

MODELO DE PREVISÃO DE VAZÃO COM INFORMAÇÃO DE PRECIPITAÇÃO UTILIZANDO REDES NEURAIAS

Karla Figueiredo

DETEL/UERJ – Universidade do Estado do Rio de Janeiro
karlaf@uerj.br

**Carlos R. Hall Barbosa, André V. A. da Cruz, Marley M.B.R. Vellasco, Marco Aurélio C. Pacheco,
Roxana J. Contreras, Mônica Barros, Reinaldo Castro Souza,
Valdo da Siva Marques, Ulmar Manoel Duarte**

ICA/DEE- Pontifícia Universidade Católica do Rio de Janeiro

{ball, andrev, marley, marco, roxana, reinaldo, monica}@ele.puc-rio.br, valdo@lenep.uenf.br, ulmardu@yahoo.com.br

Marcos Huber Mendes

Decision Support Ltda
ds_marcos@genesis.puc-rio.br

RESUMO

Este trabalho apresenta modelos de previsão de vazão natural para a Bacia do Rio Iguaçu, incorporando informações de precipitação, baseados em redes neurais artificiais e métodos estatísticos. Há dois tipos de dados de precipitação disponíveis: medidas oriundas de postos pluviométricos distribuídos ao longo da bacia, e previsões de precipitação utilizando o modelo ETA do CPTEC em um horizonte de 10 dias. O modelo neural utiliza ainda medidas de vazão observada, fornecidas por postos fluviométricos existentes ao longo do Rio Iguaçu, e o histórico das séries de vazão natural que se deseja prever. Inicialmente, foram aplicados métodos de pré-processamento das diversas séries, seguidos por métodos de seleção das variáveis de entrada mais relevantes para o modelo de previsão. Este trabalho é um resumo do trabalho de modelagem de previsões de vazões naturais para a Bacia do Rio Iguaçu. O trabalho para esta Bacia envolveu modelos baseados em previsões estatísticas e de redes neurais artificiais. Os métodos estatísticos utilizados foram de análise multivariada com incorporação de informações hidrometeorológicas e de regressão dinâmica. Ao final do trabalho são apresentadas, junto com o resumo dos métodos estatísticos utilizados, as comparações dos resultados obtidos com os modelos estatísticos e os de redes neurais. Os resultados obtidos comprovam a viabilidade da utilização de métodos quantitativos (redes neurais artificiais e métodos estatísticos) neste problema, que é altamente não-linear e muito complexo, permitindo obter previsões com boa acurácia que podem ser utilizados no planejamento da operação hidroelétrica das bacias em questão.

Palabras-chave - Redes Neurais Artificiais, Análise Fatorial, Stepwise, Regressão Dinâmica, Previsão de Vazão

INTRODUÇÃO

O Operador Nacional do Sistema Elétrico (ONS) (ONS, 2006) tem como uma de suas responsabilidades elaborar a previsão de vazões naturais médias diárias, semanais e mensais, para todos os locais de aproveitamentos hidrelétricos do Sistema Interligado Nacional (SIN). Considerando a predominância significativa da geração hidroelétrica em nosso sistema de energia elétrica, a qualidade desta previsão de vazão natural apresenta-se como peça fundamental no planejamento e programação da operação do SIN.

A previsão de vazão num sistema hídrico é uma das técnicas utilizadas para minimizar o impacto das incertezas do clima sobre o gerenciamento dos recursos hídricos (Tucci et al., 2003a). A utilização das vazões previstas para a otimização da operação de reservatórios é sugerida por muitos autores (Hamlet et al., 2002), e alguns entendem

que o seu uso é preferível, embora com erros, a fazer o controle do reservatório sem previsões (Andreolli, 2003).

Os modelos matemáticos conceituais, teoricamente, possuem a vantagem de representar os fenômenos hidrológicos envolvidos, embora apresentem dificuldades com respeito à atualização contínua dos parâmetros para acompanhar evoluções em processo. Estes modelos possuem natureza determinística, mas operam dados parcialmente aleatórios. Dessa forma, seus resultados dificilmente coincidem com as observações (Andreolli, 2003).

Com objetivo de superar as deficiências dos modelos matemáticos, ocorreu um aumento do número de trabalhos que utilizam modelos baseados em redes neurais (Valença e Ludermir, 2000; Valença e Ludermir, 2001; Valença e Ludermir, 2002; Valença e Ludermir, 2004; Valença, 2005).

Mais recentemente, pode-se citar Valença et al. (2005a) que desenvolveu um modelo utilizando redes

neurais para previsão da vazão média mensal em um horizonte de longo prazo. Nesse trabalho, os resultados obtidos com as redes neurais foram comparados com modelos lineares como PARMA (*Periodic Auto Regressive Moving Average*). Os resultados obtidos com as redes neurais foram melhores do que os obtidos com o método PARMA.

Destacam-se também os avanços no tema de variabilidade climática e na previsão de tempo e clima, com a qualidade das previsões evoluindo a cada ano.

Andreolli (2003) em sua pesquisa teve por objetivo avaliar o ganho da previsão de vazão com o uso integrado de previsão de precipitação. Nessa pesquisa foram apresentados e discutidos diversos modelos do tipo vazão-vazão e chuva-vazão. Na literatura existem muitos modelos do tipo vazão-vazão (Tucci, 1998; Zamanillo, 1988). No caso desse tipo de modelo só são utilizadas variáveis relacionadas à vazão.

Os modelos de previsão chuva-vazão podem ser alimentados com chuva observada, ou com chuva prevista, para aumentar o horizonte de previsão. Se o modelo de previsão utiliza apenas chuva observada, a previsão de vazão fica limitada ao tempo de concentração da bacia. A introdução da chuva prevista no modelo pode trazer benefícios em termos de antecedência e redução do erro das vazões (Lettenmaier e Wood 1993; Andreolli, 2003).

Andreolli (2003) destaca que os modelos chuva-vazão apresentam diversas alternativas para estimativa da precipitação futura nos modelos de previsão de vazão, e essas alternativas são: a previsão de vazão com chuva zero; previsão de vazão com chuva observada (nesse caso a chuva observada é utilizada como chuva prevista); previsão de vazão com previsão quantitativa de chuva; e previsão de vazão com previsão estatística de chuva.

Para a hidrologia existe um pleno potencial de utilização dessas estimativas climáticas de chuvas para a previsão de vazões. Isso pode ser confirmado pelo número crescente de estudos de previsão de vazão em tempo real em que se introduz nos modelos de previsão hidrológica a previsão de chuva feita por modelos meteorológicos de meso escala (Damrath, et al., 2000; Ibbitt, et al., 2001; Jasper, et al., 2002; Anderson, et al., 2002; Koussis, et al., 2003; Tucci, et al., 2003b; Haas, et al., 2003).

