

Rede Neural STEPWISE-ARTMAP Fuzzy aplicada ao problema de Previsão de Cargas Elétricas

Thays Abreu, Marleide F. Alves, Carlos R. Santos Junior, Anna Diva P. Lotufo,

Programa de Pós Graduação em Eng. Elétrica, FEIS, UNESP
15385-000, Ilha Solteira, SP

E-mail: thays7abreu@gmail.com

E-mail: marleidealves11@gmail.com

E-mail: carlos9.rsj@gmail.com

E-mail: annadiva@dee.feis.unesp.br

Mara L. M. Lopes

Departamento de Matemática, FEIS, UNESP

15385-000, Ilha Solteira, SP

E-mail: mara@mat.feis.unesp.br

***Resumo:** Metodologias híbridas estão sendo cada vez mais utilizadas para realizar a previsões de séries temporais. Neste trabalho apresentam-se resultados para uma série temporal de demanda de energia elétrica de uma companhia de setor elétrico, sendo proposto um modelo no qual são utilizados o método stepwise para a seleção de variáveis com auxílio da regressão linear múltipla e a rede neural ARTMAP Fuzzy.*

1. Introdução

Realizar a previsão de cargas elétricas é um papel importante no planejamento de sistemas de energia elétrica. A precisão da previsão é fundamental já que é através dela que é estabelecida quando e quanto de capacidade de geração e transmissão deve-se dispor para atender os consumidores sem interrupções no fornecimento com o propósito de garantir energia de forma econômica, segura e contínua [1],[10]. Na literatura destacam-se as seguintes técnicas para previsão de carga [5]: técnica de regressão linear simples ou múltipla, alisamento exponencial, estimação de estado, filtro de Kalman, ARIMA (*Auto Regressive Integrated Moving Average*) de Box e Jenkins. Esses métodos necessitam da modelagem prévia da carga para aplicação posterior. Os fatores que ajudam a modelar a carga podem ser condições meteorológicas como: nebulosidade, velocidade do vento, variações bruscas de temperatura; fatores diversos como efeito de dias atípicos (feriados, greves, etc.) [10]. Atualmente, o uso das redes neurais artificiais (RNAs) [7] é um método alternativo e eficiente para previsão de cargas elétricas, uma de suas vantagens é que não necessita da modelagem prévia da carga.

A proposta deste trabalho foi desenvolver um modelo predictor de cargas elétricas a curto prazo utilizando a regressão linear múltipla com o critério de seleção de variáveis *stepwise* e uma rede neural ARTMAP Fuzzy. O procedimento *stepwise* seleciona quais dados possuem mais correlação para servir de entrada para rede neural, que enfim realizará a previsão desejada. Optou-se por utilizar a rede neural ARTMAP-Fuzzy, devido a sua arquitetura estável e plástica, o que garante uma vantagem em relação aos outros tipos de redes neurais [4].

Na literatura existem poucos trabalhos utilizando o procedimento *stepwise* com redes neurais. No trabalho de Ghunem [6] é utilizada uma rede neural com regressão *stepwise* para previsão de óleo transformador, a rede *perceptron* é utilizada para modelar as relações entre os vários parâmetros de óleo transformador e a regressão para ajustar o modelo de previsão. Alves [2] propõe uma rede híbrida com o critério de seleção *stepwise* e uma rede neural *perceptron* com algoritmo *backpropagation* para realizar previsão de cargas elétricas, no qual na primeira fase o *stepwise* tem a função de selecionar as variáveis mais relevantes para compor a rede neural.

Para avaliar o desempenho do método proposto, o mesmo foi testado nos períodos de 30, 60 e 90 dias, todos com o objetivo de prever o dia 1 de agosto de 1990.

2. Método de seleção de variáveis Stepwise

Análise de Regressão Linear: Correlação Linear

Sejam dois conjuntos de observações X e Y , em que X é o conjunto de variáveis independentes (ou de entrada) e Y o conjunto de variáveis dependentes (ou de saída), a correlação é definida como uma relação entre esses conjuntos. Quando esta relação entre X e Y apresentar um comportamento próximo a uma reta a correlação é linear. A correlação linear é medida através do coeficiente de correlação linear, dado na equação (1) [9].

