

# Previsão de demanda a médio prazo aplicada em dados reais do sistema de distribuição: uma comparação entre RNA e Lógica Fuzzy



Romero Álamo Oliveira de Medeiros <sup>[1]</sup>, Bruno Golzio Navarro Winkeler <sup>[2]</sup>, Juan Moisés Maurício Villanueva <sup>[3]</sup>, Yuri Percy Molina Rodriguez <sup>[4]</sup>, Euler Cássio Tavares de Macedo <sup>[5]</sup>, Helon David de Macedo <sup>[6]</sup>

[1] romero.medeiros@cear.ufpb.br, [2] gbrunowinkeler@gmail.com, [3] jmauricio@cear.ufpb.br, [4] molina.rodriguez@cear.ufpb.br, [5] euler@cear.ufpb.br, [6] helon@cear.ufpb.br - UFPB - Centro de Energias Alternativas e Renováveis, Cidade Universitária - João Pessoa - PB

## RESUMO

A previsão de demanda é uma importante ferramenta de apoio à decisão no planejamento de sistemas de energia, fornecendo informações necessárias para que os especialistas do setor elétrico possam alocar os recursos disponíveis. Métodos baseados em inteligência computacional vêm sendo utilizados para previsão há mais de vinte anos. As Redes Neurais Artificiais (RNA) e a Lógica Fuzzy estão entre as técnicas mais utilizadas. Neste trabalho, foram desenvolvidos dois sistemas de previsão de demanda para uma subestação real, por meio de uma RNA e um sistema de inferência Fuzzy. O caso estudado foi a subestação de Itaporanga, localizada na Paraíba/Brasil, e os valores de potência ativa entre os anos de 2008 e 2013, obtidos por meio de medições de um sistema de aquisição e monitoramento de dados (SCADA), que formaram os dados das séries temporais.

**Palavras-chave:** : Previsão de demanda a médio prazo. Inteligência computacional. Lógica Fuzzy. Redes Neurais Artificiais.

## ABSTRACT

*Demand forecasting is an important tool to support decision-making in the planning of power systems, providing essential information to aid specialists in the electricity sector in the allocation of available resources. Methods based on computational intelligence have been used in demand forecasting for more than twenty years. The Artificial Neural Networks (ANN) and Fuzzy Logic are among the most widely used techniques. In this study, we developed two demand forecasting systems for a real substation by means of an RNA and a fuzzy inference system. The case at hand studied the Cajazeiras substation, located in Paraíba/Brazil and its active power values, between the years 2008 and 2013, obtained by measurements of a system data acquisition (SCADA), which formed the time series data.*

**Keywords:** *Medium-term demand forecasting. Computational intelligence. Fuzzy Logic. Artificial Neural Networks.*

## 1 Introdução

Uma importante ferramenta no planejamento estratégico de um sistema de potência é a previsão de demanda. O consumo de energia tem crescido significativamente com o passar dos anos, e as concessionárias de energia elétrica precisam antever o crescimento da demanda de energia elétrica para que seja possível alocar os recursos disponíveis com antecedência. Entre esses recursos estão a compra de novos equipamentos, a ampliação e construção de linhas de transmissão, as manutenções programadas, a compra e venda de energia etc.

A previsão de demanda pode ser feita para os horizontes de longo, médio, curto e curtíssimo prazo. A previsão a médio prazo pode ser feita desde semanas até meses e fornece informações úteis para o planejamento e operação de um sistema de potência (GHIASSI; ZIMBRA; SAIDANE, 2006).

Antes do surgimento de métodos baseados em Inteligência Computacional, apenas métodos estatísticos eram utilizados para a previsão de séries temporais, com destaque para o modelo Box & Jenkins (BOX; JENKINS; REINSEL, 2008). As técnicas baseadas em inteligência computacional (GHANBARI, HADAVANDI, ABBASIAN-NAGHNEH, 2010; AQUINO et al., 2012; Xu, CAI, MILANOVIC, 2014), como as Redes Neurais Artificiais (RNA) e a Lógica Fuzzy, a exemplo do trabalho de Tao, Zhong e Shuyan (2013), ganharam destaque por conseguirem trabalhar com grandes quantidades de dados não lineares e não dependerem de complexos modelos matemáticos. Essas técnicas são inspiradas em aspectos biológicos de aprendizagem e raciocínio e são executadas e aplicadas em diferentes campos da ciência e da engenharia (BOX, JENKINS, REINSEL, 2008; MAKRIDAKIS, WHEELWRIGHT, HYNDMAN, 1998).

O objetivo deste trabalho é apresentar uma ferramenta de previsão de demanda de médio prazo que auxilie os especialistas na área de planejamento do setor de distribuição de energia elétrica, realizando uma avaliação quanto ao uso de RNA e Lógica Fuzzy.