Os modelos de previsão de vazão atualmente utilizados pelo ONS, em geral, são estocásticos e não consideram informações de precipitação. Contudo, nas últimas décadas, as diferentes tecnologias de modelagem de fenômenos naturais têm evoluído rapidamente, propiciando a oportunidade de se ampliar seus conhecimentos sobre a natureza e compreender seus processos físicos e biológicos.

Considerando estes avanços, o ONS busca desenvolver novos sistemas de previsão de vazão incluindo informações de precipitação, tanto observadas quanto previstas.

A exemplo disso tem-se um outro trabalho de Valença et al. (2005b) utilizando uma Rede Neural Construtiva para a previsão diária da vazão do rio Parnaíba. Este trabalho confirma a importância de entradas exógenas (chuva observada).

É nesse contexto que este trabalho se insere, empregando redes neurais artificiais para a criação de modelos de previsão de vazão, considerando a chuva observada e/ou prevista. É importante ressaltar que nos modelos em que se utiliza chuva prevista, está sendo utilizada a previsão de precipitação baseada no modelo ETA do CPTEC, ou seja, segundo a denominação apresentada por Andreolli (2003), é a previsão quantitativa de chuva.

Na próxima seção apresenta-se a bacia hidrográfica do Rio Iguaçu, que foi utilizada como caso de estudo nesse trabalho. Em seguida, descrevem-se os dados históricos disponíveis para treinamento das redes neurais. Prossegue-se apresentando os métodos de pré-processamento de dados e seleção de variáveis empregados.

Na seqüência, os modelos baseados em redes neurais para previsão de vazão, juntamente com os resultados obtidos, são detalhados. Em seguida, os resultados obtidos através dos modelos de redes neurais são comparados com os formecidos pelos modelos estatísticos investigados. Finalmente, a última seção apresenta as conclusões do trabalho e indica trabalhos futuros.

BACIA DO RIO IGUAÇU

A bacia do rio Iguaçu possui diversas usinas hidroelétricas (UHE) existentes ao longo desse rio, denominadas Foz do Areia, Segredo, Salto Santiago, Salto Osório e Salto Caxias (respectivamente, de leste para oeste). Nestas UHE há disponíveis postos fluviométricos responsáveis pelas medições de vazão. Há ainda na bacia diversos postos pluviométricos, que realizam as medições de precipitação. Esta bacia pode ser dividida em três grandes sub-bacias, delimitada pelas UHE de Foz do Areia e de Salto Santiago. Há, ainda, um reservatório a montante de Segredo, no afluente Jordão.

Neste trabalho, visando a atender às necessidades do ONS na elaboração do Programa Mensal de Operação (PMO), o objetivo foi obter modelos de previsão para três trechos distintos da bacia do Rio Iguaçu, a saber: Vazão natural afluente à UHE Foz do Areia, Vazão natural afluente ao reservatório Jordão e Vazão natural incremental entre a UHE Foz do Areia, reservatório Jordão e UHE Salto Osório.

Para cada série, deseja-se obter a previsão da vazão diária, para um horizonte de 12 dias, sempre iniciando às quartas-feiras, e também a previsão da vazão média semanal (média da previsão diária de 7 dias), considerando três “semanas elétricas” distintas: Sábado a sexta-feira (4° ao 10° dia); Domingo a sábado (5° ao 11° dia); e Segunda-feira a domingo (6° ao 12° dia).

As semanas elétricas podem ser definidas conforme a Figura 1. Os dias especificados com o índice 1

correspondem à semana elétrica que começa em um sábado e termina em uma sexta-feira; o índice 2 define a semana elétrica que vai do domingo até o sábado; e a semana elétrica definida pelo índice 3, retrata a semana elétrica que se inicia em uma segunda-feira e termina no domingo. O ponto de referência é a quarta-feira marcada em cinza mais escuro. As vazões das semanas elétricas são calculadas como a média dos valores das vazões correspondentes aos dias da semana considerados para cada uma das três semanas. A cada quarta-feira o processo se repete.

Q	Q	S	S	D	S	T	Q	Q	S	S	D

Figura 1. Semanas Elétricas.

DADOS HISTÓRICOS

Os dados históricos disponíveis para a construção dos modelos de previsão podem ser divididos em quatro grandes grupos, a saber:

- Precipitação diária observada, medida por 30 postos pluviométricos, em mm, com dados de 1922 a 2001;
- Vazão média diária observada, medida por 14 postos fluviométricos, em m^3s^{-1} , com dados de 1930 a 2001;
- Previsão de precipitação diária, gerada semanalmente pelo modelo ETA com horizonte de 10 dias, em uma grade com 40 km de resolução, em mm, com dados de 1996 a 2001; e
- Vazão natural (incremental ou não) média diária, correspondente à série que se deseja prever, em m^3s^{-1} com dados de 1931 a 2001.

Considerando que os dados de previsão de precipitação (ETA) estão disponíveis somente para o período de 1996 a 2001, restringiram-se todas as demais séries ao mesmo período, descartando-se o restante dos dados. Tem-se, portanto, uma base de dados contendo 6 anos de dados diários, sendo que o último ano disponível (2001) foi utilizado para teste dos modelos de previsão.

PRÉ-PROCESSAMENTO DE DADOS

Descreve-se a seguir o pré-processamento empregado nas diversas séries de dados históricos disponíveis.

PRECIPITAÇÃO OBSERVADA

Para o cálculo da precipitação média na área de drenagem correspondente a cada uma das estações pluviométricas, utilizou-se o método do Polígono de Thiessen (muito comumente empregado em hidrometeorologia) (Pinto, 1976), o qual atribui um fator de ponderação aos totais precipitados em cada pluviômetro proporcional à área de influência de cada um. As áreas de influência (pesos) são determinadas no mapa da bacia

contendo as estações, unindo-se os pontos adjacentes por linhas retas e, em seguida, traçando-se as mediatrizes dessas retas, formando polígonos. Os lados dos polígonos são os limites das áreas de influência de cada estação (Pinto, 1976) (Euclides et al., 1999). Assim, foi possível viabilizar a construção dos modelos de previsão a partir dos dados relativos aos 30 pluviômetros, consolidados em uma única série de precipitação observada para toda a bacia hidrográfica, e não apenas em pontos específicos da bacia dados pelos pluviômetros.

