

## PREVISÃO DE CARGAS MULTINODAIS REALIZADA ATRAVÉS DA ANÁLISE DA PREVISÃO DE CARGAS ELÉTRICAS AGREGADAS

JOAQUIM R. MOREIRA JUNIOR<sup>1</sup>, THAYS ABREU<sup>2</sup>, CARLOS R. MINUSSI<sup>1</sup>, MARA L.M. LOPES<sup>1</sup>

<sup>1</sup>UNESP – Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de Ilha Solteira  
Av. Brasil, 56, 15385-000, Ilha Solteira, São Paulo, Brasil

<sup>2</sup>IFSP – Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, Câmpus Hortolândia  
Av. Thereza Ana Cecon Breda, 56, 13183-091, Hortolândia, São Paulo, Brasil

E-mails: j.jhonkin@hotmail.com, thays7abreu@gmail.com,  
carlos.minussi@unesp.br, mara.lobes@unesp.br

**Abstract**— Forecasting electrical loads is essential from a practical and economic point of view, as it is through this forecast that it is possible to supply energy safely and continuously, without interruptions in supply. In the literature, most of the works that perform the electric load forecast consider the global demand, that is, the sum of the total energy consumption. This work proposes to carry out the load forecast along the buses of a distribution system (multimodal forecast). The proposed method uses an Fuzzy ARTMAP neural network to forecast electric charges in substations (multimodal forecast) 24 hours ahead, with the main objective of studying and identifying possible aggregations of multimodal loads, carried out aiming at improving the forecast multimodal cargo. The database used was from a New Zealand electricity distribution subsystem, consisting of nine substations.

**Keywords:** Artificial Neural Network, Adaptive Resonance Theory, Electrical System Distribution, Multinodal Load Forecasting, Aggregate Electric Load.

**Resumo:** Realizar a previsão de cargas elétricas é indispensável do ponto de vista prático e econômico, pois é através dessa previsão que é possível fornecer energia de forma segura e contínua, sem interrupções no fornecimento. Na literatura a maioria dos trabalhos que realiza a previsão de carga elétrica considera a demanda global, isto é a soma do consumo total de energia. Este trabalho propõe realizar a previsão de carga ao longo dos barramentos de um sistema de distribuição (previsão multimodal). O método proposto utiliza uma rede neural ARTMAP Fuzzy para realizar a previsão de cargas elétricas nas subestações (previsão multimodal) 24 horas a frente, tendo como principal objetivo estudar e identificar as possíveis agregações das cargas multimodais, realizadas visando a melhoria da previsão de carga multimodal. O banco de dados utilizado foi de um subsistema de distribuição de energia elétrica da Nova Zelândia, composto por nove subestações.

**Palavras-chaves:** Rede Neural Artificial, Teoria da Ressonância Adaptativa, Distribuição do Sistema Elétrico, Previsão de Carga Multinodal, Carga Elétrica Agregada.

### 1. Introdução

Fornecer energia de forma segura e contínua é uma das principais preocupações dos fornecedores de energia. Assim, é essencial realizar estudos e análises continuamente e incorporar ações antecipatórias no sistema de energia elétrica para evitar qualquer tipo de interrupção no fornecimento de eletricidade. Esses objetivos podem ser alcançados se as concessionárias de energia obtiverem informações antecipadas e precisas sobre a carga elétrica.

A previsão de cargas elétricas é realizada há muito tempo, através da aplicação de ferramentas clássicas (O'Donovan, 1983) com base em métodos estatísticos e estocásticos, como, por exemplo, o ARIMA de Box-Jenkins (Box & Jenkins, 1976) modelos de regressão linear (simples ou múltiplo), filtro de Kalman, etc. (Moghram; Rahman, 1989).

Na última década, os métodos baseados em sistemas inteligentes (Haykin, 2008; Zadeh, 1965) por exemplo, lógica nebulosa, redes neurais artificiais, algoritmos genéticos, ganharam uma atenção especial dos pesquisadores e estão sendo cada vez mais utilizados para esse fim.

A previsão de carga global, define a quantidade de energia que as concessionárias devem comprar para

fornecer aos seus consumidores, e é responsável pela maioria das publicações disponíveis na literatura, com base em técnicas como RNA (Taylor; Buizza, 2002), lógica fuzzy (Pandian et. al., 2006; Kocak, 2017), algoritmos genéticos (Liao; Tsao, 2006) métodos clássicos (Gross; Galiana, 1987; Moghram; Rahman, 1989; El Desouky; El Kateb, 2000), fuzzy-ART & ARTMAP ANN (Lopes et al., 2005), ARIMA ((Box & Jenkins, 1976; O'Donovan, 1983; Moghram; Rahman, 1989), RNA com base no método de treinamento Levenberg – Marquardt (Saini; Soni, 2002) e RNA por aprendizado gradiente descendente (Malki et al., 2004).

No entanto, sem a previsão da carga multinodal é impossível executar qualquer tipo de análise estática ou dinâmica do sistema (por exemplo: estabilidade do ângulo, fluxo de carga, etc.), sendo escasso as publicações para este fim. A seguir são apresentados alguns trabalhos que abordam a previsão de carga elétrica em subestações.

No trabalho de Chen et al. (1996), os autores realizaram um método de previsão de carga para três subestações para atender a diferentes tipos de consumidores (residencial, comercial e industrial). Altran

(1999) utiliza uma RNA de perceptron múltiplas camadas, com treinamento baseado em retropropagação, mas substituindo a função de ativação usual por uma base radial para realizar uma previsão de carga multinodal. Em Nose-Filho et al. (2011) foi proposto um modelo genérico de previsão de carga de curto prazo que pode ser aplicado à previsão de carga multinodal usando uma rede neural de regressão geral. Em Kong et al. (2017), é proposta uma metodologia para prever a corrente elétrica em várias linhas de transmissão com base em um método estatístico. O trabalho de Abreu et al. (2018) é desenvolvida uma metodologia utilizando a rede neural ARTMAP *Fuzzy* para prever o consumo de energia das nove subestações em um sistema da Nova Zelândia.

