

ANÁLISE COMPARATIVA ENVOLVENDO MODELOS ARIMA E SISTEMAS INTELIGENTES PARA PREVISÃO DE DEMANDA DE ENERGIA ELÉTRICA NO CURTÍSSIMO PRAZO

Luciano Carli M. de Andrade¹, Ivan Nunes da Silva¹

¹Laboratório de Automação Inteligente de Processos de Sistemas, Depto. de Engenharia Elétrica, Universidade de São Paulo – São Carlos, Av. Trabalhador São-Carlense, 400, CEP: 13566-590, São Carlos, SP, Brasil
lucarli@sc.usp.br; insilva@sc.usp.br

Abstract – The main purpose of this paper is to achieve a comparative analysis among Autoregressive Integrated Moving Average model, Artificial Neural Networks and Adaptive Neuro-Fuzzy System techniques for load demand forecasting in distribution substation. The system inputs are two load demand time series, which are composed of data measured at each five minutes interval during seven days from substations located at Andradina and Votuporanga. Autoregressive Integrated Moving Average models with suitable results has been studied, whereas several input configurations and different architectures has been investigated for Artificial Neural Networks and Adaptive Neuro-Fuzzy System techniques aiming at twelve steps forecasting. The results showed the Artificial Neural Network based technique superiority for such sort of forecasting, followed by Autoregressive Integrated Moving Average model and Adaptive Neuro-Fuzzy approach. The load demand forecasting can minimize costs of energy generation and improve the electric power system safety.

Keywords – Load demand; very short-term; neuro-fuzzy system, forecasting.

Resumo – O objetivo deste trabalho é realizar uma análise comparativa entre modelos Auto-Regressivos Integrados de Médias Móveis, Redes Neurais Artificiais e Sistemas de Inferência Neuro-Fuzzy Adaptativos, com o propósito de se executar previsão de demanda de energia elétrica em subestações de distribuição. As entradas do sistema são duas séries temporais de demanda de energia elétrica, compostas por dados mensurados a cada intervalo de cinco minutos durante sete dias em subestações localizadas nas cidades de Andradina e Votuporanga. Modelos Auto-Regressivos Integrados de Médias Móveis com parâmetros apropriados foram investigados, enquanto que para as técnicas de Redes Neurais Artificiais e de Sistemas de Inferência Neuro-Fuzzy Adaptativo foram examinadas diversas configurações de entradas e diferentes arquiteturas para se fazer a previsão de doze passos à frente. Os resultados mostraram superioridade das Redes Neurais Artificiais para esse tipo de previsão, seguido do Modelo Auto-Regressivo Integrado de Médias Móveis e do Sistema de Inferência Neuro-Fuzzy Adaptativo. A previsão de demanda de energia elétrica pode minimizar os custos envolvidos na geração de energia e aumentar a segurança do sistema.

Palavras-chave – Demanda de eletricidade, curtíssimo prazo, sistema neuro-fuzzy; previsão

1. Introdução

Previsão de demanda de energia elétrica tem tido papel importante no que se refere a investimentos na área de distribuição de energia, planejamento e estratégias de gerenciamento. Além disso, previsões imprecisas podem aumentar os custos operacionais.

A previsão de horas e até de dias, ou uma semana à frente, é chamada de previsão em curto prazo. Esse tipo de previsão é usado para planejamento operacional em estações de carga e suas unidades de geração, e também para transações no mercado de energia.

Várias pesquisas e publicações são relatadas no que se refere à previsão em curto prazo [1-2], mas, particularmente, é mais indispensável uma previsão precisa minutos à frente, pois permite se empregar um controle automático do sistema elétrico de potência de forma a se evitar distúrbios indesejáveis entre demanda e carga.