A figura 2 a seguir apresenta os polígonos de Thiessen obtidos para os pontos de medição disponíveis. As séries correspondentes aos diversos pluviômetros são então ponderadas pelas áreas relativas dos polígonos correspondentes. A figura 3 apresenta a série de Thiessen obtida.

Não foi necessário o uso de método para preenchimento de falhas nos dados pluviométricos, pois o método de Thiessen é baseado em uma média ponderada dos pluviômetros, cujo fator de ponderação, conforme mencionado anteriormente, é proporcional à área de influência de cada pluviômetro. Dessa forma, a falta de uma medida na série de algum pluviômetro é diluída na média sem causar prejuízos aos resultados. Ou seja, o valor do peso do pluviômetro faltante é considerado zero, não sendo considerado no cálculo da média ponderada. Já os pluviômetros que não apresentam falhas mantêm os pesos calculados pela área de influência e entram no cálculo da média de Thiessen normalmente.

Apesar de não ter sido usado o preenchimento de falhas, foi desenvolvida uma metodologia para esse preenchimento, caso o número de dados faltantes prejudicasse os resultados de previsão. O preenchimento de um dado faltante para um certo posto foi realizado através de uma média ponderada das medidas existentes em postos previamente selecionados. A escolha de quais postos eram os mais adequados para o preenchimento de falhas baseou-se em uma metodologia híbrida, que considera aspectos puramente matemáticos (correlação entre os postos) e geográficos (distância entre os postos e características fisiográficas da área em estudo, por exemplo, divisores de subacias).



Figura 2. Bacia hidrográfica do Rio Iguçu – Método de Thiessen.




Figura 3. Série consolidada de precipitação observada, calculada pelo Método de Thiessen

PRE
VIS

ÂO DE PRECIPITAÇÃO

Este caso é similar ao da precipitação observada, pois é necessário consolidar as séries de previsão, disponíveis para cada ponto da grade com resolução de 40 Km (figura 4), em uma única série, representativa de toda a bacia. A precipitação é baseada no modelo ETA do CPTEC.

A metodologia empregada para se calcular a chuva média prevista sobre a bacia teve como ponto de partida a avaliação dos pontos da grade de previsão que deveriam ser considerados nesse cálculo. A seleção desses pontos contou com a ajuda de um especialista na área de hidrologia e outro da área de meteorologia. Segundo a opinião desses especialistas, deveriam ser escolhidos os pontos localizados no interior da fronteira da bacia e alguns outros pontos muito próximos da mesma. O objetivo desta seleção é considerar os pontos de previsão de precipitação que estão relacionados às chuvas que alimentarão a vazão na bacia. A figura 4, a seguir, apresenta os 68 pontos selecionados (círculos maiores). Como todos os pontos correspondem a áreas geográficas de mesma dimensão, cada pluviômetro dentro da bacia tem o mesmo peso. Assim, a série consolidada pode ser obtida simplesmente calculando a média de todas as séries individuais.

VAZÃO OBSERVADA E VAZÃO NATURAL

No caso das séries de vazão observada, medidas por um conjunto de fluviômetros, e de vazão natural, aplicou-se simplesmente a transformação logarítmica, seguida por uma normalização linear dos dados com o objetivo de normalizar os valores da série de vazões, reduzindo sua variabilidade.




Figura 4. Pontos da grade de previsão ETA. Os pontos mais largos indicam os selecionados como pertencentes à Bacia

SELEÇÃO DE VARIÁVEIS

Mesmo após a consolidação obtida pelo pré-processamento, há ainda disponível um número muito grande de séries de vazão observada (medidas pelos fluviômetros) para construção dos modelos de previsão. Portanto, fez-se necessário aplicar métodos de seleção de variáveis, de modo a identificar os postos fluviométricos que têm maior relação com as séries de vazão que se deseja prever.

Inicialmente, foram calculadas as funções de correlação cruzada (Manual de Estatística, 2006) entre cada série fluviométrica e as séries de vazão, de modo a determinar o atraso (lag) entre as séries.

Em seguida, foi realizada uma pré-seleção dos postos que poderiam ter influência em cada um dos três trechos da Bacia do Rio Iguaçu, com base em critérios geográficos e hidrometeorológicos.

Finalmente, foram aplicados dois métodos de seleção de variáveis, chamados de LSE (Least Squares Estimator) (Cao e Rossiter, 1997) e SIE (Single Input Effectiveness) (Chung e Duan, 2000), combinando os resultados de ambos os métodos de forma heurística.

Assim, dos 12 postos fluviométricos da bacia (Fluviópolis, União da Vitória, Jangada, Madeira Gavazoni, Solais Novo, Santa Clara, Usina Cavernoso, Porto Palmeirinha, Balsa do Santana, Águas do Verê, Flor da Serra, Porto Santo Antônio), foram selecionados os seguintes postos: 4 postos para o trecho afluente à UHE Foz do Areia: Fluviópolis, União da Vitória, Jangada, Madeira Gavazoni; 1 posto para o trecho afluente ao reservatório Jordão: Santa Clara; e 7 postos para o trecho entre a UHE Foz do Areia, reservatório Jordão e UHE Salto Osório: Fluviópolis, União da Vitória, Jangada, Madeira Gavazoni, Solais Novo, Santa Clara e Usina Cavernoso.

MODELOS DE PREVISÃO DE VAZÃO

Uma vez pré-processados os dados históricos e selecionados os postos pluviométricos mais significativos para a obtenção de modelos de previsão, passou-se à construção, propriamente dita, dos modelos com base nas seguintes duas técnicas: Redes Neurais Artificiais Multi-layer Perceptron com treinamento por Levenberg-Marquardt (Haykin, 1998) – MLP-IM – e Redes Neurais Artificiais Multi-layer Perceptron com treinamento Bayesiano (Mackay, 1995) – MLP-BAY.

Foram testados diversos modelos com entradas multivariadas, cada um especializado em um dos 12 dias a serem previstos, no caso das previsões das médias diárias, e nos 3 tipos de semana elétrica, no caso das previsões das médias semanais.

MODELOS DE PREVISÃO DE VAZÃO DIÁRIA REDES NEURAS MLP-IM

O conjunto de dados compreendidos entre 1996 a 2000 foi utilizado para treinamento (sendo 80% treinamento e 20% para validação), e o conjunto de dados

relativos ao ano de 2001 foi usado para teste. O treinamento das redes foi feito utilizando validação cruzada, repetindo 30 vezes para cada topologia.