Neste trabalho foi desenvolvida uma metodologia para realizar a previsão de cargas elétricas a curto prazo, 24 horas a frente, sendo considerados vários pontos do sistema, como subestações, transformadores e alimentadores. A previsão de carga multinodal é realizada utilizando uma rede neural ARTMAP *Fuzzy* (Carpenter et al., 1992), que é baseada na teoria da ressonância adaptativa (Grossberg, 2013), sendo estável para aprender novos conhecimentos e plástica ao não perder as informações já adquiridas.

A metodologia foi desenvolvida em quatro partes (i) realiza-se a previsão das cargas globais; (ii) calcula-se os fatores de participação de cada subestação e em seguida são realizadas as previsões das cargas locais; (iii) efetua-se uma análise para identificar as possíveis agregações das cargas multinodais (subestações), visando a melhoria da previsão de carga local e carga global e (iv) através das agregações das subestações efetuadas, é realizada a previsão de carga multinodal referente ao bloco de subestações agregadas com objetivo de prever a cargas das subestações individuais.

## 2. Rede Neural ARTMAP *Fuzzy*

A rede neural artificial ARTMAP-*Fuzzy* (Carpenter et al., 1992) é uma rede da família ART (*Adaptive Resonance Theory*) com arquitetura baseada na teoria da ressonância adaptativa. Seu sistema de aprendizagem é supervisionado, sendo capaz de auto-organizar o reconhecimento estável de categorias em resposta a sequências arbitrárias de padrões de entradas. Esta rede é composta por um par de módulos da teoria da ressonância adaptativa, ART<sub>a</sub> *Fuzzy* e ART<sub>b</sub> *Fuzzy*, que são conectados através de um módulo de memória associativa inter-ART (Carpenter et al., 1992). A rede neural ART<sub>a</sub> *Fuzzy* é que recebe os dados de entrada, e a rede ART<sub>b</sub> *Fuzzy* constitui a resposta desejada para o padrão apresentado à rede que são interligadas pelo módulo de memória associativa Inter-ART, que verifica a similaridade das entradas e saídas com as categorias existentes (Carpenter et al., 1992).

Os parâmetros da rede neural ARTMAP *Fuzzy* são (Carpenter et al., 1992):

- Parâmetro de escolha  $\alpha$  ( $\alpha > 0$ ): responsável pela seleção de categorias
- Taxa de aprendizagem  $\beta$  ( $\beta \in [0,1]$ ): controla a velocidade de aprendizagem da rede
- Parâmetro de vigilância do módulo ART<sub>a</sub>, ART<sub>b</sub> e inter-ART ( $\rho_a, \rho_b$  e  $\rho_{ab} \in [0,1]$ ): controla a ressonância da rede neural, sendo responsável pelo número de categorias criadas.

A Fig. 1 ilustra a arquitetura da rede neural ARTMAP *Fuzzy*.

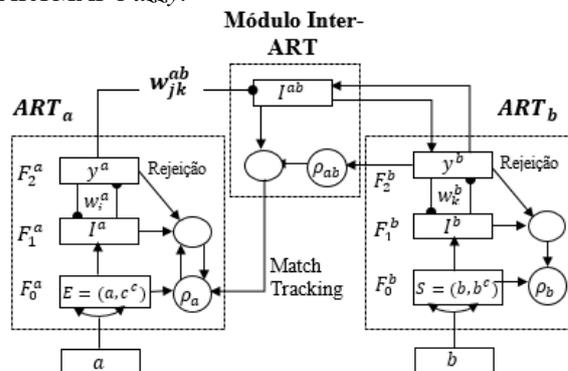


Figura 1. Estrutura da Rede Neural ARTMAP *Fuzzy*.

## 3. Metodologia Proposta

Este artigo apresenta uma nova metodologia de previsão de carga multinodal sendo que neste sentido podem-se ser considerados vários pontos do sistema de energia elétrica. Neste trabalho será tratado a previsão de carga elétrica em subestações utilizando técnicas inteligentes alicerçadas na previsão realizadas em blocos (subestações agregadas).

Portanto, para desenvolver esta metodologia é necessário realizar os seguintes passos:

1. Prever a carga elétrica global do sistema (PCG);
2. Prever as cargas elétricas em vários nós do sistema (carga multinodal), (PCM);
3. Agregar alguns nós do sistema e verificar como o comportamento das cargas elétricas agregadas (blocos) influenciam o sistema;
4. Analisar as cargas agregadas e a partir delas prever as cargas elétricas nodais (subestações).

As previsões de cargas elétricas, global, nodais e agregadas são realizadas através da rede neural ARTMAP *Fuzzy*.

### 3.1 Previsão de Carga Elétrica Global

Para realizar a previsão de carga elétrica global é utilizada a rede neural ARTMAP *Fuzzy* (PCG). Para compor o conjunto de dados de entrada da rede neural ARTMAP *Fuzzy* (Carpenter et al., 1992) são utilizados 48 dados de cargas elétricas de meia em meia hora. O conjunto de dados de entrada, no módulo ART<sub>a</sub> é composto por: dados exógenos (dia da

semana, hora do dia, feriado e horário de verão) e valores de carga global (CG) em três tempos anteriores,  $t-1$ ,  $t-2$  e  $t-3$ . Esta representação das cargas globais contemplam um movimento de janela (Altran, 1999) que é realizado com o objetivo da rede identificar o comportamento do perfil da carga. A saída da rede neural ARTMAP *Fuzzy* é dada pelo valor de carga elétrica global subsequente, ou seja, no instante  $t$ .