Previsões de alguns minutos a vários minutos à frente são classificadas de previsões em curtíssimo prazo. Embora previsões de carga tenham recebido atenção crescente, apenas alguns trabalhos foram publicados sobre previsão de demanda de energia elétrica no curtíssimo prazo [3]. Estas previsões, aliadas

a informações sobre disponibilidade de transmissão, custos de geração, preço de pacotes de energia no mercado e requisitos de reserva de carga, são usadas para determinar a melhor estratégia para utilização de recursos. Assim, previsão de demanda de energia elétrica tornou-se de grande importância no mercado industrial desregulamentado [4].

Previsão de demanda de energia elétrica em curtíssimo prazo requer uma abordagem diferente. Ao invés de se modelar relacionamentos entre carga, tempos e condições climáticas, e outros fatores que afetam a demanda, deve-se focar no padrão das medidas recentes observadas para prever um futuro próximo. Métodos para previsão de demanda de energia elétrica em curtíssimo prazo não são muito numerosos [4]. As técnicas utilizadas nesse trabalho fazem uso do modelo Auto-Regressivo Integrado de Média Móvel (ARIMA), de Redes Neurais Artificiais (RNAs) e do Sistema Neuro-Fuzzy Adaptativo (ANFIS).

A Seção 2 apresenta informações sobre as séries temporais estudadas. A Seção 3 apresenta informações sobre os métodos utilizados para previsão. A Seção 4 apresenta os resultados obtidos e a Seção 5 apresenta uma conclusão sobre o trabalho desenvolvido.

2. Séries Temporais

As séries temporais de demanda de energia elétrica foram medidas ao longo de sete dias, com uma frequência de cinco em cinco minutos, nas subestações de Andradina e Votuporanga, cidades do interior do estado de São Paulo. A Figura 1 apresenta os gráficos das séries temporais de carga em MW ao longo do tempo.

Verifica-se que as séries têm comportamento sazonal, ou seja, nas primeiras horas da madrugada o consumo de energia elétrica é baixo, aumentando durante a manhã, até apresentar uma pequena queda no início da tarde. Volta a aumentar e atinge pico máximo no início da noite. Depois desse pico, com o entardecer, o consumo vai diminuindo até atingir seu ponto mínimo durante a madrugada.

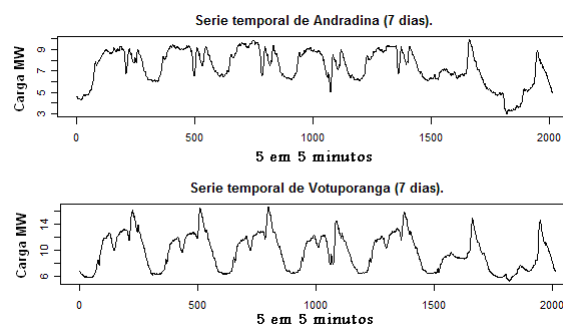


Figura 1 - Histórico de demanda de energia elétrica em Andradina e Votuporanga.

3. Método de Previsão

3.1 Aspectos do Modelo Auto-Regressivo Integrado de Médias Móveis

O Modelo ARIMA é um caso geral dos modelos propostos por Box e Jenkins (1976), apropriado para descrever séries não estacionárias, ou seja, séries em que a média não é constante no período de análise, apresentando tendência e sazonalidade [5].

Os modelos ARIMA são compreendidos em:

- modelo auto-regressivo de ordem p – $AR(p)$: usado quando há auto-correlações entre as observações, ou seja, a observação Y_t depende da Y_{t-1} e de um termo aleatório (μ'). A forma básica do modelo – $AR(1)$ pode ser representado pela equação.

$$Y_t = \phi_1 Y_{t-1} + \mu' + e_t \quad (1)$$

onde Y_t é a observação no tempo t , Y_{t-1} é a observação no tempo $t-1$, ϕ_1 é um coeficiente auto-regressivo compreendido entre -1 e 1 , μ' é um termo aleatório e e_t é um termo de erro.