Foram utilizadas as seguintes entradas:

- precipitação média na bacia, calculada pelo método de Thiessen, dos últimos 7 dias (de quarta-feira a terça-feira da semana anterior);
- vazão média diária observada dos 7 últimos dias (de quarta-feira a terça-feira da semana anterior);
- precipitação prevista pelo modelo ETA para os próximos 10 dias;
- vazões medidas na terça-feira (anterior ao da previsão) pelos postos fluviométricos selecionados relativos a cada trecho (ver seção Seleção de Variáveis).

Cada topologia é definida pelo número de neurônios na camada escondida. Foram avaliadas diversas topologias, variando o número de neurônios na camada escondida no intervalo de 1 neurônio a 2 vezes o número de entradas + 5 neurônios, ou seja, para redes com 10 entradas, foram avaliadas topologias desde 1 neurônio na camada escondida até 25 neurônios.

REDES NEURAIS MLP-BAY

O conjunto de dados entre 1996 a 2000 foi utilizado para treinamento (as redes neurais bayesianas não precisam fazer validação cruzada e, portanto, os dados podem ser utilizados inteiramente para o treinamento), e o conjunto de dados relativos ao ano de 2001 foi usado para teste. Este procedimento é repetido 30 vezes para cada topologia. Isso permite escolher a rede que apresenta o melhor desempenho, dentre as 30 redes avaliadas para cada topologia.

A topologia também é definida pelo número de neurônios na camada escondida. Foram avaliadas topologias com número de neurônios na camada escondida variando de 1 a n neurônios, dependendo da sub-bacia analisada.

Foram testadas diferentes redes neurais artificiais com entradas multivariadas, cada uma especializada em cada um dos 12 dias a serem previstos, com até 67 entradas.

Para o caso das redes bayesianas, foram usados todos os postos fluviométricos da bacia, já que a rede bayesiana é capaz de selecionar quais são as variáveis de entrada mais relevantes para obter a melhor previsão (Barbosa, 2002). Assim, as variáveis de entrada deste modelo são as mesmas do modelo MLP-LM, exceto por este usar todos os postos fluviométricos.

MODELOS DE REDES NEURAIS PARA PREVISÃO DE VAZÃO SEMANAL - SÁBADO A SEXTA-FEIRA

A Tabela 1 apresenta as diferentes combinações de entradas para ambos os modelos de redes neurais, MLP-LM e MLP-BAY, conforme consta na primeira coluna dessa tabela. A segunda coluna faz referência às configurações das entradas; da 3ª até a 8ª colunas tem-se as variáveis de entrada da rede descritas abaixo:

- M1: 9 entradas para a previsão da Vazão Natural UHE Foz do Areia: 1 a 23 neurônios na camada escondida.
- M2: 5 entradas para a previsão da Vazão Natural Reservatório Jordão: 1 a 15 neurônios na camada escondida.
- M3: 13 entradas para a previsão da Vazão Natural Incremental entre a UHE Foz do Areia, Reservatório Jordão e UHE Salto Osório: 1 a 31 neurônios na camada escondida.
- M4: 24 entradas para a previsão da Vazão Natural UHE Foz do Areia.
- M5: 24 entradas para a previsão da Vazão Natural Reservatório Jordão.
- M6: 26 entradas para a previsão da Vazão Natural Incremental entre a UHE Foz do Areia, Reservatório Jordão e UHE Salto Osório.

MODELOS DE REDES NEURAIS MLP-LM PARA PREVISÃO DE VAZÃO SEMANAL - DOMINGO A SÁBADO

A Tabela 2 apresenta as diferentes combinações de entradas para o modelo MLP-LM; a segunda coluna faz referência à configuração das entradas, conforme abaixo:

- M1: 12 entradas para a previsão da Vazão Natural UHE Foz do Areia: 1 a 29 neurônios na camada escondida.
- M2: 7 entradas para a previsão da Vazão Natural Reservatório Jordão: 1 a 19 neurônios na camada escondida.
- M3: 15 entradas para a previsão da Vazão Natural Incremental entre a UHE Foz do Areia, Reservatório Jordão e UHE Salto Osório: 1 a 35 neurônios na camada escondida.

As redes Bayesianas apresentaram resultados inferiores aos obtidos pelas MLP-LM, obtendo erros maiores em todas as bacias para a semana elétrica de sábado a sexta-feira. Sendo assim, esta modelagem não foi utilizada para a previsão das semanas de domingo a sábado e de segunda-feira a domingo.

MODELOS DE REDES NEURAIS MLP PARA PREVISÃO DE VAZÃO SEMANAL - SEGUNDA-FEIRA A DOMINGO

A Tabela 3 apresenta as diferentes combinações de entradas para o modelo MLP-LM; a segunda coluna faz referência à configuração das entradas, conforme abaixo:

- M1: 12 entradas para a previsão da Vazão Natural UHE Foz do Areia: 1 a 29 neurônios na camada escondida.
- M2: 9 entradas para a previsão da Vazão Natural Reservatório Jordão: 1 a 23 neurônios na camada escondida.
- M3: 12 entradas para a previsão da Vazão Natural Incremental entre a UHE Foz do Areia, Reservatório Jordão e UHE Salto Osório: 1 a 29 neurônios na camada escondida.

RESULTADOS

Na Tabela 4 observam-se os resultados alcançados, no período de teste formado pelo ano de 2001, com a topologia que teve o melhor desempenho para cada dia de previsão *single-step* diária até 12 dias à frente, dentre as várias topologias avaliadas. Na primeira coluna dessa tabela estão os dias de previsão; nas demais colunas são apresentados os erros MAPE para os dois modelos de redes neurais para cada uma das sub-bacias: Foz do Areia, Jordão e Salto Osório. Em todos os testes de previsão diária ou semanal, o critério para escolha das melhores topologias não considerou apenas os erros (MAPE) apresentados, mas também topologias com menor número de neurônios.

O MAPE (equação 1) indica o valor médio do erro percentual das previsões sobre todo o conjunto de teste.

$$MAPE = \frac{\sum_{k=1}^N \left| \frac{a_k - y_k}{a_k} \right|}{N} \cdot 100 \quad \text{Eq. 1}$$

onde, N = número de previsões realizadas; a_k = saída desejada para a previsão índice “k”; y_k = saída prevista para a previsão índice “k”.

Na Tabela 5 pode-se observar o erro MAPE para os melhores modelos de previsão de vazão semanal (sábado a sexta), também para o período de teste formado pelo ano de 2001.

Na Tabela 6 podem ser observados os erros MAPE dos modelos de previsão de vazão semanal para as outras semanas, isto é, de domingo a sábado e de segunda-feira a domingo.. Nesses dois casos, foram avaliadas somente redes MLP-LM.