## 2 Previsão de séries temporais

Uma série temporal é uma sequência de dados referenciada no tempo (BOX, JENKINS, REINSEL,

2008). Diversas áreas, como economia, engenharia e ciências naturais, usam as séries temporais para prever comportamentos e tomar decisões.

Autores como Franco Junior (2013); Guirelli (2006) e Viglioni, Cury e Da Silva (2006) dividem os métodos de previsão de séries temporais em duas classes: estatísticos e os que utilizam inteligência artificial (computacional). A regressão linear, a *autoregressive moving average* (ARMA), a *autoregressive integrated moving average* (ARIMA) e a análise espectral são exemplos de técnicas estatísticas para previsão. Com relação aos métodos de inteligência artificial, os principais são os sistemas especialistas, as RNA, a Lógica Fuzzy e Estratégias Evolutivas (EEs).

## 3 Redes Neurais Artificiais (RNA)

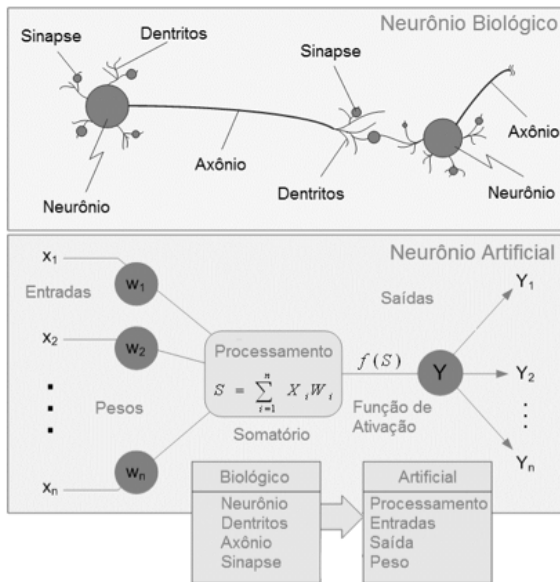
O cérebro é uma estrutura complexa e não-linear que funciona como um sistema de processamento paralelo de dados (HAYKIN, 2001). Essas características proporcionam, entre outras, a grande habilidade de reconhecimento e generalização de padrões. Essa habilidade é a grande motivadora para o desenvolvimento de Redes Neurais Artificiais (RNA). As RNA são sistemas paralelos formados por unidades de processamento chamadas de neurônios, responsáveis por calcular funções matemáticas determinadas. Existem várias aplicações de RNA, entre elas, a previsão de séries temporais (VIGLIONI, CURY, DA SILVA, 2006; ZHANG, XU, ZHOU, 2010; AQUINO et al., 2007; CARMONA et al., 2002; PARK et al., 1991; GHIASSI, ZIMBA, SAIDANE, 2006; CHARYTONIUK, CHEN, 2000, 2000b).

### 3.1 O neurônio artificial

A unidade básica de uma RNA é o neurônio artificial. É um modelo matemático concebido a partir de um neurônio biológico, como ilustrado na Figura.

O neurônio artificial recebe uma ou mais entradas (representando os dendritos) que são somadas para produzir uma saída. Normalmente, as somas de cada nó são ponderadas, e este resultado é usado como entrada de uma função não linear conhecida como função de ativação ou função de transferência. As funções de transferência, normalmente, têm uma forma sigmoide, mas também podem assumir a forma de outras funções não lineares, lineares segmentadas ou degrau. Elas também são muitas vezes monótonas crescentes e contínuas, diferenciáveis e delimitadas (ANTHONY, 2001).

**Figura 1** – Neurônio biológico x modelo de neurônio artificial



Fonte: Adaptado de Knowledge seeker's blog (2012)

### 3.2 O Perceptron Multicamadas (PMC)

Um PMC é uma rede de neurônios simples, chamadas *perceptrons*. O conceito básico de um único *perceptron* foi introduzido por Rosenblatt (1958). O *perceptron* computa uma única saída de múltiplas entradas de valor real, formando uma combinação linear de acordo com seus pesos de entrada e, em seguida, possivelmente colocando a saída através de alguma função de ativação não linear.

### 3.3 Algoritmo de Retropropagação

Em 1986, D. E. Rumelhart, C. E. Hinton e R. J. Williams apresentaram uma técnica diferente para estabelecer o processo de aprendizagem em redes neurais (SATHYANARAYANA, 2014). O algoritmo de retropropagação (backpropagation) aprende com exemplos. Cada exemplo faz os pesos da rede mudarem para que, quando o treinamento termine, a saída seja correspondente apropriada. A BP é um dos algoritmos mais populares para treinar redes neurais.

