

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS BASEADAS NA TEORIA DA RESSONÂNCIA ADAPTATIVA NA PREVISÃO DE CURTÍSSIMO PRAZO EM NÍVEIS MENOS AGREGADOS

MARLEIDE FERREIRA ALVES, MARCOS R. MÜLLER, ANNA DIVA P. LOTUFO, MARA LÚCIA MARTINS LOPES

Laboratório de Sistemas Inteligentes - Sintel, Depto. de Engenharia Elétrica, Universidade Estadual Paulista "Júlio de Mesquita Filho" - UNESP

Caixa Postal 31, CEP 15385-000, Ilha Solteira-SP

E-mails: marleidealves11@gmail.com, marcos_ricardo@live.com, annadiva@dee.feis.unesp.br, mara@mat.feis.unesp.br

Abstract - The forecast of electricity demand in less aggregate level is a pretty difficult task. Several techniques have been used, including: time series, regression analysis and techniques involving computational and artificial intelligence. To address the forecast problem in this kind of scenario, an artificial neural network called Fuzzy ARTMAP with and without continuous training is proposed, which is called renewed Fuzzy ARTMAP. This work uses real data from a smart microgrid installed in Brazil. Simulations with two different approaches, with and without continuous training were conducted. It was observed that the scenario that uses continuous training provides better results.

Keywords - Artificial Neural Networks, ARTMAP Fuzzy, Demand Forecasting, Disaggregated Consumption, Time Series.

Resumo - A previsão de demanda de energia elétrica em níveis menos agregados é um trabalho consideravelmente difícil. Diversas técnicas têm sido utilizadas, entre elas: séries temporais, análise de regressão e técnicas envolvendo inteligência computacional e artificial. Para abordar o problema de previsão neste tipo de cenário, foi proposto o uso da rede neural artificial ARTMAP Fuzzy e rede neural ARTMAP Fuzzy Remodelada. Este trabalho utiliza dados reais de uma *smart microgrid* instalada em território brasileiro. Foram realizadas simulações utilizando as duas abordagens distintas, ARTMAP Fuzzy e ARTMAP Fuzzy Remodelada. Foi possível observar que o cenário que utilizou a rede neural ARTMAP Fuzzy Remodelada apresentou melhores resultados.

Palavras-chave - Redes Neurais Artificiais, ARTMAP Fuzzy, Previsão da Demanda, Consumo Desagregado, Séries Temporais.

1 Introdução

A perspectiva de aumentar lucros e evitar multas estimula empresas de comercialização de energia elétrica (EE) a investirem em ferramentas de previsão de demanda, uma vez que o ganho está atrelado ao cumprimento dos limites contratados.

Nos Sistemas de Energia Elétrica (SEE) importantes tarefas de tomada de decisão são baseadas na capacidade de prever adequadamente curvas de demanda de carga.

Uma considerável quantidade de fatores pode moldar a demanda de Energia Elétrica (EE), e é justamente nos níveis menos agregados do consumo que tais fatores se mostram numerosos e mais compreensíveis. De tal modo, *e.g.* a súbita interrupção do consumo de EE por um ou um pequeno grupo de consumidores, dificilmente causaria mudança significativa no perfil da curva de carga da subestação que atende determinada cidade, porém no transformador, ou abaixo disso, nas residências, tais mudanças seriam bastante significativas.

Entre os fatores capazes de influenciar a curva de carga, pode-se citar: efeitos sazonais, condições climáticas, ciclos de trabalho, tipo de dia (dia útil, final de semana ou feriado), falhas na rede entre outros fatores (Gross, Galiana, 1987).

Tendo em vista a previsão de carga para subestação ou níveis ainda mais agregados, não é difícil compreender que prever a demanda em níveis menos agregados (como por transformadores, ou unidades consu-

midoras) é um trabalho consideravelmente mais difícil, uma vez que as cargas são mais estocásticas e voláteis que as primeiras (Yu, Mirowski, Ho, 2016).

Com a utilização de Medidores Inteligentes (MI) nas unidades consumidoras ou nos transformadores que atendem pequenos grupos de consumidores (entra-se no conceito de *Smart Grids/Smart Microgrids*), as empresas comercializadoras de EE passam a visualizar novas possibilidades de agregar valor ao serviço prestado, além de oferecer configurações de fornecimento que possam ser mais atrativas para cada grupo de consumidores, graças a maior disponibilidade de dados (Isa, Wei, Yatim, 2015; Zheng, Gao, Lin, 2013).