Como pode ser observado, os resultados obtidos para a previsão diária com o modelo Bayesiano foram, em muitos dias, bastante próximos aos obtidos pela rede MLP-LM. Prova disso é que para segundo, quarto e décimo dias de previsão de vazão natural na UHE de Foz do Areia, os resultados apresentados pelas redes Bayesianas têm erros MAPE menores.

Tabela 4- Erros MAPE para a previsão diária usando redes MLP-LM e MLP-Bayesiana

	Foz da Areia		Jordão		Salto Osório	
	MLP-LM	Bayes	MLP-LM	Bayes	MLP-LM	Bayes
1	3,96	4,00	7,60	8,48	10,46	10,34
2	8,55	7,77	11,90	13,03	17,19	19,64
3	11,34	12,12	14,96	14,07	23,68	26,38
4	17,18	16,97	16,99	14,68	24,29	27,94
5	20,77	21,45	25,43	19,24	30,59	33,30
6	23,51	24,73	26,86	24,17	33,25	42,09
7	25,86	26,78	28,02	26,62	36,22	49,28
8	27,40	28,45	28,38	29,63	38,36	48,63
9	27,56	28,77	28,22	30,03	38,16	46,42
10	29,53	28,68	26,77	26,84	39,60	42,60
11	29,49	31,47	25,04	25,16	34,33	40,01
12	34,54	35,08	27,94	31,24	37,87	42,86

Tabela 5- Erros MAPE para a previsão semanal de **sábado a sexta-feira** usando redes MLP-LM e MLP-Bayesiana

Sub-bacias	MLP-LM	MLP-Bayesiano
Foz do Areia	20,39	24,68
Jordão	22,71	24,14
Salto Osório	30,35	37,92

Tabela 6- Erros MAPE para a previsão semanal de usando redes MLP-LM

Sub-bacias	MLP-LM	
	domingo a sábado	segunda-feira a domingo
Foz do Areia	22,50	23,63
Jordão	22,19	23,76
Salto Osório	31,86	32,83

Como pode ser observado, os resultados obtidos para a previsão diária com o modelo Bayesiano foram, em muitos dias, bastante próximos aos obtidos pela rede MLP-LM. Prova disso é que para segundo, quarto e décimo dias de previsão de vazão natural na UHE de Foz do Areia, os resultados apresentados pelas redes Bayesianas têm erros MAPE menores.

Para a previsão de vazão natural no Reservatório de Jordão, o Bayesiano apresenta menores erros do terceiro ao sétimo dia.

Já para a previsão natural incremental entre a UHE Foz do Areia, Reservatório Jordão e UHE Salto Osório, o modelo MLP apresenta erro maior que o modelo Bayesiano somente no primeiro dia.

No entanto, por motivos de consistência computacional (não variar as metodologias ao longo dos 12 dias o modelo de previsão), a rede MLP-LM foi escolhida como o modelo que oferece a melhor previsão diária desta bacia.

As figuras de 5 a 7 apresentam os gráficos com os resultados para a previsão do primeiro dia para as sub-bacias, Foz do Areia, Jordão e Salto Osório, respectivamente.

Para a previsão semanal (Tabela 5) as redes Bayesianas apresentaram sistematicamente resultados com erro maior para todas as sub-bacias para a semana elétrica (sábado a sexta-feira).

As figuras de 8 a 10 apresentam os gráficos com os resultados para a previsão da semana elétrica (sábado a sexta-feira) para as sub-bacias, Foz do Areia, Jordão e Salto Osório, respectivamente.

As figuras de 11 a 13 exibem os gráficos com os resultados para a previsão da semana elétrica (domingo a sábado) para as sub-bacias, Foz do Areia, Jordão e Salto Osório, respectivamente. Nas figuras de 14 a 16 são exibidos os gráficos com os resultados para a previsão da semana elétrica (segunda-feira a domingo) para as sub-bacias, Foz do Areia, Jordão e Salto Osório, respectivamente. Nos gráficos das figuras de 5 a 16 podem ser identificados, além das previsões e erros, o valor máximo e mínimo dos valores previstos, para o ano de 2001.

COMPARAÇÃO DOS RESULTADOS COM MODELOS ESTATÍSTICOS

A pesquisa dos modelos estatísticos para previsão de vazões diárias e semanais da Bacia do Iguazu foi realizada em duas etapas:

Seleção do método: foram realizados testes para selecionar, entre os métodos de Função de Transferência e de Regressão Dinâmica, o método que apresentaria consistentemente uma melhor performance de ajuste e previsão.

Otimização da previsão no método selecionado: onde foi realizada uma intensa pesquisa de modelagem com objetivo de encontrar um modelo considerado como o melhor de previsão.

Os testes realizados apontaram para os modelos de regressão dinâmica como aqueles que apresentam consistentemente uma melhor performance para ajuste e previsão. A otimização dos modelos de Regressão Dinâmica e a seleção do melhor modelo de previsão foram realizadas considerando métricas de qualidade de ajuste e de qualidade de previsão e priorizando sempre os modelos com as seguintes características:

- Privilegiar a precisão na previsão em relação à precisão no ajuste.
- Evitar modelos com variáveis com defasagens de ordem alta ou variáveis auto-regressivas de ordem alta que não apresentassem explicação hidrometeorológica.
- Simplicidade na utilização das previsões demandadas

Para a seleção dos modelos foi utilizado um procedimento de análise dentro e fora da amostra. Isto significa que parte dos dados foi separada (neste caso os últimos 365 dias, ou últimas 52 semanas) para validar o poder de previsão dos modelos ajustados com os dados restantes.

O procedimento de análise fora da amostra utiliza os parâmetros estimados para os dados passados, e move a origem da previsão no período fora da amostra, obtendo previsões para cada nova origem.

A pesquisa de modelagem com objetivo de otimização da previsão por regressão dinâmica gerou variáveis explicativas, construídas a partir dos dados ETA, com o objetivo de: capturar o efeito de dependência geográfica e hidrometeorológica, a partir da determinação de grupos isoetais, formados por pontos da grade ETA, considerados homogêneos hidrometeorologicamente em relação à precipitação, área geográfica e defasagem da precipitação em relação à vazão da Bacia; e capturar o efeito de dependências temporais através do cômputo de médias dos pontos de grade ETA de diferentes “comprimentos” (número de dias).

Assim, além das variáveis fluviométricas, pluviométricas e dos pontos de grade da previsão ETA, uma coleção de variáveis explicativas foi obtida a partir dos pontos de grade ETA tomando-se médias de diferentes números de dias, de forma a tentar capturar uma possível

dependência temporal existente entre a série de vazões (variável dependente) e as séries de médias ETA.