### 3.4 Resilient Backpropagation

Em 1993, Riedmiller, M. e Braun, H. propuseram uma evolução ao clássico algoritmo de retropropagação, o *resilient backpropagation* (RPro). Este algoritmo era capaz de realizar uma adaptação local da atualização dos pesos de acordo o comportamento da função do erro (RIEDMILLER, BRAUN, 1993).

Isso tornou o processo de adaptação extremamente eficiente se comparado com outras técnicas adaptativas.

O algoritmo modifica o valor atual por cada peso, de acordo com o comportamento dos sinais das derivadas parciais em cada dimensão do espaço de pesos. Como resultado, o número de passos de aprendizagem é reduzido e o esforço computacional é consideravelmente pequeno.

## 4 Lógica Fuzzy

A Lógica Fuzzy viola o pensamento lógico ocidental que considera uma declaração apenas verdadeira ou falsa (lógica binária) (COX, 1994). Na verdade, entre a certeza de ser e a certeza de não ser, existem infinitos graus de incerteza (MENDEL, 1995).

Com base na teoria dos conjuntos nebulosos (*Fuzzy Sets*), a Lógica Fuzzy tem se mostrado mais adequada para tratar imperfeições da informação do que a teoria das probabilidades. É a lógica que suporta os modos de raciocínio que são aproximados ao invés de exatos (ALTROCK, 1995).

Assim, tais conjuntos são caracterizados por funções de pertinência que associam a cada objeto um grau de pertinência entre zero e um.

### 4.1 Grau de pertinência

Na teoria clássica de conjuntos, um elemento ou pertence a um conjunto ou não. Dado um universo de discurso  $U$  e um elemento  $x \in U$ , o grau de pertinência do elemento  $x$ ,  $\mu_A(x)$  com relação ao conjunto  $A \subseteq U$  é dado por:

$$\mu_A(x) \begin{cases} 1, & \text{se } x \in A \\ 0, & \text{se } x \notin A \end{cases} \quad (1)$$


A função  $\mu_A(x): U \rightarrow \{0,1\}$  é nomeada de função característica na teoria clássica de conjuntos. Essa função na teoria clássica pode somente assumir valores discretos. Pode-se observar esse fato pela expressão (1).

Na Figura 2 (a), observa-se que o intervalo de dados tem pertinência 1 em relação ao conjunto  $A$  considerado. Para elementos que não pertencem a esse intervalo, mas pertencem ao conjunto universo  $U$ , o grau de pertinência tem valor 0. Essa é a representação de pertinência referente à lógica clássica.

Na Figura 2 (b), o caso preciso é apresentado e deste tem-se que o grau de pertinência tem valor

1 somente em determinado valor, sendo 0 para os demais valores.

Figura 2 – Funções características




Fonte: Elaborada pelo autor.

Já ao considerar um conjunto Fuzzy, um elemento  $x$ , pertencente ao conjunto universo  $U$ , tem um determinado grau de pertinência com relação ao conjunto  $A$ , grau este que é definido no intervalo  $[0, 1]$  e descrito por  $\mu_A(x)$ , em que 0 significa a exclusão total do elemento em relação ao conjunto, e o valor 1 significa a inclusão total do elemento e qualquer valor entre esses dois representa um pertinência parcial.

A Figura 3 aborda uma função de pertinência triangular com pico em  $x$ , o que sugere a ideia de que quanto mais próximo de  $x$ , mais o elemento se identifica com o conceito representado por  $x$  em relação ao conjunto  $A$ .

Figura 3 – Função de pertinência triangular



Fonte: Elaborada pelo autor.

Já que o grau de pertinência não é mais um dado binário, não faz sentido definir um conjunto apenas pelos seus elementos. Conjuntos Fuzzy são definidos por pares ordenados, que indicam cada elemento com seu grau de pertinência para o conjunto em questão, assim como na expressão (2).

$$A = (x, \mu_A(x)) | x \in U \tag{2}$$

Os conjuntos contínuos são representados pela função de pertinência. Já os conjuntos discretos podem ser representados conforme a Expressão (3),

em que a somatória representa a operação união (disjunção), e o termo  $\mu_A(x)/x$  indica que o elemento  $x$  pertence ao conjunto  $A$  com grau de pertinência  $\mu_A(x)$ .


$$A = \sum_i \mu_A(x_i) / x_i \tag{3}$$

Normalmente, para simplificar a visualização, a lista dos elementos de conjuntos discretos apresenta apenas os elementos que possuem grau de pertinência diferente de zero.

#### 4.2 Regras de inferência

Na teoria Fuzzy, os parâmetros de entrada do sistema são mapeados em variáveis linguísticas que são utilizadas na definição de regras para o processamento de variáveis de saída. Assim, ao invés de assumir instâncias numéricas, estas variáveis assumem instâncias linguísticas. Na Figura 4, podem-se verificar três possíveis valores para a variável temperatura.

