prever a demanda um passo a frente. Na segunda abordagem são assumidas como entradas as diferenças relativas entre duas medidas consecutivas da carga. Os promissores resultados apresentaram um erro percentual médio absoluto - MAPE (*Mean Absolute Percentage Error*) de 1,25% a 0,66%.

A referência [5] também faz uso de RNA para previsão de demanda no curtíssimo prazo. As saídas das RNA sofrem ajustes por parte da teoria *rough set* a fim de alcançar maior precisão. Os resultados obtidos indicaram que o método melhorou significativamente a previsão.

Vale comentar que o foco principal de muitos dos trabalhos já publicados é a comparação entre métodos. A referência [7], por exemplo, faz uma comparação entre dez métodos utilizados para previsão de demanda de energia elétrica no curtíssimo prazo. São empregados métodos como modelos ARIMA, abordagens de alisamento exponencial, como Holt-Winters, e técnicas baseadas em previsões meteorológicas. Em oito dos dez métodos, os seus erros permanecem entre 0,3% e 2% para a previsão de até trinta minutos à frente. Uma contribuição importante do trabalho foi a da confirmação de que previsões com dados meteorológicos são superiores apenas em horizontes maiores do que uma hora.

A referência [16] apresenta uma abordagem baseada em RNA com pré-processamento por meio da Transformada *Wavelet* (TW) e um método de pré-filtragem das entradas para previsão de demanda de energia elétrica no curtíssimo prazo. A previsão ocorre para até uma hora à frente em passos de cinco em cinco minutos. A TW é empregada para representar a carga em vários níveis de frequência. Cada nível é analisado de forma apropriada e apresentado para uma RNA a fim de que os padrões da carga sejam bem modelados. Para melhorar a previsão, um perfil de carga correspondendo a 10 dias similares foi considerado. O MAPE para previsão de cinco minutos à uma hora a frente variou de 0,1% a 0,59%.

A referência [24] compara quatro métodos diferentes para a previsão de demanda de energia elétrica no curtíssimo prazo. O desempenho dos vetores de suporte de regressão é comparado com a regressão linear, com a média dos mínimos quadrados e com RNA por retro propagação. Para cada um dos métodos, quatro abordagens são empregadas. Na primeira foi feita a classificação dos dados de acordo com os dias da semana, ou seja, dados de dias similares, de semanas anteriores, foram empregados como entrada para a previsão de determinado dia. Na segunda, os dados de cada dia foram divididos em quatro períodos. Para fazer a previsão de um horário, dentro de determinado período, foram apresentadas as medidas anteriores, e valores binários, indicando que a medida a ser estimada pertence a determinado intervalo do dia. Na terceira, os dias da semana foram classificados em quatro categorias. Medidas anteriores e dados binários indicando à qual das quatro categorias pertence à medida a ser prevista foram apresentadas como entrada para os métodos de previsão. Os resultados demonstraram que a regressão por vetores de suporte, a regressão linear e a média dos mínimos quadrados, obtiveram os melhores desempenhos com MAPE chegando a 0,31%. As RNA por retropropagação apresentaram resultado sensivelmente inferior, com um MAPE de 0,4%.

A referência [25] apresenta uma abordagem para previsão de demanda de energia elétrica baseada na técnica da reconstrução dinâmica caótica e na teoria da LF. Depois que a ordem do modelo é estimada pela teoria da reconstrução, dois sistemas neurofuzzy estruturados são apropriadamente projetados e empregados na previsão. O melhor sistema é escolhido de acordo com o método de *Dimension Switching Detector* que se baseia no erro apresentado pelos diferentes sistemas neurofuzzy. O resultado apresentado pelas RNA foi caracterizado por um MAPE de 1,06% e pelo sistema neurofuzzy com um MAPE de 0,88%.

Este trabalho em questão apresenta a previsão de demanda no curtíssimo prazo baseada em RNA recorrentes NARX. Pode-se dizer que a abordagem a ser apresentada não exigiu nenhum pré-processamento dos dados, a não ser sua normalização. Os dados não foram divididos de acordo com os dias da semana, ou períodos do dia, e também não foram decompostos em componentes, ou apresentados na forma da diferença entre medidas consecutivas. Desta maneira, pode-se classificar a técnica a ser exposta como mais simples do que as apresentadas nos trabalhos citados. Vale também comentar que foram analisadas três séries temporais distintas com comportamento variado, e não apenas uma série como em alguns dos trabalhos mencionados. Isso permite apontar com maior segurança que a técnica aqui empregada foi eficiente. Outro fator importante a ser ressaltado é que os resultados serão apresentados por gráficos de barras dos erros e sua variância, onde se pode identificar o valor dos erros

nos piores casos. Tal abordagem é importante no contexto apresentado, pois permitirá evidenciar que em muitos casos, a média dos erros pode ser pequena, mas que em determinados pontos, o erro pode ser significativo.

3. SÉRIES TEMPORAIS DE DEMANDA

As séries temporais de demanda de energia elétrica estudadas nesse trabalho são indicadas na Figura 1 e foram registradas ao longo de uma semana, iniciando-se na segunda-feira e terminando no domingo, em intervalos de 5 minutos, em três subestações de energia elétrica brasileiras.

