

# INFERÊNCIA BAYESIANA NO DESENVOLVIMENTO DE PREVISORES NEURAIS DE VAZÃO DIÁRIA UTILIZANDO INFORMAÇÕES DE PRECIPITAÇÃO

Caio Monteiro Leocádio, Vitor Hugo Ferreira

Departamento de Engenharia Elétrica, Universidade Federal Fluminense

Rua Passo da Pátria, 156, Bloco D, sala 509, São Domingos, Niterói, RJ, CEP 24210-240, Brasil

caioleocadio@gmail.com, vitor@v.muff.br

**Abstract** – This paper deals with Bayesian neural models applied to daily water inflow forecasting, including automatic algorithms for input selection, structure stabilization and complexity control. The available database includes water inflow and precipitation in a daily basis from Grande River basin, enabling tests of the applicability of the inclusion of precipitation information in the daily water inflow forecasting models in order to decrease the forecasting error of the developed neural models. Six forecasting strategies are compared, all of them using Bayesian neural models but different input space representation, including models that use only past water inflow information and models that combine precipitation and past values of the water inflows. The use of seasonal dummy variables in order to represent the dry, wet and transition periods of the year is also tested. The obtained results show the viability of the application of Bayesian neural models combining water inflows and precipitation as inputs for daily water inflow forecasting, with these models showing the best results for the test periods considered.

**Keywords** – daily water inflow forecasting, energy planning, neural networks, Bayesian inference applied to neural networks.

## 1 Introdução

O sistema elétrico brasileiro é composto por uma matriz energética bastante diversificada, que inclui desde geração hidrelétrica e térmica, quanto nuclear e eólica. Dentre essas fontes geradoras de energia as que mais se destacam são as hidroelétricas. Elas representam cerca de 67% da energia elétrica disponível para geração no país [1]. A geração de energia através de uma usina hidrelétrica depende diretamente da água disponível, ou especificamente, da vazão afluyente naquele ponto da bacia onde a unidade está instalada. Desta forma, o conhecimento do comportamento futuro das vazões afluentes é de vital importância para o planejamento da operação eletroenergética de sistemas elétricos de potência com parque gerador predominantemente hidráulico, como é o caso do Sistema Interligado Nacional (SIN).

Os modelos tradicionais de previsão de vazão utilizam formulações auto-regressivas para análise das séries de vazões naturais. Estes modelos são baseados nas informações históricas de vazão dos rios em diferentes postos fluviométricos e de séries de vazões afluentes aos reservatórios das usinas hidrelétricas. Contudo, os mesmos não utilizam informações exógenas, como as previsões de precipitação nos locais de aproveitamento hidrelétrico. Dentre os modelos mais empregados no setor elétrico brasileiro estão aqueles baseados em modelos estocásticos. Porém, devido ao comportamento cíclico dos períodos secos e úmidos, as séries temporais de vazão possuem características não estacionárias, o que torna os erros de previsão altos se comparados com os erros de previsão de carga, por exemplo.

A utilização de redes neurais artificiais (RNAs) vem ganhando destaque nos últimos anos por sua comprovada facilidade de aproximar com boa precisão qualquer função contínua, devido ao seu alto grau de flexibilidade e robustez. No caso do problema de previsão de múltiplas séries de vazões, as redes neurais vêm mostrando sucesso em problemas complexos com diversas variáveis e envolvendo uma base de dados de cardinalidade elevada. Contudo, na presença de dados ruidosos, a capacidade de aproximação universal dos modelos neurais [2] permite que, além da função geradora dos dados, o ruído presente na amostra em particular seja modelado pela rede, comprometendo a capacidade de generalização do modelo desenvolvido. O controle de complexidade ou regularização de modelos neurais visa adequar o nível de não-linearidade disponibilizado pela estrutura à regularidade apresentada pelos dados, evitando a modelagem desnecessária do ruído e a consequente redução da capacidade de generalização do modelo.

Na literatura de previsão de vazões naturais, foco principal deste trabalho, os estudos realizados utilizando redes neurais não apresentam metodologias sistemáticas para o tratamento do controle de complexidade do modelo [3], [4], [5]. Por outro lado, existem na literatura de previsão de séries temporais metodologias automáticas e acopladas para regularização de modelos neurais, incluindo técnicas analíticas para seleção de entradas e definição de estrutura [6], [7], desenvolvidas originalmente para previsão de carga e com resultados satisfatórios também para previsão de vazão mensal [8]. Estudos recentes ainda mostram que a introdução de informações de precipitação como entradas exógenas nos modelos de previsão de vazão podem contribuir para a diminuição dos erros de previsão [9]-[11], se comparados aos modelos clássicos que se utilizam apenas vazões observadas.

Visando melhorar a qualidade das previsões de vazão média diária, neste trabalho foram pesquisadas diversas estratégias de previsão utilizando modelos neurais, desde modelos considerando como entradas somente dados de vazão até

modelos com entradas incluindo dados de vazão, precipitação e informações sazonais para representação do período do ano. O objetivo é avaliar a aplicabilidade de informações de precipitação nos modelos de previsão de vazão diária e identificar o melhor modelo de previsão utilizando os modelos neurais autônomos bayesianos propostos em [6], [7] para previsão de carga em curto prazo, baseados na inferência bayesiana aplicada à especificação e treinamento de perceptrons de múltiplas camadas (*multilayered perceptron* – MLP).