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{n \sum x^2 - (\sum x)^2} \sqrt{n \sum y^2 - (\sum y)^2}} \quad (1)$$

Em que n é o número de observações, $x \in X$, $y \in Y$ e $-1 \leq r \leq 1$.

Para analisar se a correlação entre as variáveis de entrada e saída são fortes ou fracas temos a seguinte esquema:

r próximo de 1 :	Correlação positiva forte
r próximo de -1 :	Correlação negativa forte
r próximo de 0 :	Não há correlação linear

Se os conjuntos X e Y possuírem correlação linear forte é possível obter uma equação, chamada equação de regressão linear, que melhor se ajusta aos dados observados. A equação (2) tem a forma de uma equação de regressão linear [9].

$$\hat{y} = m_0 + m_1x_1 + m_2x_2 + \dots + m_kx_k \quad (2)$$

Sendo x_i a entrada (variável independente) e \hat{y} a saída prevista (variável dependente).

Para se determinar uma equação de regressão linear deve-se obter m_0, m_1, \dots, m_k de tal forma que a soma dos quadrados dos resíduos (diferença entre os valores observados e os valores previstos) seja mínima. Para isso utiliza-se o método dos mínimos quadrados [12].

Método de Seleção de Variáveis

Os métodos de seleção de variáveis têm a finalidade de selecionar as variáveis mais significativas de um conjunto de observações e descartar as menos significativas, sem que haja prejuízo na previsão. O método de seleção de variáveis utilizado neste trabalho foi o método *stepwise*, que é um método iterativo composto por dois outros métodos, o método *forward* (que adiciona variáveis) e o método *backward* (que retira variáveis). O método *stepwise* esta descrito nos passos abaixo [8]:

Passo *forward*

1. Escolhe-se a variável x_k que possui o maior coeficiente de correlação para entrar no modelo.
2. Uma variável x_i entra no modelo, se o coeficiente de correlação for maior que o anterior, x_i permanece no modelo, caso contrário x_i sai do modelo.

Passo *backward*

3. x_i sai do modelo e se o coeficiente de correlação for menor que o anterior, x_i fica no modelo, caso contrário, x_i permanece fora do modelo. Este passo é repetido até que não tenha mais x_i para sair do modelo. Terminada esta etapa retorna-se ao passo 2 e este passo continua até que não tenham mais variáveis para entrar no modelo.

3. Rede Neural ARTMAP Fuzzy

A rede neural artificial ARTMAP-Fuzzy possui uma arquitetura baseada na teoria da ressonância adaptativa, sendo uma rede da família ART (*Adaptive Resonance Theory*) [3]. 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_a Fuzzy e ART_b Fuzzy, que são conectados através de um módulo de memória associativa inter-ART [4]. Cada módulo ART é composto por três camadas: sendo F_0 a camada de entrada, F_1 a camada de comparação, e F_2 a camada de reconhecimento, que realiza o armazenamento em categorias. As camadas F_1 e F_2 são conectadas pelos pesos (w_j^a no ART_a e w_k^b no ART_b). A rede ART_a Fuzzy é que recebe os padrões de entrada apresentados, e a ART_b Fuzzy constitui a resposta desejada para o padrão apresentado à rede que são interligadas pelo módulo de memória associativa Inter-ART, que verifica o casamento das entradas e saídas com as categorias existentes [4].

Os parâmetros da rede neural ARTMAP Fuzzy são:

- Parâmetro de escolha α ($\alpha > 0$): responsável pela seleção de categorias
- Taxa de aprendizagem β ($\beta \in [0,1]$): controla a velocidade de aprendizagem da rede
- Parâmetro de vigilância do módulo ART_a , ART_b e inter-ART (ρ_a , ρ_b e $\rho_{ab} \in [0,1]$): parâmetro responsável pelo número de categorias criadas, ou seja, controla a ressonância da rede.

