

# **SISTEMA FUZZY PARA PREVISÃO DE SÉRIES TEMPORAIS DE DEMANDA DE ENERGIA ELÉTRICA**

**JOEL ADELAIDE MEDEIROS (UFPB)**

JOEL.MEDEIROS@CEAR.UFPB.BR

**THEREZA RAKEL DE ALCANTARA LIRA ARAUJO DA  
CUNHA (UFPB)**

therezarcunha@gmail.com

**Juan Moises Mauricio Villanueva (UFPB)**

jmauricio@cear.ufpb.br

**Ricardo Wagner Correia Guerra Filho (UFPB)**

rwguerra@gmail.com

**DIEGO HENRIQUE DA SILVA CAVALCANTI (UFPB)**

diego.cavalcanti@cear.ufpb.br



*Nos dias atuais, a previsão de demanda é uma importante ferramenta de apoio à decisão no planejamento de sistemas de energia, fornecendo informações necessárias para os especialistas do setor. Nesse trabalho, foi desenvolvido um sistema de previsão de séries temporais de demanda, por meio de um sistema de inferência fuzzy. O caso estudado foi uma subestação de energia elétrica, localizada em Itaporanga, no estado da Paraíba/Brasil. Foram utilizadas as séries temporais de potência ativa entre os anos 2008 e 2014. Os dados foram obtidos por meio de medições de um sistema aquisição de dados (SCADA), e estas medições foram armazenadas em um banco de dados. Após a coleta dos dados, foram criados dois conjuntos de dados, um usado para a*

*extração de regras, e o outro, para validação da previsão. Os resultados obtidos das previsões foram avaliados por meio do erro percentual absoluto médio e o erro absoluto médio, comprovando, assim, a eficiência da lógica fuzzy na previsão de séries temporais.*

*Palavras-chave: Lógica Fuzzy, Previsão, Demanda, Planejamento, Sistema de Inferência Fuzzy.*

## 1. Introdução

Uma série temporal ou histórica é um conjunto de observações feitas sequencialmente ao longo do tempo, existindo nas mais variadas áreas de aplicação, como finanças, *marketing*, demografia, epidemiologia, energia.

Na engenharia, as séries históricas podem ser associadas aos processos industriais, como na venda de automóveis, serviços de transportes, venda de produtos, entre outros. Podem-se caracterizar as séries por meio de parâmetros estatísticos e funções de densidade de probabilidade. Também se podem utilizar as séries temporais para construir modelos matemáticos e de inferência para utilização em aplicações de previsão, obtendo cenários futuros de acordo com o conhecimento passado, auxiliando, por exemplo, na determinação dos recursos necessários nos processos industriais.

A previsão de curto, médio e em especial longo prazo é de difícil elaboração devido a incertezas no setor econômico, sócio-político e tecnológico. Por exemplo, as flutuações nos mercados de capital, suprimentos, mão de obra e vendas ajudam na concepção de um ambiente instável e competitivo. Neste atual ambiente dinâmico, a grande preocupação das empresas é com o que pode acontecer e como atuar sobre estes eventos preventivamente ou como adaptar suas estratégias às mudanças previstas (KOTLER, 1991), (MOON, MENTZER, *et al.*, 1998).

Montgomery, Johnson e Gardiner (1990) e Makridakis (1996) afirmam que, para obter sucesso na formulação de planejamentos e no direcionamento estratégico das empresas, são necessárias a identificação e a previsão correta das mudanças emergentes no ambiente de negócios, o que torna a previsão de demanda um elemento chave na tomada de decisão gerencial. As empresas podem melhorar sua eficiência se elas puderem antecipar problemas e desenvolver planos para responder a esses problemas (ARMSTRONG, 1983).