## 2 A previsão de vazão no contexto brasileiro

Dentre os diversos processos de planejamento e programação da operação eletroenergética do SIN, pode ser destacado como um dos principais estudos do Operador Nacional do Sistema Elétrico (ONS) o Programa Mensal de Operação (PMO), que representa a referência técnica mensal para definição das metas de geração de todas as unidades geradoras que integram o SIN [12]. Para a elaboração do PMO e suas revisões, um dos principais insumos é a previsão de vazão semanal para todos os locais de aproveitamentos hidrelétricos. A cada revisão, as previsões de vazão para todas as semanas remanescentes passam por um procedimento de revisão e atualização. A previsão das vazões afluentes aos reservatórios do SIN é uma atividade fundamental em função da necessidade de informações para o processo de otimização do despacho centralizado do sistema elétrico. Estas são obtidas com a participação dos agentes de geração responsáveis por essas instalações, para dois horizontes temporais: de curtíssimo prazo, até 12 dias, com discretização em valores médios diários, para fins de programação diária; e de curto prazo, até seis semanas, por meio de valores médios semanais, para o planejamento de curto prazo da operação eletroenergética.

Os modelos hidrológicos atualmente utilizados realizam previsões apenas com base nas vazões históricas verificadas. Dois modelos de previsão de vazão são comumente utilizados pelas empresas de geração e pelo ONS para realizar as previsões. O PREVIVAZH é um modelo de previsão de vazões em base diária, para um horizonte de até 14 (quatorze) dias à frente, baseado na desagregação da previsão semanal a partir da tendência inferida das últimas vazões passadas e de séries sintéticas diárias de vazões naturais de forma ponderada [12]. O PREVIVAZ constitui-se num modelo estocástico univariado de previsão de vazões em base semanal, para um horizonte de até 6 (seis) semanas à frente [12]. Ambos utilizam modelos lineares do tipo PARMA (p,q), acoplados a diferentes pré-transformações das séries históricas, tipo Box-Cox ou logarítmicas e a diferentes formas de estimação de parâmetros dos modelos. A análise de desempenho disponível destes modelos, ao longo dos últimos anos, mostra que, para a previsão de vazões médias semanais (uma semana à frente), os erros médios absolutos percentuais variam de 12% a 68%, para o período de 1997 a 2004 [13].

Com o objetivo de superar as deficiências dos modelos matemáticos de previsão de vazão, pode-se registrar um aumento significativo nos últimos anos do número de trabalhos que utilizam modelos baseados em redes neurais [3], [4], [5], [7] e do número de trabalhos que agregam, à filosofia de redes neurais, o histórico de vazões e informações de chuvas (observadas e previstas) nos locais dos aproveitamentos [10], [11], [13], [14]. As Redes Neurais Artificiais (RNAs) são uma das técnicas de aprendizado de máquina de maior sucesso e com estrutura matemática flexível, capaz de identificar relações não-lineares complexas entre entrada e saída, sem a necessidade de entendimento dos fenômenos naturais. Quando existem relações não-lineares e incertezas entre muitos parâmetros na modelagem de previsão de vazão, a calibração de modelos conceituais ou físicos é freqüentemente um procedimento complicado e que consome muito tempo e esforço computacional. O uso de um modelo heurístico do tipo caixa-preta, como por exemplo, as Redes Neurais Artificiais, tornou-se uma boa alternativa para o tratamento deste problema. Como motivação para o uso neste trabalho de Redes Neurais Artificiais pode-se destacar, dentre os estudos realizados por [3], [4], [5], [8], [10], [11], [13], [14], onde modelos baseados em Redes Neurais foram superiores aos modelos tradicionais de Regressão Múltipla e modelos lineares de séries temporais usando metodologia de Box e Jenkins.

A possibilidade de introdução de informações de precipitação na previsão de vazões vem ganhando destaque nos estudos sobre o tema nos últimos anos [9], [10], [11], [13]. A previsão da vazão com base na precipitação observada permite estender o horizonte da previsão, ou melhorar a qualidade da previsão dentro de um determinado horizonte, considerando que existe um tempo de deslocamento da água entre a ocorrência da precipitação e a vazão na seção de interesse. Neste caso, o máximo que se pode obter de antecedência está limitado pelo tempo de concentração da bacia. A inclusão de previsões de precipitação num modelo de previsão pode permitir estender o horizonte da previsão para além do tempo de concentração, e melhorar a qualidade da previsão dentro de horizontes determinados, o que vai depender, fundamentalmente, da qualidade das previsões de precipitação. Esses resultados são importantes tendo em vista que erros pequenos na previsão de precipitação geralmente geram pequenos ruídos nas previsões de vazão. O objetivo deste estudo envolve o desenvolvimento de modelos neurais que utilizem as informações de precipitação observadas visando a melhoria das previsões de vazão sete dias à frente e, conseqüentemente, compará-los com modelos que utilizam apenas vazões observadas como entradas.

## 3 Inferência Bayesiana Aplicada a MLP's

Os modelos neurais utilizados neste trabalho derivam dos modelos neurais autônomos bayesianos propostos em [6] para previsão de carga em curto prazo, modelos estes baseados na inferência bayesiana aplicada à especificação e treinamento

de MLPs. A metodologia em questão também foi aplicada ao problema da previsão de vazões médias mensais obtendo resultados satisfatórios [8].