- modelo de média móvel de ordem q – $MA(q)$: usado quando há auto-correlação entre os resíduos, ou seja, há uma relação de dependência entre o conjuntos de erros em período passados. A forma básica do modelo – $MA(1)$ pode ser representado pela equação:

$$Y_t = \mu + e_t - \theta_1 e_{t-1} \quad (2)$$

onde Y_t é a observação no tempo t , μ é um termo aleatório, e_t é um termo de erro e e_{t-1} é um termo de erro anterior com coeficiente θ_1 .

- modelo auto-regressivo de média móvel – $ARMA(p,q)$: usado quando há auto-correlação entre as observações e auto-correlação entre os resíduos. A forma básica do modelo – $ARMA(1,1)$ pode ser representado pelo equação:

$$Y_t = \underbrace{\phi_1 Y_{t-1}}_{AR(1)} + \underbrace{\mu'}_{constante} + \underbrace{e_t - \theta_1 e_{t-1}}_{MA(1)} \quad (3)$$

onde Y_t é a observação no tempo t , Y_{t-1} é a observação no tempo $t-1$, ϕ_1 é um coeficiente auto-regressivo compreendido entre -1 e 1 , μ' é um termo aleatório e e_t é um termo de erro e e_{t-1} é um termo de erro anterior com coeficiente θ_1 .

- Modelo auto-regressivo integrado de média móvel – $ARIMA(p,d,q)$: usado em séries não estacionárias. A forma básica do modelo – $ARIMA(1,1,1)$ pode ser representado pela equação:

$$\underbrace{(1-B)}_{\text{Primeira diferenciação}} \underbrace{(1-\phi_1 B)}_{AR(1)} Y_t = \mu' + \underbrace{(1-\theta_1 B)}_{MA(1)} e_t \quad (4)$$

onde Y_t é a observação no tempo t , ϕ_1 é um coeficiente auto-regressivo compreendido entre -1 e 1 , μ' é um termo aleatório, e_t é um termo de erro, θ_1 é o coeficiente do termo de erro em $t-1$ e $BY_t = Y_{t-1}$.

- Modelo sazonal auto-regressivo integrado de média móvel – $SARIMA(p,d,q)(P,D,Q)^S$: usado em séries não estacionárias sazonais: A forma básica do modelo – $SARIMA(1,1,1)(1,1,1)^{12}$, medidos anualmente, pode ser representado pela equação:

$$\underbrace{(1-\phi_1 B)}_{AR(1) \text{ não sazonal}} \underbrace{(1-\Phi_1 B^{12})}_{AR(1) \text{ sazonal}} \underbrace{(1-B)}_{\text{Diferenciação não sazonal}} \underbrace{(1-B^{12})}_{\text{Diferenciação sazonal}} Y_t = \underbrace{(1-\theta_1 B)}_{MA(1) \text{ não sazonal}} \underbrace{(1-\Omega_1 B^{12})}_{MA(1) \text{ sazonal}} e_t \quad (5)$$

onde Y_t é a observação no tempo t , ϕ_1 é um coeficiente auto-regressivo compreendido entre -1 e 1 , Φ_1 é um coeficiente auto-regressivo sazonal compreendido entre -1 e 1 , e_t é um termo de erro, θ_1 é o coeficiente do termo de erro em $t-1$, Ω é o coeficiente sazonal de erro em $t-12$, $BY_t = Y_{t-1}$ e $B^{12}Y_t = Y_{t-12}$.

A construção desse modelo baseia-se em uma metodologia empírica que, pode ser dividida em três fases e composta por cinco passos básicos, como apresentado na Figura 2 [5].

A Fase I ou Fase de Identificação tem como objetivo tornar os dados da série estacionários, pois essa característica é indispensável para se modelar o processo ARIMA. Para isso essa fase está dividida nos dois passos seguintes:

- Preparação dos dados – segundo [5] para se obter a estacionariedade dos dados deve-se projetar os dados em gráficos para que se possa identificar algum padrão, caso seja

necessário, estabilizar a variância através da logaritmização, fazer a identificação e diagnósticos através da Função de Auto-correlação (FAC) e Função de Auto-correlação Parcial (FACP) para verificar a existência de um padrão nos dados da série e através de diferenciações obter estacionariedade.

