

Proceeding Series of the Brazilian Society of Computational and Applied MathematicsRede Neural Híbrida ARTMAP-*Fuzzy*-MMQMarleide Ferreira Alves¹

Departamento de Engenharia Elétrica, UNESP, Ilha Solteira, SP

Anna Diva Placencia Lotufo²

Departamento de Engenharia Elétrica, UNESP, Ilha Solteira, SP

Mara Lúcia Martins Lopes³

Departamento de Matemática, UNESP, Ilha Solteira, SP

Resumo. Modelos de previsão são importantes nas mais diversas áreas do conhecimento. São métodos que têm o papel de extrair de modo sintético a realidade que se propõem a reproduzir no futuro da forma mais fiel possível. Existem diversos modelos na literatura como os modelos estatísticos, as redes neurais artificiais e os modelos híbridos que é a união de dois ou mais modelos de previsão explorando as vantagens de cada um. Este trabalho propõe um modelo híbrido que é a união entre a Rede Neural ARTMAP *Fuzzy* e o Método dos Mínimos Quadrados(MMQ). Este modelo é chamado ARTMAP *Fuzzy* - MMQ. Nele, a rede neural desempenha o papel de selecionar os vetores de entrada para a obtenção da equação de regressão através da técnica dos Mínimos Quadrados e esta equação realiza a previsão. Para testar a metodologia foram realizadas várias previsões de cargas elétricas a curto prazo e comparadas às previsões realizadas utilizando individualmente a técnica dos Mínimos Quadrados e a rede neural ARTMAP *Fuzzy*. Em todos os testes a rede híbrida se saiu melhor que os outros dois modelos testados.

Palavras-chave. Modelos de Previsão, Previsão de Cargas Elétricas, Regressão Linear Múltipla, Métodos dos Mínimos Quadrados, Rede Neural artificial ARTMAP *Fuzzy*, Arquitetura Híbrida.

1 Introdução

Modelos de previsão são largamente utilizados nas mais diversas áreas como economia, saúde, marketing, engenharias, etc. Fazer projeções futuras são importantes para planejamento estratégico, como por exemplo, para vendas, tendências de mercado, demandas de consumo, estimativas de custos, demanda de cargas elétricas, etc. Existem diversas técnicas de previsão na literatura como os modelos ARIMA de Box & Jenkins, alisamento exponencial, regressão linear simples e múltipla [3], [5]. Existem também as redes neurais artificiais (RNA) que possuem a capacidade de lidar com problemas não lineares, O trabalho de [1] utiliza a RNA ARTMAP-*Fuzzy* de Carpenter & Grossberg [4] para previsão de cargas elétricas. Os modelos híbridos que são a junção de duas ou mais

¹marleidealves11@gmail.com²annadiva@dee.feis.unesp.br³mara@mat.feis.unesp.br

técnicas de previsão explorando as vantagens de cada um. O trabalho de [2] utiliza um modelo híbrido de seleção de variáveis e a RNA Perceptron Multicamadas. Este trabalho propõe uma arquitetura híbrida entre a RNA ARTMAP *Fuzzy* e o Método dos Mínimos Quadrados (MMQ). Esta arquitetura visa explorar a capacidade de classificação da RNA ARTMAP *Fuzzy* para melhorar a previsão através da equação de regressão obtida pelos mínimos quadrados. Foram feitas previsões de demanda de carga a curto prazo (horizonte de 24 horas) e os resultados foram satisfatórios comparados ao modelo de regressão linear e à RNA ARTMAP *Fuzzy* utilizados individualmente,

2 Rede Neural Artificial ARTMAP - *Fuzzy*

As Redes Neurais Artificiais são sistemas computacionais desenvolvidos para simular o funcionamento do cérebro humano [7]. São capazes de adquirir conhecimento através de experiências prévias. São úteis nas mais diversas áreas, como engenharia e computação. Baseada na Teoria da Ressonância Adaptativa, a Rede Neural ARTMAP *Fuzzy* é uma rede neural integrante da família ART que foi desenvolvida por Carpenter et. al. [4]. Utiliza treinamento supervisionado e auto-organizável é adequada para aproximação de funções não lineares multidimensionais.