Seja  $\underline{x} \in \mathbb{R}^n$  o vetor contendo os sinais de entrada e  $\underline{w} \in \mathbb{R}^M$  o vetor com todos os pesos e bias da RNA, sendo  $M = nm + 2m + 1$ , com  $m$  respondendo pelo número de neurônios na camada oculta. Os bias dos neurônios sigmoidais da camada oculta são representados por  $b_k$ , com  $b$  sendo o bias do neurônio linear da saída, dada por:

$$f(\underline{x}, \underline{w}) = \sum_{k=1}^m \left[ w_k \varphi \left( a_k \sum_{i=1}^n (w_{ik} x_i) + b_k \right) \right] + b \quad (1)$$

Dado um conjunto  $U = \{\underline{X}, \underline{Y}\}$  contendo  $N$  pares entrada/saída,  $\underline{X} \in \mathbb{R}^n \times \mathbb{R}^n$ ,  $\underline{X} = [x'_1, x'_2, \dots, x'_N]$ ,  $\underline{Y} \in \mathbb{R}^N$ ,  $\underline{Y} = [d_1, d_2, \dots, d_N]^T$ ,  $d_j \in \mathbb{R}$  sendo a saída desejada, o objetivo do treinamento de RNAs sob a ótica bayesiana reside na estimação do vetor  $\underline{w}$  que maximize a probabilidade a posteriori dada por:

$$p(\underline{w} | \underline{Y}, \underline{X}) = \frac{p(\underline{Y} | \underline{X}, \underline{w}) p(\underline{w})}{p(\underline{Y} | \underline{X})} \quad (2)$$

Na equação (2),  $p(\underline{Y} | \underline{X}, \underline{w})$  é a verossimilhança de  $\underline{Y}$ ,  $p(\underline{w})$  a probabilidade a priori de  $\underline{w}$  e  $p(\underline{Y} | \underline{X}) = \int p(\underline{Y} | \underline{X}, \underline{w}) p(\underline{w}) d\underline{w}$ . Assumindo que  $\underline{w}$  possui uma distribuição gaussiana com vetor média nulo e matriz de covariância diagonal igual a  $\alpha^{-1} \underline{I}$ ,  $\underline{I}$  igual à matriz identidade de dimensão  $M \times M$ , e que as saídas desejadas estão corrompidas com ruído branco gaussiano com variância  $\beta^{-1}$ , ou seja,  $d_j = f(x_j, \underline{w}) + \zeta_j$ , a aplicação da equação (2) resulta em:

$$p(\underline{w} | \underline{Y}) = \frac{e^{[-S(\underline{w})]}}{\int e^{-S(\underline{w})} d\underline{w}} \quad (3)$$

onde

$$S(\underline{w}) = \frac{\beta}{2} \sum_{j=1}^N [d_j - f(x_j, \underline{w})]^2 + \frac{\alpha}{2} \sum_{l=1}^M w_l^2 \quad (4)$$

Portanto, maximizar a probabilidade a posteriori  $p(\underline{w} | \underline{Y})$  é equivalente a minimizar  $S(\underline{w})$ .

Para problemas multivariados, a utilização de um único  $\alpha$  para todos os pesos não é recomendável. Neste trabalho, os pesos que ligam cada entrada aos neurônios da camada oculta são agrupados, com cada grupo possuindo o seu respectivo  $\alpha_i$ . A mesma idéia é aplicada aos demais pesos, sendo agrupados os bias dos neurônios da camada oculta, os pesos que ligam a camada oculta à saída e o bias do neurônio de saída, totalizando  $n+3$  grupos. Neste caso,  $S(\underline{w})$  passa a ser dado por:

$$S(\underline{w}) = \frac{\beta}{2} \sum_{j=1}^N [d_j - f(x_j, \underline{w})]^2 + \frac{1}{2} \sum_{i=1}^{n+3} \alpha_i \sum_{l=1}^M w_{il}^2 \quad (5)$$

A magnitude dos  $\alpha_i$ 's relacionados às entradas pode ser utilizada para mensuração da relevância de cada sinal. A inserção de variáveis de prova proposta em [6] é utilizada neste trabalho para definição empírica de limiares de relevância. Ao utilizar o próprio modelo na seleção das entradas, a metodologia utilizada neste trabalho pode ser inserida no grupo de técnicas encapsuladas [15].

A inferência bayesiana também pode ser utilizada para seleção da melhor estrutura dentre uma série de hipóteses  $H = \{H_1, H_2, \dots, H_K\}$ , com o conjunto de variáveis relevantes para cada hipótese previamente selecionada. Supondo que todas as hipóteses sejam equiprováveis e utilizando uma aproximação gaussiana em torno dos hiperparâmetros estimados, o logaritmo da evidência para os modelos  $\ln p(\underline{Y} | H_h)$  pode ser obtido pela expressão [2]:

$$\ln p(\underline{Y}|\underline{H}_h) = -S(\underline{w}) - \frac{1}{2} \ln |\nabla \nabla S(\underline{w})| + \frac{1}{2} \sum_{i=1}^{n+3} M_i \alpha_i + \ln \left( \beta^{\frac{N}{2}} m^2 m! \right) + \frac{1}{2} \sum_{i=1}^{n+3} \ln \left( \frac{2}{\gamma_i} \right) + \frac{1}{2} \ln \left( \frac{2}{N-\gamma} \right) \quad (6)$$

Na equação (6),  $\nabla \nabla S(\underline{w})$  representa a matriz hessiana de  $S(\underline{w})$ ,  $M_i$  representa o número de pesos incluídos no subgrupo  $i$ ,  $\gamma_i$  o número de parâmetros efetivos estimados para o grupo  $i$  e  $\gamma$  o número total de parâmetros efetivos. Os hiperparâmetros  $\gamma_i$  e  $\gamma$  são calculados ao longo do processo de treinamento, conforme será apresentado a seguir.