Para atingir esses objetivos, novas abordagens na construção de modelos de previsão têm sido publicadas na literatura baseadas nas técnicas de inteligência artificial (GHANBARI, 2010),

(DE AQUINO, LIRA, *et al.*, 2012), (XU, CAI e MILANOVIC, 2014), como a lógica *fuzzy* (ZHOU TAO, 2013) e redes neurais artificiais (DONGXIAO NIU, 2007), as quais apresentaram resultados muito relevantes. Essas técnicas são inspiradas em aspectos biológicos de aprendizagem e raciocínio, e são executadas e aplicadas em diferentes campos da ciência e da engenharia (G. E. P. BOX, 2008), (S. G. MAKRIDAKIS, 1998).

Uma rede neural artificial (RNA) é um sistema capaz de processar informação de forma distribuída e de incorporar conhecimento através de exemplos. Logo após a validação do modelo, são realizados mapeamentos, do tipo caixa preta, da entrada para saída do sistema proposto. De outro lado, os modelos de previsão baseados em lógica *fuzzy* são construídos baseados em regras oriundas de especialistas, interpretando, assim, os resultados de acordo com o raciocínio imposto pelo especialista.

Portanto, este artigo tem como objetivo o desenvolvimento de um sistema de previsão utilizando a lógica *fuzzy*. Para tal fim, será tomado como estudo de caso os históricos de demanda de uma concessionária de energia elétrica. A partir dos históricos coletados, foram definidas as regras para a inserção do conhecimento ao sistema. Os dados correspondem ao período de 2008 a 2014, com intervalos de amostragem das máximas potências ativas semanais. Para validar os resultados obtidos de previsão foram utilizadas métricas estatísticas, como o erro percentual absoluto médio (MAPE) e o erro absoluto médio (MAE).

## 2. Definições preliminares: lógica *fuzzy*

Afirmar que uma declaração é verdadeira ou falsa (COX, 1994), não podendo ser ao mesmo tempo parcialmente verdadeira e parcialmente falsa, junto ao princípio da contradição, formam a base do pensamento lógico clássico.

A lógica *fuzzy* ou lógica nebulosa (MENDEL, 1995) viola estas suposições. Um sim ou um não, na maioria das vezes, é uma resposta incompleta. Na verdade, entre a total certeza e a total incerteza, existem infinitos graus. No passado, esta imperfeição intrínseca à informação representada numa linguagem natural tem sido tratada matematicamente com o uso da teoria

das probabilidades. Contudo, a lógica nebulosa, com base na teoria dos conjuntos nebulosos ou conjuntos *fuzzy* (*fuzzy set*), tem se mostrado mais adequada para tratar imperfeições de informação quando comparada a teoria das probabilidades.

A lógica *fuzzy* (ALTROCK, 1995) é a lógica que suporta os modos de raciocínio que são aproximados ao invés de exatos. Controle de decisões, sistemas de previsões, controle e modelagem são técnicas para o tratamento de informações qualitativas de uma forma rigorosa.

Proveniente do conceito de conjuntos *fuzzy*, a lógica *fuzzy* constitui a base para o desenvolvimento de métodos e algoritmos de modelagem e controle de processos, permitindo a redução da complexidade de projeto e implementação. Assim, torna-se a solução para problemas até então intratáveis por técnicas clássicas ou métodos estatísticos.

## 2.1. Conjuntos *fuzzy* e grau de pertinência

Os conjuntos *fuzzy* são conjuntos que não possuem fronteiras bem definidas e que foram introduzidos devido ao fato de os conjuntos clássicos apresentarem limitações para lidar com problemas onde as transições de uma classe para outra acontecem de forma suave, e não de forma brusca como nos conjuntos clássicos. Sua definição, propriedades e operações são obtidas da generalização da teoria de conjuntos clássicos, recaindo esta em um caso particular da teoria de conjuntos *fuzzy*.


Na teoria clássica de conjuntos, um elemento ou pertence a um conjunto ou não. Dado um universo  $U$  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 pode somente assumir valores discretos, ou 0 ou 1. Pode-se observar esse fato na expressão (1).

Na lógica *fuzzy*, um elemento  $x$  que pertence 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  $\mu_A(x)$ . O grau 0 significa a exclusão total do elemento em relação ao conjunto, o valor 1 significa a inclusão total do elemento e qualquer valor entre esse dois representa um pertinência ou inclusão parcial.