A utilização de MI nas unidades consumidoras permite que o cliente tenha maior conhecimento do seu consumo de EE, e desta forma possa alterar seu perfil de consumo de maneira consciente, guiado por questões pessoais, ambientais ou financeiras.

Uma vez que a empresa fornecedora de EE detenha dados de consumo de seus clientes, novas possibilidades são reveladas, entre elas a de trabalhar com ferramentas de previsão em resoluções mais desagregadas de consumo, que posteriormente poderiam ser agrupadas a fim de formar uma curva geral de carga.

Comumente as previsões são classificadas de acordo com a faixa de tempo futuro que abrangem: curto prazo (abrangem horizontes de algumas horas a poucos dias), médio prazo (envolvem períodos de meses a um ano) e longo prazo (o qual projeta a demanda para o limiar de até uma década) (Al-Alawi, Islam, 1996). Atualmente devido as novas resoluções de dados disponíveis (em considerável parte devido ao uso de MI), fala-se em previsão de curtíssimo prazo, abrangendo horizontes de segundos a minutos.

Disponer de dados de consumo de EE no curtíssimo prazo, sobretudo para pesquisa, ainda é desafio, porém este trabalho se diferencia ao passo que dispõem de um conjunto de dados capturados por MI's e armazenados com um janelamento de 15 minutos, durante o decorrer de mais de 02 anos. Tais informações são provenientes de uma microrrede instalada em território brasileiro, dispondo de medições de diversas grandezas elétricas, além de energia ativa consumida e temperatura.

Existe considerável quantidade de trabalhos voltados à análise e previsão de carga e como exemplo tem-se o artigo de Gross e Galiana (1987) que listam algumas técnicas já experimentadas. De acordo com Hahn, Meyer-Nerberg e Pickl (2009), os métodos utilizados para resolução do problema de previsão de carga podem ser divididos em duas categorias: 1) métodos clássicos: são técnicas que aplicam os conceitos decorrentes de séries temporais e análise de regressão; 2) sistemas inteligentes: métodos que abrangem a inteligência computacional e artificial (Hahn, Meyer-Nieberg, Pickl, 2009).

As redes neurais artificiais (RNA) tiveram seu início a mais de 70 anos em um trabalho de McCulloch e Pitts (1943), em que os autores buscaram modelar matematicamente o comportamento de um neurônio biológico, sendo seu resultado embasador para posteriores implementações computacionais (Eberhart e Dobbins, 1990). Esta técnica bio-inspirada procura converter para a realidade computacional estruturas neurais de organismos inteligentes capazes de adquirir conhecimentos e efetuar assimilações ao serem expostos a determinadas experiências.

Desde seu início até tempos atuais, as RNA's se destacam pela importante capacidade de apresentar respostas referentes a dados de entrada diferentes daqueles utilizados na etapa de treinamento da rede (generalização). Existem diversos modelos de redes neurais artificiais que são propostos na resolução de determinados problemas.

As RNA's da família ART (*Adaptive Resonance Theory*) são exemplos claros de evolução das RNA's. Surgem com o objetivo de contornar o problema de estabilidade-plasticidade, ou seja, quando a rede não é mais capaz de aprender novos padrões. A arquitetura de RNA utilizada neste trabalho, a ARTMAP Fuzzy pode ser vista em (Carpenter, Grossberg, 1992a; Carpenter, Grossberg, Iizuka, 1992b; Carpenter, Grossberg, Markuzon, *et al.*, 1992c).

Uma das vantagens desta arquitetura é a possibilidade da inclusão do treinamento continuado que pode ser visto em (Santos Junior, Abreu, Lotufo, 2015). A diferença é que esta técnica propicia o aprendizado após a fase de treinamento (*off-line*).

O objetivo deste trabalho é apresentar uma remodelagem da rede neural ARTMAP Fuzzy de tal forma que em sua fase de treinamento (*off-line*) o número de categorias criadas nos módulos ART_a , ART_b , e inter-ART seja, exatamente ao número de categorias necessárias. Além disso, permite a criação de novas categorias em sua fase de diagnóstico (*on-line*). Esta técnica

é denominada rede neural ARTMAP Fuzzy remodelada.

