

XVI SNPTTE
Seminário Nacional de Produção e
Transmissão de Energia Elétrica

GRUPO IX

ESTUDO DE OPERAÇÃO DE SISTEMAS ELÉTRICOS

PREVISÃO DE VAZÕES DE LONGO PRAZO UTILIZANDO REDES NEURAIS

Mêuser Valença
CHESF/UNIVERSO

Teresa Bernarda Ludemir
UFPE-PE

Luiz Guilherme Guilhon *
ONS

RESUMO

O Operador Nacional do Sistema Elétrico – ONS com o objetivo de otimizar o despacho centralizado das usinas, possui dentre outras atribuições a de realizar de forma mensal a previsão de vazões para os locais dos aproveitamentos hidrelétricos.

A previsão para o primeiro mês é realizada utilizando-se o modelo PREVIVAZ, que a partir de dados em base semanal, seleciona o melhor modelo dentre as 94 diferentes combinações de séries temporais, estruturas estacionária ou periódica, métodos de estimação de parâmetros e diferentes transformações e consolida os resultados em base mensal.

Para os meses entre o segundo e duodécimo à frente, utiliza-se o modelo PREVAVZ que trabalha em base mensal, com a metodologia combinada de Box & Jenkins e Yevjehich[1].

A Universidade Federal de Pernambuco - UFPE vem pesquisando novas metodologias baseadas em tecnologia de redes neurais e resolveu aplicar à previsão de vazões mensais um algoritmo baseado na técnica de abordagem construtiva, de tal modo que os usuários possam fazer uso dessa ferramenta sem se preocupar com a definição da arquitetura da rede. Para tal utilizou-se redes conhecidas como Non-Linear Sigmoidal Regression Blocks Networks – NSRBN.

A técnica utilizada neste trabalho procura encontrar dentre vários um modelo matemático de estrutura ótima capaz de representar um dado objeto complexo, tendo como base um critério de seleção externo.

O presente trabalho tem por objetivo comparar as duas aplicações metodológicas e para tal foram selecionados os aproveitamentos de Furnas no rio Grande, Itumbiara no rio Paranaíba, Itaipu no rio Paraná, Três Marias no rio São Francisco, Tucuruí no rio Tocantins, Foz do Areia no rio Iguaçú,

GOP/032

21 a 26 de Outubro de 2001
Campinas - São Paulo - Brasil

Passo Real no rio Jacuí e o trecho incremental entre Três Marias e Sobradinho.

Foram analisadas duas seqüências de previsões mensais para 12 meses à frente, entre os períodos maio de 1999 a abril de 2000 e entre novembro de 1999 a outubro de 2000, de forma a apresentar resultados previstos em períodos seco e úmido respectivamente, verificando os erros associados na utilização das duas técnicas.

PALAVRAS-CHAVE

PREVISÃO DE VAZÕES; PREVAVZ; REDES NEURAIS; NSRBN.

1.0 INTRODUÇÃO

A Diretoria de Planejamento e Programação do ONS, visando a otimização operativa das usinas por ele despachadas centralizadamente, realiza de forma mensal previsões de vazões mensais para um horizonte de um ano à frente, utilizando modelos tradicionais baseados nas tecnologias de Box & Jenkins, permitindo realizar análises energéticas avaliando o comportamento Sistema Interligado Nacional – SIN e tomar medidas de mitigação dos efeitos da carência de oferta de energia elétrica através de campanhas de conservação de energia ou até mesmo de contratos de compra de energia de países vizinhos para garantir o suprimento energético de forma adequada tentando evitar o racionamento.

Até maio de 2000 vinha sendo utilizado somente o modelo PREVAVZ para a previsão de vazões nos doze meses seguintes, e a partir de então, passou-se a utilizar também o modelo PREVIVAZ para o primeiro mês, continuando-se com o modelo PREVAVZ para os demais meses.

A UFPE, vem desenvolvendo pesquisas na modelagem baseada em técnicas de redes neurais, através do uso de abordagem construtiva, permitindo aos usuários o uso da ferramenta sem preocupar-se com a arquitetura da rede [2][3][4].

As Redes Neurais apresentam-se, atualmente como uma abordagem alternativa aos métodos estatísticos tradicionais na solução de problemas de previsão de séries temporais já que permite um mapeamento não-linear entre as variáveis de entrada e saída. O que torna esta tecnologia atrativa é o seu emprego em uma grande variedade de problemas que envolvem, muitas vezes, a determinação de relacionamentos complexos entre os atributos de entrada e as variáveis definidas como saídas para o sistema. O objetivo deste trabalho é de comparar a técnica de modelos estatísticos de Box-Jenkins à tecnologia de Redes Neurais que apresenta-se como uma poderosa ferramenta para modelagem e previsão de variáveis climáticas, hidrológicas, energéticas, bolsas de valores, séries econômicas.