Pela Figura 1, verifica-se que as séries temporais das Subestações I e III têm um comportamento sazonal bem evidente. Nas primeiras horas da madrugada (entre zero hora e seis horas da manhã) o consumo de energia é baixo, aumentando durante a manhã (depois das sete horas), até uma pequena queda no início da tarde (ao meio dia). Este consumo volta então a aumentar durante a tarde (entre as duas e as seis horas da tarde) e atinge um pico máximo no início da noite (oito horas da noite). Depois desse pico, o consumo diminui até atingir seu ponto mínimo durante a madrugada. Pode-se verificar também um comportamento sensivelmente distinto para os dois últimos dias que reflete o final de semana (sábado e domingo). A série temporal da Subestação II apresenta um comportamento também sazonal, mas com fortes variações ao longo dos dias da semana, sendo que na segunda e terça-feira o consumo é menor do que nos outros dias.

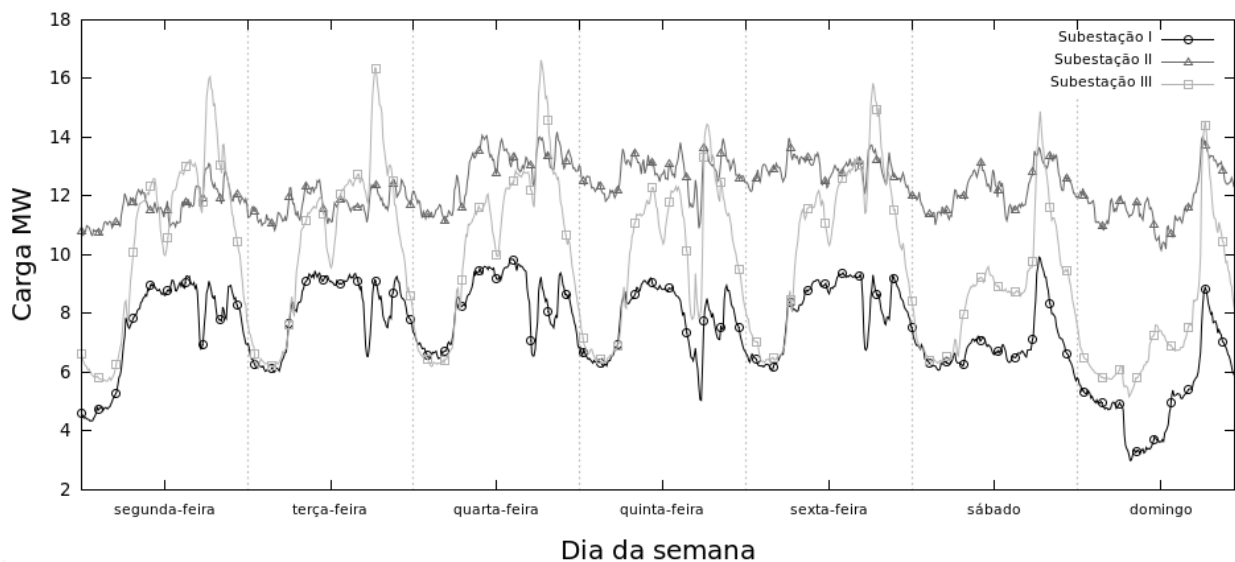


Figura 1 –Séries temporais de demanda de energia elétrica.

4. ASPECTOS SOBRE AS REDES NEURAS ARTIFICIAIS NARX

O modelo NARX (*Nonlinear Autoregressive Model with Exogenous Input*) representa matematicamente uma importante e útil classe de sistemas não lineares de tempo discreto, definido como:

$$y(n) = \hat{x}(n + 1) = f[\bar{u}(n); \bar{y}(n - 1)] \quad (1)$$

$$y(n) = \hat{x}(n + 1) = f[x(n), \dots, x(n - d_u + 1); \widehat{\hat{x}}(n), \dots, \hat{x}(n - d_y + 1)] \quad (2)$$

Onde $\bar{u}(n) \in \mathbb{R}$ e $\bar{y}(n) \in \mathbb{R}$ denotam, respectivamente, a entrada e a saída do modelo no passo de tempo discreto n , enquanto $d_u \geq 1$ e $d_y \geq 1$ com $d_u \leq d_y$ são as ordens da memória de entrada e memória de saída. A Figura 2 ilustra uma rede neural recorrente NARX com uma camada escondida. Deve-se mencionar que as RNA recorrentes NARX podem possuir mais de uma camada escondida.

A função $f(\cdot)$ é um função não linear, geralmente desconhecida. Fazendo-se a aproximação dessa função por meio de uma rede neural MLP, a topologia resultante é conhecida como redes recorrentes NARX, que constitui uma importante classe de arquiteturas neurais dinâmicas, computacionalmente equivalentes à máquina de Turing [26]. Redes neurais recorrentes são sistemas dinâmicos com propriedades sensitivas às sequências temporais. Na abordagem das redes neurais recorrentes

NARX foi criada uma camada de entrada com neurônios adicionais, como pode ser visto na Figura 2. Tais unidades interagem com outros nós internos da rede neural e permitem a apresentação para as redes neurais recorrentes NARX das saídas estimadas por ela mesma.

A rede neural recorrente NARX pode ser treinada e utilizada no modo de identificação paralelo, que também pode ser chamado de modo recorrente, e no modo de identificação série-paralelo, que também pode ser chamado de modo não-recorrente [23]. A Figura 2 apresenta o modo de identificação paralelo, uma vez que esta pesquisa tem por objetivo avaliar o desempenho de redes neurais recorrentes NARX.




Figura 2–Rede neural artificial recorrente NARX.

