

# ANÁLISES E PREVISÕES DE VAZÕES DO RIO GRANDE UTILIZANDO MODELOS DE BOX & JENKINS E REDES NEURAIS ARTIFICIAIS

André L. F. Batista<sup>1</sup>

<sup>1</sup>Departamento de Informática – Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro (IFTM)  
Ituiutaba – MG – Brasil

andreluiz@iftm.edu.br

**Abstract:** *This article aims at investigating two different methodologies to forecast time series of river flows. Models originated from Box & Jenkins method, as well as models based on artificial neural networks technique have been constructed. The proposed models were used in order to forecast future values of the historical series of Rio Grande's natural flows. The time series data have been collected from the stream gauge station of Madre de Deus de Minas, MG. Afterwards, a comparative analysis between both techniques used at the prognostication of time series has been done. The results obtained from the comparison have shown that each methodology can be adequately adjusted to the set of studied observations; however, each technique has advantages and disadvantage.*

**Resumo:** *O presente artigo investiga duas metodologias distintas para realizar previsão de séries temporais de vazões fluviais. Foram construídos modelos de Box & Jenkins, e também modelos de Redes Neurais Artificiais. Os modelos propostos foram empregados para prever valores futuros da série histórica de vazões naturais do Rio Grande. Os dados da série temporal foram coletados na seção de controle no posto fluviométrico de Madre de Deus de Minas, MG. Posteriormente foi feita uma análise comparativa entre ambas as técnicas empregadas no prognóstico da série temporal. Os resultados obtidos na comparação mostram que cada metodologia pode ser ajustada adequadamente ao conjunto de observações em estudo, entretanto cada técnica possui vantagens e desvantagens.*

## 1. Introdução

A volubilidade natural do regime hidrológico é uma das principais dificuldades enfrentadas pelos sistemas de geração de energia elétrica no país, uma vez que a matriz energética nacional é hidráulica. As atividades de planejamento e operação de sistemas de energia e recursos hídricos requerem a utilização de muitas variáveis de entrada, principalmente a vazão natural.

Conhecer os valores futuros da vazão de um rio afluente a um reservatório de usina geradora de energia é fundamental. Tais valores são usados no planejamento de sistemas de produção de energia elétrica com propósitos de simulação, otimização e tomada de decisões.

Redes neurais artificiais (RNAs) têm sido largamente adotadas para prever valores futuros com base em valores passados. São muito utilizadas em séries temporais que descrevem uma sequência real de valores.

O objetivo deste artigo consistiu em realizar uma análise comparativa entre diferentes metodologias para previsão de índices de vazão fluvial. A série temporal usada nesse artigo (Figura 1) é composta por observações da vazão do Rio Grande, afluente ao reservatório da Usina Hidrelétrica de Camargos/CEMIG. As duas metodologias pesquisadas forneceram os modelos estocásticos e os modelos de Redes Neurais Artificiais para que a comparação fosse feita.

Uma série temporal é um conjunto de observações indexada no tempo, conforme Morettin & Toloi (2006). Para realizar previsões de séries temporais um dos métodos mais disseminados na literatura é a metodologia de Box & Jenkins. Essa técnica foi apresentada pelos autores na década de 70, de acordo com Box & Jenkins (1976), e é executada em fases ou etapas. Essencialmente, tais etapas procuram identificar o modelo mais apropriado a série; em seguida estimar os parâmetros; e, posteriormente, verificar se a modelagem foi bem ajustada.

Resolver problemas usando RNAs é bastante atrativo, expõe Braga et al. (2000), uma vez que a maneira como estes são representados internamente pela rede e o paralelismo natural inerente à arquitetura das RNAs possibilitam um desempenho superior ao dos modelos convencionais. Os autores em Braga et al. (2000) ainda complementam esclarecendo que, em RNAs, o procedimento padrão na resolução de problemas passa inicialmente por uma fase de aprendizagem, onde um conjunto de exemplos é apresentado à rede. Então essa rede extrai as características necessárias para representar a informação fornecida. Tais características são empregadas na construção do modelo para produção de respostas para o problema em questão.