Mais variáveis foram criadas em cada bacia, ao realizar-se uma análise isoetal, e ao computar as previsões pluviométricas através de médias de sub-regiões consideradas homogêneas em cada bacia, para tentar capturar as dependências geográficas e hidrometeorológicas entre as séries de vazões e os pontos ETA.

Realizou-se uma análise minuciosa dos mapas isoetais, traçando-se isoetas para identificar limites de faixas de precipitação. Em seguida, foram identificados, dentro de uma análise espacial e geográfica (declividade e sinuosidade dos cursos d'água, conformação das sub-bacias e distância dos pontos ETA aos reservatórios), grupos de pontos com a mesma defasagem para previsão da vazão, para cada faixa de precipitação identificada inicialmente.

Além das variáveis construídas através de médias de pontos ETA, também foram construídas, através do método estatístico de Análise Fatorial com método de Componentes Principais, variáveis que através de combinações lineares ortogonais foram dimensionadas para condensar até 90% da variabilidade das variáveis originais. Por último, uma análise de sazonalidade foi utilizada para gerar variáveis binárias, indicadores que especificam as variações sazonais das séries de vazões.

Este conjunto de variáveis, criadas com objetivo de apresentar para o método de modelagem estatística informações a respeito da estrutura hidrometeorológica do fenômeno de vazões, foi finalmente reduzido às variáveis utilizadas na modelagem pelo método *StepWise* (passo-a-passo) de seleção de variáveis.

Apresenta-se, a seguir, a comparação dos resultados dos melhores modelos estatísticos de regressão dinâmica com os melhores modelos de redes neurais artificiais para as previsões diárias e semanais da bacia do Iguazu.

As tabelas 7, 8, 9 e 10 apresentam a comparação dos resultados obtidos com o melhor modelo estatístico e com o melhor modelo obtido com as redes neurais. A tabela 7 apresenta os resultados das previsões diárias e as tabelas 8, 9 e 10 apresentam os resultados das previsões semanais, onde a semana de sábado a sexta-feira esta codificada como semana S1, a semana de domingo a sábado esta codificada como semana S2 e a semana de segunda-feira a domingo esta codificada como semana S3.

Tabela 7- Comparação dos Erros MAPE para as Previsões Diárias

	Foz da Areia		Jordão		Salto Osório	
	Estat	RN	Estat	RN	Estat	RN
1	9,7	3,96	17,3	7,60	22,9	10,46
2	9,7	8,55	17,3	11,90	22,8	17,19
3	19,4	11,34	25,1	14,96	35,4	23,68
4	19,4	17,18	25,0	16,99	35,2	24,29
5	26,4	20,77	28,0	25,43	41,4	30,59
6	26,3	23,51	27,9	26,86	41,2	33,25
7	32,7	25,86	30,1	28,02	44,8	36,22

8	32,5	27,40	30,0	28,38	44,5	38,36
9	37,8	27,56	31,1	28,22	47,2	38,16
10	37,7	29,53	31,0	26,77	46,9	39,60
11	41,8	29,49	33,0	25,04	49,4	34,33
12	41,8	34,54	33,0	27,94	49,2	37,87

Tabela 8- Comparação dos Erros MAPE para as Previsões Semanais-Iguaçu-Foz do Areia

Iguaçu – Foz do Areia MAPE (anual)	S1	S2	S3
Estatística	32,80	32,00	31,50
Redes Neurais	20,39	22,50	23,63

Tabela 9- Comparação dos Erros MAPE para as Previsões Semanais-Iguaçu-Jordão

Iguaçu – Jordão MAPE (anual)	S1	S2	S3
Estatística	30,30	28,40	27,70
Redes Neurais	22,71	22,19	23,76

Tabela 10- Comparação dos Erros MAPE para as Previsões Semanais-Iguaçu-Salto Osório

Iguaçu – Salto Osório MAPE (anual)	S1	S2	S3
Estatística	47,10	48,00	44,80
Redes Neurais	30,35	31,86	32,83

CONCLUSÕES

Os modelos apresentados deram um passo maior na pesquisa na área de previsão de vazão, ao explorar mais de um modelo de rede neural em diversas combinações de configurações de variáveis de entradas, buscando o melhor conjunto de variáveis de entrada que minimiza o erro da previsão das sub-bacias estudadas. Assim, foram avaliadas as redes MLP-LM e MLP-Bayesiana, considerando vazões naturais e incrementais históricas nos pontos de interesse, vazões diárias observadas em postos fluviométricos, chuva média diária observada na bacia, médias das chuvas médias diárias observadas na bacia, chuva prevista diária e média da chuva prevista.

De uma forma geral, sabe-se que, à medida que o horizonte de previsão aumenta, a capacidade preditiva de qualquer modelo se deteriora. Portanto, nos modelos diários é natural esperar que, para uma dada bacia, os erros médios percentuais de previsão (MAPE) aumentem à medida que o horizonte de previsão cresce. Logo, é de se esperar que o MAPE para o 10º dia, nos modelos diários, por exemplo, seja maior que o do 1º dia.

O melhor desempenho, tanto no modelo semanal como no modelo diário, foi para o modelo que utiliza Back Propagation (LM). A explicação para este fato é que a bacia do Iguaçu, por ser uma bacia com comportamento complexo, se adequa melhor a modelos de redes neurais (modelos não lineares), apresentando melhores resultados que os modelos estatísticos. Estes resultados comprovam os resultados obtidos por outros pesquisadores que

utilizaram redes neurais, e evidenciam a importância do uso de variáveis exógenas (chuva observada e prevista).