O princípio de maximização da evidência, aplicado aos parâmetros  $\underline{w}$  dando origem ao funcional  $S(\underline{w})$  a ser minimizado para estimação de  $\underline{w}$  e aplicado às hipóteses  $H = \{H_1, H_2, \dots, H_K\}$  para cálculo de  $\ln p(\underline{Y}|\underline{H}_h)$ , também é aplicado aos hiperparâmetros  $\alpha_i$  e  $\beta$  dando origem a um algoritmo iterativo para estimação destes hiperparâmetros. Os valores estimados de  $\alpha_i$  e  $\beta$  obtidos ao final deste algoritmo, juntamente com  $\gamma_i$  e  $\gamma$ , são utilizados na equação (6) para o cálculo de  $\ln p(\underline{Y}|\underline{H}_h)$ . Em linhas gerais, a inferência bayesiana baseada na maximização da evidência aplicada ao desenvolvimento de MLPs pode ser resumida pelo seguinte algoritmo:

Passo 1. Especifique o número mínimo ( $N_{\min}$ ) e o número máximo ( $N_{\max}$ ) de neurônios na camada escondida a faça o número de neurônios  $m = N_{\min}$ . Neste trabalho,  $N_{\min} = 1$  e  $N_{\max} = 10$ .

Passo 2. Adicione variáveis de prova [6] ao vetor  $n$ -dimensional de entradas. Se variáveis binárias forem utilizadas, o conjunto de entrada passará a conter  $(n+2)$  entradas. Caso somente entradas contínuas forem utilizadas, existirão  $(n+1)$  entradas.

Passo 3. Faça  $l = 0$  e inicialize  $\underline{w}(l) = [w_1(l), \dots, w_{n+3}(l)]^T$ ,  $\underline{\alpha}(l) = [\alpha_1(l), \dots, \alpha_{n+3}(l)]^T$  e  $\beta(l)$ .

Passo 4. Utilizando retropropagação do erro, minimize  $S(\underline{w})$  (Eq. (5)) sobre  $\underline{w}(l)$  para obtenção de  $\underline{w}(l+1)$ .

Passo 5. Calcule  $\alpha_i(l+1)$ ,  $\beta(l+1)$  e  $\gamma_i(l+1)$  utilizando as seguintes expressões:

$$\nabla \nabla S(\underline{w}) = \beta(l) \nabla \nabla E_s(\underline{w}, U) + \alpha(l) \underline{I} \quad (7)$$

$$\underline{B}_i(l+1) = [\nabla \nabla S(\underline{w})]^{-1} \underline{I}_i \quad (8)$$

$$\gamma_i(l+1) = M_i - \text{trace}\{\underline{B}_i(l+1)\} \quad (9)$$

$$\alpha_i(l+1) = \gamma_i(l+1) / \|\underline{w}_i(l+1)\|^2 \quad (10)$$

$$\beta(l+1) = N - \sum_{i=1}^{n+3} \gamma_i(l+1) / \sum_{j=1}^N [d_j - f(x_j, \underline{w})]^2 \quad (11)$$

Passo 6. Faça  $l = l+1$  e retorne ao passo 4 até a convergência. Após a convergência, vá para o próximo passo.

Passo 7. Separe em dois subconjuntos os hiperparâmetros  $\alpha_i$ 's relacionados com entradas contínuas e os hiperparâmetros  $\alpha_j$ 's relacionados com entradas binárias.

Passo 8. Para cada lista, selecione as entradas com  $\alpha_i < \alpha_{ref}$ , onde  $\alpha_{ref}$  representa o hiperparâmetro associado com a variável de prova.

Passo 9. Repita os passos 4 a 6 utilizando somente as entradas selecionadas no passo 8, com  $n$  responde pelo número de entradas selecionadas, para obtenção do modelo treinado  $H_m$ .

Passo 10. Calcule o logaritmo da evidência para as hipóteses (número de neurônios na camada oculta)  $H_m$  usando Eq. (6).

Passo 11. Se  $m = N_{\max}$ , vá para o passo 12. Do contrário, faça  $m = m+1$  e retorne ao passo 2.

Passo 12. Selecione a hipótese  $H_k$  com maior evidência  $\ln p(\underline{Y}|\underline{H}_h)$  para realização das previsões.