Outro conjunto de dados é usado para validação do modelo elaborado, explica Haykin (1994), onde o modelo é avaliado sob condições reais de utilização. Após ser treinada e validada, a rede então poderá ser aplicada para encontrar as respostas.

Em um sistema hidrelétrico, a geração de energia está sujeita essencialmente a série de vazões afluentes às várias usinas presentes no sistema, esclarecem Mine & Tucci (2002). Ao empregar a utilização de recursos hídricos, a série temporal de vazões na região é comumente empregada como variável de entrada em modelagens de simulação e otimização para tomada de decisões.

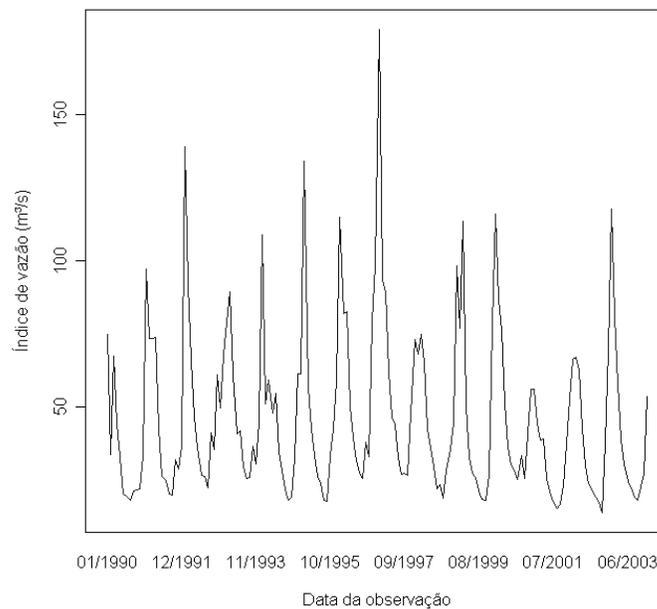
Usinas hidrelétricas apresentam particularidades de produção não-linear e as suas vazões afluentes são variáveis de comportamento aleatório, o que revela um problema estocástico não-linear. Segundo Tucci (2003), os valores das vazões tem influência significativa na geração de energia, e por isso devem ser previstos com precisão. A elaboração de modelos de previsão de vazões é de grande relevância para o planejamento do conjunto de ações inerentes à produção de energia elétrica.

O artigo apresenta uma introdução sobre redes neurais, séries temporais e séries de vazões. Posteriormente é demonstrada a estrutura metodológica utilizada no artigo, explicando como foram modelados os modelos de redes neurais e modelos estatísticos. Depois são apresentados os resultados e realizadas algumas discussões sobre esses resultados. E finalmente são feitas algumas conclusões sobre o artigo e apresentadas algumas sugestões para trabalhos futuros.

## 2. Estrutura metodológica

Com o intuito de avaliar diferentes modelos de previsão dos índices de vazão do Rio Grande, afluente ao reservatório da Usina Hidrelétrica de Camargos/CEMIG, este estudo trabalhou com alguns modelos estocásticos e com alguns modelos de Redes Neurais Artificiais. Tais técnicas foram então comparadas visando identificar o modelo que apresentar desempenho superior aos demais.

Para construção dos modelos de prognóstico de índices de vazão aplicados, utilizou-se uma série histórica de índices de médias mensais de vazões naturais do Rio Grande, com dados coletados no posto fluviométrico de Madre de Deus de Minas/MG abrangendo 168 meses, desde Janeiro de 1990 a Dezembro de 2003. A base de dados de vazões utilizada neste artigo está disponível no Sistema de Informações Hidrológicas (HIDROWEB) da Agência Nacional das Águas, em Das Águas (2011). A Figura 1 mostra um esboço da série utilizada nesse artigo.