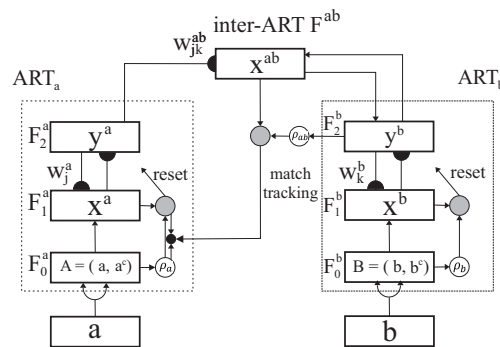


Figura 1: Rede Neural ARTMAP *Fuzzy*. Fonte: [4]

Conforme ilustrado na figura 1 esta rede é composta por três módulos, à esquerda o módulo ART_a que processa os padrões de entrada adaptando os pesos de W_a , o parâmetro ρ_a determina o grau de similaridade mínimo no qual uma categoria é aceita, quanto maior esse parâmetro, mais categorias em W_a serão criadas. À direita o módulo ART_b que processa os padrões de saída desejada, do mesmo modo que em ART_a o parâmetro ρ_b mede o grau de similaridade mínimo no qual uma categoria é aceita em W_b . Ao centro, o módulo *inter-ART* que faz o casamento entre os módulos ART_a e ART_b e o parâmetro ρ_{ab} verifica se a entrada de a saída desejada são compatíveis. Mais detalhes sobre o funcionamento podem ser encontrados em [4]. Após a fase de treinamento, a rede está apta a entrar em operação. A figura 2 mostra o funcionamento desta fase.

Um padrão de entrada desconhecido para a rede é apresentado este é comparado com toda a matriz W_a selecionando um vetor de W_a mais similar com o padrão de entrada.

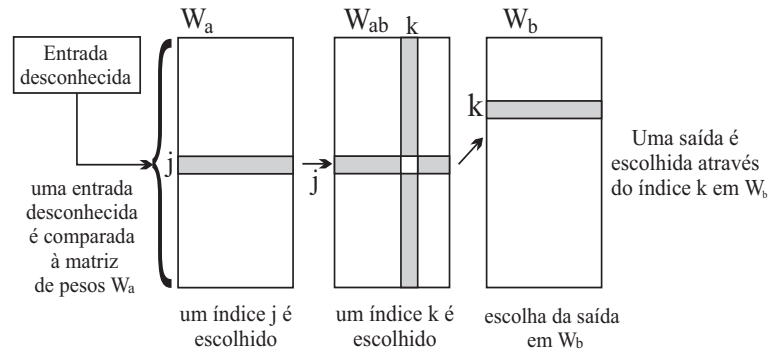


Figura 2: Esquema da fase de operação da Rede Neural ARTMAP *Fuzzy*.

Assim, o índice j correspondente a tal vetor é selecionado. Esse índice j é também correspondente ao um vetor j da matriz W_{ab} (que faz o casamento entre os dois módulos). Assim, o vetor j escolhido em W_{ab} aponta para seu correspondente em W_b (através do índice k) que armazena a saída da rede.

3 Método dos Mínimos Quadrados (MMQ)

O método dos Mínimos Quadrados é bastante usado em diversos trabalhos para realizar os mais diferentes tipos de previsão. Ele é utilizado para encontrar os coeficientes de uma equação de regressão linear múltipla, que descreve uma reta que melhor se ajusta a um dado conjunto de observações. Para conseguir uma boa equação de regressão é necessário que o conjunto de observações tenha correlação linear significativa. Correlação linear é a medida de força entre as variáveis independentes e dependentes de um conjunto de informações, quanto maior for essa medida, mais correlacionadas as variáveis estarão e quanto menor for essa medida menos correlacionadas as variáveis estarão [6]. A figura 3 ilustra os tipos correlação.




Figura 3: Exemplos de tipos de correlação.

A figura 3(a) ilustra uma correlação linear fraca, observa-se que as observações estão bastante dispersas. Já a figura 3(b) ilustra uma correlação linear forte indicado observações

mais concentradas. A linha na 3(b) ilustra uma reta de regressão linear. Uma reta de regressão, também chamada de linha de melhor ajuste, é a linha para a qual a soma dos quadrados dos resíduos é um mínimo. Os resíduos (ou desvios) é a diferença entre a saída real e a saída prevista (calculada) [6]. Um método de solução dos mínimos quadrados pode se encontrado em [8].