5. METODOLOGIA

5.1 ASPECTOS GERAIS SOBRE A VALIDAÇÃO CRUZADA

Segundo[20], a ideia principal da aprendizagem por retropropagação é ajustar os pesos sinápticos e limiares de um *perceptron* multicamadas de acordo com um mapeamento entrada-saída. Espera-se que a rede, uma vez que bem treinada, aprenda o suficiente sobre o passado para generalizar o futuro.

Nesse contexto, uma ferramenta padrão de estatística conhecida como validação cruzada fornece um princípio orientador atraente. Inicialmente, o conjunto de dados é dividido de forma aleatória em um conjunto de treinamento e em um conjunto de teste. O conjunto de treinamento é subdividido em dois conjuntos disjuntos:

- Subconjunto de estimação, usado para selecionar o modelo; e
- Subconjunto de validação, usado para testar ou validar o modelo.

Essa subdivisão tem por objetivo validar o modelo com um conjunto de dados distinto do que foi utilizado para estimar os parâmetros da RNA. Pode-se então usar o conjunto de treinamento para avaliar o desempenho de inúmeros modelos candidatos a fim de escolher o melhor. Contudo, existe a possibilidade de que o modelo selecionado dessa forma ajuste excessivamente o subconjunto de validação. Para evitar essa possibilidade, o poder de generalização do modelo selecionado é determinado por meio de um conjunto do teste distinto do conjunto de validação.

Vale afirmar que o uso da validação cruzada foi atrativo para este trabalho para a determinação dos parâmetros estruturais e de treinamento das RNA-NARX com o objetivo de garantir uma capacidade de generalização apropriada.

Conforme será apresentado, o procedimento de seleção do modelo baseado na validação cruzada fornece uma abordagem bem-fundamentada para determinar o número de neurônios ocultos de um *perceptron* multicamadas [20], e nesse trabalho foi

empregado com sucesso na determinação da melhor topologias RNA-NARX para previsão de demanda de energia elétrica no curtíssimo prazo.

5.2 METODOLOGIA POR MEIO DA VALIDAÇÃO CRUZADA

A seleção das variáveis de entrada se resume ao uso exclusivo da série temporal da carga mensurada, pois, segundo [4], a previsão de demanda de energia elétrica no curtíssimo prazo exige uma abordagem cujo foco deve ser voltado para o padrão apresentado pelas últimas leituras observadas, e não para a relação da demanda com fatores que a influenciariam, como, por exemplo, condições meteorológicas, sociais e econômicas.

Posto isso, nesta pesquisa, a validação cruzada pode ser descrita pelo fluxograma da Figura 3, contendo os seguintes passos:

- Divisão dos dados em conjuntos de treinamento, validação e teste, na proporção de 5 dias para treinamento (de segunda à sexta-feira), 1 dia para validação (sábado), e 1 dia para teste (domingo);
- Normalização dos dados entre -1 e 1, para minimizar o tempo de aprendizagem e evitar o uso de entradas com média diferente de zero[20];
- Determinação do número de entradas para formação dos padrões entrada e saída. Vale adiantar que o melhor resultado encontrado foi considerando quatro entradas para os dados de todas as subestações estudadas;
- Determinação do número de neurônios para uma camada intermediária. O melhor número encontrado foi de cinco neurônios para todos os casos estudados;
- Uso das funções de ativação tangente hiperbólica e linear, para os neurônios escondidos, e para o único neurônio da camada de saída, respectivamente;
- Uso do algoritmo de treinamento *Levenberg-Marquardt* para ajuste dos pesos da rede neural devido à convergência mais acentuada da curva de treinamento;
- Determinação do melhor número de ciclos para o treinamento; e
- Caso o MAPE calculado diminua durante o ciclo de validação cruzada, novas modificações na formação dos padrões, na topologia da RNA e seus parâmetros devem ser verificados e, caso o MAPE não diminua depois de algumas tentativas, considera-se os valores obtidos para o menor MAPE encontrado.

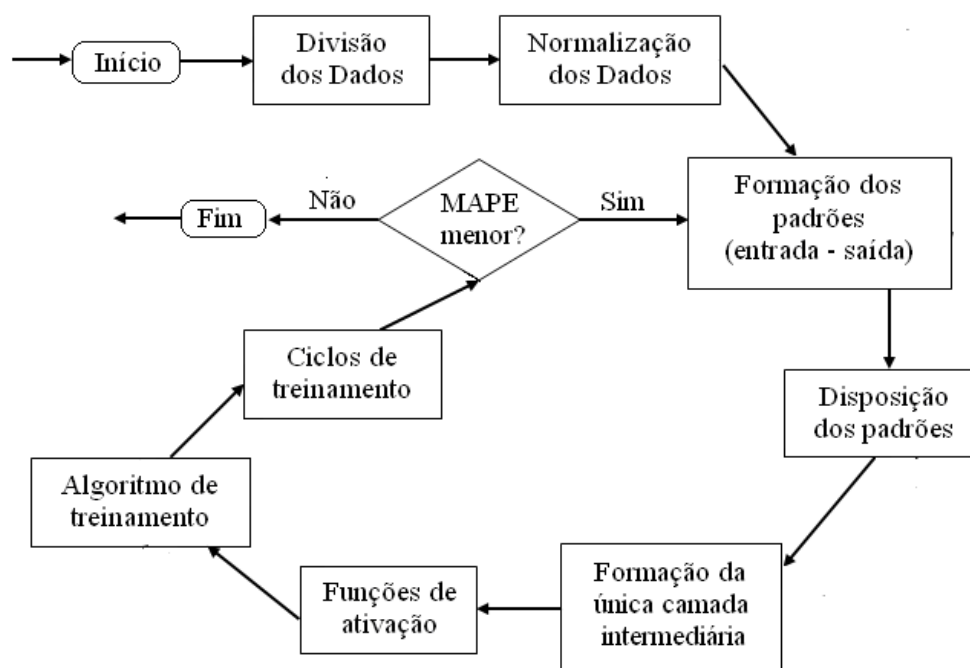


Figura 3– Fluxograma para a validação cruzada empregada.