**Figura 1. Esboço da série temporal das médias das vazões do Rio Grande.**

Essas observações foram separadas em dois grupos distintos, sendo o primeiro composto por 164 valores destinados a fase de treinamento e ajuste dos modelos; e o segundo grupo, com as quatro observações restantes, para teste e validação da modelagem.

Baseados na metodologia de Box & Jenkins, foram modelados dois modelos SARIMA sendo o primeiro um SARIMA  $(1,1,0)(1,1,0)_{12}$  e o último um SARIMA  $(1,1,1)(1,1,1)_{12}$ . Os modelos foram escolhidos após a inspeção visual do gráfico da série utilizada, onde se verificou a presença da componente sazonalidade na série. Tal componente foi confirmada com a construção, e análise, do periodograma, onde se encontrou o valor de  $p=12$ . Nas modelagens estatísticas realizadas utilizou-se as funções dos pacotes *stats* e *tseries* do programa R.2.7.2, em TEAM R (2011).

As Redes Neurais utilizadas neste artigo são do tipo *perceptron* de múltiplas camadas, ou MLP (*multi-layer perceptron*). O algoritmo utilizado no treinamento foi o algoritmo de retropropagação de erros, ou *back-propagation*. O treinamento foi realizado em 1000 épocas. As implementações dos modelos de redes neurais serão feitas utilizando as funções da *toolbox Artificial Neural Networks* do programa Scilab 4.1.2, em Scilab Consortium (2011).

Cada rede neural aplicada possui uma configuração diferente, de modo que pudessem ser avaliadas com o propósito de escolher o modelo que melhor se ajustou aos dados. O critério de avaliação de desempenho das redes foi o Erro Quadrático Médio, ou EQM. A variável de entrada utilizada foi as médias mensais de vazões naturais do Rio Grande.

### 3. Resultados e discussões

A Tabela 1 apresenta a estimativa dos parâmetros dos modelos de Box & Jenkins propostos, bem como os respectivos erros padrão.

**Tabela 1. Estimativas dos parâmetros dos modelos e respectivos erros padrão.**

Modelo	Parâmetros	Estimativas	Erros padrão
SARIMA(1,1,0)(1,1,0) <sub>12</sub>	$\phi_1$	-0,451934	0,073509
	$\Phi_1$	-0,544394	0,071300
SARIMA(1,1,1)(1,1,1) <sub>12</sub>	$\phi_1$	0,15513	0,11002
	$\Phi_1$	0,80565	0,06493
	$\theta_1$	-0,1883	0,10200
	$\Theta_1$	0,73111	0,06570

Após a estimação dos parâmetros verificou-se que os resíduos dos modelos propostos caracterizam ruído branco. Para seleção do melhor modelo foram empregados os critérios de informação de Akaike (AIC), e critério de informação Bayesiana (BIC). Os resultados da aplicação de tais critérios estão na Tabela 2.

O modelo SARIMA(1,1,1)(1,1,1)<sub>12</sub> apresentou menor AIC e BIC, e por isso foi o modelo escolhido para realizar as previsões. As previsões encontradas para cada observação do conjunto de teste, usando o modelo selecionado, estão apresentados na Tabela 3.

**Tabela 2. Resultados dos Critérios de Informação Akaike (AIC) e Bayesiana (BIC).**

Modelo	AIC	BIC
SARIMA(1,1,0)(1,1,0) <sub>12</sub>	6,169777	6,20758
SARIMA(1,1,1)(1,1,1) <sub>12</sub>	5,745226	5,78303

**Tabela 3. Resultados encontrados pelo modelo SARIMA.**

Modelo	Data da observação	Valor Real	Valor Previsto	Erro de previsão
SARIMA(1,1,1)(1,1,1) <sub>12</sub>	09/2003	17,69271	17,97935	0,28664
	10/2003	22,28818	18,46028	-3,82790
	11/2003	26,58616	32,75332	6,16716
	12/2003	53,32198	53,71121	0,38923

O modelo ajustado SARIMA(1,1,1)(1,1,1)<sub>12</sub> encontrou bons resultados na previsão para os meses de Setembro/2003 e Dezembro/2003. Entretanto os valores obtidos para os meses de Outubro/2003 e Novembro/2003 tiveram um erro de previsão maior.