- Seleção do modelo – potenciais modelos são identificados através da análise da Função de Auto-correlação e da Função de Auto-correlação Parcial.

A Fase II ou Fase de Estimação e Teste, os coeficientes (p,d,q) do modelo ARIMA são determinados e testados quanto a estacionariedade. Esta fase é dividida nos seguintes passos:

- Estimação – são geradas as estatísticas dos resíduos (FAC, teste Ljung-Box e teste Box-Pierce, o histograma e o gráfico de normalidade).
- Diagnóstico – através da análise das estatísticas geradas no passo anterior verifica-se a validade do modelo escolhido. Caso os resíduos sejam não correlacionados, ou seja, não há mais nenhum padrão a ser considerado, segue-se para o passo de previsão, se não seleciona-se outro modelo.

A Fase III ou Fase de aplicação compreende um único passo que consiste na previsão.

Em muitos casos as séries temporais apresentam comportamento periódico, nesse caso é necessário acrescentar uma componente sazonal (P,D,Q) ao modelo, que passa a ser representado por *SARIMA*. De qualquer forma, a adição desse componente sazonal não altera a metodologia empregada na construção do modelo [5].

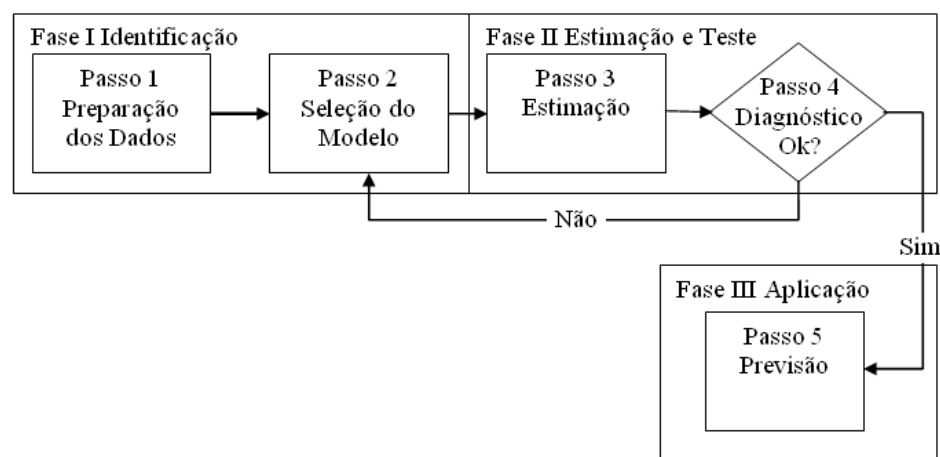


Figura 2 – Representação esquemática da Metodologia ARIMA.

Portanto, o propósito da análise ARIMA é encontrar um modelo que represente precisamente os padrões passados e futuros das séries temporais, ou seja, a metodologia empregada para estimação do modelo ARIMA consiste em encontrar os parâmetros adequados que descrevam a seguinte estrutura a ser utilizada:

$$SARIMA(p,d,q)(P,D,Q)$$

onde p é a ordem do modelo auto-regressivo; d é o número de diferenciações, com o propósito de se obter estacionariedade; q é a ordem do modelo de média móvel; P é a ordem do modelo auto-regressivo sazonal; D é o número de diferenciações sazonais, também com o propósito de se obter estacionariedade; e Q é a ordem do modelo de média móvel sazonal.

3.2 Aplicação do Modelo Auto-Regressivo Integrado de Médias Móveis

É importante mencionar que os padrões sazonais são variados e de análise complexa. Além disso, ainda há a possibilidade de combinação de modelos sazonais. Diante disso, a análise da série temporal desse trabalho é complexa, apresentando possíveis combinações de padrões sazonais, o que dificulta

muito a identificação dos parâmetros corretos, por parte do especialista, a serem usados pelo modelo ARIMA, ou seja, é necessária muita perspicácia e conhecimento para se definir, com precisão, os parâmetros a serem usados no modelo [5].