O funcionamento da rede ARTMAP Fuzzy é baseado nos seguintes passos [4]:

1º) É realizada a leitura dos padrões de entrada a e b ;

Os vetores de entrada e saída são normalizados com o intuito de evitar a proliferação de muitas categorias.

$$\bar{a} = \frac{a}{|a|} \quad \text{e} \quad \bar{b} = \frac{b}{|b|} \quad (3)$$

2º) Codificação do vetor de entrada e saída;

$$I = [\bar{a} \ \bar{a}^c] \quad \text{e} \quad I = [\bar{b} \ \bar{b}^c] \quad (4)$$

3º) Escolha da categoria ganhadora na camada F_2 em ART_a e ART_b através da equação (5);

$$T_j^a(I_a) = \frac{|I_a \wedge w_j^a|}{\alpha + |w_j^a|} \quad \text{e} \quad T_k^b(I_b) = \frac{|I_b \wedge w_k^b|}{\alpha + |w_k^b|} \quad (5)$$

Em ART_a ganha a categoria J com $T_j = \max\{T_j\}$ e índice J mínimo e em ART_b ganha a categoria K com $T_k = \max\{T_k\}$ e índice K mínimo.

4º) É feito o teste de vigilância do modulo ART_b de acordo com (6);

$$\frac{|I_b \wedge w_k^b|}{I_b} \geq \rho_b \quad (6)$$

Se a equação (6) é satisfeita é alcançada a ressonância e atualiza-se os pesos através de (7), caso contrário ocorre o reset, assim o neurônio K é excluído do processo de busca, e é determinado um novo neurônio ganhador. Se todos neurônios são rejeitados, a rede cria um novo neurônio.

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

5º) Teste de vigilância do modulo ART_a é realizado através de (8);

$$\frac{|I_a \wedge w_j^a|}{I_a} \geq \rho_a \tag{8}$$

Se a equação (8) é satisfeita ocorre a ressonância para o modelo ART_a e verifica se a adequação dos neurônios vencedores K e J através do *Match Tracking* descrito com a equação (9).

$$\frac{|y_j^b \wedge w_{JK}^{ab}|}{|y_j|} \geq \rho_{ab} \tag{9}$$

Se ocorrer a ressonância no *Match Tracking*, é ativado o índice J ganhador, confirmado os índices J e K e atualizam-se os pesos no modulo ART_a e Inter-ART através das equações (10) e (11), respectivamente.

$$w_j^{novo} = \beta(I_a \wedge w_j^{velho}) + (1 - \beta)w_j^{velho} \tag{10}$$

$$\begin{aligned} w_{JK}^{ab} &= 1 \\ w_{jk}^{ab} &= 0, \text{ se } j \neq J; k \neq K \end{aligned} \tag{11}$$

Se não ocorre a ressonância é descartada a categoria atual e há um acréscimo ϵ na equação 8 (parâmetro de vigilância) para excluir de vez a categoria da ART_a que não combinou com a categoria do ART_b .

$$\rho_a = \frac{|I_a \wedge w_j^a|}{I_a} + \epsilon \tag{12}$$

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

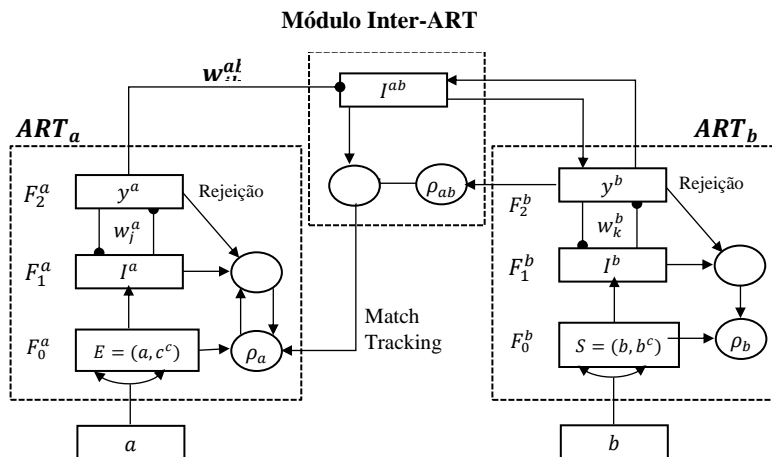


Figura 1: Estrutura da rede neural ARTMAP-Fuzzy

4. Metodologia Proposta

Na primeira fase da metodologia proposta o conjunto de dados históricos de cargas elétricas como dia, tipo de dia (sábado, domingo, feriados, dias úteis), temperatura mínima, temperatura média, hora(h), carga (h-2), carga (h-1), carga(h) e saída de carga (h+1) são aplicadas no critério de seleção *stepwise*, com objetivo de verificar quais variáveis possuem correlações mais fortes. As variáveis selecionadas pelo processo *stepwise* serão utilizadas como entrada da rede neural artificial ARTMAP *Fuzzy* que enfim realizará a previsão.