Para validar a metodologia proposta aplicou-se a rede neural ARTMAP Fuzzy remodelada no problema de previsão de cargas elétricas em curtíssimo prazo para transformador (*bottom-up*), no qual o consumo de energia é altamente influenciado pelo comportamento humano.

2 Rede Neural ARTMAP Fuzzy

2.1 Funcionamento da Rede Neural ARTMAP Fuzzy

A rede ARTMAP Fuzzy utiliza treinamento supervisionado e auto-organizável. É adequada para aproximação de funções não-lineares multidimensionais.

A rede é composta por dois módulos ART Fuzzy (ART_a e ART_b) que desempenham a função de um módulo ART. Durante a fase de treinamento, o conjunto de dados de entradas é apresentado ao módulo ART_a , e o conjunto de dados de saída correspondente é apresentado ao módulo ART_b (Carpenter, Grossberg, 1992a)

O módulo *inter-ART* realiza um mapeamento que busca efetuar uma ligação entre as entradas e as saídas e este mecanismo é denominado *match tracking*.

Uma rede devidamente treinada para determinado cenário deve ser capaz de apresentar saídas coerentes para entradas distintas daquelas utilizadas durante a fase de treinamento.

2.1.1 Algoritmo da rede ARTMAP Fuzzy

Em (Lopes, Lotufo, Minussi, 2005) é apresentado um fluxograma que contempla o processamento da rede neural ARTMAP Fuzzy.

Portanto, utilizando os conceitos definidos em (Carpenter, Grossberg, 1992a; Carpenter, Grossberg, Iizuka, 1992b; Carpenter, Grossberg, Markuzon, *et al.*, 1992c) e o fluxograma ilustrado em (Lopes, Lotufo, Minussi, 2005) foi realizado um detalhamento dos passos a serem realizados para melhor compreensão da rede neural ARTMAP Fuzzy. Os passos podem ser subdivididos em quatro módulos: 1) Inicial, 2) ART_b Fuzzy; 3) ART_a Fuzzy e 4) Match Tracking.

- **Módulo Inicial:**
- Leitura do padrão de entrada (A) e saída (B) para o treinamento:

$$A = [a_1, a_2, \dots, a_n] \text{ e}$$

$$B = [b_1, b_2, \dots, b_n];$$

- Normalização do vetor de entrada (A) e saída (B):

$$\bar{a} = \frac{a}{|a|} \text{ e } \bar{b} = \frac{b}{|b|} \quad (1)$$

$$\text{em que } |a| = \sum_i |a_i|$$

- Complemento do padrão de entrada (A) e saída (B):

$$\bar{a}_i^c = 1 - a_i \text{ e } \bar{b}_i^c = 1 - b_i; \quad (2)$$

- Vetor de entrada (A) e saída (B) normalizados e complementados:

$$I^e = [a \ \bar{a}] \text{ e } I^s = [b \ \bar{b}]; \quad (3)$$

- Inicialização das matrizes de pesos (valor 1):

$$w_j^a = 1; w_k^b = 1; w_j^{ab} = 1;$$

indicando que não existe nenhuma categoria ativa.

- Leitura dos parâmetros:

$$\alpha, \beta, \rho_a, \rho_b, \rho_{ab}, \varepsilon;$$

- **Módulo ART_b Fuzzy:**

- Cálculo da função T_k^b :

$$T_k^b(I^s) = \frac{|I^s \wedge w_k^b|}{\alpha + |w_k^b|}, \quad (4)$$

- Escolha de categoria (K) para o módulo ART_b Fuzzy:

$$T_k^b = \max\{T_k^b : k = 1, \dots, N_b\}; \quad (5)$$

- Verifica se atende o critério de vigilância do módulo ART_b Fuzzy:

$$|x^b| = \frac{|I^s \wedge w_k^b|}{|I^s|} \geq \rho_b; \quad (6)$$

- Se não atende: Reset: $T_k^b = 0$;

- Se atende:

- Ressonância, adaptação de pesos da ART_b – Fuzzy:

$$w_k^{novo} = \beta(I^s \wedge w_k^{velho}) + (1 - \beta)w_k^{velho}; \quad (7)$$

e

Cálculo do vetor de atividade em F_2 :

$$y_k^b = [y_1^b, y_2^b, \dots, y_N^b], \text{ sendo:}$$

$$y_k^b = \begin{cases} 1, & \text{se } k = K \\ 0, & \text{se } k \neq K \end{cases} \quad (8)$$