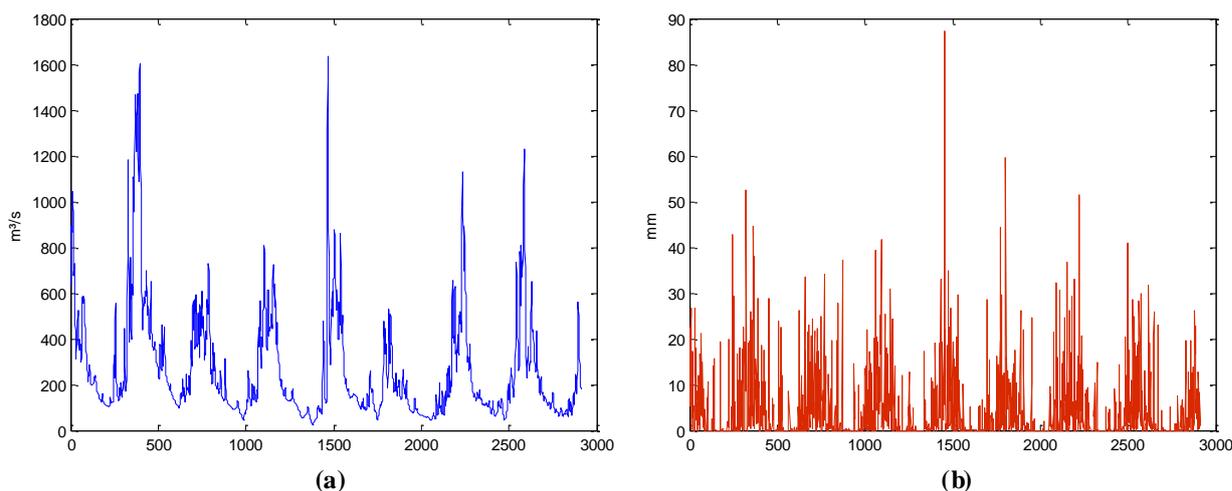
In Eq. (8),  $\underline{I}_i$  representa uma matriz nula  $M \times M$  com elementos na sua diagonal principal iguais a um somente para as posições referentes aos pesos incluídos no  $i$ -ésimo grupo de pesos. A matriz hessiana  $\nabla \nabla S(\underline{w})$  pode ser calculada utilizando um algoritmo semelhante à retropropagação do erro conforme apresentado em [2].

## 4 Resultados

Neste trabalho foram utilizados os dados de vazões provenientes da Bacia do Rio Grande, mais especificamente as vazões naturais registradas nas estações fluviométricas em torno da UHE de Furnas. Em sua composição estão presentes 23 postos pluviométricos, onde foram registradas as chuvas verificadas na região no período de estudo.

Os dados disponíveis para o treinamento e teste dos modelos podem ser divididos inicialmente em 2 grupos:

- Vazões médias diárias verificadas no período de janeiro de 1995 a dezembro de 2007 na UHE Furnas;
- Média das precipitações diárias verificadas, observadas nos 23 postos pluviométricos distribuídos pela bacia. Os dados disponíveis são de janeiro de 1996 a dezembro de 2003.



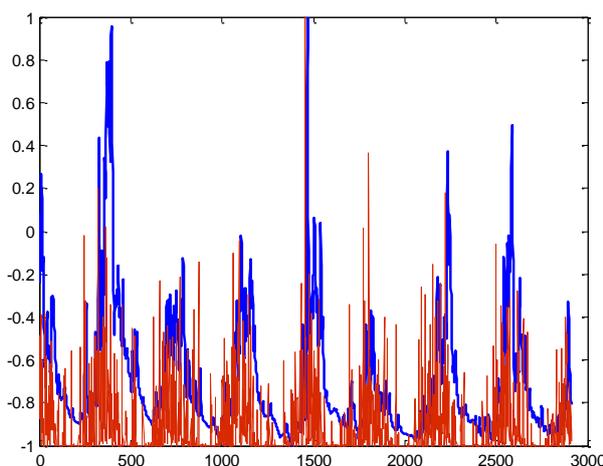
**Figura 1** - vazão observada (a) e precipitação observada (b)

Considerando que os dados disponíveis de precipitação observada são menores que os de vazões, para treinamento e teste dos modelos desenvolvidos foram utilizados apenas dados compreendidos no período de janeiro de 1996 a dezembro de 2003, totalizando oito anos disponíveis para estudo. Esta Figura evidencia também o comportamento sazonal existentes nas duas séries relacionado com as estações do ano. Este comportamento caracteriza quatro períodos, a saber: período úmido, correspondendo ao período de novembro a março; período de transição úmido-seco, relacionado com os meses de abril a maio; período seco, representando os meses de junho a agosto; e período de transição seco-úmido, correspondendo aos meses de setembro a outubro. Estes períodos serão representados nas entradas dos modelos neurais utilizando representação 1 de  $k$ .

Com o objetivo de contribuir para as pesquisas de previsão de vazões diárias no âmbito do SIN e satisfazer a necessidade de melhoria das previsões para o planejamento energético brasileiro, os modelos desenvolvidos neste trabalho geram previsões para um horizonte de uma semana, ou seja, sete dias à frente, utilizando recursão, ou seja, a vazão prevista  $v(n)$  é apresentada na entrada do modelo para que seja realizada a previsão de  $v(n+1)$ , e assim sucessivamente. Foram testados seis modelos neurais com entradas multivariadas, com todos realizando previsões para um horizonte de uma semana. Desta forma, os modelos são avaliados considerando previsões sete passos à frente. Todos os modelos desenvolvidos utilizaram oito conjuntos diferentes de treinamento e teste contidos entre os anos de 1996 e 2003. Cada conjunto se caracterizava pela divisão dos dados em sete anos para treinamento e um ano para teste, sendo este último alternado entre cada ano, com os anos restantes utilizados para treinamento, formando assim os oito conjuntos. Essa técnica foi utilizada para evitar que as conclusões acerca da melhor estratégia de previsão fossem restritas a um ano em particular, i.e., conjunto de teste considerando um ano muito chuvoso ou muito seco. A figura 2 evidencia a correlação existente entre os dados de vazões observadas e as informações de precipitação da mesma bacia no período entre janeiro de 1996 e dezembro de 2003, após a normalização dos dados. Esta relação demonstra que a introdução das precipitações verificadas como variáveis exógenas nos modelos de previsão de vazão podem contribuir para uma diminuição dos erros de previsão.