A Fig. 2 ilustra a estratégia utilizada na rede neural ARTMAP *Fuzzy* indicando as variáveis de entrada e de saída da rede.

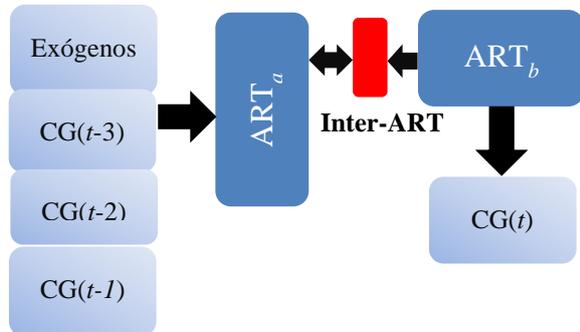


Figura 2. Dados de Entrada e Saída da Rede ARTMAP *Fuzzy* para o Sistema Previsor Global.

Os dados exógenos são compostos por dias da semana, hora do dia, feriado ou dia atípico e horário de verão, representados em números binários.

### 3.2 Previsão de Carga Elétrica Multinodal

Na previsão de carga multinodal (CM) também fez-se o uso da rede neural ARTMAP *Fuzzy* aplicada a um Sistema Previsor de Cargas Multinodal (SPCM).

Este sistema previsor é composto por módulo previsores que atuam de forma independente, de forma que, em cada módulo (subestação) tem-se uma rede ARTMAP *Fuzzy* atuando de forma a realizar a previsão em pontos de interesse específicos da rede, como subestações, transformadores, alimentadores, entre outros. Neste trabalho o SPCM é utilizado para realizar a previsão de subestações, portanto, neste sentido é utilizado a definição de fator de participação global (FPG) que se refere ao percentual de atuação da carga de cada subestação no sistema e é definido pela equação (1) (Nose-Filho et al., 2011; Altran, 1999):

$$FPG_j(t) = \frac{CM_j(t)}{CG(t)} \quad (1)$$

sendo:

$CM_j(t)$ : cara multinodal referente à  $j$ -ésima subestação no instante de tempo  $t$ ;

$CG(t)$ : carga global (soma das cargas de cada subestação) no instante  $t$ .

Portanto, para cada subestação do sistema abordado é realizada uma previsão de carga configurando a previsão multinodal. O conjunto de entradas utilizada na rede ARTMAP *Fuzzy* para cada subestação  $j$  é composta pelo valor de carga global no tempo  $t$ ,  $CG(t)$ , e os fatores de participação da subestação  $j$  nos instantes de tempos,  $t-1$ ,  $t-2$  e  $t-3$ .

A saída da rede neural ARTMAP *Fuzzy* para o SPCM é dada pelo valor do fator de participação no instante  $t$ .

Na Fig. 3 é ilustrada o SPCM utilizando a rede neural ARTMAP *Fuzzy* com as variáveis de entrada e de saída da rede.

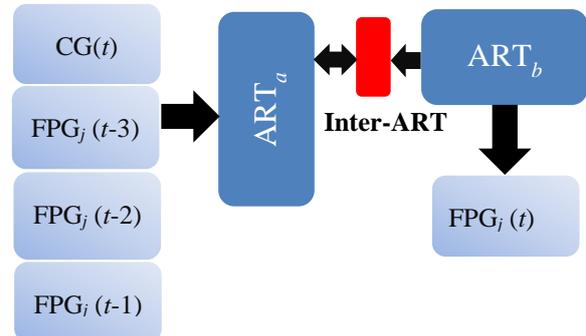


Figura 3. Dados de Entrada e Saída da Rede ARTMAP *Fuzzy* para Sistema Previsor Multinodal.

Uma vez previsto o  $FPG_j$  no instante  $t+1$  é necessário identificar qual o valor de carga da subestação  $j$ , está associado a esse percentual. Desta forma, calcula-se a carga multinodal associando o fator de participação previsto para subestação  $j$  no instante  $t$ ,  $PFPG_j(t)$ , e o valor previsto da carga global no instante  $t$ ,  $PCG_j(t)$ . Desta forma, tem-se:

$$PCMCA_{ij}(t) = PFCA_i(t) \times PCA_i(t) \quad (2)$$

### 3.3 Análise das Agregações das Subestações na Previsão

Considerando a previsão multinodal no qual a carga elétrica é prevista para cada nó do sistema, neste caso, as subestações, tem-se que:

$$\sum_{j=1}^n FPG_j(t) = 1 \quad (3)$$

no qual:

$FPG_j(t)$ : fator de participação global da subestação  $j$  no instante de tempo  $t$ ;

$n$ : número total de subestações do sistema.

Se o sistema possui uma grande quantidade de subestações, é normal pensar que os valores do fator de participação global de algumas subestações envolvidas teriam valores muito pequenos e, portanto, esta variável iria prejudicar o desempenho do treinamento da rede ARTMAP *Fuzzy* (Abreu et. al., 2019). Este desempenho está associado ao diagnóstico (previsão) da rede neural e tempo de processamento. Portanto, esta estratégia pode representar mais rapidez (Abreu et. al., 2018) e melhoria nos resultados.

A princípio a ideia foi identificar no sistema, os nós que podem ser agrupados com o propósito minimizar as discrepâncias do fator de participação e com isso, melhor a previsão de carga multinodal e assim, consequentemente, a previsão de carga global.

Então, foram gerados agrupamentos de forma a manter a distribuição do sistema e garantir uma previsão de carga mais precisa.