5.3 MAPE

As diversas topologias foram avaliadas calculando-se o erro percentual médio absoluto - MAPE para o conjunto de teste. Esta metodologia é amplamente empregada no problema de previsão de séries temporais:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{d_i - o_i}{d_i} \right| \times 100\% \quad (3)$$

Onde d_i é a saída desejada, o_i é a saída obtida e N é o número de padrões de teste.

6. APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

Conforme anteriormente apresentado, o objetivo desse trabalho é demonstrar a capacidade de previsão das RNA-NARX. Para isso, estas foram empregadas na previsão de demanda de energia elétrica no curtíssimo prazo. Esta previsão poderá ser empregada como informação complementar para regular a demanda e a oferta por energia elétrica a fim de minimizar possíveis flutuações, evitando assim, distúrbios indesejáveis na operação do SEP como um todo. Neste contexto, analisaram-se as séries temporais mensuradas em intervalos de cinco minutos, ao longo de sete dias, em três subestações.

Determinada a melhor topologia (quatro entradas e cinco neurônios em uma camada intermediária) por meio da validação cruzada (menor MAPE), foram traçadas as curvas de treinamento, tabelados os MAPE de três treinamentos distintos e calculada sua média, traçadas a curva mensurada e a prevista ao longo do conjunto de teste, como também, foram compilados os gráficos com a distribuição dos erros relativos para cada uma das medidas que constituem as leituras do último dia (domingo), ou conjunto de teste.

6.1 SUBESTAÇÃO I

Como mencionado, os dados foram divididos na proporção de cinco dias para treinamento, um dia para validação e um dia para teste. Uma vez treinada a RNA-NARX, os dados do dia determinado para teste (último dia) foi apresentado para que esta fizesse a previsão de um passo à frente. No gráfico da Figura 4, representa-se a curva desejada (registrada na subestação) e a curva obtida (estimada pela RNA-NARX). Observa-se que as duas curvas possuem comportamento similar ao longo de todos os dados de teste, sendo o MAPE obtido para os dados da Subestação I de 0,7973%.




Figura 4 – Curvas de demanda desejada e obtida por meio da previsão com a RNA-NARX.

Ao longo do gráfico de barras da Figura 5 são apresentados os valores do erro relativo percentual para cada um dos pontos que formam os dados de teste para a Subestação I. Por meio da figura, observa-se que a grande maioria dos erros ficou abaixo de 1%, uma vez que sua média, como mencionado anteriormente, foi de 0,7973%. Verifica-se também a existência de alguns pontos onde a RNA-NARX teve maior dificuldade para estimar o valor desejado. Como, por exemplo, na queda do consumo de energia que a curva apresenta às sete horas da manhã, onde o erro relativo percentual ficou próximo a 9%, como também, na previsão do aumento do consumo de energia que começa às seis horas da tarde, onde o erro relativo percentual foi de 4%.

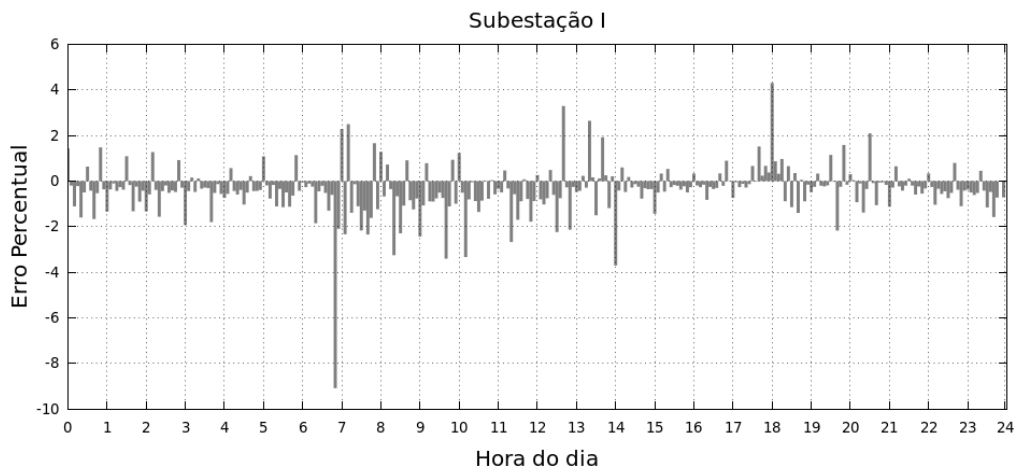


Figura 5 –Gráfico de barras com os erros de previsão ao longo do dia.

Uma vez calculado o MAPE para a previsão de um passo à frente, os dados estimados foram apresentados como entrada para a RNA-NARX para que esta estime dois passos à frente, e assim sucessivamente. Consta-se pelo gráfico de barras da Figura 6 o aumento do MAPE que atingiu o valor de 4,7074% para um horizonte de cinco passos à frente. Isso se deve ao fato de que na medida em que dados estimados pela RNA-NARX são adotados como entrada para prever múltiplos passos à frente, esses agregam os erros na previsão dos passos anteriores.