Além da possível introdução destas duas componentes relacionadas, são testadas a introdução de 4 variáveis binárias para representação 1 de  $n$  dos períodos seco, úmido e transição. Exemplificando, para previsão contida entre os meses de novembro e março, correspondente ao período úmido, somente a primeira binária é ativada, com as demais feitas iguais a zero. Analogamente, para o intervalo entre os meses de setembro e outubro, relativo ao período de transição seco-úmido, as três primeiras binárias estão desativadas (nulas), com a última binária sendo feita igual a 1.

Tendo como objetivo a previsão da vazão média diária para o próximo dia ( $n$ ), os modelos de previsão de vazão diária testados possuem configurações com as seguintes entradas:



**Figura 2** - correlação entre vazão e precipitação observada no período entre 1996 e 2003

### Modelos Vazão - Vazão

- *Modelo 7 últ. vazões*: vazão média diária observada dos 7 últimos dias;
- *Modelo 7 últ. vazões + bin* : vazão média diária observada dos 7 últimos dias e 4 variáveis binárias para codificação 1 de  $k$  do período do ano ;

### Modelos Chuva/Vazão - Vazão

- *Modelo últ. vazão + chuva prev.* : vazão média diária observada do último dia, precipitação prevista para o dia a ser previsto ( $n$ ) e 4 variáveis binárias para codificação 1 de  $k$ ;
- *Modelo últ. vazão + 3 chuvas( $n-1, n, n+1$ )* – vazão média diária observada do último dia ( $n - 1$ ), precipitação observada do último dia ( $n - 1$ ), precipitação prevista para os próximos 2 dias ( $n$  e ( $n + 1$ )) e 4 variáveis binárias para codificação 1 de  $k$ ;
- *Modelo 7 últ. vazões + chuva prev.*– vazão média diária observada dos 7 últimos dias, precipitação prevista para o dia a ser previsto ( $n$ ) e 4 variáveis binárias para codificação 1 de  $n$ ;
- *Modelo 7 últ. vazões + 3 chuvas( $n-1, n, n+1$ )* – vazão média diária observada dos 7 últimos dias, precipitação observada do último dia ( $n - 1$ ), precipitação prevista para os próximos 2 dias ( $n$  e ( $n + 1$ )) e 4 variáveis binárias para codificação 1 de  $k$ ;

Para que o efeito da inserção das informações de precipitação na acurácia das previsões de vazão fosse identificado de forma mais clara, foram utilizados somente dados verificados de precipitação, tanto no que se refere à precipitação observada quanto na precipitação prevista. Esta avaliação prévia permite observar se estes dados previstos contribuem efetivamente para a diminuição dos erros de previsão de vazão.

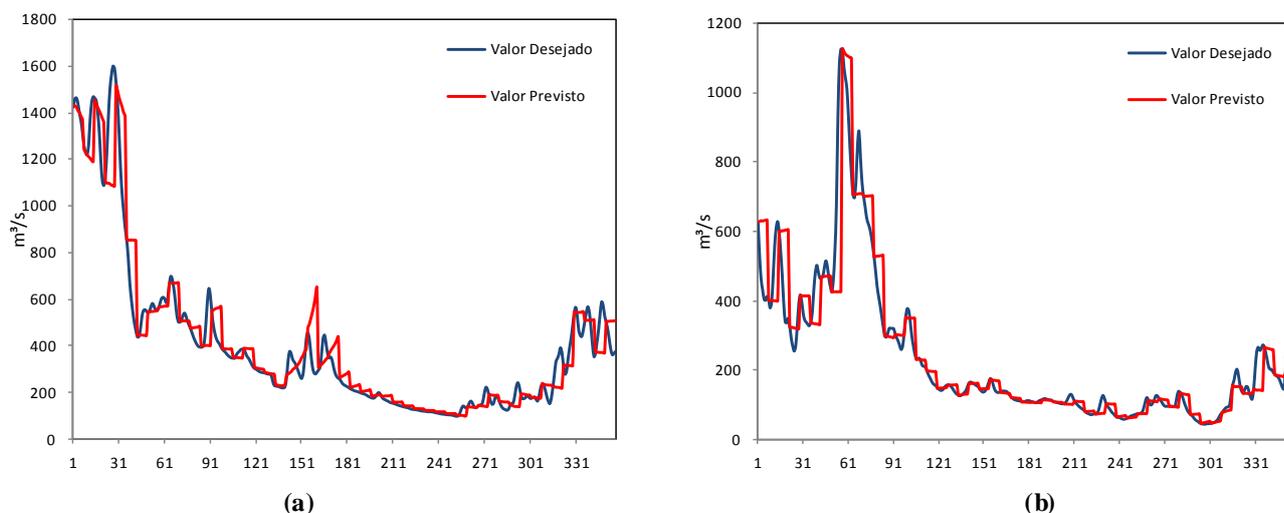
A Tabela 1 apresenta o erro absoluto percentual médio (EAPM) obtido pelos modelos considerados neste trabalho para as previsões realizadas para os períodos de teste, com a média sendo calculada sobre os resultados verificados para cada um dos oito conjuntos de teste gerados independentemente. Nesta Tabela é destacado o modelo que apresentou o melhor desempenho considerando a média dos resultados obtidos nos oito conjuntos de teste, além das características específicas de cada modelo, como número de entradas e presença ou não da componente binária. Os resultados da Tabela I mostram que a representação da componente sazonal contribui para melhoria do desempenho dos modelos. Esta questão está evidenciada nos resultados apresentados na primeira linha desta Tabela, referente ao desempenho do modelo autônomo que não faz uso de nenhuma representação direta da informação sazonal (Sem Binárias). O desempenho médio inferior (20,66%) contrasta com o desempenho dos modelos autônomos que incluem nas suas entradas 4 variáveis binárias para codificação 1 de  $n$  dos períodos seco, úmido ou de transição em que está sendo realizada a previsão (Com Binárias), modelo este que apresentou erro absoluto percentual médio entre de 14,19% e 20,47%.