Figura 4 – Representação da variável linguística temperatura



Fonte: Elaborada pelo autor.

A forma mais comum de expressar o conhecimento é por meio de regras do tipo condição-ação (ALTROCK, 1995). As regras são formadas por antecedentes e consequentes:

$$SE <antecedentes> ENTÃO <consequentes> \tag{4}$$

Os termos denominados antecedentes descrevem as condições necessárias para que haja um determinado resultado, sendo que os termos denominados consequentes representam os próprios resultados ou ações que podem ser executadas quando os antecedentes são verificados.

De uma forma distinta da teoria clássica, uma regra Fuzzy pode ser avaliada mesmo se os antecedentes não forem completamente satisfeitos (ZADEH, 1973). Um sistema de inferência Fuzzy baseado em regras permite a fusão de múltiplas regras Fuzzy. Esta

fusão é obtida pelo uso de ponderadores, ou seja, valores que se associam às regras e que determinam um grau de importância a cada uma delas.

Um sistema de inferência baseado em regras é uma generalização do esquema lógico de raciocínio denominado *modus ponens*. Na lógica clássica, se o antecedente de uma regra é dito verdadeiro, então se pode afirmar que o conseqüente dessa regra também será verdade.

Um sistema de inferência Fuzzy baseado em regras generaliza *modus ponens* para permitir que a conclusão da regra seja inferida pelo grau em que o antecedente é satisfeito. Essa é a essência dos sistemas de inferência Fuzzy baseada em regras (ZADEH, 1973).

Uma regra Fuzzy típica pode ser dada por:

$$\mu_{Ri} = \mu_{(Ai \text{ and } Bi \rightarrow Ci)}(u, v, w) \quad (5)$$

$$\mu_{Ri} = [\mu_{(Ai)}(u) \text{ and } \mu_{(Bi)}(v)] \rightarrow \mu_{(Ci)}(w) \quad (6)$$

em que  $A_i, B_i, C_i$  são conjuntos Fuzzy que pertencem aos universos de discursos  $U, V$  e  $W$ , respectivamente, e o operador “ $\rightarrow$ ” indica uma função de implicação Fuzzy.

Utilizando-se a regra de inferência composicional de Zadeh (1973) para uma relação do tipo  $RA \rightarrow B$ , em que  $A \in U$  e  $B \in V$ , e considerando-se um conjunto Fuzzy de  $U$  denotado por  $A'$  e um conjunto Fuzzy  $B'$  de  $V$ , a inferência de  $A'$  é dada pela função de pertinência abaixo:

$$\mu_B(v) = \max(\min(\mu_{A'}(u), \mu_R(u, v)) ; u \in U, v \in V) \quad (7)$$

A resposta do sistema consistirá então da união de todas as funções Fuzzy ativadas. O valor final, ou seja, aquele que será apresentado pelas saídas do sistema Fuzzy, será determinado pelo processo de defuzzificação (BOX; JENKINS; REINSEL, 2008).

### 4.3 Defuzzyficação

Realizado o processo de agregação das regras, tem-se como resultado um conjunto nebuloso representativo da saída do sistema de inferência Fuzzy. Em muitas aplicações, há a necessidade de se expressar os resultados em valores numéricos, denominados “*crisp*”. Dessa necessidade, surge o processo de defuzzificação, que consiste na interpretação quan-

titativa de uma variável de saída do sistema Fuzzy para expressar o seu valor numérico (ZADEH, 1973).

Existem diversas metodologias para se realizar esse processo, entre as quais se pode destacar a média dos máximos, o centro de massa e o centro geométrico.

### 4.4 Sistema de inferência

O processo de inferência ocorre por meio da determinação do valor de cada conseqüente das regras nebulosas, a partir dos graus de compatibilidade entre as proposições derivadas das medidas e as respectivas proposições presentes nos antecedentes das regras.


Uma vez descritos, alguns dos aspectos de sistemas Fuzzy podem resumir o sistema de inferência Fuzzy ou controlador Fuzzy em três fases: fuzzificação, inferência e defuzzificação. A Figura 5 apresenta o sistema de inferência Fuzzy e a forma de interligação entre as fases.

Na fuzzificação, os valores de entrada, fornecidos no formato numérico por sensores ou medidores, são convertidos em valores linguísticos.

Na fase de inferência, os valores linguísticos, resultados da fuzzificação, são combinados de forma a gerar valores linguísticos de saída, de acordo com regras de inferência Fuzzy determinadas. Em um controlador Fuzzy, as regras têm um papel relevante, pois o bom desempenho do sistema está vinculado à produção de regras consistentes. A base do conhecimento pode ser fornecida por especialistas por meio de termos linguísticos. Esse processo pode ser complicado, mas, independentemente do conhecimento do especialista, uma alternativa para formação da base de regras é por intermédio da mineração de dados numéricos.