Neste trabalho, a aplicação do Modelo ARIMA, apresentado na Subseção 3.1 se deu da seguinte forma:

Na preparação foi feita a projeção dos dados em gráficos como ilustrado na Figura 1.

Pode-se observar que os dados apresentam comportamento não estacionário e sazonal, pois como descrito da Seção 2, os dados repetem seu comportamento dia a dia.

Dessa forma, diferenciações não sazonais e sazonais são necessárias para se obter uma série temporal estacionária [5].

No caso das séries temporais estudadas aqui, foram necessárias duas diferenciações não sazonais e uma diferenciação sazonal para se obter estacionariedade.

No passo de seleção do modelo, a análise da Função de Auto-Correlação (FAC) e Função de Auto-Correlação Parcial (FACP) das séries resultantes das diferenciações deve ser feita.

A Figura 3 apresenta os gráficos de FAC e FACP para a série diferenciada de Andradina.




Figura 3 - Gráficos de FAC e FACP para a série temporal diferenciada de Andradina.

Analisando-se os gráficos da Função de Auto-Correlação e da Função de Auto-Correlação Parcial, ilustrados na Figura 3, pode-se concluir que um modelo candidato a ser analisado é o seguinte:

$$SARIMA (3,2,2)(0,1,1)$$

pois o gráfico FAC possui três picos significativamente diferentes de zero e o gráfico FACP possui queda exponencial de valores negativos [5].

A Figura 4 apresenta os gráficos da FAC e da FACP para a série temporal da subestação de Votuporanga.




Figura 4 - Gráficos de FAC e FACP para a série temporal diferenciada de Votuporanga.

Fazendo-se a análise dos gráficos da Função de Auto-Correlação e da Função de Auto-Correlação Parcial, ilustrados na Figura 4, pode-se concluir que um modelo candidato a ser avaliado é o seguinte:

$$SARIMA (1,2,2)(0,1,1)$$

pois o gráfico FAC possui um pico significativamente diferente de zero e o gráfico FACP possui queda exponencial de valores negativos [5].

Fazendo-se uma análise conjunta das séries temporais investigadas, verifica-se que os modelos candidatos para seu ajuste são parecidos, apesar de apresentarem um número de picos da FAC distintos.

Encontrados os modelos candidatos, o passo seguinte é fazer a análise de seus resíduos para se verificar sua adequação (resíduos não correlacionados), para então, no passo seguinte, utilizá-los para previsão.

A análise dos resíduos (FAC, teste Ljung-Box e teste Box-Pierce), indicaram que o modelo candidato de Andradina ($SARIMA(3,2,2)(0,1,1)$) não possuía resíduos correlacionados; portanto o modelo a empregado para o caso da série temporal de Andradina foi mesmo:

$$SARIMA (3,2,2)(0,1,1)$$

A FAC e o teste Ljung-Box, para os resíduos do modelo final para previsão em Andradina, são apresentados na Figura 5.

Pode-se observar que a FAC dos resíduos para a série temporal de Andradina não apresenta picos que se destaquem, indicando então que o modelo está bem ajustado. Outro indicativo de que o modelo final escolhido é adequado, são os p-valores da estatística Ljung Box serem próximos de um.

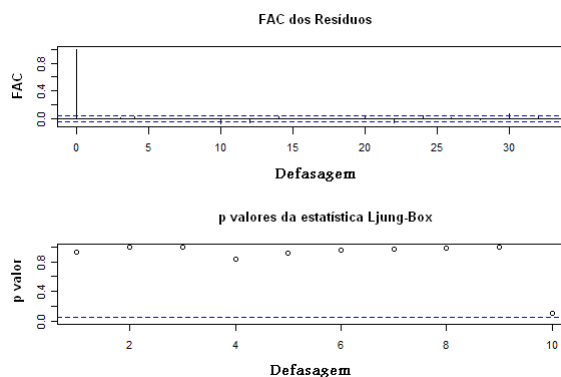


Figura 5 - A FAC e o teste Ljung-Box para os resíduos do modelo final utilizado para previsão em Andradina.