A modelagem de Redes Neurais Artificiais consistiu em modelar três arquiteturas distintas para que fossem avaliadas entre si e selecionado o modelo que apresentasse melhores resultados. As arquiteturas modeladas possuem as seguintes configurações: MLP(12,4,2,1), MLP(12,3,1), MLP(12,2,1). Onde as notações MLP(A,B,C,D) e MLP(A,B,D) representam redes *perceptron* com múltiplas camadas com: A, número de neurônios na camada de entrada; B e C, quantidade de neurônios nas camadas intermediárias; D, neurônio presente na camada de saída.

Durante o processo de treinamento e validação das redes modeladas foram obtidos os EQMs de cada modelo em cada fase da implementação. A Tabela 4 expõe os EQMs encontrados com cada uma das arquiteturas modeladas.

**Tabela 4. Redes Neurais aplicadas para prognóstico de série de vazões.**

Tipo de rede	Topologia	EQM Treinamento	EQM Teste/Validação
MLP	(12,4,2,1)	0,0063646	0,0056664
	(12,3,1)	0,0064178	0,0066918
	(12,2,1)	0,0066284	0,0046568

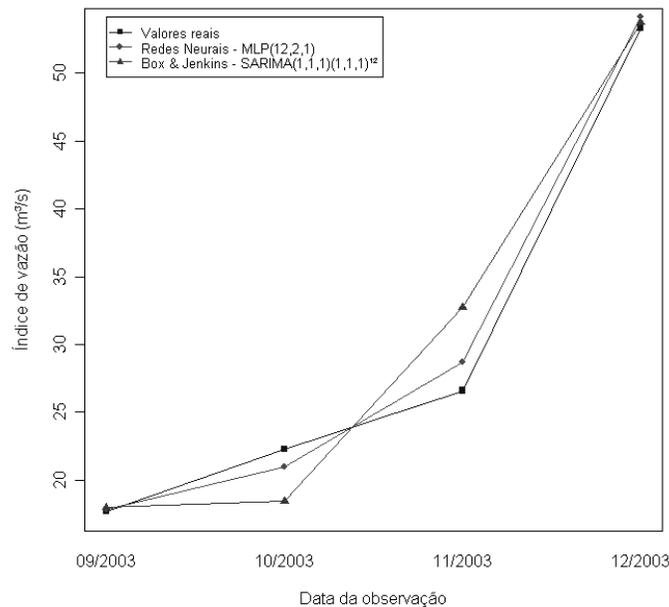
O modelo com a topologia MLP(12,4,2,1) obteve um EQM menor para o conjunto de observações destinadas ao treinamento da rede neural. A modelagem com a arquitetura MLP(12,3,1) teve um desempenho intermediário entre todas as modelagens realizadas. A rede MLP(12,2,1) apresentou menor EQM para o conjunto de dados de teste, e com isso conseguiu previsões melhores do que os outros modelos. A Tabela 5 exibe os valores previstos pela rede neural MLP(12,2,1).

**Tabela 5. Resultados obtidos pela rede neural artificial.**

Modelo	Data da observação	Valor Real	Valor Previsto	Erro de previsão
MLP(12,2,1)	09/2003	17,69271	17,82722	0,13451
	10/2003	22,28818	20,99408	-1,29410
	11/2003	26,58616	28,71629	2,13013
	12/2003	53,32198	54,14257	0,82059

Através dos resultados encontrados pela rede neural pode-se perceber que essa metodologia conseguiu melhor desempenho como preditor quando comparada a metodologia de Box & Jenkins. Com a rede devidamente modelada, e os dados estudados representando bem o comportamento da série, as redes neurais se mostram eficientes para tratar problemas não-lineares como previsão de séries temporais.

