

Previsão de Vazões Afluentes Naturais Usando o Modelo ANFIS

Manoel H. N. Marinho¹, Secundino Soares¹, Rosangela Ballini²

¹Universidade Estadual de Campinas
Faculdade de Engenharia Elétrica e de Computação
Caixa Postal: 6101 - CEP 13083-970 Campinas-SP-Brasil.
{henrique,dino}@densis.fee.unicamp.br

²Universidade Estadual de Campinas
Instituto de Economia
Caixa Postal: 6135 - CEP 13083-970 Campinas-SP-Brasil
ballini@eco.unicamp.br

Abstract

The goal of this paper is to present a neuro fuzzy network model for seasonal streamflow forecasting. The model is based on an adaptive network based fuzzy inference system (ANFIS). The model was applied to the problem of seasonal streamflow forecasting using a database of average monthly inflows of one Brazilian hydroelectric plant located at Grande river. The performance of the model was compared with multi-layer perceptron. The results show that the ANFIS model provides a better one-step-ahead streamflow forecasting, with forecasting errors significantly lower than the other approach.

1. Introdução

O Brasil, quinto país do mundo em superfície, possui 8% do total de água doce existente no mundo. Diante deste quadro verifica-se que, em nosso país, a fonte de energia mais abundante e de menor custo de geração de energia elétrica tem sido de origem hidráulica.

A operação de um reservatório de geração de energia elétrica é definida em função das vazões afluentes da bacia hidrográfica. Como esta variável é aleatória, existem riscos na sua estimativa, que se refletem na operação da usina. Para reduzir estes riscos é necessário prever as vazões afluentes. A produção energética de um sistema hidroelétrico depende da série de vazões afluentes às diversas usinas do sistema.

Uma condição de fundamental importância para que o atendimento à demanda de energia seja realizado de forma otimizada, é que se disponha de um sistema de previsão de vazões eficientes, uma vez que a capacidade de geração futura do sistema é influenciada pelas futuras vazões afluentes cuja natureza é intrinsecamente estocástica.

Análise e previsão de vazões são de fundamental importância no planejamento da operação de sistemas

de recursos hídricos. Uma das grandes dificuldades na previsão das séries de vazões é a presença da sazonalidade devido aos períodos de cheia e seca do ano.

As séries de vazões naturais médias mensais têm como características o comportamento periódico, como por exemplo a média, a variância, a assimetria e a estrutura de auto-correlação. A análise destes tipos de séries pode ser feita pelo uso de formulações auto-regressivas cujos parâmetros apresentam um comportamento periódico. A esta classe de modelos costuma-se denominar modelos auto-regressivos periódicos [1]. O modelo auto-regressivo periódico é utilizado no Modelo Estratégico de Geração Hidrotérmica a Subsistemas Equivalentes Interligados (NEWAVE) [2].

Até recentemente, a alternativa mais comum aos modelos determinísticos ou hidrológicos na previsão de vazões eram os modelos estocásticos para análise de séries temporais, baseadas principalmente nas metodologias de Box & Jenkins [3]. Estes modelos tem sido empregados pelo setor elétrico brasileiro, inicialmente no âmbito do Grupo Coordenador da Operação Interligada – GCOI, coordenado pela ELETROBRÁS [4] e, posteriormente, no âmbito do Operador Nacional do Sistema Elétrico - ONS.

Em anos recentes, surgiu um novo método unindo as vantagens de redes neurais e lógica nebulosa, resultando em um sistema integrado, onde a aprendizagem e o poder computacional dos modelos de redes neurais e a capacidade de representação e raciocínio da lógica nebulosa são combinados. Estes sistemas são chamados de redes neurais nebulosas [5].

O objetivo deste trabalho foi realizar a previsão de vazões afluentes naturais médias mensais um passo à frente, usando o modelo ANFIS, e fazer uma análise comparativa com o modelo perceptron multi-camadas com algoritmo de retropropagação proposto por [6].

A estrutura de rede neurofuzzy usada neste trabalho foi o modelo Adaptive - Network - Based Fuzzy Inference System (ANFIS) desenvolvido por [7]. Utilizou-se os dados de vazões afluentes do posto

hidrológico da hidrelétrica de Furnas (pertencente ao curso de água do rio Grande), para fazer a previsão de vazões afluentes naturais médias mensais um passo à frente.