Figura 6 –Gráfico do MAPE da Subestação I para até cinco passos à frente.

6.2 SUBESTAÇÃO II

Como no caso dos dados da Subestação I, os dados foram divididos em treinamento, validação e teste, adotando-se para teste o último dia dentre os sete dias registrados para a Subestação II. No gráfico da Figura 7 foram traçadas as curvas para os dados desejados (registrados na subestação) e para os dados obtidos (estimados pela RNA-NARX) para um passo à frente. Visualiza-se um comportamento similar entre as duas curvas, sendo este caracterizado por um MAPE de 0,3926%.

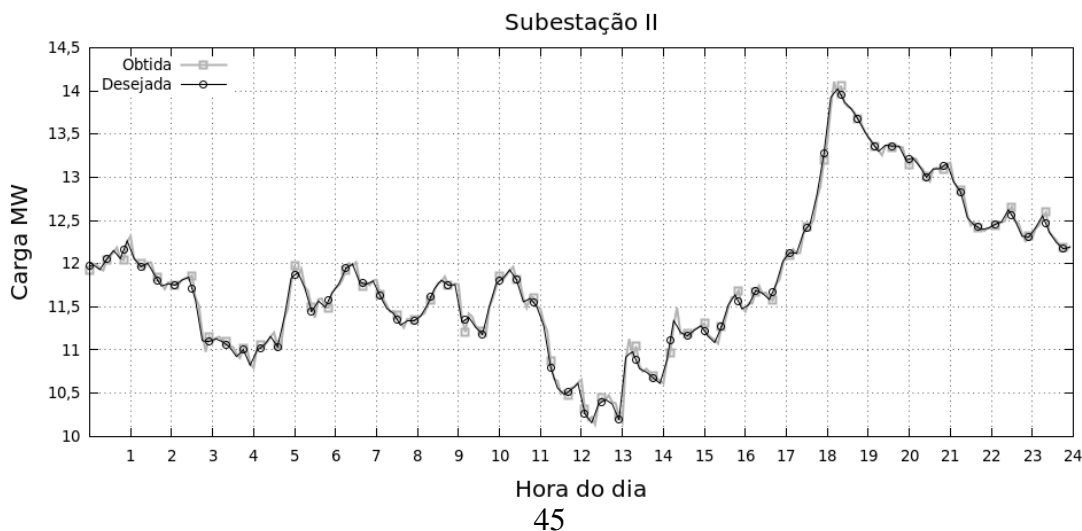


Figura 7–Curvas da demanda desejada e obtida por meio da previsão com a RNA-NARX.

Uma vez traçados os gráficos da curva desejada e obtida pela RNA-NARX, também foi calculado o erro relativo percentual para cada uma das medidas que formam o conjunto de teste. Por meio do gráfico da Figura 8 é possível verificar o desempenho da rede na estimação de cada uma das medidas do último dia mensurado na Subestação II. Como no caso da Subestação I, a maioria dos erros relativos percentuais ficou abaixo de 1%, uma vez que o MAPE foi de apenas 0,3926%. Também se observa que a rede apresentou maior dificuldade na previsão no período das onze horas da manhã até às duas horas da tarde, apresentando um erro relativo percentual máximo de 4% à uma hora da tarde. Isso se deve ao fato de ocorrer uma queda mais acentuada no consumo de energia elétrica neste horário.




Figura 8–Gráfico de barras com os erros de previsão ao longo do dia.

Uma vez determinada a previsão de demanda da energia elétrica para um passo à frente, os valores estimados foram apresentados como entrada para a RNA-NARX para a previsão de múltiplos passos, e assim, avaliar o seu comportamento para esta tarefa. Como mencionado anteriormente, e como apresentado no gráfico da Figura 9, o MAPE para os dados mensurados na Subestação II foi de 0,3926% para um passo à frente, subindo para 0,5163% para dois passos à frente, e assim sucessivamente, até atingir um MAPE de 1,7448% para cinco passos à frente. Novamente, vale frisar que tais erros se justificam devido à propagação dos erros obtidos nos passos anteriores.

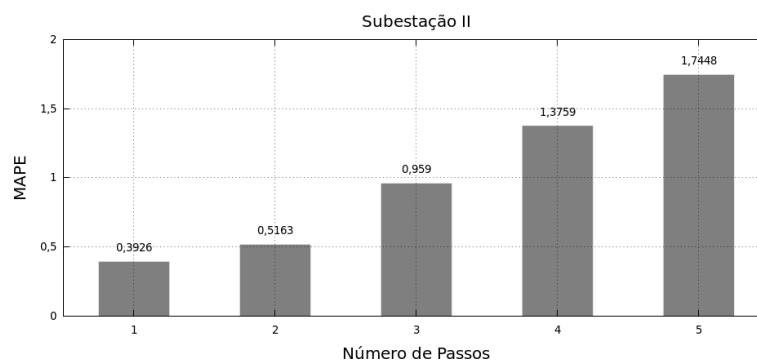


Figura 9–Gráfico do MAPE da Subestação II para até cinco passos à frente.

6.3 SUBESTAÇÃO III

Os dados registrados na Subestação III também foram apresentados para a RNA-NARX para avaliar o seu desempenho. Assim como nas subestações anteriores, a primeira análise foi conduzida para a previsão de um passo a frente, onde seu desempenho também foi promissor. O MAPE resultante foi de 0,5189%. Pela Figura 10, observa-se que as curvas das medidas registradas (desejadas) e estimadas para a Subestação III pela RNA-NARX têm comportamento semelhante.