Dentre os principais benefícios dessa técnica pode-se citar: não-linearidade ; adaptatividade (adequação a um novo ambiente); aprendizagem (o seu conhecimento é extraído do histórico); modelagem de sistemas complexos (pode trabalhar com uma grande quantidade e diversidade de dados); processamento paralelo (testa todas as possibilidades ao mesmo tempo); tolerância a falhas (perda do desempenho é gradual) e a capacidade de generalização (fornecer resposta razoável quando estimulada com novas informações).

O MODELO PREVAZ

O modelo estocástico de previsão de vazões, PREVAZ, foi desenvolvido na década de 1970, é considerado um modelo tradicional e baseia-se numa metodologia combinada de Yevjevich e Box & Jenkins.

O modelo PREVAZ pode utilizar modelos autoregressivos, modelos AR(p) [1], onde o valor atual do processo estocástico expressa-se como agregado linear de valores anteriores, ou seja, o próximo valor possui uma forte dependência dos “p” últimos valores ocorridos. Também pode utilizar modelos de médias móveis MA(q) no qual o valor do processo estocástico é linearmente dependente de um número finito de ruídos brancos “q” defasados no tempo. Por último, também pode utilizar um modelo misto autoregressivo e médias móveis ARMA(p,q) que possui as características dos dois anteriores.

O sistema de utilização do modelo PREVAZ, baseia-se em cinco programas executados em seqüência.

O primeiro, denominado “Transfor”, aplica a família de transformações de Box & Cox (logarítmica) aos dados básicos X(t), de vazões naturais médias mensais, obtendo uma distribuição normal Y(t), que contém a melhor transformação a ser aplicada.

O segundo programa “Comptest”, realiza uma padronização aos dados Y(t), a partir de sua média e desvio padrão, analisando a componente estocástica padronizada, obtendo um processo estocástico estacionário E(t).

O terceiro programa “Identifi”, fornece subsídios para a identificação dos modelos ARIMA (autoregressivos e médias móveis) a serem ajustados, calculando as funções de auto-correlação e auto-correlação parcial do processo estacionário E(t).

O quarto programa “Estima”, através do critério de Akaike estima os coeficientes dos modelos ARMA(p,q), calcula os respectivos erros padrão e seleciona o melhor deles.

O quinto programa “Prevaz”, a partir do modelo ARMA(p,q) selecionado, realiza uma despadronização e uma transformação inversa para se obter a previsão de vazão para todos os aproveitamentos considerados postos base (aproveitamentos com série de vazões históricas e representativos em suas bacias) e seus intervalos de confiança. As limitações do modelo encontram-se nos 600 meses de valores históricos observados e no número máximo de 30 postos base. Este programa também calcula a previsão de vazão para outros aproveitamentos que não são considerados postos base, através de regressão linear múltipla mensal, previamente calculada e determinada.

A previsão é realizada primeiro considerando os postos base por tratar-se de um modelo univariado.

2.0 REDES NEURAIIS

Neste trabalho dar-se-á ênfase especial às redes auto-organizáveis que caracterizam-se por utilizarem uma metodologia híbrida, redes neurais e conceitos estatísticos, com o objetivo de estimar redes de arquitetura ótima com uma estrutura que evolui durante o processo de treinamento. A mais importante contribuição deste trabalho reside no desenvolvimento de uma nova classe de redes neurais feedforward de alta ordem, chamadas de redes neurais por combinação de blocos de regressões sigmóides não-lineares (NSRBN), que são capazes de aproximar qualquer função contínua definida sobre um conjunto compacto[5]. Essas redes têm como fundamento a auto-organização, além de utilizar um aprendizado incremental baseado em um algoritmo construtivo. Este algoritmo construtivo é responsável pela escolha do modelo de ótima complexidade, ou seja, pela definição da arquitetura da rede. As redes que aqui são propostas, podem ser vistas como aproximações polinomiais multivariadas, uma vez que essas têm

como elemento de construção básico polinômios homogêneos de grau k , nos quais k varia de 1 a N (complexidade máxima, ou seja, máximo grau polinomial).