Figura 1 - Função de pertinência triangular



A Figura 1 aborda uma função de pertinência triangular com pico em  $x$ . Quanto mais próximo de  $x$ , mais o elemento se identifica com o conceito representado por  $x$  em relação ao conjunto  $A$ . Em outras palavras, quando mais próximo a  $x$ , maior seu grau de pertinência.

Portando, como o grau de pertinência não é mais um dado binário, não são definidos um conjunto apenas pelos seus elementos. Agora, 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).


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

## 2.2. 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, que também são representadas por variáveis linguísticas.

Assim, ao invés de assumir instâncias numéricas, as entradas e saídas assumem instâncias linguísticas. A Figura 2 ilustra três possíveis termos linguísticos para a variável linguística representando a potência elétrica. Nesta figura, observa-se a construção de três conjuntos *fuzzy* (baixa, média, alta) contidas dentro do domínio da variável Potência. Nesta subdivisão do domínio, as interfaces entre os conjuntos são do tipo *fuzzy*, isto é, não existe uma definição binária entre eles.

Figura 2 - Representação da variável linguística potência



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.

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 diferente 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 (ZADEH, 1973).

Uma regra *fuzzy* típica pode ser dada por:

$$\text{Se Potência}_{(n-1)} \text{ é Alta e Potência}_{(n)} \text{ é Alta então Potência}_{(n+1)} \text{ é Alta} \quad (3)$$

Onde:  $\text{Potência}_{(n-1)}$ ,  $\text{Potência}_{(n)}$ ,  $\text{Potência}_{(n+1)}$  são conjuntos *fuzzy* que representam a potência elétrica de um determinado equipamento e o operador “então” indica uma função de implicação *fuzzy*. O índice ( $n$ ) representa o instante de tempo atual, ( $n-1$ ) representa o instante de tempo passado e ( $n+1$ ) representa o instante de tempo futuro.

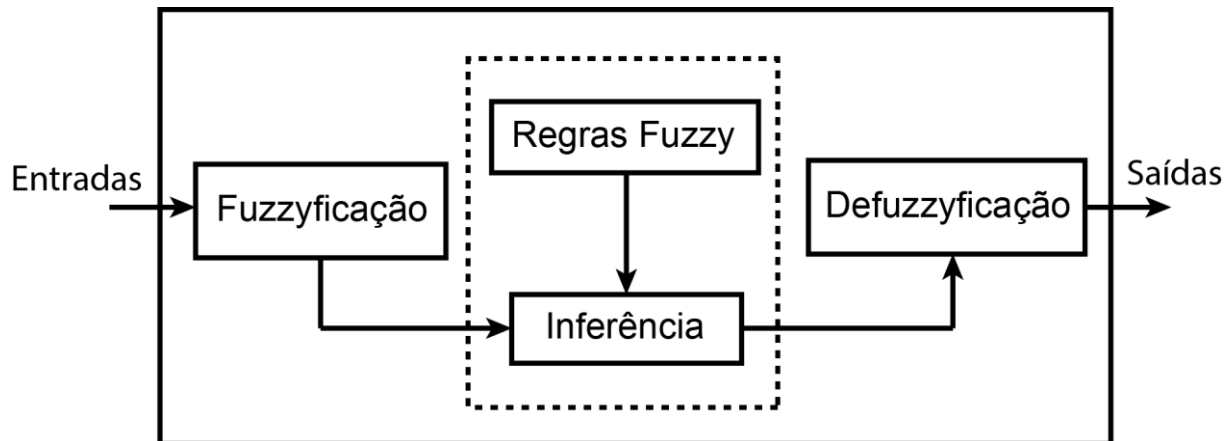
### 2.3. Sistemas de inferência

O processo de inferência (ZADEH, 1973) ocorre através da determinação do valor de cada conseqüente das regras nebulosas, a partir dos graus de compatibilidade entre as proposições derivadas das medidas com as respectivas proposições presentes nos antecedentes das regras.