A mesma análise foi realizada para a série temporal de Votuporanga. Foi feita a análise de resíduos para o modelo candidato ($SARIMA (1,2,2)(0,1,1)$), mas nesse caso, os resíduos eram correlacionados. Então, com auxílio do software estatístico R outros modelos foram avaliados, permitindo aos autores identificar que o melhor modelo a ser utilizado no caso de Votuporanga também é:

$$SARIMA (3,2,2)(0,1,1)$$

A FAC e o teste Ljung-Box, para os resíduos do modelo final para a previsão em Votuporanga, são apresentados na Figura 6.

No caso de Votuporanga, a FAC e o teste Ljung-Box também indicaram que os resíduos são não correlacionados para o modelo final escolhido.




Figura 6 - A FAC e teste Ljung-Box para os resíduos do modelo final utilizado para previsão em Votuporanga.

Outra análise que deve ser feita sobre os resíduos é a verificação de que se estes possuem distribuição normal, a qual também indicaria que os mesmos são não correlacionados. Embora não apresentados aqui, o histograma e o gráfico de normalidade dos resíduos para Andradina e Votuporanga foram analisados, confirmando-se então que seus resíduos possuem distribuição normal, ou seja, que estes são não correlacionados.

O último passo é o de previsão, onde os modelos escolhidos (que apresentaram resíduos não correlacionados) foram utilizados para previsão recursiva de doze passos à frente.

Os resultados obtidos são apresentados na Seção 4.

3.3 Redes Neurais Artificiais

A RNA empregada nesse trabalho foi a MLP (*Multilayer Perceptron*) com uma camada intermediária e algoritmo de aprendizado Levenberg-Marquardt, isto devido ao mesmo apresentar um melhor ajuste dos pesos e maior velocidade de convergência quando comparado aos algoritmos de *backpropagation* convencionais [6].

A metodologia utilizada para o caso das RNAs foi de *cross-validation*. Várias janelas de entradas foram avaliadas (duas, três, quatro ou mais entradas anteriores, com uso também, de medidas dos dias anteriores como entrada), e o melhor desempenho encontrado, ou seja, menor erro de validação (rede com maior poder de generalização), foi com quatro medidas anteriores mais uma medida, no mesmo horário daquele a ser previsto, do dia anterior.

Os dados foram normalizados entre menos um e um e foram divididos em conjuntos de treinamento, validação e teste, com um montante para treinamento de mil e setecentas medidas, doze medidas para validação e doze medidas para teste.

É importante mencionar que o número de neurônios da camada intermediária também foi pesquisado, variando-se de dois a quinze neurônios com menor MAPE (*Mean Absolut Percentage Error*) para o caso de três neurônios.

Portanto, a melhor arquitetura para o caso das RNAs possui cinco entradas e três neurônios intermediários, com um neurônio de saída.

3.4 Sistema *Neuro-Fuzzy* Adaptativo

No caso do ANFIS, a metodologia empregada também foi a de *cross-validation*. A melhor formação dos padrões de entrada se deu como no caso das RNAs (quatro medidas anteriores mais uma

medida do mesmo horário do dia anterior). Após a formação dos padrões foi determinado o número de funções de pertinência. Foram avaliadas duas e três funções de pertinência, com melhor resultado para a segunda formação. Algumas funções de pertinência também foram avaliadas como, por exemplo, função de pertinência com curva gaussiana, função de pertinência com combinação de gaussianas e função de pertinência trapezoidal. Mas, a função de pertinência que apresentou melhor resultado foi a função Sino [7-8].