A carga agrupada ou agregada é representada por um conjunto,  $CA_i$ , no qual contem  $k$  nós (subestações) agrupadas neste conjunto. O índice  $i$  indica que em uma análise podem ser analisados mais de um conjunto agregado de cargas. Considerando  $n$  o número de subestações do sistema e para  $2 \leq ns < n$ , então:

$$CA_i = \sum_{k=1}^{ns} CMA_k(t) \quad (4)$$

sendo:

$CMA_k(t)$ : carga multinodal (subestação) do conjunto agregado no instante  $t$ .

$ns$ : número de subestações agrupadas.

As demais cargas multinodais são tratadas de forma individual e, portanto, a carga global do sistema será constituída das cargas multinodais individuais e os conjuntos de cargas agregadas.

### 3.4 Previsão de Carga Multinodal realizada através das Previsões de Cargas Agregadas

A previsão de carga multinodal realizada através da participação de cada nó do sistema é realizado conforme ilustrado na Fig. 3. Contudo, como as cargas multinodais são cargas desagregadas as previsões tornam-se menos precisas. No intuito de melhorar as previsões, é utilizado a estratégia de agrupamento das subestações mais sensíveis visando a melhoria nas previsões. Porém uma vez agrupado um conjunto de subestações, perde-se a informação referente as subestações que foram agregadas.

Desta forma, utiliza-se um sistema predictor carga multinodal com cargas agregadas (SPCMCA) que tem como objetivo prever apenas as cargas elétricas das subestações usadas no conjunto agregado dado por (1).

O SPCMCA possui a mesma estrutura do SPCM com uma única diferença, que a carga global agora refere-se a carga agregada do conjunto,  $CA_i$ . Calcula-se fator de participação da carga agregada ( $FPCA_i$ ) pela equação (5).

$$FPCA_{ij}(t) = \frac{CMA_{ij}(t)}{CA_i(t)} \quad (5)$$

sendo:

$CMA_{ij}(t)$ : carga multinodal referente à  $j$ -ésima subestação contida no  $i$ -ésimo conjunto de subestações agregadas no instante de tempo  $t$ ;

$CA_i(t)$ :  $i$ -ésimo conjunto de subestações agregadas (soma das cargas de  $ns$  subestações agregadas) no instante  $t$ .

O SPCMCA tem a finalidade de realização a previsão das cargas das subestações agregados do conjunto  $CA_i(t)$ . O conjunto de entradas utilizada na rede ARTMAP *Fuzzy* para cada subestação  $j$  que compoem o conjunto  $CA_i(t)$  é composta pelo valor de carga agrupada no tempo,  $CA_i(t)$ , e os fatores de participação da  $j$ -ésima subestação de  $CA_i(t)$  nos instantes de tempos,  $t-1$ ,  $t-2$  e  $t-3$ .

A saída da rede neural ARTMAP *Fuzzy* para o SPCMCA é dada pelo valor do fator de participação

de carga agregada no instante  $t$ . O SPCMCA via rede neural ARTMAP *Fuzzy* é ilustrado na Fig. 4 e nela observa-se as variáveis de entrada e de saída da rede.

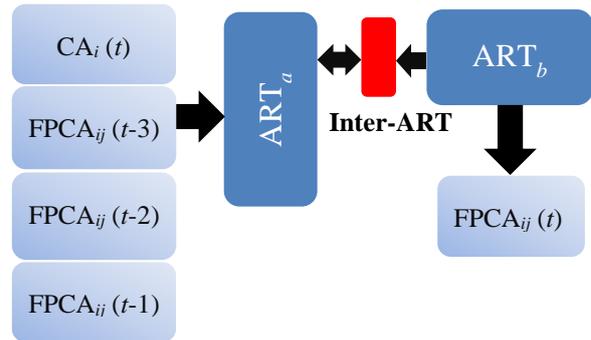


Figura 4. Dados de Entrada e Saída da Rede ARTMAP *Fuzzy* para Sistema Predictor Multinodal através da Carga Agregada.

Obtidos os valores dos fatores de participação das cargas agregadas para cada subestação  $j$ , é calculada e realizada a PCMA, de acordo com a equação (6).

$$PCMCA_{ij}(t) = FPCA_i(t) \times PCA_i(t) \quad (6)$$

A metodologia foi aplicada na previsão de carga multinodal de um subsistema de distribuição da Nova Zelândia.

## 4. Resultados e Discussões

Neste trabalho foi utilizado o conjunto de dados fornecidos por uma companhia da Nova Zelândia (Nose Filho et. al., 2011), cujo sistema é composto por nove subestações (sub1, sub2, sub3, sub4, sub5, sub6, sub7, sub8, sub9).

A fase de treinamento da rede neural ARTMAP *Fuzzy* é composta por dados referente ao período de 8 de dezembro de 2007 a 7 de janeiro de 2008 que totalizam 1488 informações.

A saída da fase de diagnóstico constitui a previsão de carga realizada no dia 8 de janeiro de 2008 e possui 48 valores de carga elétrica ( $\frac{1}{2}$  em  $\frac{1}{2}$  hora) que representam a previsão de carga de um dia (24 horas).