- Vai para o módulo de Match Tracking:

- **Módulo ART_a Fuzzy:**

- Cálculo da função T_j^a :

$$T_j^a(I^e) = \frac{|I^e \wedge w_j^a|}{\alpha + |w_j^a|} \quad (9)$$

- Escolha de categoria (J) para o módulo ART_a – Fuzzy:

$$T_j^a = \max\{T_j^a : j = 1, \dots, N_a\} \quad (10)$$

- Verificação do critério de vigilância do módulo ART_a – Fuzzy:

$$|x^a| = \frac{|I^e \wedge w_j^a|}{|I^e|} \geq \rho_a \quad (11)$$

- Se atendido: Cálculo do vetor de atividade em F_2 :

$$y_j^a = [y_1^a, y_2^a, \dots, y_N^a], \text{ sendo:}$$

$$y_j^a = \begin{cases} 1, & \text{se } j = J \\ 0, & \text{se } j \neq J \end{cases} \quad (12)$$

- Vai para o módulo de Match Tracking:

- **Módulo Match Tracking:**

- Verifica se atende o critério de vigilância do módulo Inter – ART:

$$|x^{ab}| = \frac{|y^b \wedge w_j^{ab}|}{|y^b|} \geq \rho_{ab} \quad (13)$$

- Se não atende: Incrementa o parâmetro de vigilância:

$$\rho_a = \frac{|I^e \wedge w_j^a|}{|I^e|} + \varepsilon \quad (14)$$

- Reset: $T_j^a = 0$;

- Se *Match Tracking* atendido:

- Ressonância, adaptação de pesos da ART_a Fuzzy:

$$w_j^{novo} = \beta(I^e \wedge w_j^{velho}) + (1 - \beta)w_j^{velho} \quad (15)$$

- Atualização dos pesos do módulo Inter – ART:

$$W_{JK}^{ab} = [y_1^{ab}, y_2^{ab}, \dots, y_N^{ab}], \text{ sendo:}$$

$$y_{jk}^{ab} = \begin{cases} 1, & \text{se } j = J; k = K \\ 0, & \text{se } j \neq J; k \neq K \end{cases} \quad (16)$$

- Verifica se todos os pares de treinamento foram processados;

- Se não: $\rho_a = \rho_a^{original}$ e continua em ART_a Fuzzy e ART_b Fuzzy;

- Se sim: fim do treinamento.

sendo:

α : parâmetro de escolha ($\alpha > 0$);

β : taxa de treinamento [0, 1];

ρ_a : parâmetro de vigilância do módulo ART_a (0, 1);

ρ_b : parâmetro de vigilância do módulo ART_b (0, 1);

ρ_{ab} : parâmetro de vigilância do módulo ART_{ab} (0, 1);

ε : incremento do parâmetro ρ_a ;

n : número de padrões de entrada.

3 Aplicação da Rede Neural ARTMAP Fuzzy Remodelada na Previsão de Demanda de Carga Elétrica em Níveis Menos Agregados

A rede neural ARTMAP Fuzzy remodelada foi formulada com a proposta de dimensionar as matrizes de pesos de acordo com a necessidade de criação de novas categorias.

3.1 Funcionamento da RNA ARTMAP Fuzzy Remodelada

Na RNA ARTMAP Fuzzy tradicional todas as categorias podem ser utilizadas na fase de treinamento, sendo elas ativas ou não. Este trabalho propõe uma remodelagem da RNA ARTMAP Fuzzy para que a rede ative apenas as categorias necessárias no processo de treinamento.

Para melhor compreensão do funcionamento da metodologia proposta será realizada uma comparação com a rede ARTMAP Fuzzy convencional utilizando somente o módulo ART_a .

Suponha um conjunto de n padrões de entrada, em que cada padrão tem m informações, logo inicialmente o módulo ART_a na ARTMAP Fuzzy convencional terá dimensão $n \times m$ com todos valores iguais a

um. Na RNA remodelada o módulo ART_a terá dimensão $1 \times m$, também com valores iguais a um, conforme expressões descritas em (17)

$$\begin{bmatrix} 1 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \dots & 1 \end{bmatrix}_{n \times m} \quad (17)$$

$$[1 \quad \dots \quad 1]_{1 \times m}$$

Quando o primeiro padrão é apresentado, a primeira categoria é ativada na rede ARTMAP Fuzzy convencional, enquanto a RNA remodelada é iniciada com uma categoria.