O procedimento *stepwise* é utilizado com objetivo de reduzir o máximo o número de variáveis, otimizando o tempo computacional para a previsão de cargas elétricas. As variáveis

que apresentaram correlação mais forte foram hora(h) e carga(h), assim a rede neural ARTMAP *Fuzzy* é composta por duas entradas referentes à hora(h) e carga(h) e saída (h+1).

O fluxograma do funcionamento do modelo proposto é apresentado na figura 2.

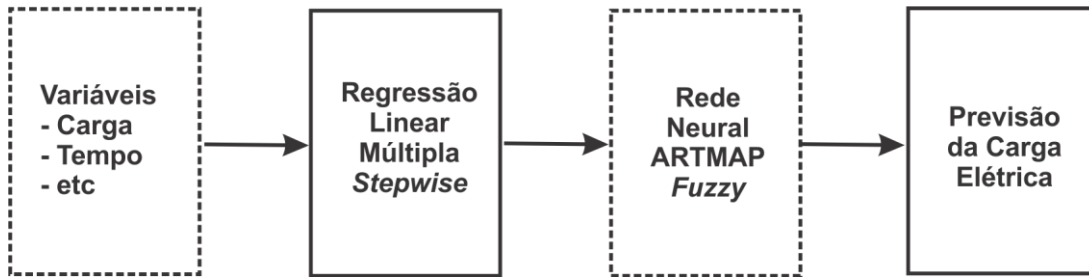


Figura 2: Fluxograma da metodologia proposta.

5. Aplicações e Resultados

O modelo proposto foi submetido a três aplicações distintas, diferenciadas pela quantidade de dados, com objetivo de realizar a previsão de 24 horas do dia 01/08/1990. A Tabela 1 descreve os períodos utilizados para cada aplicação.

Período 1	Período 2	Período 3
01/07/90 a 31/07/90	01/06/90 a 31/07/90	01/05/90 a 31/07/90

Tabela 1: Períodos utilizados

Para analisar os resultados foram calculados os erros percentuais médios (MAPE) e o erro máximo obtido durante a previsão das cargas nas 24 horas, que são calculados, respectivamente, por (13) e (14).

$$MAPE = \frac{1}{NT} \sum_{h=1}^{NT} \left\{ \frac{|L(h) - \underline{L}(h)|}{L(h)} \right\} \times 100\% \quad (13)$$

$$Erro\ máximo\ (\%) = máx \left\{ \frac{|L(h) - \underline{L}(h)|}{L(h)} \right\} \times 100\% \quad (14)$$

No qual $L(h)$ é o valor da carga real referente a hora h ; $\underline{L}(h)$ o valor da carga estimada pelo modelo proposto referente a hora h e NT o número total de horas.

Na Tabela 2 apresentam-se os resultados obtidos pelo sistema predictor de cargas elétricas considerando os valores do MAPE e erro máximo para as aplicações 1, 2 e 3. As Figs. 4-6 apresentam as curvas de previsão de cargas de 24 horas à frente para cada aplicação.

Aplicação	MAPE (%)	Erro máximo (%)
1	1,31	4,14
2	1,46	8,68
3	1,95	8,73

Tabela 2: Resultados da rede Stepwise-ARTMAP *Fuzzy*.

Do ponto de vista econômico da geração, observou-se que resultados com precisão de até 5% apresentam uma redução significativa no custo da geração [11]. Diminuir esta precisão se torna indispensável do ponto de vista econômico, e o modelo proposto obteve resultados inferiores a 2%, fazendo com que a redução do custo de geração se torne pequena, com previsões em tempo real.

As Figs. 3-5 apresentam as curvas de previsão de cargas de 24 horas à frente para cada aplicação.




Figura 3: Curva da carga prevista 24 horas à frente no período 1.




Figura 4: Curva da carga prevista 24 horas à frente no período 2.