Os resultados mostraram que o modelo ANFIS, ajustado para prever a vazão no mês, apresentou melhor desempenho que a rede multi-camadas para previsão de vazões médias mensais.

2. Sistema Neuro Fuzzy

Sistemas neurofuzzy (SNF) são sistemas híbridos, já que utilizam mais de uma técnica de identificação de sistemas para a solução de um problema de modelagem. Essa combinação de técnicas resulta num sistema mais poderoso em termos de interpretação, de aprendizado, de estimativa de parâmetros e de generalização, entre outros.

Estes sistemas estão entre os sistemas híbridos mais pesquisados na atualidade, por associarem vantagens de duas técnicas de modelagem muito populares como as Redes Neurais e a Lógica Fuzzy.

Os sistemas neurofuzzy combinam a capacidade de aprendizado das redes neurais artificiais (RNAs) com o poder de interpretação lingüístico dos Sistemas de Inferência Fuzzy (SIFs). A idéia básica de um sistema híbrido neurofuzzy é implementar um sistema de inferência fuzzy numa arquitetura paralela distribuída de tal forma que os paradigmas de aprendizado comuns às redes neurais possam ser aproveitados nessa arquitetura híbrida. Estes modelos têm sido aplicados, com grande sucesso, a diversos problemas de classificação, controle, previsão e aproximação de funções.

No presente trabalho utilizou-se o modelo proposto por [8]. O modelo ANFIS implementa uma base de regras fuzzy do tipo Takagi – Sugeno, ou seja,

$$R^i : \text{SE } x \text{ é } A \text{ e } y \text{ é } B \text{ ENTÃO } z = f(x, y)$$

Takagi - Sugeno




Figura 1: Modelo Takagi-Sugeno¹.

Neste caso, a saída de cada regra é uma função das variáveis de entrada. Geralmente, a função que mapeia a entrada e saída para cada regra é uma combinação linear

das entradas, isto é $z = px_1 + qx_2 + r$. No caso em que $p = q = 0$, temos $z = r$ (fuzzy singleton). A saída do sistema é obtida pela média ponderada (procedimento de defuzzificação) das saídas de cada regra, usando-se o grau de disparo (firing strength) destas regras como pesos da ponderação.

3. ANFIS

Buscou-se neste trabalho obter um treinamento efetivo para o Sistema de Lógica Fuzzy (SLF). Assim, utilizou-se o pacote de software MATLAB® [9], mais especificamente o “Fuzzy Logic Toolbox”.

Devido o modelo ANFIS usar somente funções deriváveis, torna-se fácil aplicar um algoritmo de aprendizado padrão da teoria de RNA. Para isso uma combinação do algoritmo do método de estimação de mínimos quadrados é realizada. O algoritmo de retro-propagação é utilizado para o aprendizado dos antecedentes das regras fuzzy, isto é, as funções de pertinências, e a estimação de mínimos quadrados é usado para determinar os coeficientes das combinações nos consequentes das regras fuzzy. O procedimento de aprendizado subdivide-se em duas partes: na primeira parte, os padrões de entrada são propagados e os parâmetros do consequente são estimados, enquanto que os parâmetros do antecedente são determinados pelo conjunto de treinamento. Na segunda parte, os padrões são propagados novamente e, nesta etapa, o algoritmo de retro-propagação é utilizado para modificar os parâmetros do antecedente, enquanto os parâmetros do consequente permanecem fixos. Este procedimento continua até um número de iterações pré-fixadas.

A estrutura da rede é similar a uma rede neural, a qual mapeia as entradas através de funções de pertinência e dos parâmetros associados a essas funções e, também através de funções de pertinência associadas às variáveis de saída da rede.

Os pesos das sinapses e do bias, são associados às funções de pertinência que serão atualizadas no processo de aprendizagem. O trabalho computacional para a obtenção dos parâmetros (e seus ajustes) é facilitado com a técnica de vetor gradiente descendente, que proporciona a medição da diminuição do erro. Uma vez que o gradiente é obtido, qualquer rotina de otimização pode ser aplicada para ajustar os parâmetros e, conseqüentemente, reduzir o erro.

Utilizou-se um sistema neurofuzzy como uma ferramenta de previsão para predizer a tendência dos índices do mercado de ações [10]. O desempenho do modelo ANFIS é comparado com o método de regressão linear múltipla. As melhores previsões foram para os sistemas ANFIS.