Figura 10 –Curvas da demanda desejada e obtida por meio da previsão com a RNA-NARX.

Para uma análise mais detalhada da previsão para a Subestação III, também foi traçado o gráfico de barras dos erros relativos percentuais para cada um dos pontos, como pode ser observado na Figura 11. Por meio do gráfico, constata-se que a RNA-NARX apresentou maior dificuldade na previsão de dois trechos. O primeiro trecho ocorre entre as seis e trinta da manhã e às oito horas da manhã. Observando o gráfico da Figura 10, tem-se a ocorrência de uma queda no consumo de energia nesse período do dia, dificultando a previsão. O segundo trecho ocorre das 17 às 19 horas, onde o erro relativo percentual atingiu o valor de 9% devido a um crescimento acentuado do consumo de energia.




Figura 11– Gráfico de barras com os erros da previsão ao longo do dia.

Uma vez determinado o desempenho da RNA-NARX para a previsão de um passo a frente para os dados registrados na Subestação III, os dados estimados foram apresentados como entrada, com o propósito de permitir a previsão de múltiplos passos à frente. Como pode ser visto no gráfico da Figura 12, e como mencionado anteriormente, o MAPE para esta rede considerando um passo frente foi de 0,5189%, crescendo para 0,912% para dois passos à frente, e assim sucessivamente, até atingir 3,1368% para cinco passos à frente.

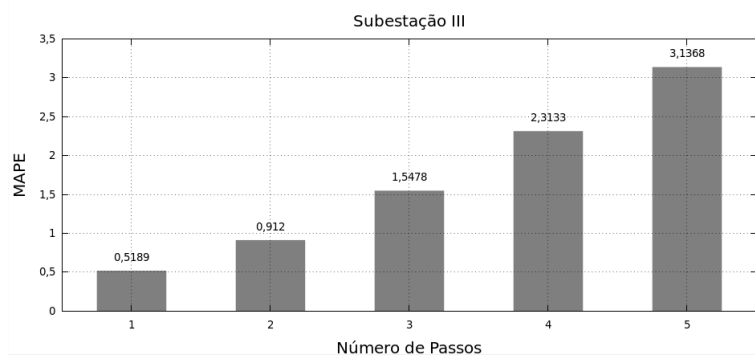


Figura 12 – Gráfico do MAPE da Subestação III para até cinco passos à frente.

7. COMPARAÇÃO COM OUTRAS ABORDAGENS

A mesma metodologia foi empregada para a determinação de topologias de RNA *Feedforward* e RNA recorrentes de *Elman* para previsão de demanda de energia elétrica com os dados mensurados nas Subestações I, II e III. Portanto, a técnica de validação cruzada, como descrita na seção 5, foi empregada para a determinação das melhores topologias das RNA *feedforward* e *Elman* para horizontes de previsão de 5 minutos e um passo a frente. Os resultados obtidos foram comparados com os das RNA-NARX para uma melhor avaliação de seu desempenho quando aplicadas a esse tipo de problema.

Foram executadas dezenas de treinamentos para as RNA-NARX, RNA *feedforward* e RNA recorrente de *Elman*. Contudo, devido à pequena alteração nos valores do MAPE obtidos, foram escolhidos de forma aleatória três treinamentos distintos para exemplificar o desempenho das RNA, conforme pode ser observado na Tabela 1. A rede neural *feedforward* apresentou um MAPE de 1,1499%, enquanto que a rede recorrente de *Elman* teve um desempenho superior, apresentando um MAPE de 0,9282%. Contudo, verifica-se que ambas tiveram desempenho inferior à RNA-NARX, que apresentou um MAPE de 0,7007%.

Como se pode observar nos dados da Tabela 1, a variância calculada para cada um dos treinamentos apresentou resultados da ordem de 10^{-4} , o que permite concluir que cada um dos erros estimados está próximo do MAPE determinado.

Tabela 1. Dados comparativos entre as RNA para a Subestação I.

	Subestação I					
	<i>Feedforward</i>		Elman		Narx	
	MAPE(%)	Variância	MAPE(%)	Variância	MAPE(%)	Variância
Tr1	1,1545	2,24E-04	0,9438	1,14E-04	0,81629	1,18E-04
Tr2	1,1741	2,80E-04	0,9865	1,46E-04	0,7272	1,15E-04
Tr3	1,1212	2,53E-04	0,8543	1,26E-04	0,7675	1,16E-04
Média	1,1499	2,52E-04	0,9282	1,29E-04	0,7703	1,16E-04

No caso da Subestação II, como podeser observado na Tabela 2, também foram calculadas as médias do MAPE para três treinamentos distintos para uma análise comparativa entre a abordagem que emprega a RNA-NARX, RNA *feedforward* e RNA recorrente de *Elman*. Os valores do MAPE obtidos com a aplicação das três abordagens foram bem próximos, mas a RNA-NARX apresentou um MAPE sensivelmente inferior, quando comparado com as outras redes neurais. O MAPE obtido com o uso da RNA *feedforward* foi de 0,4038%. Já o obtido com o uso da RNA recorrente de *Elman* foi de 0,4388%, e o obtido com a RNA-NARX com valor de 0,3885%.

Pode-se observar nos dados da Tabela 2, que a variância calculada para cada um dos treinamentos apresentou resultados da ordem de 10^{-5} , o que também permite concluir que cada um dos erros estimados está próximo do MAPE determinado.

Tabela 2.Dados comparativos entre as RNA para a Subestação II.