### 4.1 Critério de Comparação dos Resultados

Para avaliar o desempenho da metodologia proposta neste trabalho, utilizou-se o Erro Percentual Médio Absoluto (MAPE) como critério de avaliação, o MAPE é representado conforme a equação (7):

$$MAPE = \frac{1}{n_i} \sum_{h=1}^{n_i} \left\{ \frac{|L(h) - \underline{L}(h)|}{L(h)} \right\} \times 100 \quad (7)$$

sendo:

$n_i$ : Número de informações da série temporal;

$L(h)$ : Valor da carga real no instante  $h$ ;

$\underline{L}(h)$ : Valor da carga prevista no instante  $h$ ;

### 4.2 Resultado da Previsão Global

Os parâmetros utilizados na rede neural ARTMAP *Fuzzy* foram encontrados através da realização de vários testes. Os valores dos parâmetros aplicados a rede neural ARTMAP *Fuzzy*, utilizados na

previsão global foram:  $\beta = 1$ ,  $\alpha = 0.7$ ,  $\rho_{a_{baseline}} = 0.99$ ,  $\rho_b = 0.991$ ,  $\rho_{ab} = 1$ , e  $\varepsilon = 0.001$ .

Os resultados da previsão de carga elétrica obtidos pela rede neural ARTMAP Fuzzy e o valor de carga global real para o dia 08/01/2008 é mostrada na Fig. 5.

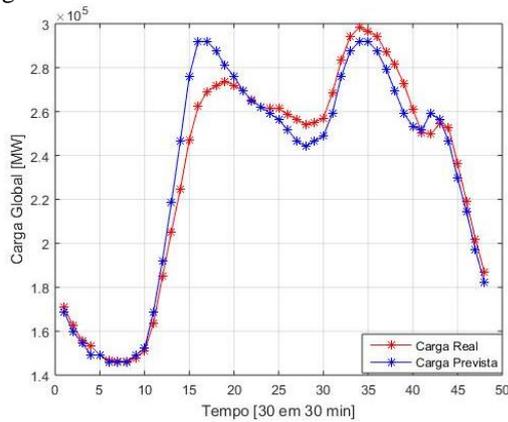


Figura 5. Curvas de Carga Elétrica Global Real e Prevista pela Rede Neural ARTMAP Fuzzy.

#### 4.3 Resultados das Previsões das Subestações

Para previsão multinodal foram utilizados os mesmos parâmetros usados na previsão global e apresentados na anteriormente.

Os resultados do erro percentual médio absoluto referentes a previsão multimodal utilizando a rede neural ARTMAP Fuzzy encontram-se na Tabela 1.

Tabela 1. Valores do Erro Percentual Médio Absoluto (MAPE) das Subestações obtidas através da Rede ARTMAP Fuzzy.

Subestações	MAPE (%)
sub1	5,91
sub2	12,29
sub3	3,52
sub4	6,02
sub5	4,21
sub6	4,70
sub7	4,99
sub8	6,49
sub9	16,26
Carga Global	2,91
Carga Global (soma previsões multinodais)	4,74

Observa-se na Tabela 1 o valor da previsão da carga global e o valor da carga global obtida pela previsão multinodal no qual refere-se a soma dos valores de cargas das subestações previstas pela rede neural ARTMAP Fuzzy.

A Fig. 6 apresenta as curvas de carga globais real e prevista pela soma das previsões multinodais.

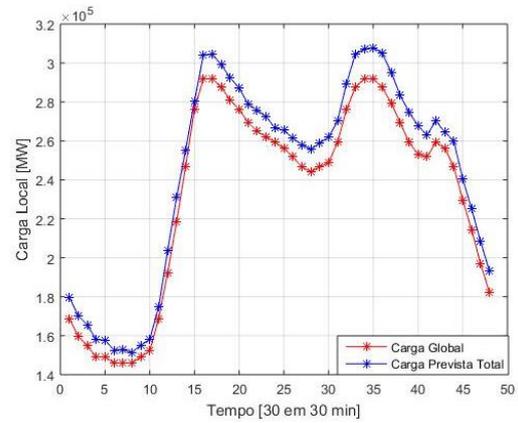


Figura 6. Curvas de Carga Elétrica Global Real e Prevista pela Rede Neural ARTMAP Fuzzy através da Soma das Previsões de Cargas Multinodais.

#### 4.4 Resultados das Previsões de Cargas Agregadas

Através da Tabela 1 é possível notar que existem subestações com erros percentuais médios acima de 6% (subestações 2, 8 e 9) e a soma das previsões cargas multinodais (carga global) apresenta um que apresentam um erro percentual médio de 4,74%.

Portanto, para melhorar os resultados das previsões em relação a estas subestações pretende-se realizar agrupamentos das cargas multinodais visando uma previsão menos desagregada e conseqüentemente mais precisa. Foram realizados vários testes e serão apresentadas duas análises realizadas:

- Análise 1:  $CA_1 = \{\text{sub2, sub8, sub9}\}$
- Análise 2:  $CA_2 = \{\text{sub2, sub8}\}$  e  $CA_3 = \{\text{sub4, sub6, sub9}\}$

Á princípio as agregações foram realizadas utilizando o diagrama elétrico do sistema. Porém, observou-se que as melhores agregações eram obtidas analisando-se o equilíbrio das previsões das cargas individuais do sistema.

Tabela 2. Valores do Erro Percentual Médio Absoluto (MAPE) das Subestações Individuais e Agregadas obtidas através da Rede ARTMAP Fuzzy para Análise 1.

Subestações	MAPE (%)
sub1	5,91
sub3	3,52
sub4	6,02
sub5	4,21
sub6	4,70
sub7	4,99
CA <sub>1</sub>	3,75
Carga Global	1,28

As Tabelas 2 e 3 apresentam os valores do MAPE obtidos para as subestações individuais e para as subestações agregadas.

A Tabela 2 apresenta o erro percentual médio obtido na previsão agregada considerando a Análise 1 e, portanto, tem-se que a agregação das subestações 2, 8 e 9, proporcionou uma redução significativa do erro

de previsão que pode ser observada através da curva de carga esboçada na Fig. 7. Da mesma forma, através da Tabela 3, é possível notar a melhoria no resultado da previsão de carga global obtida através da agregação das subestações realizadas pela Análise 2.