Por fim, na defuzzificação, os valores de saída são, novamente, convertidos em valores numéricos.

Figura 5 – Representação de um sistema Fuzzy




Fonte: Elaborada pelo autor.



## 5 Estudo de caso: subestação de Cajazeiras


São necessárias, para o sistema de previsão em estudo, as amostras passadas da demanda. Para isso, foram considerados os dados recolhidos a partir de uma subestação de alta tensão real de uma cidade brasileira chamada Cajazeiras, que pertence à empresa fornecedora de energia local, a Energisa. Os dados medidos foram de 2008 até 2013, considerando a potência ativa máxima semanal. Na Figura 6, pode-se verificar o diagrama unifilar simplificado da subestação Cajazeiras. Os pontos de medição, cujos dados de natureza elétrica foram obtidos, estavam referidos aos barramentos (69kV e 13,8kV) e equipamentos (disjuntores ou religadores).

Figura 6 – Diagrama unifilar da subestação de Cajazeiras-PB, Brasil



Fonte: Elaborada pelo autor.

Figura 7 – Esquema dos elementos básicos de um monitoramento de subestações e sistema SCADA



Fonte: Elaborada pelo autor.


Como observado na Figura 7, um sistema elétrico de potência contém subestações de distribuição de energia, e estes são normalmente monitorados por sistemas de aquisição de dados (RTU - Unidade Terminal Remota) que registram tensão, corrente, potência, fator de potência etc. e todos os dados

medidos são enviados para um servidor, com base em um sistema SCADA, como ilustrado na Figura 7. Estas informações são usadas para extração do comportamento desta rede.

Na Figura 8 é ilustrada a representação em séries temporais dos dados medidos no ponto 12B1, com um período de amostragem de 15 minutos, para o período de 2008-2013. É possível observar nos perfis de demanda uma alta não-linearidade da série histórica, com características sazonais e tendência.

O objetivo do sistema de previsão é determinar a potência máxima permitida para o transformador em funcionamento em um tempo futuro, com base nos históricos de valores de picos semanais.

Figura 8 – Série temporal de demanda para o período de 2008-2013 para a subestação de Itaporanga-PB, Brasil



Fonte: Elaborada pelo autor.


## 6 Método proposto – RNA's

O método proposto, baseado em redes neurais artificiais, foi desenvolvido na linguagem de programação C# (C Sharp). As simulações foram feitas com o auxílio de dois frameworks livres (*open sources frameworks*), o AForge.NET e o Accord.NET, e do auxílio da biblioteca OxyPlot para os gráficos.

Na Figura 9 é ilustrado o modelo de previsão usando RNA, que considera uma janela de valores passados de demanda e o índice da semana seguinte, por exemplo  $P(k)$ ,  $P(k-1)$ ,  $P(k-2)$ ,  $P(k-3)$  e  $I_d(k+1)$ , para prever uma demanda futura  $(k+1)$ . É possível observar que a demanda é representada usando valores semanais e considerando o valor mais alto da semana. Essa representação permite que o modelo de previsão seja implementado em situações que o sistema alcance os níveis de operação máximos.

O índice da semana seguinte é dividido considerando as 52 semanas do ano e, então, os valores são convertidos em números binários de 6 dígitos. Esse procedimento melhora o processo de treinamento bem como a própria rede. Para uma janela de previsão superior a um, é possível criar modelos com

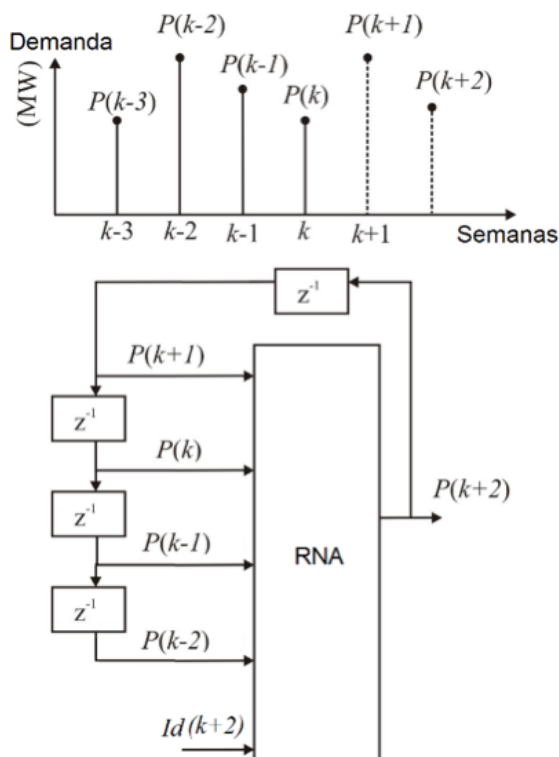
**Figura 9** – Modelagem de previsão para um passo a frente utilizando RNA



Fonte: Elaborada pelo autor.  
realimentação para usar o valor previsto de demanda  $P(k+1)$  como entrada no próximo passo  $P(k+2)$  e assim sucessivamente, como ilustrado na Figura 10.