A estrutura da rede neurofuzzy é composta por 5 camadas, como ilustra a Figura 2.

¹ Figura extraída de [7].




Figura 2: Estrutura ANFIS².

Na primeira camada, cada unidade (A_1, A_2, B_1 e B_2 , Figura 2) armazena três parâmetros para definir uma função de pertinência na forma de um sino, que representa um termo lingüístico como sendo:

$$O_i^1 = \mu_{A_i}(x) \quad (1)$$

onde:

x : é a entrada do nó i ;

A_i : é a classificação lingüística associada com a função do nó;

O_i^1 : é a função de pertinência de A_i ;

$\mu_{A_i}(x)$: é a função em forma de sino com máximo em 1 e mínimo em 0.

$$\mu_{A_i} = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (2)$$

em que $\{a_i, b_i, c_i\}$ é um conjunto de parâmetros.

Cada unidade é conectada a exatamente uma unidade de entrada e computa o grau de pertinência do valor de entrada obtida. O limite inferior da função de pertinência na forma de um sino é representado por “ a ”, “ b ” é o limite médio desta mesma função e “ c ” é o limite superior.

Na segunda camada, cada nó computa o peso w_i associado as funções de ativação, ou seja:

$$w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y), i = 1, 2 \quad (3)$$

a saída de cada nó nesta camada representa o nível de ativação de uma regra.

Cada nó na terceira camada calcula a taxa dos i -ésimos nós e o grau de desempenho relativo das i -ésimas regras para o somatório dos níveis de ativação dos nós, isto é:

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2 \quad (4)$$

Por conveniência, a saída desta camada pode ser chamada nível de ativação normalizado.

Na quarta camada é computado o produto da saída do nó i da terceira camada pela função f_i , $i=1,2$; ou seja,

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (5)$$

onde, $\{p_i, q_i, r_i\}$ é o conjunto de parâmetros associado ao nó i .

Finalmente, a quinta camada é composta por um único nó o qual computa a saída da rede sendo o somatório de todos os sinais de entrada, isto é,

$$O_i^5 = \sum \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (6)$$

4. Rede Perceptron Multi-Camadas

A rede perceptron multi-camadas (MLP) é uma das mais conhecidas e aplicadas arquiteturas de redes neurais, a qual representa uma generalização do perceptron proposto por [11].

Para treinamento da rede MLP, o método de aprendizagem mais utilizado é o algoritmo de retro-propagação do erro. Este algoritmo consiste basicamente de duas etapas. Na primeira etapa, conhecida como “forward”, as entradas são apresentadas e propagadas através da rede, camada por camada, calculando a saída de cada neurônio. Durante esta fase, os pesos são fixos e a saída calculada é comparada com a saída desejada, resultando em um erro para cada unidade. Na segunda etapa, o erro é retropropagado da camada de saída para a camada de entrada. Esta etapa é chamada “backward”, e os pesos são ajustados de acordo com a regra de correção do erro, originando o termo “retro-propagação do erro”.

Redes neurais multi-camadas para previsão de vazões a longo prazo foram aplicadas e comparadas com os modelos de séries temporais Box & Jenkins [12]. Os resultados mostraram desempenho promissor para a rede neural, apresentando erros menores que os métodos estatísticos.

5. Previsão de Vazões

Neste trabalho, foram utilizados os dados de vazões afluentes naturais médias mensais da usina hidrelétrica de Furnas. A usina hidrelétrica de Furnas está localizada no rio Grande, pertencente à empresa FURNAS – Centrais Elétricas S.A.

Utilizou-se para todas as abordagens uma série histórica de 55 anos (1931 a 1985) de vazões afluentes naturais médias mensais referente ao posto de Furnas. Os modelos foram ajustados para o período de 1931 a 1980, ou seja, foram ajustados 50 anos para treinamento. Para avaliar o desempenho dos modelos foi escolhido um período úmido, correspondente ao

² Figura extraída de [7].

período de janeiro de 1981 a dezembro de 1985, ou seja, foram considerados 60 meses para o aprendizado da rede. O modelo ANFIS(m) foi ajustado para cada mês pois, assim, o modelo torna-se mais específico para prever a vazão do mês.

A Figura 3 apresenta o histórico de vazões afluentes naturais médias mensais do período de 1931 a 1985. Nota-se que a série histórica do posto hidrológico de Furnas apresenta sazonalidades referentes a períodos de seca e chuvas intensas ao longo dos anos.