Tabela 3. Valores do Erro Percentual Médio Absoluto (MAPE) das Subestações Individuais e Agregadas obtidas através da Rede ARTMAP Fuzzy para Análise 2.

Subestações	MAPE (%)
sub1	5,91
sub3	3,52
sub5	4,21
sub7	4,99
CA <sub>2</sub>	3,07
CA <sub>3</sub>	4,39
Carga Global	1,27

Observa-se que a agregação das subestações tanto na Análise 1 quanto na Análise 2 alcançaram o objetivo que era reduzir o erro das previsões, uma vez que, a literatura sugere que este erro seja inferior a 5% para se tenha uma boa previsão (Ranaweera et al., 1997).

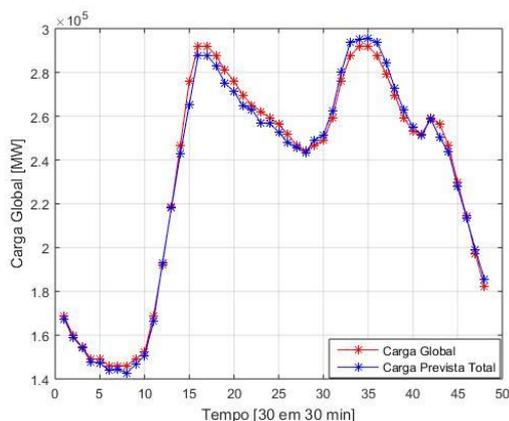


Figura 7. Curvas de Carga Elétrica Global Real e Prevista pela Rede Neural ARTMAP Fuzzy através da Soma das Previsões de Cargas Multinodais Individuais e Agregadas para Análise 1.

As Figs. 7 e 8 ilustram as curvas de carga global real e obtida pela soma das cargas das previsões de subestações individuais e subestações agregadas, respectivamente, pela Análise 1 e Análise 2.

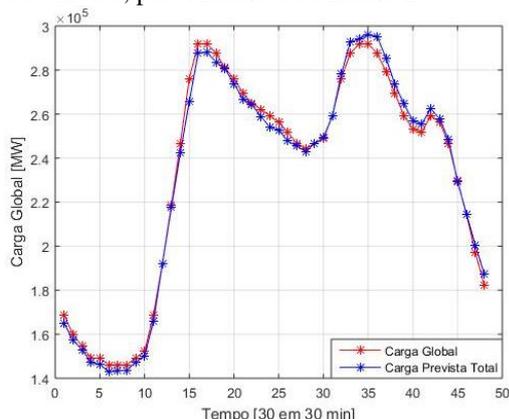


Figura 8. Curvas de Carga Elétrica Global Real e Prevista pela Rede Neural ARTMAP Fuzzy através da Soma das Previsões de Cargas Multinodais Individuais e Agregadas para Análise 2.

Os parâmetros aplicados a rede neural ARTMAP Fuzzy, utilizados na previsão de carga agregada para as análises, 1 e 2, foram:  $\beta = 1$ ,  $\alpha = 0.7$ ,  $\rho_{\alpha baseline} = 0.9$ ,  $\rho_b = 0.999$ ,  $\rho_{ab} = 1$ ,  $\varepsilon = 0.0005$ .

#### 4.5 Resultados das Previsões das Subestações realizada a partir das Previsões de Cargas Agregadas

Uma vez a carga multinodal seja agregada perde-se a análise das subestações individualizadas. Portanto, executou-se uma previsão de carga considerando como carga global a carga agregada com a finalidade de prever as cargas individuais que foram agregadas no conjunto  $CA_i(t)$ .

Para análise 1, CA<sub>1</sub>, o SPCMCA irá prever as cargas das subestações 2, 8 e 9. Já na análise 2 tem-se duas agregações no sistema CA<sub>2</sub> e CA<sub>3</sub>. Para cada uma delas será realizada um SPCMCA, ou seja, pfiara CA<sub>2</sub>, o sistema irá prever as cargas das subestações 2 e 8 e para CA<sub>3</sub> será previsto as cargas das subestações 4, 6 e 9.

Para SPCMCA<sub>1</sub> os parâmetros utilizados para previsão de cada subestação é ilustrado na Tabela 4.

Tabela 4. Valores dos Parâmetros da Rede ARTMAP Fuzzy para Previsão das Subestações da Carga Agregada na Análises 1.

Parâmetro	Valor para Subestações		
	2	8	9
$\beta$	1,0000	1,0000	1,0000
$\alpha$	0,0500	0,0700	0,6000
$\rho_{\alpha baseline}$	0,9000	0,9000	0,9000
$\rho_b$	0,9992	0,9900	0,9992
$\rho_{ab}$	1,0000	1,0000	1,0000
$\varepsilon$	0,0005	0,5900	0,0005

Já na análise 2 é necessário realizar a previsão de dois sistemas previsores SPCMCA<sub>2</sub> e o SPCMCA<sub>3</sub>.

Tabela 5. Valores dos Parâmetros da Rede ARTMAP Fuzzy para Previsão das Subestações da Carga Agregada na Análises 2 – CA<sub>2</sub>.

Parâmetro	Valor para Subestações	
	2	8
$\beta$	1,0000	1,0000
$\alpha$	0,9000	0,9900
$\rho_{\alpha baseline}$	0,9000	0,9000
$\rho_b$	0,9992	0,99905
$\rho_{ab}$	1,0000	1,0000
$\varepsilon$	0,0500	0,5000

Tabela 6. Valores dos Parâmetros da Rede ARTMAP Fuzzy para Previsão das Subestações da Carga Agregada na Análises 2 – CA<sub>3</sub>.