Ao longo do treinamento das redes, a ARTMAP Fuzzy convencional **ativa** uma determinada categoria de acordo com a necessidade, enquanto a rede remodelada **adiciona** uma nova categoria.

Assim, ao final do treinamento se k categorias foram necessárias, o módulo ART_a da rede ARTMAP Fuzzy remodelada apresentará dimensão $k \times m$, enquanto a ARTMAP Fuzzy convencional permanece com dimensão $n \times m$, $k < n$, com k neurônios ativos e o restante dos neurônios inativos.

O fato de ser possível **adicionar** novas categorias de acordo com a necessidade na fase de treinamento (*off-line*) e na fase de diagnóstico (*on-line*) faz com que a rede remodelada tenha de trabalhar com matrizes significativamente menores que a abordagem convencional.

A Figura 1 apresenta um esquema simplificado da rede neural artificial ARTMAP Fuzzy remodelada, enfatizando as modificações realizadas nos módulos ART_b e ART_a , respectivamente.




Figura 1. Esquema Simplificado da RNA ARTMAP Fuzzy remodelada

Com esta modelagem é criada exatamente o número de categorias necessárias para o treinamento de uma RNA ARTMAP Fuzzy, assim novos padrões podem ser adicionados à rede para treinamento mesmo em modo *on-line*. O objetivo desta abordagem é manter as informações atualizadas, e com isso, alcançar

bons resultados de previsão. Devido ao comportamento altamente mutável do consumo de energia elétrica, a rede ficaria fadada a necessidade de realizar novamente a etapa de treinamento (*off-line*) de tempos em tempos, caso não utilizasse alguma estratégia como a apresentada neste trabalho.

3.2 Rede Neural ARTMAP Fuzzy Remodelada aplicada na Previsão de Carga Elétrica

Para validar a metodologia proposta (rede neural ARTMAP Fuzzy remodelada) foram utilizados dados de consumo de energia ativa de uma *Smart Microgrid* composta por cargas bastante diversas. Os dados são provenientes de um único prédio inserido em um complexo formado por vários prédios similares, porém com cargas distintas. As medições das grandezas elétricas foram realizadas por medidor eletrônico instalado junto ao transformador que atende exclusivamente o prédio citado.

Os dados são coletados e transportados por uma rede de dados com proteção contra interferência eletromagnética (*Shielded Twisted Pair - STP*), exclusivamente instalada para conectar os medidores eletrônicos ao servidor de dados, onde são armazenados.

As diversas cargas do bloco são formadas pelos equipamentos elétricos de um restaurante (em que o expediente inicia entre 8:00h e 8:30h, e finaliza entre 17:30h e 18:00h, com atendimento ao público entre 11:30h e 14:00h~14:30h), uma agência bancária de pequeno porte (expediente entre 10:00h e 15:00h), uma pequena agência dos correios (expediente entre 08:00h e 12:00h e entre 13:30h e 17:30h) e um quiosque de café (horário de funcionamento entre 8:00h e 18:00 h).




Figura 2. Amostra dos padrões de entrada segunda, quarta e sexta




Figura 3. Amostra de padrões de entrada sábado e domingo

Os gráficos das Figuras 2 e 3, respectivamente, são amostras do alto nível de desagregação dos dados analisados, ilustrando a complexidade da tarefa de previsão. As curvas de carga apresentadas foram escolhidas aleatoriamente entre os dias 21 de junho e 22 de setembro de 2013, compreendendo o inverno daquele ano.

As medidas foram tomadas em intervalos de 15 minutos e foram utilizados 6616 padrões para treina-

mento e 96 padrões (equivalente a 1 dia) para previsão. Foram utilizados dados relativos ao inverno de 2013, sendo que, a escolha deu-se devido a menor ocorrência de dados faltantes e *outliers*. Os dados de entrada X e saída Y que serão utilizados na fase de treinamento são descritos pela equação (17):

$$\begin{aligned} X_{(t)} &= [t \ C_t]^T, X \in \mathbb{R}^m \\ Y_{(t)} &= [C_{(t+1)}], Y \in \mathbb{R}^1 \end{aligned} \quad (17)$$

sendo:

- m : dimensão do vetor X ;
- $C_{(t)}$: valor da carga no tempo t ;
- $C_{(t+1)}$: valor da carga elétrica correspondente ao tempo subsequente ao tempo t ;
- t : tempo expresso em intervalos de 15 minutos.