Figura 3. Histórico das vazões afluentes do posto hidrológico de Furnas.

Também foi ajustado um único modelo ANFIS para a previsão dos 60 meses (1981 a 1985). Para ajuste do modelo ANFIS foram analisadas várias topologias, ou seja, foram alteradas o número de entradas, juntamente com o número de regras.

O modelo ANFIS desenvolvido para realizar a previsão de vazões afluentes naturais médias mensais um passo à frente apresentou as seguintes informações, como mostra a Tabela 1.

Tabela 1: Informações do modelo ANFIS.

Funções de Pertinência Gaussiana	2
Número de Entradas (meses passados)	2
Número de Nós	21
Parâmetros Lineares	4
Parâmetros Não Lineares	8
Total de Parâmetros	12
Regras Nebulosas	4

Diversas outras tentativas no intuito de encontrar o menor erro relativo percentual médio foram realizadas, modificando o número de funções de pertinência e o número de entradas (meses passados), mas a melhor escolha foi para 2 (duas) entradas e 2 (duas) funções de pertinência tipo gaussiana.

Na Tabela 2 são apresentados os erros relativo percentual médio mensal (EPM) do modelo ANFIS(m). Observa-se que o menor erro percentual foi para o mês de junho e o maior erro percentual foi para o mês de novembro.

Tabela2: EPM mensal do modelo ANFIS(m).

Erro relativo percentual médio mensal (EPM) do modelo ANFIS(m) (%)			
jan	29,57	jul	24,02
fev	33,39	ago	14,37
mar	28,11	set	19,55
abr	14,94	out	27,20
mai	14,10	nov	33,83
jun	10,79	dez	32,82

Na Tabela 3 são apresentados os números de entradas (meses passados) para cada mês do modelo ANFIS(m).

Tabela 3: Número de entradas do modelo ANFIS(m).

Nº de entradas do modelo ANFIS(m)			
jan	02	jul	01
fev	01	ago	01
mar	01	set	01
abr	02	out	01
mai	01	nov	01
jun	02	dez	01

Observa-se na Tabela 3 que apenas nos meses de janeiro, abril e junho o número de entradas foram para 02 (dois) meses passados e os demais meses 01 (um) mês passado.

A Figura 4 mostra os resultados da previsão das vazões afluentes médias mensais do modelo ANFIS(m).




Figura 4. Previsão de vazões afluentes médias mensais do modelo ANFIS(m).

Para avaliar o desempenho dos modelos estudados neste trabalho foram analisados os erros quadrático médio (EQM), absoluto médio (EAM), relativo percentual médio (EPM) e relativo percentual máximo (EP_{max}), definidos como segue:

$$EQM = \frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2 \quad (7)$$

$$EAM = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (8)$$

$$EPM = \frac{100}{n} \sum_{j=1}^n \frac{|y_j - \hat{y}_j|}{y_j} \quad (9)$$

$$EP_{max} = \max \left\{ 100 \left| \frac{y_j - \hat{y}_j}{y_j} \right| \right\} \quad (10)$$

onde $n = 60$, y_j é o valor real e $\hat{y}_j$ é o valor previsto.

O modelo de rede neural multicamadas (MLP) foi ajustado um único modelo e m modelos, ou seja, um modelo para cada mês ($m=1, \dots, 12$) (MLP(m)) [13]. A Tabela 4 mostra os erros para os modelos MLP, MLP(m), ANFIS e ANFIS(m).

Observa-se na Tabela 4 que a melhor previsão de vazões afluentes naturais para o modelo neurofuzzy foi para o modelo ANFIS(m). Este resultado foi desenvolvido através do ajuste de 12 modelos ANFIS(m) ao invés de um único (ANFIS) e MLP.

Tabela 4: Estatísticas para os modelos de previsão.

Erros	MLP	MLP(m)	ANFIS	ANFIS(m)
EQM ($\times 10^5$)	3,91	3,73	19,60	4,52
EAM	434,74	429,51	386,77	373,40
EPM (%)	30,28	30,56	25,46	23,55
EPmax (%)	151,19	115,53	68,78	114,17

Analisando a Tabela 4, observa-se que o modelo ANFIS apresentou melhor desempenho que o modelo MLP, quando ajustado um único modelo para previsão.