	Subestação II					
	Feedforward		Elman		Narx	
	MAPE (%)	Variância	MAPE(%)	Variância	MAPE%	Variância
Tr1	0,4133	3,68E-05	0,4301	5,17E-05	0,3914	3,40E-05
Tr2	0,3933	3,35E-05	0,4631	5,54E-05	0,3892	3,40E-05
Tr3	0,4049	3,59E-05	0,4231	4,14E-05	0,3848	3,37E-05
Média	0,4038	3,54E-05	0,4388	4,95E-05	0,3885	3,39E-05

O MAPE obtido para a Subestação III confirma o fato de que a RNA-NARX apresentou, para a previsão da demanda de energia elétrica no curtíssimo prazo, desempenho superior àqueles obtidos com a RNA *feedforward* e RNA recorrente de *Elman*. Observa-se na Tabela 3, que o MAPE obtido com a RNA *feedforward* foi de 0,5287%, com a RNA recorrente de *Elman* de 0,5239%, e sendo o menor MAPE, o obtido com o uso da RNA-NARX com valor de 0,5119%.

Como se pode observar nos dados da Tabela 3, a variância calculada para cada um dos treinamentos apresentou resultados da ordem de 10^{-4} o que permite concluir também que cada um dos erros estimados está próximo do MAPE determinado.

Tabela 3. Dados comparativos entre as RNA para a Subestação III.

	Subestação III					
	Feedforward		Elman		Narx	
	MAPE (%)	Variância	MAPE(%)	Variância	MAPE%	Variância
Tr1	0,5214	9,15E-05	0,5300	1,56E-04	0,5149	9,32E-05
Tr2	0,5258	9,75E-05	0,5185	9,37E-05	0,5123	9,20E-05
Tr3	0,5388	9,71E-05	0,5233	9,07E-05	0,5086	9,10E-05
Média	0,5287	9,54E-05	0,5239	1,13E-04	0,5119	9,21E-05

8. CONCLUSÃO

Nesta pesquisa, uma investigação a respeito da previsão de demanda de energia elétrica no horizonte de curtíssimo prazo foi realizada com o objetivo de obter informações sobre os métodos empregados e os resultados obtidos nos últimos anos. Pôde-se constatar que são poucos os trabalhos de previsão da demanda de energia elétrica em um horizonte de curtíssimo prazo, ou de minutos à frente. A maioria dos trabalhos se concentra na pesquisa em horizontes de curto prazo ou horas à frente. Estes trabalhos normalmente extraem informações de dados relacionados à demanda da energia elétrica considerando fatores meteorológicos ou socioeconômicos. No caso do horizonte de curtíssimo prazo, a literatura afirma que toda informação para se realizar a previsão está contida na própria série temporal da carga mensurada no sistema elétrico de potência [4,6,7]. Intuitivamente, verifica-se que tal informação é pertinente, pois as mudanças no clima e razões socioeconômicas não podem influenciar, significativamente, o comportamento dos dados que serão mensurados alguns minutos à frente.

Diferentemente da maioria dos trabalhos investigados, nesta pesquisa não foi empregado um elaborado pré-processamento dos dados, como, por exemplo, classificações por similaridade, decomposição em componentes ou cálculo das diferenças considerando medidas anteriores, o que torna tal técnica mais simples do que as investigadas. Vale também frisar, que a maioria dos trabalhos consultados investigou seus resultados para apenas uma série temporal. Aqui foram investigados os resultados para três séries temporais o que aponta para uma maior segurança dos resultados.

Nesta pesquisa foi adotado o método de validação cruzada para obter a melhor formação dos conjuntos de entrada e saída, assim como para determinar a melhor configuração e parâmetros das redes neurais recorrentes NARX, tais como, número de entradas para formação dos padrões entrada e saída, melhor número de neurônios para uma camada intermediária, dentre outros.

O MAPE obtido para previsão de demanda de energia elétrica no curtíssimo prazo em um passo à frente foi, conforme Tabela 1, de 0,7703% para a Subestação I, de 0,3885% para a Subestação II (Tabela 2) e de 0,5119% para Subestação III (Tabela 3). Também foram apresentados gráficos com as curvas registradas nas subestações e estimadas pelas redes neurais recorrentes NARX, onde se pôde verificar que seus comportamentos são muito semelhantes. Também foram traçados gráficos com o erro relativo percentual para cada uma das medidas que formam o dia de teste, o que permitiu uma análise mais precisa da previsão para cada período do dia.

Finalizando, cabe colocar que os resultados encontrados demonstraram que a metodologia proposta é uma técnica simples e promissora para previsão de demanda de energia elétrica no curtíssimo prazo.

9. AGRADECIMENTOS

Os autores agradecem ao Prof.Dr. Ivan Nunes da Silva pela disponibilização dos dados relacionados aos perfis das três subestações analisadas nesta pesquisa, ao Laboratório de Sistemas de Energia Elétrica (LSEE) pela infraestrutura fornecida, e a CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pelo apoio ao Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia de São Carlos – USP, o qual possibilitou o desenvolvimento de parte desse trabalho.