Durante a fase de previsão da rede (fase *on-line*) os padrões utilizados na previsão foram apresentados para treinamento, com o objetivo de incorporar novo aprendizado, readaptando os pesos conforme a necessidade na realização da previsão.

4 Resultados e Discussão

Para as simulações foram utilizados os seguintes cenários:

- **Cenário 1:** Rede Neural ARTMAP Fuzzy sem a remodelação.
- **Cenário 2:** Rede Neural ARTMAP Fuzzy remodelada com apresentação dos padrões na fase *on-line* para treinamento.

Os parâmetros utilizados em ambos os cenários, 1 e 2, são apresentados na Tabela 1.

Tabela 1. Parâmetros utilizados no treinamento das redes neurais ARTMAP Fuzzy e ARTMAP Fuzzy remodelada

Parâmetros	Valor
ρ_a	0,95
ρ_b	1,00
ρ_{ab}	0,98
α	0,85
β	0,90

As Figuras 4 e 5 apresentam os resultados de previsão juntamente com as cargas reais. Devido à volatilidade do cenário que produz as curvas de carga, observa-se maior dificuldade do preditor justamente ao se aproximar do horário de pico, período em que ocorrem as maiores variações.

A Figura 6 permite comparar as previsões geradas pelas redes ARTMAP Fuzzy convencional, modificada e a carga real. É possível observar que nos horários iniciais e finais da curva de carga, a rede modificada se mostrou superior à implementação convencional, já na porção central da curva, onde existe maior variação no consumo de energia elétrica, as duas redes alternaram as melhores previsões, com vantagem para rede modificada.




Figura 4. Resultado da previsão de carga utilizando a rede neural ARTMAP Fuzzy




Figura 5. Resultado da previsão de carga utilizando a rede neural ARTMAP Fuzzy remodelada




Figura 6. Comparação da carga real e as previstas pelas redes ARTMAP Fuzzy convencional e remodelada

Para avaliar os resultados obtidos pela metodologia proposta e pelo método convencional utilizou-se o *Mean Absolute Percentage Error* (MAPE), e o *Root Mean Squared Error* (RMSE) como descrito nas equações (18) e (19):

$$MAPE = \frac{1}{n_e} \sum_{i=1}^{n_e} \frac{|L_i(t) - \underline{L}_i(t)|}{L_i(t)} \times 100 \quad (18)$$

$$RMSE = \frac{1}{n_e} \sum_{i=1}^{n_e} (L_i(t) - \underline{L}_i(t))^2 \quad (19)$$

em que:

$L(t)$: carga elétrica real no tempo t ;

$\underline{L}(t)$: carga elétrica prevista no tempo t ;

n_e : número de entradas apresentadas para a fase de diagnóstico.

Tabela 2. Resultados comparativos dos erros (MAPE e RMSE) para análise dos Cenários 1 e 2

Cenários	Análise dos Erros	
	MAPE (%)	RMSE (kW)
1	15,51	2,29
2	13,68	1,97

Durante a execução do Cenário 1 foram ativados 4.931 neurônios em W_a , dos 6616 possíveis, já em W_b

foram ativados 54 neurônios. No Cenário 2, W_a teve 5001 neurônios ativados, e W_b apresentou os mesmos 54.

A Tabela 2 permite observar que a qualidade dos resultados de MAPE e RMSE obtidos no Cenário 2 foram superiores aos verificados no Cenário 1. A RNA ARTMAP *Fuzzy* remodelada mostrou uma melhora quando comparada com a rede ARTMAP *Fuzzy* tradicional para o conjunto de dados considerado.

5 Considerações Finais

A RNA ARTMAP *Fuzzy* foi remodelada com o objetivo de se manter a qualidade da previsão da rede em cenários mutantes ao longo do tempo. Devido o horizonte bastante curto de tempo considerado neste trabalho, observou-se uma pequena melhora do Cenário 2 em relação ao Cenário 1, tanto que não foram criadas novas categorias em ART_b .