4 Rede Neural Híbrida ARTMAP *Fuzzy* - MMQ

Durante a fase de diagnóstico da rede neural ARTMAP *Fuzzy* é escolhido apenas um único índice k para fornecer uma resposta ao padrão de entrada desconhecido da rede conforme foi descrito na seção 2. Resumindo, é escolhido em W_a o vetor mais similar ao padrão de entrada e que através de W_{ab} aponta para uma resposta (ou saída) em W_b , sendo assim, pode ser que a resposta obtida em W_b não seja uma resposta adequada. Isso ocorre porque o alto grau de similaridade que W_a tem com uma dada entrada desconhecida, e consequentemente escolhendo um j , conduzindo W_{ab} a escolher um k que não necessariamente leva a melhor saída em W_b , ou seja, alto grau de similaridade entre a entrada desconhecida e W_a pode não conduzir alto grau de similaridade entre W_b e uma resposta mais adequada. Depois de algumas observações, vimos que respostas mais adequadas estão em outros pontos de W_b , acontece que o k fornecido por W_{ab} não aponta para elas. Por esse motivo, foi desenvolvida a Rede Neural Híbrida *Fuzzy* - MMQ. Nesta arquitetura é mantido o treinamento utilizando a Rede Neural ARTMAP *Fuzzy* e na fase de operação da rede ao invés de escolhermos um único j em W_a , escolhemos vários índices j em W_a e vários índices k em W_b . O critério de escolha é o maior grau de similaridade entre a entrada desconhecida e W_a . Feito isso, para cada entrada é feita uma equação de regressão linear para fornecer a resposta da rede. A figura 4 ilustra como é feita a seleção dos dados a serem utilizados na equação de regressão.

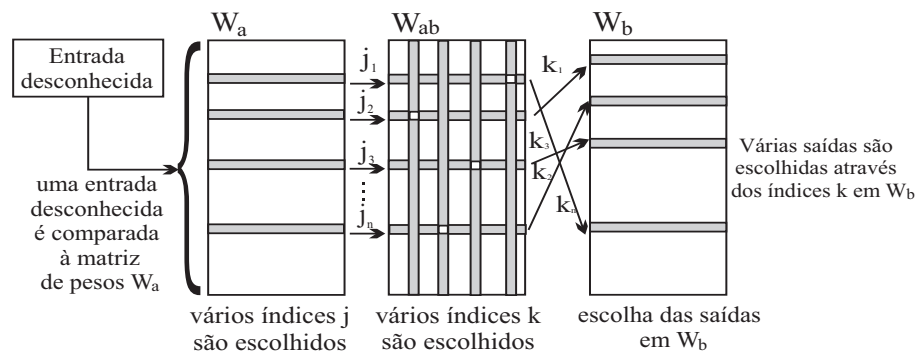


Figura 4: Seleção de Entradas para o MMQ.

Esta estratégia visa escolher as entradas mais similares para a construção de uma boa equação de regressão, uma vez que a regressão é muito dependente da correlação dos dados. Assim esta estratégia busca os dados em W_b mais próximos entre si o que aumentam as chances de se obter uma resposta mais adequada. Outro ponto a observar é que nesta

nova arquitetura para cada entrada da rede uma equação de regressão diferente é obtida logo, obtêm-se uma equação de regressão para dar a resposta de um único ponto.

5 Ambiente de Testes e avaliação dos resultados

Para testar a metodologia híbrida foram feitas previsões de demanda de carga de curto prazo (horizonte de 24 horas à frente) utilizando dados de carga de uma companhia de energia espanhola de vários períodos. O conjunto de padrões de entrada foi composto pelos seguintes dados:

$$X(h) = [h \quad ds \quad L(t-4) \quad L(t-3) \quad L(t-2) \quad L(t-1) \quad L(t)]; X \in \mathbb{R}^m$$

$$Y(h) = [L(h+1)]; Y \in \mathbb{R}^1$$

em que:

- m : dimensão do vetor X
- h : hora
- ds : dia da semana (segunda a domingo)
- $L(h-p)$: valor da carga L "p" tempo anterior a t
- $L(h+1)$: valor da carga em $t+1$
- $X(h)$: vetor de entrada em ART_a
- $Y(h)$: vetor de saída desejada em ART_b

As informações de carga máxima, mínima e média são em relação à hora e ao dia da semana. Para avaliar os resultados obtidos foram utilizados o MAPE e o erro máximo (EM) dados pelas equações 1 e 2 a seguir:

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

$$EM = \frac{|L(h) - \underline{L}(h)|}{L(h)} \times 100 \quad (2)$$

em que:

- NT : quantidade total de entradas
- $L(t)$: valor da carga real em h
- $\underline{L}(t)$: valor da carga prevista em h

Os experimentos foram feitos da seguinte forma: 1- MMQ; 2-ARTMAP *Fuzzy* e 3- Metodologia Híbrida

Foram feitas previsões de carga horária com o horizonte de 24 horas de oito dias seguidos, conforme a tabela 1.