Os dados históricos de demanda são uma série temporal não estacionária que apresenta características sazonais e de tendência. A tendência da curva

**Figura 10** – Modelagem de previsão para janelas com tamanho superior a um, utilizando RNA



Fonte: Elaborada pelo autor.

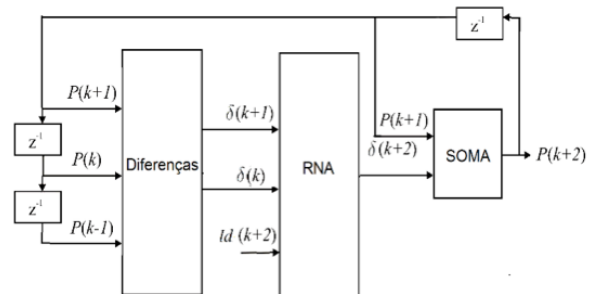
indica um crescimento, e o método de previsão precisa ser capaz de prever este comportamento. Entretanto é difícil prever valores mais altos que aqueles presentes na série, assim como prever uma série não estacionária.

Para resolver este problema, um método para prever as mudanças ou diferenças de um valor para o próximo é proposto. Desta forma, a tendência de crescimento não entra como parte da previsão. A rede é treinada para prever estas diferenças, e só depois que o sinal é reconstituído. A modelagem para este método pode ser visualizada na Figura 11.

Procurando melhorar ainda mais o processo de previsão, foi proposto um método para diminuir a chance da rede neural aprender demais (*overfitting*) e perder a habilidade de se generalizar a novas situações. A ideia principal é armazenar a melhor configuração dos pesos dos neurônios durante a fase de treinamento e usá-la na fase de testes.

Para isso, foi criada uma técnica de validação diferente do tipo de validação que normalmente é utilizada. Enquanto o método regular interrompe o treinamento quando o erro de aprendizado começa a crescer, o método implementado consiste basicamente em testar a rede neural durante toda a fase de treinamento. Após cada iteração, a rede é testada e o erro, salvo. O melhor erro de validação tem sua configuração armazenada e então esta rede é utilizada na fase de testes.


**Figura 11** – Modelagem de previsão para prever diferenças



Fonte: Elaborada pelo autor.

Na Figura 12, pode-se verificar a evolução do teste da melhor validação. O primeiro gráfico apresenta a simulação após 61 iterações; o segundo, como a curva de validação vai se aproximando da curva real e, finalmente, o terceiro, que apresenta a configuração escolhida após o fim do treinamento.

**Figura 12** – Evolução do método de validação proposto



Fonte: Elaborada pelo autor.

## 7 Método proposto – Lógica Fuzzy

Na Figura 13 é ilustrado o método proposto para previsão, no qual se utiliza uma janela de 4 entradas (3 potências anteriores e 1 entrada do índice da semana a prever) para prever 1 potência. O Sistema de Inferência Fuzzy (FIS) incorpora conhecimento por meio de regras para ser utilizado na inferência e, assim, construir um sistema não linear que visa mapear entradas para saídas.

**Figura 13** – Sistema Fuzzy



Fonte: Elaborada pelo autor.

O processo é definido em 6 etapas:

- 1 - Coleta de Dados;
- 2 - Definição de Variáveis;
- 3 - Preparo dos Dados;
- 4 - Configuração dos Conjuntos Fuzzy;
- 5 - Inferência: execução do sistema de inferência Fuzzy;
- 6 - Previsão: saída do sistema Fuzzy.

A etapa 1 é a extração, no banco de dados, das máximas potências de cada semana, assim como os índices da semana por ano, de 1 a 52.

Em seguida, na etapa 2, constrói-se tabelas com dados de entradas e saídas precisas, em que foram adotadas 4 entradas e 1 saída, tendo essas saídas

como possíveis entradas para realimentações de previsões feitas pelo sistema.

Na etapa 3, realiza-se a separação dos dados para análise. Foram utilizados 70% dos dados para extrair o comportamento da demanda (gerar as regras) e 30% para validar a previsão da demanda.