Uma vez descrito alguns dos aspectos de sistemas *fuzzy*, pode-se resumir o sistema de inferência *fuzzy* ou controlador *fuzzy* em três fases: fuzzificação, inferência e defuzzificação.

Figura 3 - Sistema *fuzzy*






A **Erro! Fonte de referência não encontrada.** apresenta o sistema de inferência *fuzzy* e a forma de interligação entre as fases. A função de cada fase pode ser descrita da seguinte forma:

- 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*. Em um controlador *fuzzy*, as regras têm um papel fundamental, pois o bom desempenho do sistema está vinculado à produção de regras consistentes. A base do conhecimento pode ser fornecida por especialistas através de termos linguísticos. Esse processo pode ser complicado, mas, independente do conhecimento do especialista, uma alternativa para formação da base de regras é através da mineração de dados numéricos;
- Por fim, na defuzzificação, os valores de saída são, novamente, convertidos em valores numéricos.

### 3. Método proposto para previsão de demanda

Na **Erro! Fonte de referência não encontrada.** é ilustrado o método proposto para previsão, no qual se utiliza uma janela de 4 entradas no sistema *fuzzy* (3 potências anteriores ( $P_k$ ,  $P_{k-1}$ ,  $P_{k-2}$ ), representando a demanda de energia elétrica, e 1 entrada do índice da semana a prever ( $S_{k+1}$ )) para prever 1 potência ( $P_{k+1}$ ). O Sistema de Inferência *Fuzzy* (FIS) incorpora conhecimento através de regras para ser utilizada na inferência e assim construir um sistema não linear para mapear entradas para saídas.

Figura 4 - Sistema fuzzy



O processo de construção do sistema *fuzzy* para previsão de demanda é definido em 6 etapas:

- Coleta de dados;
- Definição de variáveis;
- Preparo dos dados;
- Configuração dos conjuntos *fuzzy*;
- Inferência: execução do sistema de inferência *fuzzy*;
- Previsão: saída do sistema *fuzzy*.

A Etapa 1 é a extração do banco de dados das máximas potências de cada semana, assim como a data respectiva dessa potência e os índices da semana.

Em seguida, na etapa 2, constrói-se tabelas com dados de entradas e saídas precisas, em que foi adotado 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. Nesta proposta, foi utilizado os dados do período de 2008 a 2011 para extrair o comportamento da demanda (gerar as regras) e de 2012 para validar a previsão da demanda.

Prosseguindo, na etapa 4, foi configurado as variáveis do sistema. Definiram-se as configurações das variáveis de potência e de semana. Vale salientar que o número de conjuntos *fuzzy* para potência é variado e os *ranges* (intervalo de valores possíveis para variável) são constantes e comuns para todas as variáveis do mesmo tipo.

Foi definindo para este trabalho, de forma empírica, uma quantidade fixa de variáveis linguísticas para a semana de 31. Já para as potências, foi variada essa quantidade entre 3 a 50, todos do tipo triangular, mantendo um mesmo *range*.

Após a preparação dos dados e a configuração do sistema *fuzzy*, é realizada a etapa 5 no qual, inicialmente os valores de entrada sofrem processo de fuzzificação, transformando os valores numéricos em 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.

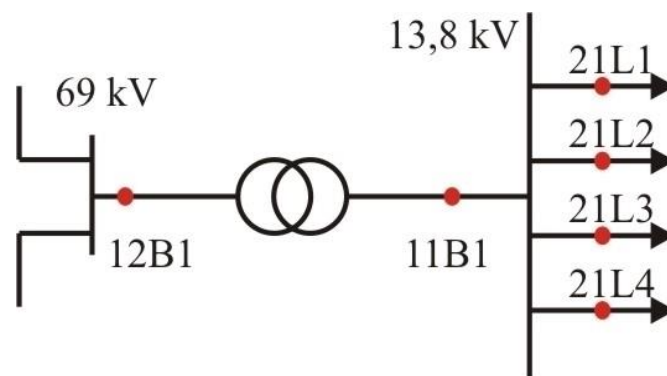
Por fim, na etapa 6, o procedimento defuzzificação transforma um conjunto *fuzzy* para um valor numérico de saída. Neste trabalho foi considerada a técnica de defuzzificação do centro geométrico (RUNKLER, 1997).