Pretende-se, como trabalhos futuros, realizar testes com modelos híbridos, neural-estatístico, com o objetivo de se obter previsões ainda mais precisas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ANDERSON, M. L.; CHEN, Z.-Q.; KAVVAS, M. L.; FELDMAN, A. (2002). Coupling HEC-HMS with atmospheric models for prediction of watershed runoff. *Journal of Hydrologic*, v. 7, n. 4, p. 312–318, jul-ago.
- ANDREOLLI, I. (2003). *Previsão de Vazão em Tempo Real no Rio Uruguai com Base na Previsão Meteorológica*, Tese de Mestrado, UFRGS.
- BARBOSA, C. H.; MELO, B.; VELLASCO, M. M. B. R.; PACHECO, M.; VASCONCELLOS, L.P. (2002). Inference of Distillation Column Products Quality using Bayesian Networks, In: *IEEE/INNS International Joint Conference on Neural Networks (IJCNN2002)*, World Congresso n Computational Intelligence (WCCI), CDROM, pp 86-91, Honolulu, Havaí, 12 a 17 de maio.
- CAO, Y. E ROSSITER, D. (1997). An Input Pre-screening Technique for control Structure Selection. *Computers Chem. Engng*. Vol 21, No 6, pp, 563-5369.
- COCHRANE, D.; ORCUTT, G. H.(1949). Application of Least Squares Regression to Relationships Containing Autocorrelated Error Terms. *Journal of the American Statistical Association*, 44, p. 32-61.
- CHUNG, FU-LAI E DUAN, JI-CHENG (2000). On Multistage Fuzzy Neural Network Modeling. *IEEE Transactions on Fuzzy Systems*. Vol 8, pp 125-816, Dec.
- HAYKIN S. (1998). *Neural Networks – A Comprehensive Foundation*, Macmillan College Publishing Company, Inc.
- DAMRATH, U; DOMS, G; FRUHWALD, D; HEISE, E; RICHTER, B; STEPELER, J. (2000). Operational quantitative precipitation forecasting at the German weather service. *Journal of Hydrologic*, n. 239, p. 260–285, set.
- EUCLYDES, H.P., SOUZA, E. F., FERREIRA, P. A. (1999) *RH 3.0 - Regionalização hidrológica: manual do programa*. Viçosa, MG: UFV/DEA; Brasília, DF: MMA; Belo Horizonte, MG: RURALMINAS, 149 p.
- HAAS, J; MINE, M. R. M; FERNANDES, C. V. S. (2003). Feasibility of Meteorological Rainfall Forecast to Improve Hydroplant Reservoir Inflows Forecasts In: *XI World Water Congress*, 5-9 Oct , Madrid, Spain.
- HAMLET, A; HUPPERT, D; LETTENMAIER, D. P. (2002). Economic value of long-lead streamflow forecast

- for Columbia river hydropower. *Journal of Water Resources Planning and Management*, Volume 128, Issue 2, pp. 91- 101, mar-abr.
- IBBITT, R. P; HENDERSON, R. D; COPELAND, J; WRATT, D. S. (2001). Simulating mountain runoff with meso-scale weather model rainfall estimates: a New Zealand experience. *Journal of Hydrology*, n. 239, p. 19-32, set.
- JASPER, K; GURTZ, J; LANG, H. (2002). Advanced flood forecasting in Alpine watersheds by coupling meteorological observations and forecast with a distributed hydrological model. *Journal of Hydrology*, n. 267, p. 40-52, set.
- KOUSSIS, A. D; LAGOUVARDOS, K; MAZI, K; KOTRONI, V; SITZMANN, D; LANG, J; ZAISS, H; BUZZI, A; MALGUZZI, P. (2003). Flood forecasts for urban basin with integrated hydro- meteorological model. *Journal of Hydrologic Engineering*, Volume 8, Issue 1, pp. 1-11, Jan/Fev.
- LETTENMAIER, D. P; WOOD, E. F. (1993). Hydrologic Forecasting. In: David R. Maidment. *Handbook of Hydrology*, ed., Editora: McGRAW – Hill.
- MACKAY, DAVID J.C. (1995), *Bayesian Non-Linear Modelling with Neural Networks*, Cavendish Laboratory, Cambridge, UK, [<http://wol.ra.phy.cam.ac.uk/is/papers/>]
- MANUAL DE ESTATÍSTICA (2006). http://www.bertolo.pro.br/AdminFin/StatFile/Manual_Estatistica.htm.
- ONS (2006). <http://www.ons.org.br/home/>
- PINTO, N. L. S. (1976). *Hidrologia Básica* ISBN: 85-212-0154-0.
- VALENÇA, M., LUDERMIR, T. (2000) Monthly streamflow forecasting using an Neural Fuzzy Network Model, In: International Join Conference on Neural Networks, Italy, Anais do International Join Conference on Neural Networks, Jul 31- Aug 4, Montréal, Canada.
- VALENÇA, M., LUDERMIR, T. (2001). Multivariate Modelling of Water Resources Time Series using Constructive Neural Networks, V Congresso Brasileiro de Redes Neurais, 2-5 Abril, Rio de Janeiro, Brazil.
- VALENÇA, M., LUDERMIR, T. (2002). NeuroInflow: The New Model to Forecast Average Monthly Inflow, VII Brazilian Symposium on Neural Networks (SBRN'02), pp 74, Recife, Brazil, Nov. 11-14,
- VALENÇA, M., LUDERMIR, T. (2004). A non-linear constructive neural network technique for updating of river flow forecasts, VIII Simpósio Brasileiro de Redes Neurais, São Luis, MA, 29 Set – 1 Out., Brasil.
- VALENÇA, M. (2005). *Aplicando Redes Neurais - Um Guia Completo*, Editora Livro Rápido – Elógica.
- VALENÇA, M., LUDERMIR, T. E VALENÇA, A. (2005a). “River Flow for Reservoir Management Through Neural Networks”, Fifth International Conference on Hybrid Intelligent Systems (HIS2005), ed. Nedjah, N., Mourelle, L., Vellasco, M., Abraham, A. E Köppen, M., IEEE Computer Society, 6-9 Nov, pp. Rio de Janeiro, Brazil.
- VALENÇA, M., LUDERMIR, T. E VALENÇA, A. (2005b). “Modeling of the rainfall-runoff relationship with artificial neural network”, Fifth International Conference on Hybrid Intelligent Systems (HIS2005), ed. Nedjah, N., Mourelle, L., Vellasco, M., Abraham, A. E Köppen, M., IEEE Computer Society, 6-9 Nov, pp. Rio de Janeiro, Brazil.
- TUCCI, C. E. M. (1998). *Modelos Hidrológicos*. 20 edição. Porto Alegre: Editora da UFRGS.
- TUCCI, C. E. M; COLLISCHONN, W; ANDREOLLI, I. (2003a) *Previsão de Vazões de Curto e Médio Prazo na Operação de Usinas Hidrelétricas*. Porto Alegre: UFRGS, Instituto de Pesquisa Hidráulicas, Universidade Federal do Rio Grande do Sul. Relatório Técnico, P&D e ANEEL.
- TUCCI, C. E. M; CLARKE, R. T; DIAS, P. L. S. DA; COLLISCHONN, W. (2003b). *Previsão de Vazão com Base na Previsão Climática*. Distrito Federal: Dupligráfica. Projeto BRA/00/029, capacitação do setor elétrico brasileiro em relação à mudança global do clima. Relatório de pesquisa.
- ZAMANILLO, E. A. (1988). *Previsão em Tempo Real em uma Hidrovia Controlada por Barragens*. Porto Alegre: UFRGS. Dissertação, (Mestrado em Recursos Hídricos e Saneamento Ambiental), Instituto de Pesquisas Hidráulicas Universidade Federal do Rio Grande do Sul.