Em relação à modelagem utilizando somente históricos de vazões observadas, os modelos propostos neste trabalho que utilizaram informações de precipitação mostraram desempenho superior, especialmente o modelo que tem como entradas um histórico de 7 últimas vazões verificadas e 3 informações de precipitação em torno do dia a ser previsto, com EAPM de 14,19%. A modelagem baseada apenas em vazões como entradas apresentou resultados inferiores, indicando que a dinâmica da

série de vazão histórica não é devidamente representada a partir somente dos dados históricos, ao contrário de outras séries com sazonalidades diárias bem definidas, como, por exemplo, séries de demanda máxima diária. Entretanto, os resultados apresentados na quinta e na sexta linha da Tabela 1 mostram que os modelos bayesianos propostos que utilizam as informações de precipitação em torno do dia a ser previsto contribuíram para melhoria do desempenho médio da previsão, evidenciando a correlação existente entre a precipitação verificada e a vazão média diária observada. Estes resultados evidenciam a contribuição das precipitações observadas no dia anterior nas vazões incrementais, devido principalmente ao acúmulo das chuvas em lençóis freáticos e ao atraso no escoamento da mesma para os leitos dos rios. Por fim, os resultados apresentados na Tabela 1 mostram que a definição das entradas a serem utilizadas pela rede neural podem ser variadas de acordo com o conhecimento do especialista a respeito da bacia estudada, porém fica claro a pertinência na utilização das informações de precipitação como entradas, visando contribuir para a diminuição do erros de previsão. A Figura 3(a) apresenta um gráfico da vazão média diária prevista 7 passos a frente em Furnas para um período de teste (janeiro de 1998 a dezembro de 1998) utilizando a rede neural de menor erro médio percentual (14,19%), sobreposto com a vazão verificada em Furnas para o mesmo período. Na Figura 3(b) é realizada a mesma comparação, contudo o período em questão refere-se ao 7º conjunto de treinamento e teste, onde o último está compreendido entre os meses de janeiro de 2002 e dezembro de 2002.

**Tabela 1** - Erro Absoluto Percentual (EAPM) verificado para cada modelo

Previsão de Vazões 7 Dias a Frente	Entradas			Resultados (%)
	nº vazões	nº chuvas	c/ binárias	
Modelo 7 últ. vazões	7	0	não	20,6596
Modelo 7 últ. vazões + bin	7	0	sim	19,9708
Modelo últ. vazão + chuva prev.	1	1	sim	18,1835
Modelo 7 últ. vazões + chuva prev.	7	1	sim	20,4741
Modelo últ. vazão + 3 chuvas(n-1, n, n+1)	1	3	sim	18,4617
Modelo 7 últ. vazões + 3 chuvas(n-1, n, n+1)	7	3	sim	14,1924



**Figura 3** - ano de 1998 (a) e ano de 2002 (b)

Os modelos neurais bayesianos utilizados neste trabalho são desenvolvidos utilizando algoritmos baseados em inferência bayesiana que possuem na sua formulação mecanismos para especificação de modelos, incluindo seleção de estrutura e controle de complexidade [8], que buscam a maximização da capacidade de generalização, ou seja, desempenho satisfatório para novos dados, sem a necessidade de um conjunto de validação. Conforme evidenciado na Figura 3, a dinâmica da série de vazão prevista é bastante semelhante em relação à dinâmica da série de vazão observada, garantindo boa generalização do modelo para diferentes conjuntos de treinamento. Como na prática os valores de vazão para o período de teste são desconhecidos, justifica-se assim a utilização de métodos analíticos para controle de complexidade e definição de estrutura que prescindam de conjuntos de validação.