#### 4. Estudo de caso: subestação de Esperança

São necessárias, para o sistema de previsão em estudo, as amostras passadas de demanda. Para isso, consideraram-se os dados recolhidos a partir de uma subestação de alta tensão real de uma cidade brasileira chamada Esperança, localizada no estado da Paraíba. Os dados

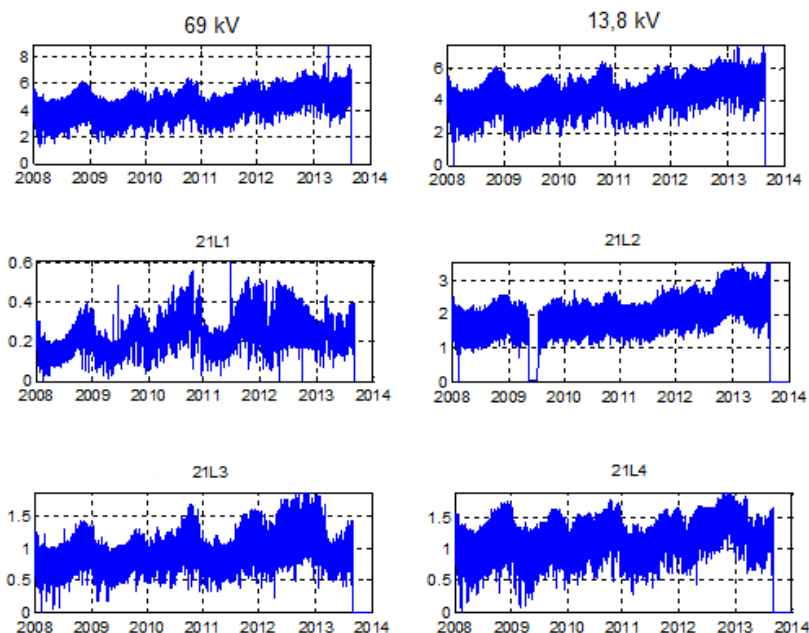
medidos foram de 2008 até 2014 e considerou-se a potência ativa máxima semanal. Na Figura 5 é ilustrado o diagrama unifilar da subestação em questão. Foram recolhidos dados sobre os pontos de medição 21L1 e 21L2.

Figura 5 - Diagrama unifilar da subestação Esperança, localizada na Paraíba/Brasil



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), onde registra tensão, corrente, potência, fator de potência, etc., e todos os dados medidos são enviados para um servidor, com base em um sistema de supervisão e aquisição de dados (SCADA). Estas informações são usadas para extração do comportamento desta rede.

Figura 6 - Séries temporais de demanda para o período de 2008-2013 para a subestação Esperança / Brasil



A Figura 6 ilustra a representação de séries temporais dos dados medidos, com um período de amostragem de 15 minutos, em níveis de média e alta tensão 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 fornecida pelos transformadores em um passo futuro, evitando sobre carregamento do mesmo e possibilitando o planejamento da demanda futura e expansão da subestação. Com isso, a concessionária de energia elétrica terá uma importante ferramenta estratégica para o planejamento anual. Ela poderá efetuar a expansão e manutenção da rede elétrica de uma determinada região com mais precisão.

## 5. Resultados e discussões

Os resultados apresentados a seguir são associados com as medições reais da subestação de Esperança localizada na Paraíba / Brasil. Os pontos de medição utilizados foram os alimentadores 21L1 e 21L2 por um período de análise de 2008-2014, considerando apenas as

máximas potências semanais. Todas as previsões têm base de tempo como o número de semanas, ou seja, 52 semanas por ano conforme apresentado na Figura 7 e

*Figura 8.* Vale salientar que o sistema proposto é adequado para diversos tipos de séries temporais.