Parâmetro	Valor para Subestações		
	4	6	9
$\beta$	1,0000	1,0000	1,0000
$\alpha$	0,9000	0,9900	0,9900
$\rho_{\alpha baseline}$	0,9000	0,9000	0,9000
$\rho_b$	0,9992	0,9999	0,999599
$\rho_{ab}$	1,0000	1,0000	1,0000
$\varepsilon$	0,5000	0,9000	0,0500

As tabelas 5 e 6 apresentam os parâmetros utilizados na rede neural ARTMAP *Fuzzy* para cada sistema predictor. A Tabela 7 apresenta os valores do MAPE obtidos para as subestações individuais que estavam contidas no CA<sub>1</sub>.

Tabela 7. Valores do Erro Percentual Médio Absoluto (MAPE) das Subestações Individuais e Subestações obtidas pelo CA<sub>1</sub> através da Rede ARTMAP *Fuzzy*.

Subestações	MAPE (%)
sub1	5,91
sub2	5,57
sub3	3,52
sub4	6,02
sub5	4,21
sub6	4,70
sub7	4,99
sub8	4,51
sub9	8,69
Carga Global	1,67

A Tabela 8 apresenta os valores do MAPE obtidos para as subestações individuais que estavam contidas no CA<sub>2</sub>.

Tabela 8. Valores do Erro Percentual Médio Absoluto (MAPE) das Subestações Individuais e Subestações obtidas pelo CA<sub>2</sub> e CA<sub>3</sub> através da Rede ARTMAP *Fuzzy*.

Subestações	MAPE (%)
sub1	5,91
sub2	5,15
sub3	3,52
sub4	4,67
sub5	4,21
sub6	3,96
sub7	4,99
sub8	5,28
sub9	6,56
Carga Global	1,32

Observando os resultados ilustrados nas Tabelas 7 e 8, é possível verificar a redução no valor do erro de previsão das cargas das subestações que foram agregadas. Comparando os resultados apresentados nas Tabelas, 1 e 7, tem-se que as previsões obtidas através desta metodologia diminuí de forma considerável o erro de previsão das subestações 2, 8 e 9. Da mesma forma, ao se comparar os resultados das Tabelas, 1 e 8, nota-se que com a metodologia proposta obteve melhores previsões de cargas multinodais para as subestações que foram agregadas (subestações 2, 8, 4, 6 e 9).

As Figs. 9 e 10 ilustram as curvas de carga global real e obtida pela soma das cargas das subestações individuais obtidas pelas previsões realizadas, respectivamente, pelo SPCMCA<sub>1</sub>, SPCMCA<sub>2</sub> e SPCMCA<sub>3</sub>.

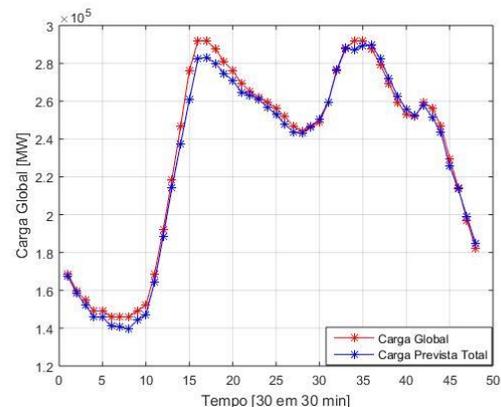


Figura 9. Curvas de Carga Elétrica Global Real e Prevista pela Rede Neural ARTMAP *Fuzzy* através da Soma das Previsões de Cargas Multinodais obtidas pelo SPCMCA via Análise 1.

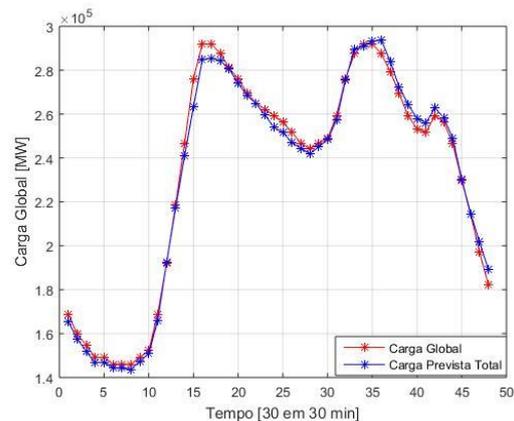


Figura 10. Curvas de Carga Elétrica Global Real e Prevista pela Rede Neural ARTMAP *Fuzzy* através da Soma das Previsões de Cargas Multinodais obtidas pelo SPCMCA via Análise 2.

Observa-se com os resultados obtidos que as previsões de carga multinodais individuais obtidas ficaram com valores dos erros abaixo de 6,56%.

#### 4 Conclusão

Este trabalho apresenta o uso da rede neural ARTMAP *Fuzzy* para realizar previsões globais e locais em um período de 24 horas à frente ou 48 valores de carga de meia em meia hora.

A literatura vem abordando a previsão multinodal (com o uso do fator de participação da carga global) e recentemente alguns trabalhos vem tratando da previsão agregada para melhoria do tempo computacional e melhoria em termos de previsão global. Porém, se as subestações estão agregadas não é possível analisar as suas cargas individualmente.

Logo, a proposta de prever as subestações que foram agregadas baseou-se no uso da metodologia muito parecida com a da previsão multinodal, porém, desta vez foi considerado como carga global a carga agregada pelas subestações. O uso do fator de participação dessas subestações no sistema agregado faz com que contemplem o novo conjunto de dados (um para cada subestação agregada no sistema) para o sistema neural prever as cargas individuais das subestações que foram agregadas.