Os MAPE's em um primeiro momento podem parecer bastante elevados, porém ao revisar trabalhos na área que também consideram cenários de consumo mais desagregados como o trabalho de Yu, Mirowski e Ho, (2016), observa-se MAPE's na faixa de 19,79% e 32,55%, e o trabalho de Müller e Carreño (2014) cuja média dos MAPE's foi de 17,32%. Deste modo tem-se como promissor o emprego da RNA ARTMAP *Fuzzy* na abordagem deste tipo de problema, ou seja, previsão de carga considerando os níveis menos agregados.

A continuação deste trabalho abrangerá o aperfeiçoamento da RNA ARTMAP *Fuzzy* remodelada com o objetivo de melhorar ainda mais a previsão mantendo a plasticidade da rede ao longo do tempo. Para tanto, pretende-se construir um mecanismo capaz de descartar dados pouco utilizados em ART_a , uma vez que sem a utilização deste mecanismo, e com a continuação do treinamento, o conjunto de categorias ativas em ART_a tende a aumentar, acarretando maiores tempos computacionais na fase de diagnóstico da rede (*on-line*).

Dentre as novas propostas para melhoria da metodologia tem-se:

- Acréscimo de novas informações no conjunto de dados de treinamento: dias da semana (domingo a sábado), dias atípicos e dados exógenos (temperatura, índice de precipitação, etc.);
- Pré-processamento dos dados com objetivo de identificar, analisar e abordar os ruídos e os dados atípicos melhorando, assim, a resposta da previsão;
- Simulações considerando maiores horizontes de tempo.

Agradecimentos

Agradecemos a CAPES pela concessão de bolsa nível doutorado aos autores 1 e 2.

Referências Bibliográficas

- Carpenter, G. A. and Grossberg, S. (1992a). A SelfOrganizing Neural Network for Supervised Learning, Recognition, and Prediction. *Communications Magazine*, Vol. 30, pp. 38-49
- Carpenter, G. A.; Grossberg, S.; Iizuka, K. (1992b). Comparative Performance Measures of Fuzzy ARTMAP, Learned Vector Quantization, and Back Propagation for Handwritten Character Recognition. *International Joint Conference on Neural Networks - IJCNN*. Vol.1, pp. 794-799.
- Carpenter, G. A.; Grossberg, S.; Markuzon, N.; Reynolds, J. H.; Rosen, D. B. (1992c). Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps. *Neural Networks, IEEE Transactions on*, Vol. 3, pp. 698-713.
- Gross, G.; Galiana, F. D. (1987). Short-term Load Forecasting. *Proceedings of the IEEE*, Vol. 75, No. 12, pp. 1558-1573.
- Al-Alawi, S. M.; Islam, S. M. (1996). Principles of electricity demand forecasting. I. Methodologies. *Power Engineering Journal*, Vol. 10, No. 3, pp. 139-143.
- Hahn, H.; Meyer-Nieberg, S.; Pickl, S. (2009). Electric load forecasting methods: Tools for decision making. *European Journal of Operational Research*, Vol. 199, No. 3, pp. 902-907.
- Isa, N. B M.; Wei, T. C.; Yatim, A. H. M. (2015). Smart Grid Technology: Communications, Power Electronics and Control System. *International Conference on Sustainable Energy Engineering and Application (ICSEEA)*, pp. 10-14.
- Lopes, M. L. M.; Lotufo, A. D. P.; Minussi, C. R. (2005) Electric Load Forecasting Using a Fuzzy ART&ARTMAP Neural Network. *Journal of Applied Soft Computing*, Vol. 5, No. 2, pp. 235-244.
- Müller, M. R; Carreño, E. M. (2014). Clusterização de Curvas de Carga para o Método de Dias Similares. In *Anais do SBSE 2014, Foz do Iguaçu, Paraná, Brasil*.
- Santos Junior, C. R.; Abreu, T.; Lotufo, A. D. P. (2015). Rede neural ARTMAP Fuzzy com treinamento continuado para detecção de spams. In *XII Congresso Brasileiro de Inteligência Computacional*, 2015, Curitiba, PR.
- Yu, C. N.; Mirowski, P.; Ho, T. K. (2016). A Sparse Coding Approach to Household Electricity Demand Forecasting in Smart Grids. *IEEE Transactions on Smart Grid*, Vol. PP, No. 99, pp. 1-11.
- Zheng, J.; Gao, D. W.; Lin, L. (2013). Smart Meters in Smart Grid: An Overview. *Green Technologies Conference, 2013 IEEE*, pp. 57-64.