Para fins de comparação visual, a Figura 2 ilustra uma comparação entre as previsões encontradas com o modelo estatístico de Box & Jenkins e com o modelo de Redes Neurais Artificiais.



**Figura 2. Resultado gráfico comparativo entre as técnicas utilizadas nesse artigo.**

A inspeção visual desse gráfico revela que as previsões encontradas pela rede neural se aproximaram mais dos valores reais do que as previsões obtidas pela técnica de Box & Jenkins. Essa análise visual corrobora e sustenta a constatação do parágrafo anterior que afirma que as redes neurais encontraram melhores resultados do que a outra técnica utilizada para previsão de séries temporais climatológicas e hidrológicas.

#### 4. Conclusões

A modelagem baseada na metodologia de Box & Jenkins mostrou-se adequada para modelar o conjunto de dados utilizados nesse artigo, encontrando bons resultados de previsão. A análise de séries temporais sugerida por essa técnica permite identificar padrões de comportamento das observações, tais como tendências e sazonalidades. Através dessa análise foi possível identificar a presença da componente sazonal no conjunto de dados estudado neste artigo.

As redes neurais mostraram-se como uma ferramenta relevante para previsão de índices de vazão naturais, podendo ser estendida para outras séries climatológicas. Com essa metodologia não é possível fazer uma análise mais precisa da série temporal, objetivando obter mais informações sobre os dados. Porém, os resultados das previsões demonstraram que essa técnica pode ser usada como instrumento de apoio a decisão de sistemas hidrelétricos geradores de energia, com propósitos de simulação e/ou otimização da produção elétrica nacional.

Trabalhos futuros podem incluir a análise de diferentes técnicas de inteligência artificial para aprimorar os resultados encontrados neste artigo. Tais técnicas podem incluir lógica *neuro-fuzzy*, redes neurais construtivas, ou sistemas híbridos que trabalham com modelos estatísticos juntamente com modelos de inteligência artificial.

#### Referências

- Box, G. E. P. and Jenkins, G. M. (1976). Time series analysis forecasting and control, edição revisada, Holden-Day, São Francisco, EUA.
- Braga, A. P., Carvalho, A. P. L. F. and Ludemir, T. B. (2000). Redes Neurais Artificiais: Teorias e Aplicações, 2ª ed, Editora LTC, Rio de Janeiro.
- Das Águas, A. N. (2011). Sistema de Informação Hidrológica - HIDROWEB, Disponível em: <<http://hidroweb.ana.gov.br>>. Acesso em: 05 jan 2011, Brasil.
- Haykin, S. (1994). Neural Networks – A Comprehensive Foundation, 2ª ed, Macmilan College Publishing Company, Nova Iorque, EUA.
- Mine, M.; Tucci, C. E. M. (2002). Gerenciamento da produção de energia e controle de inundação: Foz do areia no rio Iguaçu, Revista Brasileira de Recursos Hídricos 7(3): 85-107.
- Morettin, P. A. and Toloi, C. M. C. (2006). Análise de Séries Temporais, 2ª ed, Editora Blucher, São Paulo.
- Scilab Consortium, I. and ENPC (2011). SciLab: The open source platform for numerical computation, Disponível em: <<http://www.scilab.org>>. Acesso em: 05 jan 2011, Gennoble, França.
- Team, R. D. C. (2011). R: A language and environment for statistical computing, Disponível em: <<http://www.r-project.org>>. Acesso em: 16 jan 2011, Viena, Áustria.
- Tucci, C. E. M. (2003). Flood flow forecasting, WMO Bulletin 52(1): 46-52.