Figura 7 - Dados o alimentador 21L1 no período de 2008 a 2012





Figura 8 - Dados o alimentador 21L1 no período de 2008 a 2012



Para avaliar os resultados, utilizou-se do erro absoluto percentual médio (MAPE) e o máximo erro absoluto (MAE).

Na Figura 9 e

*Figura 10* estão ilustrados os resultados da fase de previsão, considerando os menores valores de MAPE para a variação proposta da quantidade de conjuntos *fuzzy* da potência. A curva vermelha representa os dados da série temporal real, no período de 2013 a 2014. A linha azul é o resultado da previsão para o mesmo período. Importante salientar que as figuras contêm apenas os dados separados para previsão, compreendendo 104 semanas ou 2 anos de previsão.

Figura 9 - Previsão Subestação Esperança 21L1


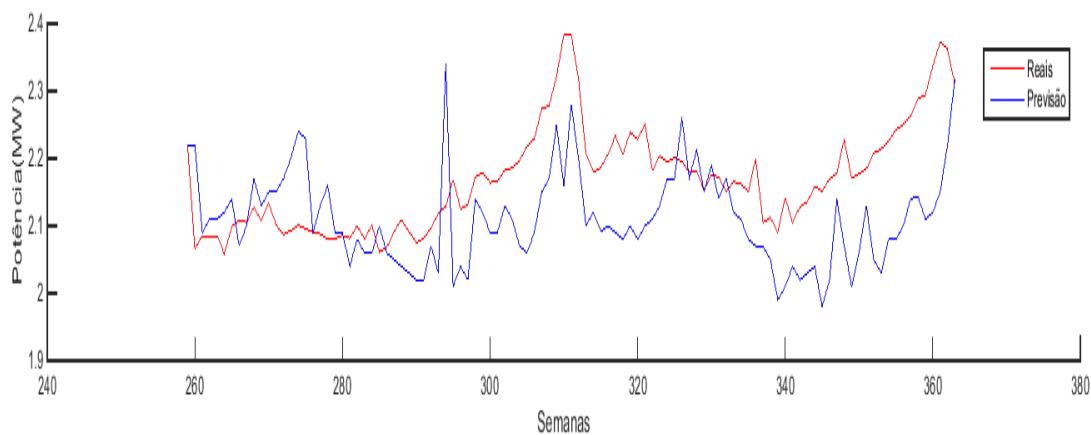


Figura 10 - Previsão Subestação Esperança 21L2



Na Figura 9, ilustra-se a previsão do ponto de medição 21L1 com 24 conjuntos *fuzzy* nas variáveis de potência e 31 conjuntos *fuzzy* na variável semana. Foi encontrado um MAPE de 4,32% para a previsão de 2 anos ou 104 semanas. Também foi encontrado o MAE de 0,27 MW.

Na



Figura 10 foi encontrado uma previsão do ponto de medição 21L2 com MAPE de 4,05% para as 104 semanas. A configuração utilizada para esse resultado foi de 26 conjuntos *fuzzy* nas variáveis de potência e 31 conjuntos para variável semana. Foi encontrado o MAE de 0,22 MW.

## 6. Conclusões

Neste trabalho foi desenvolvido um sistema de previsão de demanda utilizando um sistema de inferência *fuzzy*. Sendo que para o caso estudado, foi utilizado de forma empírica, algumas variações na quantidade de conjuntos *fuzzy* das variáveis de potência, verificado a eficiência da previsão por meio do MAPE e MAE. Para a aplicação realizada, foi encontrado uma previsão demanda de 104 semanas (2 anos) futura com um MAPE de 4,32% para o ponto de medição 21L1 e 4,05% para 21L2, utilizando uma quantidade de 24 e 26 conjuntos *fuzzy* na variável de potência, respectivamente. E o erro absoluto médio foi de 0,27 MW para o ponto de medição 21L1 e 0,22 MW para 21L2. O que concluímos que o sistema proposto opera de forma confiável e robusta na previsão de demanda. O desenvolvimento do sistema de previsão permitirá que especialistas de energia / indústria possam realizar a tomada de decisão de forma precisa, especialmente para definir os projetos de expansão da rede, os orçamentos e investimentos em novas tecnologias. Por fim, os resultados apresentados para a subestação de Esperança, localizada na Paraíba / Brasil foram bastante satisfatórios.