A arquitetura de uma rede neural, de acordo com a possibilidade de mudanças no seu tamanho durante o processo de treinamento, pode ser classificada em estática ou dinâmica. Uma rede é dita de arquitetura estática quando o número de camadas e unidades de processamento permanecem constante desde a concepção da rede até a finalização do seu treinamento. Por outro lado, uma rede de arquitetura dinâmica tem como característica principal um processo de mudanças no tamanho durante o treinamento.

Nessa nova classe de redes proposta, um algoritmo construtivo será utilizado para incrementar a estrutura da rede, partindo-se de uma pequena estrutura, até que se atinja uma estrutura de tamanho ótimo, segundo critérios estatísticos de seleção adequados. A proposta do modelo NSRBN é de se construir a rede por blocos de polinômios homogêneos, utilizando uma função de ativação adequada (tangente hiperbólica, por exemplo), para os neurônios escondidos. Quanto aos neurônios de saída, estes têm uma ativação mais complexa, uma vez que realizam uma regressão logística não-linear com relação à saída dos neurônios escondidos. Desta forma, essas redes NSRBN podem aproximar uniformemente qualquer função contínua definida em um conjunto compacto limitado e também lidar com a realização de funções booleanas, o que não é possível com os algoritmos tradicionais do grupo GMDH – Group Method Of Data Handling (combinatorial e multilayer) [5].

O primeiro passo para a construção de um modelo combinatorial consiste em dividir a função $f(x)$ em blocos compostos de termos de igual grau, como apresentado na Figura 1.

$$f(x) = \tilde{f}_1(x) + \tilde{f}_2(x) + \dots + \tilde{f}_d(x) \quad (2.0)$$

O bloco de grau p ($p=1,2,\dots,d$), de acordo com o polinômio de Kolmogorov-Gabor (teorema de Weierstrass), pode ser expresso como uma soma de produtos das entradas, isto é:

$$f_p(x) = \sum_{i_1=1}^N \sum_{i_2=i_1}^N \dots \sum_{i_N}^N a_p(i_1, i_2, i_3, \dots, i_N) \cdot x_1^{qp1(i_1)} \cdot x_2^{qp2(i_2)} \cdot \dots \cdot x_N^{qpN(i_N)} \quad (2.1)$$

em que, $qp1(i_1) + qp2(i_2) + qp3(i_3) + \dots + qpN(i_N) = p$
e $p \geq qpm(i_m) \geq 0$ para $m=1,2,3,\dots,N$.

Tem-se como objetivo realizar o mapeamento de cada um dos polinômios homogêneos de grau p .

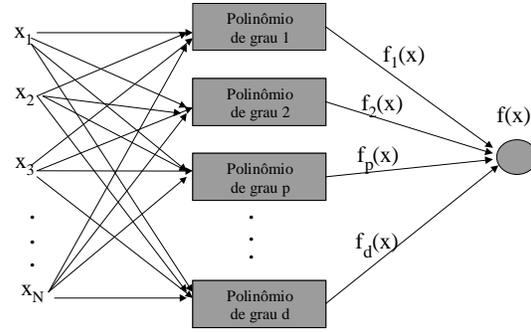


Figura 1 – Arquitetura combinatorial

Uma forma simples seria realizar todos os produtos das variáveis de entrada procurando aproximar diretamente a hipersuperfície não-linear, entretanto isto não é prático, a menos que d e N sejam relativamente pequenos (modelo combinatorial). Logo, para se ter um modelo eficiente, faz-se necessário que ele possua funções de ativação que sejam capazes de realizar vários termos dos polinômios homogêneos de forma otimizada, isto é, sem que ocorra um crescimento explosivo no número de parâmetros necessários para ajustar a função desejada. Com esse objetivo, propõe-se uma nova classe de redes neurais que tenha por base o algoritmo combinatorial (composta pela soma de blocos) com uma estrutura de blocos similar a uma rede MLP, sendo que, diferentemente destas, os neurônios de saída realizam a técnica estatística de regressão logística não-linear [6], com relação aos neurônios escondidos.