ABSTRACT

This work presents forecasting models for the natural inflow in the Basin of Iguaçu River, incorporating rainfall information, based on artificial neural networks and statistical methods. Two types of rainfall data are available: measurements taken from stations distributed along the basin, and ten-days rainfall forecasts using the ETA model developed by CPTEC. The neural model also employs observed inflows measured by stations along the Iguaçu River and historical data of natural inflows to be predicted. Initially, we applied preprocessing methods to the various series, followed by variable selection methods to identify the most relevant variables for the forecast model. We also summarize inflow forecasting models for the Iguaçu basins based on multivariate analysis and dynamic regression techniques which incorporate hydrological information. The paper concludes with a summary of the statistical models developed and a com-

parison of results provided by neural network and statistical models. The results obtained demonstrate the feasibility of using quantitative methods (artificial neural networks and statistical methods) in this problem, yielding forecasts with good accuracy

that can be used in the planning of the hydroelectrical operation of the Basin.

Tabela 1- Configuração das variáveis de entrada

Modelo	Configurações de Entrada das Redes Neurais									
	Configuração	V _{3a}	Prev ETA ₁₀	Soma ETA ₁₀	VPF _{3a}	VM ₁	VM ₂	VM ₃	VDP	VDP2
MLP-LM	M1	X		X	X (4 postos)	X	X	X		
	M2	X		X	X (1 posto)	X	X			
	M3	X		X	X (7 postos)	X			X	
MLP-Bay	M4	X	X		X (12 postos)	X				
	M5	X	X		X (12 postos)	X				
	M6	X	X		X (12 postos)	X	X	X		

Legenda:

V_{3a}: vazão observada na 3ª feira;

Prev ETA₁₀: previsão de 10 dias de precipitações pelo modelo ETA (10 valores);

Soma ETA₁₀: soma dos 10 dias de precipitações previstas pelo modelo ETA;

VPF_{3a}: vazões medidas na terça-feira pelos postos fluviométricos;

VM₁: vazão média (observada) da semana anterior à semana em que é feita a previsão para a semana elétrica;

VM₂: vazão média (observadas) de 2 semanas anteriores à semana em que é feita a previsão para a semana elétrica;

VM₃: vazão média (observada) de 3 semanas anteriores à semana em que é feita a previsão para a semana elétrica;

VDP: vazões diárias previstas (usando os resultados obtidos com a previsão diária) de 4ª feira a 6ª feira (3 valores).

VDP2: vazões diárias previstas (usando os resultados obtidos com a previsão diária) de 4ª feira a domingo (5 valores).

Tabela 2- Configuração das variáveis de entrada

Modelo	Configurações de Entrada das Redes Neurais									
	Configuração	V _{3a}	Prev ETA ₁₀	Soma ETA ₁₀	VPF _{3a}	VM ₁	VM ₂	VM ₃	VDP	VDP2
MLP-LM	M1	X		X	X (4 postos)	X				X
	M2	X		X	X (1 posto)	X			X	
	M3	X		X	X (7 posto)	X	X	X	X	

Legenda: idem Tabela 1.

Tabela 3- Configuração das variáveis de entrada

Modelo	Configurações de Entrada das Redes Neurais									
	Configuração	V _{3a}	Prev ETA ₁₀	Soma ETA ₁₀	VPF _{3a}	VM ₁	VM ₂	VM ₃	VDP	VDP2
MLP-LM	M1	X		X	X (4 postos)	X	X	X	X	
	M2	X		X	X (1 posto)	X	X	X	X	
	M3	X		X	X (7 posto)				X	

Legenda: idem Tabela 1.




Figura 5. Previsão Diária (1º Dia) da Vazão Natural UHE Foz do Areia -2001 usando rede Back Propagation (LM) com 22 Neurônios; MAPE=3,96.




Figura 6. Previsão Diária (1º dia) da Vazão Natural Reservatório Jordão-2001 usando rede Back Propagation (LM) com 3 Neurônios; MAPE = 7,60




Figura 7. Previsão Diária (1º dia) da Vazão Natural Incremental entre a UHE Foz do Areia, Reservatório Jordão e UHE Salto Osório de Vazão Diária-2001 usando Redes Neurais Back-Propagation (LM) com 11 Neurônios; MAPE = 10,46




Figura 8. Previsão Semanal (sábado a sexta-feira) da Vazão Natural UHE Foz do Areia-2001 usando Redes Neurais Back-Propagation (LM) com 6 Neurônios; MAPE = 20,39




Figura 9. Previsão Semanal (sábado a sexta-feira) da Vazão Natural Reservatório Jordão -2001 usando Redes Neurais Back-Propagation (LM) com 4 Neurônios; MAPE = 22,71




Figura 10. Previsão Semanal (sábado a sexta-feira) da Vazão Natural Incremental entre a UHE Foz do Areia, Reservatório Jordão e UHE Salto Osório - 2001 usando Redes Neurais Back-Propagation (LM) com 12 Neurônios; MAPE = 30,35




Figura 11. Previsão Semanal (domingo a sábado) da Vazão Natural UHE Foz do Areia - 2001 usando Redes Neurais Back-Propagation (LM) com 13 Neurônios; MAPE = 22,50




Figura 12. Previsão Semanal (domingo a sábado) da Vazão Natural Reservatório Jordão-2001 usando Redes Neurais Back-Propagation (LM) com 6 Neurônios; MAPE = 22,19




Figura 13. Previsão Semanal (domingo a sábado) da Vazão Natural Incremental entre a UHE Foz do Areia, Reservatório Jordão e UHE Salto Osório - 2001 usando Redes Neurais Back-Propagation (LM) com 4 Neurônios; MAPE = 31,86




Figura 14. Previsão Semanal (segunda-feira a domingo) da Vazão Natural UHE Foz do Areia -2001 usando Redes Neurais Back-Propagation (LM) com 7 Neurônios; MAPE=23,63




Figura 15. Previsão Semanal (segunda-feira a domingo) da Vazão Natural Reservatório Jordão -2001 usando Redes Neurais Back-Propagation (LM) com 19 Neurônios; MAPE = 23,76




Figura 16. Previsão Semanal (segunda-feira a domingo) da Vazão Natural Incremental entre UHE Foz do Areia, Reservatório Jordão e UHE Salto Osório-2001 usando Redes Neurais Back-Propagation (LM) com 4 Neurônios; MAPE = 31,86