Esta metodologia além de fornecer a previsão de todas as subestações do sistema fez com que os

valores dos erros percentuais de previsão de cada subestação reduzissem consideravelmente.

Foram realizadas duas análises, 1 e 2, sendo que na análise 1 o sistema continha 3 subestações agregadas e já na análise 2, o sistema apresentava dois conjuntos agregados, um com duas subestações e outro com 3 subestações agregadas. Em ambos os casos, observou-se uma melhoria na previsão das cargas multinodais comparado ao sistema predictor multinodal inicial mantendo MAPES inferiores e assegurando a técnica como uma boa estratégia na realização de previsões de carga local.

### Agradecimentos

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de financiamento 001.

### Referências Bibliográficas

- Abreu, T.; Amorim, A.J.; Santos-Junior, C.R.; A.D.P. Lotufo, A.D.P.; Minussi, C.R. (2018). Multinodal load forecasting for distribution systems using a fuzzy-ARTMAP neural network, *Applied Soft Computer*. v. 71, p. 307-316.
- Abreu, T.; Moreira-Junior, J. R.; Minussi, C. R.; P. Lotufo, A. D. e Lopes, M. L. M. (2019). Short-Term Multinodal Load Forecasting Using a Fuzzy-ARTMAP Neural Network, *In: IEEE PES Innovative Smart Grid Technologies Conference-Latin América*, p.1-6.
- Altran, A. B. (1999) Intelligent System for Multinodal Load Forecasting of Electrical Power Systems, Ph.D. Thesis, Electrical Engineering Department, UNESP – São Paulo State University, SP, Brazil (In Portuguese).
- Box, G. E.; Jenkins, G. M. (1976). *Times series analysis: forecasting and control*, 575p. Holden-Day, San Francisco, USA.
- Carpenter, G.A.; Grossberg, S.; Markuzon, N.; Reynolds, J. H. (1992) Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps, *IEEE Transaction. Neural Network*, v. 3 (5), p. 698–713.
- Chen, C.S.; Tzeng, Y.M.; Hwang, J.C. (1996). The application of artificial neural networks to substation load forecasting. *Electric Power System Research*, v. 38, (2), p. 153–160.
- O'Donovan, T. M. (1983). *Short Term Forecasting: An Introduction to the Box-Jenkins Approach*, 256p., John Wiley & Sons, New York, USA.
- El Desouky, A. A.; El Kateb, M. M. (2000). Hybrid adaptive techniques for electric-load forecast using ANN and ARIMA. *IEE Proceedings-Generation Transmission Distribution*, v. 147 (4), p. 213–217.
- Grossberg, S. (2013) Adaptive resonance theory: how a brain learns to consciously attend, learn, and recognize a changing world. *Neural Networks*, v. 37, p. 1–47.
- Gross, G.; Galiana, F.D. (1987) Short-term load forecasting. *Proceedings of the IEEE*, v. 75, (12), p. 1558-1573.
- Haykin, S. O. (2008). *Neural networks and learning machines*, Prentice-Hall 3<sup>rd</sup>. ed., New Jersey, USA.
- Kocak, C. (2017). ARMA(p,q) type high order fuzzy time series forecast method based on fuzzy logic relations. *Applied Soft Computer*. v. 58, p. 92–103.
- Kong, N.; Bocquel, M.; Barbier, T.; Girard, R.; Magliaro, E.; Kariniotakis, G.; Pelton, G.; Cauchois, P. (2017). Long-Term Forecast of Local Electrical Demand and Evaluation of Future Impacts on the Electricity Distribution Network. *In: International Conference & Exhibition on Electricity Distribution*, p. 2401–2405.
- Liao, G.C.; Tsao, T.P. (2006). Application of a fuzzy neural network combined with a chaos genetic algorithm and simulated annealing to short-term load forecasting, *IEEE Transactions on Evolutionary Computation*, v. 10 p. 330–340.
- Lopes, M.L.M.; Minussi, C.R.; Lotufo, A.D.P. (2005). Electric load forecasting using a fuzzy ART&ARTMAP neural network, *Applied Soft Computer*. v. 5, p. 235–244.
- Malki, H. A.; Karayiannis, N. B.; Balasubramanian, M. (2004). Short-term electric power load forecasting using feedforward neural networks, *Expert Systems*, v. 21 (3), p. 157–167.
- Moghram, I.; Rahman, S. (1989). Analysis and evaluation of five short-term load forecasting techniques. *IEEE Transactions on Power Systems*, v. 4, (4), p. 1484-1491.
- Nose-Filho, K.; Lotufo, A.D.P.; Minussi, C.R. (2011). Short-term multinodal load forecasting using a modified general regression neural network, *IEEE Transaction Power Delivery*, v. 26, p. 2862–2869.
- Pandian, S. C.; Duraiswamy, K.; Rajan, C.C.A.; Kanagaraj, N. (2006). Fuzzy approach for short term load forecasting, *Electric Power System Research*. v. 76, p. 541–548.
- Ranaweera, K. D.; Karady, G. G. e Farner, G. R. (1997). Economic impact Analysis of Load Forecasting. *IEEE Transactions on Power Systems*, v. 12 (3), p. 1388-1392.
- Saini, L.m.; Soni, M.K. (2002). Artificial neural network based peak load forecasting Levenberg-Marquardt and quasi-Newton methods, *IEE Proceedings- Generation Transmission Distribution*. v. 149 (5), p.578–584.
- Taylor, J. R; Buizza, R. (2002). Neural network load forecasting with weather ensemble predictions, *IEEE Transactions Power Systems*, v. 17 (3), p.626–632,
- Zadeh, L.A. (1965). Fuzzy sets. *Information and Control*, v. 8, p. 338-353.