Foram então avaliados os métodos de otimização, backpropagation e híbrido, com resultados amplamente melhores para o segundo método.

Portanto, a melhor arquitetura encontrada possui cinco entradas e três funções de pertinência.

3.5 Forma de avaliação do ARIMA, das RNAs e do ANFIS

Para o modelo ARIMA, para as RNAs e para o ANFIS, a avaliação foi feita calculando-se o erro relativo percentual médio (MAPE – *Mean Average Percentage Error*) para doze passos à frente.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{d_i - o_i}{d_i} \right| \times 100\% \quad (6)$$

onde d é a saída desejada, o é a resposta obtida pela abordagem considerada e N é o número de padrões de teste.

4. Resultados

Após a análise por meio do modelo ARIMA e da determinação das melhores arquiteturas para RNAs e para o ANFIS, os resultados foram tabelados e traçados para as duas localidades investigadas, Andradina e Votuporanga. Os erros traçados nas Figuras 6 e 7 e tabelados na Tabela 1, foram obtidos de forma recursiva e são referentes as dose últimas medidas a séries temporais, uma vez que o software R permite a previsão de dados na seqüência e de forma recursiva.

Os primeiros resultados foram para a localidade de Andradina. O gráfico dos erros para doze passos a frente pode ser visto na Figura 7.

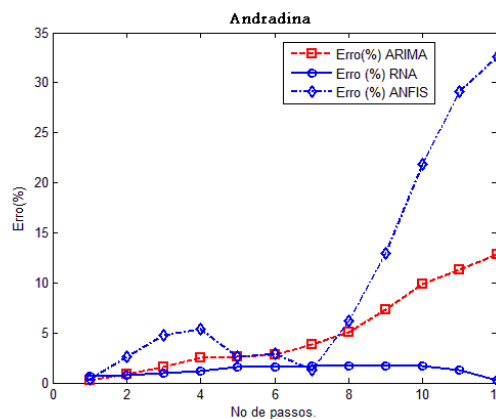


Figura 7 - Gráfico com MAPE para previsão de doze passos a frente para a localidade de Andradina.

Pela Figura 7, pode-se observar que o melhor desempenho se deu com o uso das RNAs, pois estas apresentaram menor MAPE para todos os doze passos de previsão. O modelo ARIMA apresentou bons resultados para os seis primeiros passos, mas os seis últimos passos apresentaram um MAPE significativo. No caso do ANFIS, os resultados também foram bons para seis passos à frente, mas a partir do sétimo passo o MAPE cresceu significativamente.

Os resultados do MAPE, para Andradina, também foram tabelados e podem ser visto na Tabela 1. Para a localidade de Votuporanga, o melhor desempenho também ficou com as RNAs. Pode-se visualizar no gráfico da Figura 8 de que o MAPE para cada um dos doze passos a frente não cresceu. Já no caso do ARIMA e o ANFIS, na medida em que os passos cresceram, o MAPE também cresceu, mais significativamente no caso do ANFIS.

Os resultados do MAPE para cada um dos passos de previsão ilustrados na Figura 8 também foram tabelados e podem ser visto na Tabela 1.

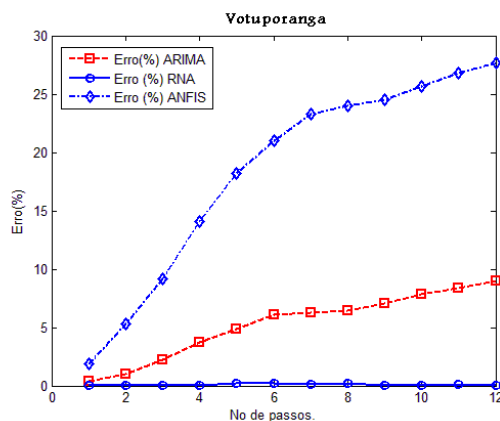


Figura 8 - Gráfico com MAPE para previsão de doze passos a frente para a localidade de Votuporanga.