Na etapa 4 foram configuradas as variáveis do sistema. Definiu-se a quantidade de conjuntos Fuzzy e as configurações das variáveis de potência e de semana. Vale salientar que o número de conjuntos Fuzzy e os *ranges* (intervalo de valores possíveis para uma variável) são constantes e comuns para todas as variáveis do mesmo tipo. Foi definido para este trabalho, de forma empírica, um *range* de 1 a 52 e uma quantidade de 31 conjuntos Fuzzy, ambos do tipo triangular para a semana. Já para as potências, foram variadas as quantidades de conjuntos Fuzzy de 3 a 17, todos do tipo triangular, mantendo um mesmo *range*.

Após a preparação dos dados e a configuração do sistema Fuzzy, foi realizada a etapa 5, na qual, inicialmente, os valores de entrada sofreram processo de fuzzyficação, em que valores numéricos são convertidos em valores linguísticos, retornando um conjunto Fuzzy com um grau de pertinência. O procedimento de inferência avalia a entrada de valores linguísticos para cada regra, ativando algumas delas e fornecendo um grau de pertinência de cada conjunto.

Por fim, na etapa 6, o procedimento de defuzzificação transforma um conjunto fuzzy para um valor numérico de saída. Neste trabalho foi considerada a técnica de defuzzificação do centro geométrico (RUNKLER, 1997).

## 8 Resultados

Os resultados apresentados são associados com as medições reais da subestação de Cajazeiras, localizada no estado da Paraíba - Brasil. O ponto de medição utilizado foi respectivo ao disjuntor do lado de 69kV – 12B1, por um período de análise de 2008-2013, para treinamento e prevendo 52 semanas para frente (ano de 2014). Todas as previsões têm base de tempo como o número de semanas, ou seja, 52 semanas por ano.

Vale salientar que o sistema proposto é adequado para qualquer tipo de conjunto de dados de demanda energética e a métrica de erro utilizada para avaliar os resultados das previsões tanto da RNA como dos



conjuntos Fuzzy foi o erro percentual absoluto médio (MAPE).


No caso das RNA, foram utilizadas 312 amostras ou valores de demanda semanal, divididos em: 80% para treinamento da rede e 20% para validação (teste). Teste final foi feito para o ano de 2014 (52 semanas).

As redes neurais foram configuradas de maneira que o número de camadas ocultas e neurônios em cada camada variasse, respectivamente, entre um e dois e entre um e oitenta.

No caso do método proposto utilizando a lógica Fuzzy, uma das premissas importantes foi variar a quantidade de conjuntos Fuzzy para cada variável. Esses conjuntos estão diretamente relacionados à eficiência da previsão. Foram realizados testes usando variações das quantidades de conjuntos na variável de potência.

O melhor resultado de previsão pode ser visualizado no gráfico da Figura 14.

**Figura 14** – Previsão de 52 semanas a frente – RNA e lógica Fuzzy



Fonte: Elaborada pelo autor.

Neste resultado, a rede neural, que foi treinada com 12 valores passados de demanda para prever um, obteve um MAPE de 2,42 % com uma camada oculta e 5 neurônios na camada. Já para a lógica Fuzzy, foram utilizados 7 conjuntos na variável Potência e 31 conjuntos na variável Semana, alcançando um MAPE de 2,41 %.

Os resultados das simulações se encontram na Tabela 1.

De modo complementar, foi possível avaliar ainda o crescimento da demanda, visto a previsão de um horizonte de três anos para frente. Na Figura 15, pode-se visualizar o resultado.

Os resultados, tanto para RNA quanto para a Lógica Fuzzy, previram um crescimento 16,7 % em três anos. Esta informação pode ser bastante útil para o setor de planejamento da concessionária.

**Tabela 1** – Resultados das previsões – RNA e Lógica Fuzzy

RNA		Lógica Fuzzy	MAPE RNA (%)		MAPE FUZZY (%)
Camada Oculta 1	Camada Oculta 2	Conjuntos Potência	CAMADAS		
Janela de Previsão	Janela de Previsão		1	2	
4	4	17	3,79	3,31	3,10
12	12	13	2,42	3,14	2,46
26	26	7	3,37	4,48	2,41
52	52	3	4,22	3,58	8,21

Fonte: Elaborado pelo autor (2016)

**Figura 15** – Previsão – Horizonte de três anos



Fonte: Elaborada pelo autor.

## 9 Conclusões

Neste trabalho foram desenvolvidos dois sistemas de previsão de demanda utilizando redes neurais artificiais e sistema de inferência Fuzzy.

Os dois sistemas alcançaram resultados significativos com valores de MAPE abaixo de 4 %, o que permite aos especialistas realizarem, com precisão, tomadas de decisão estratégicas importantes para o setor, como a compra de equipamentos, os projetos de expansão, a redução dos gastos com manutenções, o posicionamento no mercado de energia elétrica etc.

Para este conjunto de dados, o sistema de inferência Fuzzy implementado obteve melhor resultado do que a rede neural multicamada com algoritmo resilient backpropagation, porém ficaram bastante equiparados.