Tabela 1: Dados selecionados para os experimentos-8 dias consecutivos

item	Treinamento	Diagnóstico	Dia da Semana
1	01/03 a 31/05/90	01/06/90	sexta-feira
2	01/03 a 01/06/90	02/06/90	sábado
3	01/03 a 02/06/90	03/06/90	domingo
4	01/03 a 03/06/90	04/06/90	segunda-feira
5	01/03 a 04/06/90	05/06/90	terça-feira
6	01/03 a 05/06/90	06/06/90	quarta-feira
7	01/03 a 06/06/90	07/06/90	quinta-feira
8	01/03 a 07/06/90	08/06/90	sexta-feira

6 Resultados Obtidos

A tabela 2 demonstra os resultados obtidos em todos os testes o modelo híbrido teve desempenho superior às outras duas arquiteturas. Foram testados oito dias seguidos para verificar a consistência dos resultados.

Tabela 2: Resultados da previsão de cargas elétricas de oito dias consecutivos utilizando os três modelos.

Item	MMQ		Rede Neural		Modelo Híbrido		
	MAPE	Erro máx.	MAPE	Erro máx.	MAPE	Erro máx.	Entradas MMQ
1	4,55	13,16	2,21	4,88	1,95	5,06	36
2	7,92	14,42	2,70	5,64	2,03	11,29	35
3	11,19	20,17	5,94	30,19	4,89	13,09	40
4	7,70	21,82	4,84	12,24	3,34	9,90	25
5	5,75	14,75	9,54	24,20	4,61	12,27	35
6	5,56	11,99	3,37	8,94	2,32	13,86	36
7	4,75	12,51	3,01	7,14	2,19	7,37	35
8	4,53	11,90	4,98	4,85	1,77	7,57	100

A última coluna da tabela mostra quantas entradas para o método dos mínimos quadrados foram escolhidas para a construção da reta de regressão linear, lembrando que essas entradas são as que apresentam os maiores graus de similaridade com a entrada em W_a . A determinação do número de entradas para o MMQ foi feita de modo manual realizando os mais diferentes testes, os resultados mostrados foram os melhores obtidos. O banco de dados que foi utilizado possui correlação linear acima de 95% o que pode acarretar alguns dados ruidosos. Na tabela 2 nota-se que unir o MMQ com a RNA ARTMAP Fuzzy foi vantajoso oferecendo resultados mais precisos do que os métodos usados individualmente.

7 Considerações Finais

O intuito principal da Rede Neural Híbrida-MMQ é aumentar as chances de acerto na previsão. Na metodologia da equação de regressão linear múltipla pode não nos oferecer uma boa equação e a metodologia da Rede Neural ARTMAP *Fuzzy* pode não apontar para uma saída adequada, ainda mais se o banco tiver muitos dados ruidosos. Os estudos sobre a rede híbrida ainda estão em andamento. Embora os resultados sejam promissores ainda é necessário resolver o problema da escolha das entradas mais adequadas para o MMQ de forma automática com baixo custo computacional. Uma das ideias seria implementar um método para escolher as entradas que melhor se correlacionam dentro de um intervalo de confiança e excluímos as entradas fora deste intervalo.

Agradecimentos

À CAPES pelo apoio financeiro

Referências

- [1] T. Abreu, C. R. S. Júnior, M. L. M. Lopes, A. D. P. Lotufo, C. R. Minussi. Previsão de Cargas Elétricas utilizando uma Rede Neural ARTMAP Fuzzy com Treinamento Continuo. In *Anais XIII Brazilian Congress on Computational Intelligence*, 2017, Niterói- RJ.
- [2] M. F. Alves. A. D. P. Lotufo, M. L. M. Lopes . Seleção de Variáveis Stepwise Aplicadas em Redes Neurais Artificiais para Previsão de Demanda de Cargas Elétricas. In: *Anais Conferência Brasileira de Dinâmica, Controle e Aplicações - 2013*, Fortaleza - CE.
- [3] G. E. P. Box, G. M. Jenkins, *Times series analysis: forecasting and control*. San Francisco: J. Willey, 1976.
- [4] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, D. B. Rosen . A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps, *Neural Networks. IEEE Transactions*, volume 3, pages 698-713, 1992c.
- [5] G. Gross, F. D Galiana. Short term load forecasting. *Proceedings of the IEEE, New York*, v. 75, n. 12, p. 1558-1573, 1987. DOI:10.1109/PROC.1987.13927
- [6] R. Farber, F. Betsy. *Estatística Aplicada*, 4^o ed. Pearson Prentice Hall, São Paulo, 2010.
- [7] S. Haykin. *Redes Neurais Princípios e Prática*. Bookman, Porto Alegre, 2001.
- [8] A. Howard, C. Rorres. *Álgebra Linear com Aplicações* , 8^a ed. Bookman, Porto Alegre, 2011.