Verifica-se que com 12 modelos a metodologia ANFIS apresentou, também, um melhor desempenho do que o modelo MLP, com exceção apenas para o erro quadrático médio.

Analisando todos os modelos, conclui-se que a melhor metodologia empregada para desenvolver a previsão de vazões afluentes médias mensais da usina de Furnas no período de 1981 a 1985 foi para a metodologia com 12 modelos desenvolvida no ANFIS.

A Figura 5 mostra os resultados da previsão das vazões afluentes médias mensais do modelo ANFIS para uma única rede.




Figura 5. Previsão de vazões afluentes médias mensais do modelo ANFIS.

5. Conclusões

A metodologia ANFIS(m) obteve resultados significativos na previsão de vazões afluentes naturais médias mensais um passo à frente para o posto hidrológico da usina hidrelétrica de Furnas.

No desenvolvimento do modelo ANFIS(m) para previsão de vazões afluentes naturais médias mensais um passo à frente, foram consideradas diversas entradas e uma saída. O método de aprendizagem neste modelo usado para identificação dos parâmetros, combina o método do gradiente e a estimação dos mínimos quadrados, o que o torna híbrido. Neste caso, a saída de cada regra é uma combinação linear da entrada de variáveis mais um termo constante e a saída final é a média dos pesos de cada saída de regra.

Analisando a comparação entre os modelos estudados verificou-se que a melhor desempenho foi para ANFIS(m) ajustado para cada mês, tendo erro médio percentual relativo de 23,55%, obtendo melhores resultados em comparação com as outras metodologias empregadas.

Agradecimentos

Esta pesquisa teve o suporte financeiro da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

Referências

- [1] SALAS, J. D., DELLEUR, J. W., YEVJEVICH, V. e LANE, W. L. (1980). Applied modeling of hydrologic time series, Water Resources Publications.
- [2] CEPEL (1983). Centro de Pesquisa de Energia Elétrica. Modelo de Séries Hidrológicas, Manual de Metodologia, Relatório Técnico, 113-81-A.

- [3] BOX, G. E. P., JENKINS, G. M. e REINSEL, G. C. (1994). Time Series Analysis, Forecasting and Control, Prentice-Hall, Inc, 3^a ed..
- [4] GCOI (1983). Grupo Coordenador da Operação Interligada, Manual do Sistema PREVAZ, Eletrobrás.
- [5] PEDRYCZ, W e GOMIDE, F. (1998). An Introduction to Fuzzy sets: Analysis and Design. MIT Press, Cambridge, M.A.
- [6] RUMELHART, D., HINTON, G. E. e WILLIAMS, R. (1986). Learning representations by back-propagation errors, Nature (LONDON), 323, pag.: 533-536.
- [7] JANG, J.-S. R., "ANFIS: Adaptive-Network-based Fuzzy Inference Systems,"IEEE Transactions on Systems, Man, and Cybernetics, Vol. 23, No. 3, pp. 665-685, May 1993.
- [8] TAKAGI, T., SUGENO, M. Derivation of fuzzy control rule from human operator's control actions. Proc. of the IFAC Symp. on Fuzzy Information, Knowledge Representation and Decision Analysis, pages 55-60, July 1983.
- [9] MATLAB[®] 6 - Duane Hanselman e Bruce Littlefield. São Paulo: Prentice Hall, 2003. Inclui índice. ISBN 85-87918-57-7.
- [10] GOMES, D. S. (2002) Previsões Financeiras Através de Sistemas Neuronebulosos, Tese de Mestrado, Universidade de São Paulo, Escola Politécnica, São Paulo, 2002.
- [11] ROSEMBLATT, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain, Psychological Review **65**: 386-408.
- [12] FRANCELIN, R., BALLINI, R., e ANDRADE, M. G. (1996). Back-propagation and Box-Jenkins approaches to streamflow forecasting, Latin-Iberian-American Congress on Operations Research and System Engineering – CLAIO, Simpósio Brasileiro de Pesquisa Operacional – SBPO, Rio de Janeiro – RJ, pp. 1307-1312.
- [13] BALLINI, R. (2000). Análise e Previsão de Vazões Utilizando Modelos de Séries Temporais, Redes Neurais e Redes Neurais Nebulosas, Tese de Doutorado, Universidade Estadual de Campinas, Campinas, SP.