## 5 Conclusões

Este trabalho teve por objetivo o desenvolvimento de modelos neurais bayesianos para previsão de vazões diárias com horizonte de previsão de sete dias à frente. A introdução de informações de precipitação, que demonstraram possuir correlação

com as vazões médias diárias, teve como propósito contribuir para as pesquisas que visam reduzir os erros de previsão de vazão para os estudos de planejamento da operação eletroenergética. Utilizando ainda modelos neurais com mecanismos de controle de complexidade e seleção de estrutura, buscou-se evitar o ajuste excessivo dos dados e conseqüente degradação da capacidade de generalização do modelo sem a necessidade de um conjunto independente de dados para validação. Os resultados obtidos pelos testes comparativos evidenciam a aplicabilidade da introdução das informações de precipitação nos modelos chuva/vazão-vazão, que apresentou resultados superiores aos obtidos por modelos que utilizam apenas históricos de vazões observadas como entradas. A escolha de um pequeno histórico de vazões observadas somadas a algumas informações de chuvas verificadas e previstas como entradas demonstram que a união destas duas informações gerou erros de previsão menores que os outros modelos, definindo o melhor modelo de previsão entre aqueles testados. A importância da informação de precipitação também deve ser avaliada à luz do efeito dos erros de previsão de precipitação na qualidade das previsões de vazão, o que será motivo de investigação futura. Os resultados obtidos neste trabalho também evidenciam a possibilidade de representação da informação sazonal referentes aos períodos seco, úmido e de transição, o que para séries de vazões diárias não compromete a automação do processo uma vez que tais informações são disponíveis.

## 6 Agradecimentos

Os autores gostariam de agradecer o apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) por meio de bolsa de iniciação científica IC101244 e da Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) pelo Auxílio Instalação número INST E-26/110.158/2010, apoios estes que incentivaram e viabilizaram o desenvolvimento da pesquisa apresentada neste trabalho.

## 7 Referências

- [1] ANEEL, Agência Nacional de Energia Elétrica; “Banco de Informações de Geração”, Brasil, 2010. Disponível em: <<http://www.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.asp>>
- [2] C.M. Bishop, Neural Networks for Pattern Recognition, **Oxford University Press** (1995).
- [3] R. Ballini, Análise e Previsão de Vazões Utilizando Modelos de Séries Temporais, Redes Neurais e Redes Neurais Nebulosas, Tese de Doutorado, UNICAMP, Campinas, SP, Brasil (2000).
- [4] R. Ballini, S. Soares, M.G. Andrade, “Previsão de Vazões Médias Mensais Usando Redes Neurais Nebulosas”, **Controle e Automação**, v. 14, n. 3, (2003), 286-297.
- [5] M. Valença, T.E. Ludermitz, A. Valença, “River Flow for Reservoir Management Through Neural Networks”, **In: Fifth International Conference on Hybrid Intelligent Systems (HIS2005)**, Rio de Janeiro, Brazil, (2005), 6-9.
- [6] V.H. Ferreira, A.P. Alves da Silva, “Toward Estimating Autonomous Neural Network-Based Electric Load Forecasters”, **IEEE Transactions on Power Systems**, v. 22, n. 4 (2007), 1554-1562.
- [7] V.H. Ferreira, “Desenvolvimento de Modelos Neurais Autônomos para Previsão de Carga Elétrica”, Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, (2008).
- [8] V.H. Ferreira, C.M. Leocádio, “Autonomous Neural Models Applied to Medium-Term Water Inflow Forecasting”, **In: Proceedings of the 16<sup>th</sup> International Conference on Intelligent Systems Application to Power Systems – ISAP**, Greece, (paper submitted and accepted), (2011).
- [9] M. Cataldi, C. Machado, L.G. Guilhon, S. Chou, J. Gomes, J. Bustamante, “Análise das previsões de precipitação obtidas com a utilização do modelo Eta como insumo para modelos de previsão semanal de vazão natural”, **RBRH — Revista Brasileira de Recursos Hídricos**, v. 12, n. 3 (2007), 5-12.
- [10] K.T. Figueiredo, C.R.H. Barbosa, A.V. Cruz, M. Vellasco, M.A.C. Pacheco, R.J. Contreras, “Neural Networks for Inflow Forecasting Using Precipitation Information”. **New Trends in Applied Artificial Intelligence - Lecture Notes in Computer Science**, v. 4570 (2007), 552-561.
- [11] K.T. Figueiredo, C.R.H. Barbosa, A.V. Cruz, M. Vellasco, M.A.C. Pacheco, R.J. Contreras, R.C. Souza, V.S. Marques, U.M. Duarte, U. M., M.H. Mendes, “Modelo de Previsão de Vazão com Informação de Precipitação utilizando Redes Neurais”, **RBRH – Revista Brasileira de Recursos Hídricos**, v. 12 (2007), 69-82.
- [12] ONS, Operador Nacional do Sistema Elétrico, Procedimentos de Rede, 2008.
- [13] M.A.A. Fayal, “Previsão de vazão por redes neurais artificiais e transformada Wavelet”; Dissertação de Mestrado em Engenharia Elétrica, PUC-RJ, Rio de Janeiro, RJ, Brasil, (2008).
- [14] I. Andreolli, Previsão de vazão em tempo real no rio Uruguai com base na previsão meteorológica. Dissertação de mestrado. IPH UFRGS. Porto Alegre (2003)
- [15] I. Guyon, A. Elisseeff, “An Introduction to Variable and Feature Selection”, **Journal of Machine Learning Research**, n. 3, (2003), 1157-1182.
- [16] D.J.C. Mackay, Bayesian Methods for Adaptive Models, Ph.D. dissertation, California Institute of Technology, Pasadena, California, USA (1992).