10. REFERÊNCIAS

- [1] D. J. Trudnowski, W. L. McReynolds, e J. M. Johnson, “Real-time very short-term load prediction for power-system automatic generation control”, *IEEE Trans. Control Systems Technology*, vol. 9, pp. 254-260, Mar. 2001.
- [2] K. Liu, R. R. Shoults, M. T. Manry, C. Kwan, F. L. Lewis e J. Naccarino, “Comparison of very short-term load forecasting techniques”, *IEEE Trans. Power Systems*, vol. 11, pp. 877-882, May 1996.
- [3] R. P. Schulte, “An automatic generation control modification for present demands on interconnected power systems”, *IEEE Trans. Power Systems*, vol. 11, pp. 1286-1294, Aug. 1996.
- [4] W. Charytoniuke M. Chen, “Very short-term load forecasting using artificial neural networks”, *IEEE Trans. Power Systems*, vol. 15, pp. 263-268, Feb. 2000.
- [5] P. Qinglee Z. Min, “Very short-term load forecasting based on Neural Network and rough set”, in *Conf. Rec. 2010 International Conf. on Intelligent Computation Technology and Automation*, pp. 1132–1135.
- [6] L. L. Lai, *Power System Restructuring and Deregulation*. (Book style). Chichester, England: Ed. John Wiley & Sons Ltd, 2002, pp. 120–122.
- [7] J. W. Taylor, “An evaluation of methods for very short-term load forecasting using minute-by-minute british data”, *International Journal of Forecasting*, vol. 24, pp. 645-658, Sep. 2008.
- [8] J. W. Taylor e P. E. McSharry, “Short-term load forecasting methods: An evaluation based on European data”, *IEEE Trans. Power Systems*, vol. 22, pp. 2213-2219, Nov. 2007.
- [9] R. Mamlook, O. Badrane E. Abdulhadi, “A fuzzy inference model for short-term load forecasting”, *Energy Policy*, vol. 37, pp. 1239-1248, Apr. 2009.
- [10] M. Hanmandlue B. K. Chauhan, “Load forecasting using hybrid models”, *IEEE Trans. Power Systems*, vol. 99, pp. 1-10, May 2010.
- [11] S. Fan e L. Chen, “Short-term load forecasting based on an adaptive hybrid method”, *IEEE Trans. Power Systems*, vol. 21, pp.392-401, Feb. 2006.
- [12] A. S. Pandey, D. Singh e S. K. Sinha, “Intelligent hybrid wavelet models for short-term load forecasting”, *IEEE Trans. Power Systems*, vol. 25, pp. 1266-1273, Aug. 2010.
- [13] K. Song, S. Ha, J. Park, D. Kweone K. Kim, “Hybrid load forecasting method with analysis of temperature sensitivities”, *IEEE Trans. Power Systems*, vol. 21, pp. 869-876, May 2006.
- [14] A. Khosravi, S. Nahavandie D. Creighton, “Construction of optimal prediction intervals for load forecasting problems”, *IEEE Trans. Power Systems*, vol. 25, pp. 1496-1503, Aug. 2010.
- [15] Y. Chen, P. Luh, C. Guan, Y. Zhao L. D. Michel, M. A. Coolbeth, P. B. Friedlande S. J. Rourke, “Short-term load forecasting: Similar day-based wavelet neural networks”, *IEEE Trans. Power System*, vol. 25, pp. 322-330, Feb. 2010.
- [16] C. Guan, P. B. Luh, M. A. Coolbeth, Y. Zhao, L. D. Michel, Y. Chen, C. J. Manville, P. B. Friedland and S. J. Rourke, “Very short-term load forecasting: Multilevel wavelet neural networks with data pre-filtering”, *Power & Energy Society General Meeting*, pp. 1-8, Jul. 2009.
- [17] T. Lin, B. G. Horne, P. Tiño e C. L. Giles. Learning long-term dependencies in NARX recurrent neural networks. *IEEE Transactions on Neural Networks*, v. 7, n. 6, pp. 1424–1438, 1996.

- [18] J. CONNOR, L. E. ATLAS, e D. R. MARTIN. Recurrent Networks and NARMA Modeling. *In proceeding of: IV Advances in Neural Information Processing Systems*, p. 301-308, Dec 1991.
- [19] M. ARDALANI-FARSA, e S. ZOLFAGHARI. Chaotic time series prediction with residual analysis method using hybrid elman-NARX neural networks. *Neurocomputing*, v. 73, n. 13–15, p. 2540–2553, 2010.
- [20] S. Haykin, *Neural Networks: A Comprehensive Foundation*, Prentice Hall, 1999.
- [21] A. Setiawan, I. Koprinskae V. G. Agelidis, “Very short-term load demanda forecasting using support vector regression”, *Proceedings of International Join Conference on Neural Networks*, pp. 2888-2894, Jun. 2009.
- [22] R. J. Hyndman and S. Fan,, “Density Forecasting for long-term peak electricity demand”, *IEEE Trans. Power Systems*, vol. 25, pp. 1142-1153, May 2010.
- [23] C. N. Elias e N. Hatzargyriou, “An annual midterm energy forecasting model using fuzzy logic”, *IEEETrans. Power Systems*, vol. 24, pp. 469-478, Feb. 2009.
- [24] N. Amjadye F. Keynia, “Short-term load forecasting of power systems by combination of wavelet transform and neuro-evolutionary algorithm”, *Energy*, vol. 34, pp. 46-57, Oct. 2009.
- [25] H. Y. Yang, H. Ye, G. Wang, J. Khan e T. Hu, “Fuzzy neural very short-term load forecasting based on chaotic dynamics reconstruction”, *Chaos Solitons & Fractals*, vol. 29, pp. 462-469, Jul. 2006.
- [26] J. M. Menezes e Barreto G. A., *Redes Neurais Dinâmicas para Predição e Modelagem Não-Linear de Séries Temporais*, Dissertação de mestrado, 2006.