## 7. Agradecimentos

Os autores gostariam de agradecer a empresa Energisa Paraíba / Brasil e a Universidade Federal da Paraíba pelo apoio técnico e financeiro.

## REFERÊNCIAS

ALTROCK, C. V. **Fuzzy Logic & NeuroFuzzy Applications Explained**. [S.l.]: Prentice-Hall PTR, 1995.

ARMSTRONG, J. Strategic Planning and Forecasting Fundamentals. In: ALBERT, K. **The Strategic Management Handbook**, New York: MacGraw Hill, 1983.

COX, E. **The Fuzzy Systems Handbook: A Practitioner's Guide to Building, Using, and Maintaining Fuzzy Systems**. [S.l.]: AP Professiona, 1994.

DE AQUINO, R. R. B. . G. H. T. V. et al. Wind forecasting and wind power generation: Looking for the best model based on artificial intelligence. **Neural Networks (IJCNN), The 2012 International Joint Conference on**, p. 1-8, 2012.

DONGXIAO NIU, Z. G. . X. Research on Neural Networks Based on Culture Particle Swarm Optimization and Its Application in Power Load Forecasting, Natural Computation, 2007. ICNC 2007. Third International Conference on, v. 1, p. 24-27, 2007.

G. E. P. BOX, G. M. J. G. C. R. **Time Series Analysis: Forecasting and Control**. 4th. ed. [S.l.]: Wiley, 2008.

GHANBARI, A. . H. E. . A.-N. S. Comparison of Artificial Intelligence Based Techniques for Short Term Load Forecasting. **Business Intelligence and Financial Engineering (BIFE), 2010 Third International Conference on**, p. 6 – 10, 2010.

KOTLER, P. Marketing Management: Analysis, Planning, Implementation, and Control, New Jersey: Prentice-Hall, 1991.

MAKRIDAKIS, S. Forecasting: Its Role and Value for Planning and Strategy. **Internacional Journal of Forecasting**, v. 12, p. 513-537, 1996. ISSN 4.

MENDEL, J. M. Fuzzy Logic Systems for Engineering: A Tutorial, Proc. of the IEEE, v. 83, n..3, 1995.

MONTGOMERY, D.; JOHNSON, L.; GARDINER, J. Forecasting and Time Series Analysis, New York: McGraw-Hill, 1990.

MOON, M. et al. Seven Keys to Better Forecasting. **Business Horizons**, v. 41, p. 44-52, 1998.

RUNKLER, T. A. Selection of Appropriate Defuzzification Methods Using Application Specific Properties. **IEEE TRANSACTIONS ON FUZZY SYSTEMS**, v. 5, FEBRUARY 1997.

S. G. MAKRIDAKIS, S. C. W. R. J. H. **Forecasting: Methods and Applications**. 3rd. ed. [S.l.]: John Wiley & Sons, 1998.

XU, Y.; CAI, J.; MILANOVIC, J. V. On accuracy of demand forecasting and its extension to demand composition forecasting using artificial intelligence based methods. **Innovative Smart Grid Technologies Conference Europe (ISGT-Europe), 2014 IEEE PES**, p. 1 - 6, 2014.

ZADEH, L. A. Outline of a New Approach to the Analysis of Complex Systems and Decision Processes. **IEEE Transactions on Systems**, 1973.

ZHOU TAO, T. Z. . R. S. Medium and long term load forecasting based on fuzzy times series. **Advanced Mechatronic Systems (ICAMechS), 2013 International Conference on**, p. 671 – 673, 2013.