Conclui-se que a lógica Fuzzy pode ser bastante eficaz, principalmente se os dados forem tratados anteriormente, como neste estudo de caso. A influência da existência de valores nulos, picos e transferências de carga no conjunto de dados pode ser mais significativa na construção das regras Fuzzy do que no aprendizado da malha neural e, assim, comprometer os resultados das previsões.

No que se refere ao estudo de crescimento de demanda, foi possível estimar o acréscimo de demanda de 16,7 % para o horizonte de três anos para frente. Esse estudo pode auxiliar a equipe de planejamento na alocação de recursos, possibilitando antecipar a compra de equipamentos, construção de linhas de transmissão e agendamento de manutenções preventivas etc.

Apesar dos resultados satisfatórios dos métodos apresentados, o uso de técnicas híbridas poderia melhorar a precisão dos resultados ou diminuir o tempo de simulação. Métodos, como o neuro-fuzzy ou neural-genético, poderiam incrementar este trabalho.

Os resultados alcançados neste trabalho podem servir de base para estudos de reconfiguração de redes de distribuição de energia elétrica, tanto voltada para o caso de contingência (curto ou curtíssimo prazo) quanto para o planejamento de reconfiguração (médio e longo prazo) (SHAPOVALOV et al., 2014).

## REFERÊNCIAS

- ALTROCK, C. V. **Fuzzy Logic and NeuroFuzzy Applications Explained**. Prentice-Hall PTR, 1995.
- ANTHONY, M. **Discrete Mathematics of Neural Networks**: Selected Topics. SIAM, 2001.
- AQUINO, R. G. H. De. et al. **Wind forecasting and wind power generation: Looking for the best model based on artificial intelligence**. Neural Networks (IJCNN). In: THE 2012 INTERNATIONAL JOINT CONFERENCE ON.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis**: Forecasting and Control. 4. ed. N.J: Wiley, 2008.
- CARMONA, D. et al. **Electric energy demand forecasting with neural networks** IECON 02 [Industrial Electronics Society. In: IEEE ANNUAL CONFERENCE OF THE. IECON 02, 2002, p. 28.
- CHARYTONIUK, W.; CHEN, M. S. Neural network design for short-term load forecasting International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, 2000. **Proceedings... DRPT**, 2000.
- CHARYTONIUK, W.; CHEN, M.S. Very short-term load forecasting using artificial neural networks. **IEEE Transactions on Power Systems**, v. 15, n. 1, p. 263-268, fev. 2000b.
- COX, E. **The Fuzzy Systems Handbook: A Practitioner's Guide to Building, Using, and Maintaining Fuzzy Systems**, AP Professiona, 1994.
- FRANCO JUNIOR, E. F. **Modelo para previsão de demanda ativa usando RNA**. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas-SP, 2013.
- GHANBARI, A.; HADAVANDI, E.; ABBASIAN-NAGHNEH, S. **Comparison of Artificial Intelligence Based Techniques for Short Term Load Forecasting, Business Intelligence and Financial Engineering (BIFE)**, 2010. In: INTERNATIONAL CONFERENCE ON, 3., 2010.
- GHIASSI, M.; ZIMBRA, D.; SAIDANE, H. Medium term system load forecasting with a dynamic artificial neural network model. **Electric Power Systems Research**, v. 76, n. 5, p. 302-316, 2006.
- GUIRELLI, C. R. **Previsão da carga de curto prazo de áreas elétricas através de técnicas de inteligência artificial**. Tese (Doutor em Engenharia) – Universidade de São Paulo, 2006.
- KNOWLEDGE SEEKER'S BLOG; Disponível em: [http://timkienthuc.blogspot.com.br/2012\\_04\\_01\\_archive.html](http://timkienthuc.blogspot.com.br/2012_04_01_archive.html). Acesso em dez. 2016.
- HAYKIN, S. S. **Redes Neurais - Principios e Prática**. 2. ed. Porto Alegre: Bookman, 2001.
- MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting**: Methods and Applications. 3. ed. John Wiley & Sons, 1998.
- MENDEL, J. M. Fuzzy Logic Systems for Engineering: A Tutorial. **Proc. of the IEEE**, v. 83, n. 3, 1995.
- PARK, D. C. et al. Electric load forecasting using an artificial neural network. **IEEE Transactions on Power Systems**, v. 6, n. 2, p. 442-49, may. 1991.
- RIEDMILLER, M.; BRAUN, H. **A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm**. In: IEEE '93 INTERNATIONAL CONFERENCE ON NEURAL NETWORKS.
- ROSENBLATT, F. The Perceptron: A Probabilistic Model for Information Storage & Organization in the Brain. **Psychological Review**, v. 65, n. 6, p. 386-408, 1958.