Também foram calculadas as variâncias do MAPE de cada uma das localidades estudadas, como também pode ser visto na Tabela 1. Os valores das variâncias foram bem baixos, indicando que para nenhum dos passos houve um MAPE significativamente maior do que nos outros passos.

Tabela 1 - MAPE(%) e Variância para as previsões de doze passos à frente para Andradina e Votuporanga.

MAPE(%) de Andradina			MAPE(%) de Votuporanga		
ARIMA	RNA	ANFIS	ARIMA	RNA	ANFIS
0,30	0,62	0,31	0,38	0,06	1,88
0,89	0,80	2,63	0,99	0,06	5,32
1,61	0,99	4,75	2,27	0,02	9,17
2,46	1,19	5,38	3,75	0,05	14,04
2,58	1,57	2,62	4,85	0,18	18,22
2,78	1,61	2,90	6,06	0,19	20,98
3,86	1,65	1,23	6,24	0,09	23,32
5,02	1,71	6,16	6,42	0,20	23,96
7,33	1,70	12,95	7,10	0,01	24,50
9,84	1,65	21,84	7,85	0,07	25,62
11,31	1,31	29,08	8,40	0,17	26,76
12,80	0,24	32,62	8,98	0,04	27,64
Média					
5,07	1,25	10,21	5,27	0,10	18,45
Variância					
1,80E-03	2,42E-05	1,29E-02	8,20E-04	4,78E-07	7,77E-03

5. Conclusão

Os resultados obtidos demonstraram que as RNAs possuem uma maior capacidade de adaptação e aprendizado para previsão de demanda de energia elétrica no curtíssimo prazo. O modelo ARIMA, apesar de exigir maior conhecimento por parte do especialista e possuir desempenho inferior às RNAs, também apresentou bons resultados. No caso do ANFIS, os resultados demonstraram um bom desempenho para os primeiros passos de previsão, mas um crescimento significativo do MAPE a partir de dois ou três passos à frente.

Agradecimentos: Os autores agradecem o Laboratório de Automação Inteligente de Processo de Sistemas (LAIPS) pela infra-estrutura fornecida, assim como a FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo), a CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) e ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) pelo apoio ao Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia de São Carlos – USP cujo compromisso com pesquisa em Engenharia possibilitou o desenvolvimento desse trabalho.

Referências:

- [1] K. Methaprayoon, W. Lee, S. Rasnidatta, Multistage artificial neural network short-term load forecasting engine with front-end weather forecast, **IEEE Transactions on Industry Applications**, 43(2007), 1410-1416.
- [2] A. K. Topalli, I. Erkmén, A hybrid learning for neural networks applied to short term load forecasting, **Neurocomputing**, 51(2003), 495-500.
- [3] H. Y. Yang, H. Y. Guizeng, W. J. Khan, T. Hu, Fuzzy neural very-short-term load forecasting based on chaotic dynamics reconstruction, **Chaos Solitons and Fractals**, 29(2006), 462-469.
- [4] W. Charytoniuk, M. Chen, Very short-term load forecasting using artificial neural networks, **IEEE Transactions on Power Systems**, 15(2000), 263-268.
- [5] S. Makridakis, S. C. Wheelwright, V. E. McGee, Forecasting: Methods and Applications, 2a Edição, John Wiley & Sons Inc., Nova York, (1983).
- [6] M. T. Hagan, M. B. Menhaj, Training FeedForward Networks with the Marquardt Algorithm, **IEEE Transactions on Neural Networks**, 5(1994), 989-993.
- [7] J. R. Jang, C. Sun, Neuro-Fuzzy modeling and control, **Proceedings of the IEEE**, 83(1995), 378-406
- [8] J. R. Jang, Adaptive-network-based fuzzy inference system, **IEEE Transaction on Systems, Man and Cybernetics**, 23(1993), 665-685.