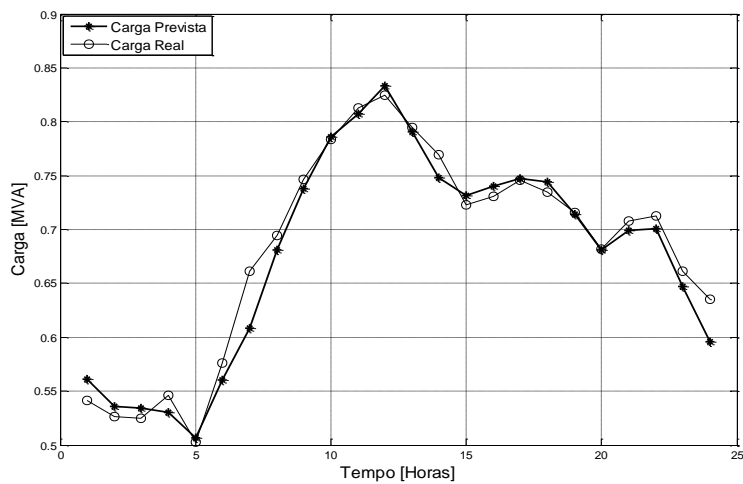


Figura 5: Curva da carga prevista 24 horas à frente no período 3.

6. Conclusão

Neste trabalho foi desenvolvido um modelo predictor de cargas elétricas a curto prazo (24 horas à frente) utilizando o método *stepwise* para selecionar as variáveis que serão utilizadas como entrada da rede neural ARTMAP *Fuzzy*. O sistema proposto obteve resultados satisfatórios em relação aos encontrados na literatura, com MAPEs inferiores a 2% e erros máximos abaixo de 9%, conforme a Tabela 2. Observa-se também que as curvas de previsão mostradas nas Figuras 4 a 6 foram capazes de acompanhar as curvas de previsões dos dados reais nas três aplicações, fazendo com que o modelo desenvolvido seja mais confiável. Uma das grandes vantagens da rede neural ARTMAP *Fuzzy* é que a previsão de cargas elétricas é realizada em segundos, portanto, esta estrutura fornece bons resultados em tempo real.

Agradecimentos

Os autores agradecem a CAPES pelo apoio financeiro.

Referências

- [1] Abreu, Santos-Junior, Lopes e Lotufo, Previsão de cargas elétricas através de um modelo de regressão ARIMA e uma rede neural ARTMAP Fuzzy, XI Congresso Brasileiro de Inteligência Computacional, Porto de Galinhas, 2013.
- [2] Alves, “Previsão de Demanda de Cargas Elétricas por seleção de variáveis *STEPWISE* e Redes Neurais Artificiais”. Dissertação de Mestrado, UNESP, Ilha Solteira, 2013.
- [3] Carpenter and Grossberg, “A massively parallel architecture for a self-organizing neural pattern recognition machine”, Computer Vision, Graphics, and Image Processing, pp. 54-115, (1987).
- [4] Carpenter, Grossberg, Markuzon, Reynolds and Rosen, Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps, IEEE Transactions on Neural Networks, vol. 3(5), pp. 698 – 713, (1992).
- [5] O’Donovan, Short Term Forecasting: An Introduction to the Box-Jenkins Approach, New York: John Wiley & Sons, 1983.
- [6] Ghunem, Assaleh and El-Hag, Artificial neural networks with stepwise regression for predicting transformer oil furan content, IEEE Transactions on Dielectrics and Electrical Insulation, vol. 19, pp. 414-420 (2012).
- [7] Haykin, Neural networks: A comprehensive foundation, Prentice-Hall, Upper Saddle River, New Jersey, USA, 1994.
- [8] Hocking, “The Analysis and Selection of Variables in Linear Regression”. Biometrics, vol. 32, pp. 1-49 (1976).
- [9] Larson e Faber, “Estatística Aplicada”, Pearson Hall, São Paulo, 2010.
- [10] Lopes, “Desenvolvimento de Redes Neurais para Previsão de Cargas Elétricas de Sistemas de Energia Elétrica”. Tese de Doutorado, UNESP, Ilha Solteira, 2005.
- [11] Ranaweera, Karady and Farner, Economic impact Analysis of Load Forecasting, IEEE Transactions on Power Systems, vol. 12 (3), pp. 1388-1392, (1997).
- [12] Ruggiero e Lopes, “Cálculo numérico: aspectos teóricos e computacionais”, Pearson Makron Books, São Paulo, 1996.