Definição 1: uma rede NSRBN é uma rede combinatorial composta pela soma de p blocos ($p=1,\dots,d$) com estrutura similar a uma MLP, na qual as unidades escondidas desses blocos realizam uma regressão sigmóide linear das entradas (tal qual uma MLP), e as unidades de saída realizam uma regressão do tipo sigmóide não-linear das unidades escondidas (tal qual uma regressão logística não-linear). Essa nova estrutura formada é um aproximador universal com forte capacidade de mapeamento não-linear. Utiliza-se aqui o termo sigmóide, significando qualquer função sigmoidal, como uma generalização da regressão logística clássica. A estrutura proposta para cada bloco é composta de apenas uma camada escondida, tendo N_h unidades escondidas em cada bloco com função de ativação do tipo [6]:

$$f(x) = (\sigma_{net(h)} + \theta_h) \quad (2.2)$$

em que $net(h)$ é a entrada líquida para cada neurônio escondido, h é um número inteiro que representa as unidades escondidas em cada bloco (variando de 1 até a ordem p do bloco), θ_h é

a tendência e $\sigma_{net(h)}$ é, por exemplo, a função tangente hiperbólica dadas por:

$$\sigma_{net(h)} = \frac{e^{net(h)} - e^{-net(h)}}{e^{net(h)} + e^{-net(h)}} \quad (2.3)$$

Poder-se-ia utilizar outras funções, como é o caso da função recíproca representada na Equação 2.5, isto é,

$$f_r(x) = \frac{net(h)}{1 + |net(h)|} \quad (2.4)$$

O valor de p correspondente ao grau do bloco é quem vai definir o número de neurônios em cada bloco, isto é: o bloco de grau 1 (p=1) tem h=1, logo um neurônio escondido; o bloco de grau 2 (p=2) terá 2 neurônios escondidos (h=1 e h=2) e assim sucessivamente, de tal forma que o bloco de grau p terá h=p e portanto p neurônios escondidos.

A estrutura proposta para cada bloco é similar à da Figura 2, na qual apresenta-se o mapeamento para um bloco de grau p (a ordem dos neurônios escondidos h variará de 1 até p), para i variáveis de entrada (onde i = 1,...,N) e uma única unidade de saída.

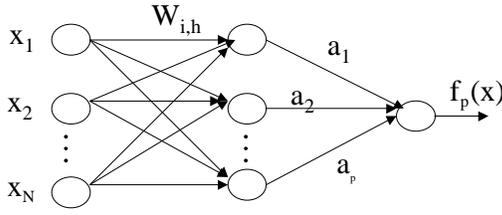


Figura 2 – Arquitetura de um bloco polinomial

Esse bloco é uma rede feedforward completamente conectada com uma única camada escondida. A diferença básica desse bloco de grau p para uma rede MLP é que os neurônios de saída são expressos como uma regressão sigmóide não-linear das unidades escondidas.

Seja $x = [1, x_1, x_2, x_3, \dots, x_N]^T$ o vetor coluna das variáveis de entrada, no qual o elemento x_i denota um elemento qualquer dele. As entradas são ponderadas pelos vetores de pesos $w = [w_{0h}, w_{1h}, w_{2h}, \dots, w_{Nh}]^T$, $h=1, \dots, p$, nos quais p é a ordem do bloco. Portanto, utilizando-se a função de ativação estabelecida na Equação 2.2, a saída

de cada unidade escondida, $f(net(h))$, desse bloco de grau p pode ser escrito como:

$$f(net(h)) = (\sigma_{net(h)} + \theta_h) \quad (2.5)$$

em que: $net(h) = \mathbf{w}_h^T \mathbf{x}$, ou seja, $net(h) = \sum_{i=1}^N w_{ih} x_i + w_{0h}$, $h=1, 2, \dots, p$.

Logo, a unidade de saída (que realiza uma regressão logística não-linear) desse bloco pode ser representada pela seguinte equação:

$$f_p(x) = a_1 (f(net(1)))^1 + a_2 (f(net(2)))^2 + a_3 (f(net(3)))^3 + \dots + a_p (f(net(p)))^p \quad (2.6)$$

sendo $a = [a_1, a_2, a_3, \dots, a_p]^T$ o vetor dos pesos das unidades escondidas para a unidade de saída.

Fazendo-se uso da Equação 2.5, a função $f_p(x)$ pode ser escrita da seguinte forma:

$$f_p(x) = a_1 (\sigma_{net(1)} + \theta_1) + a_2 (\sigma_{net(2)} + \theta_2)^2 + \dots + a_p (\sigma_{net(p)} + \theta_p)^p \quad (2.7)$$

ou

$$f_p(x) = \sum_{h=1}^p a_h (\sigma_{net(h)} + \theta_h)^h \quad (2.8)$$

com h representando a ordem dos neurônios na camada escondida, ($h=1, \dots, p$), do bloco de grau p. A arquitetura de uma rede NSRBN (Figura 1) é composta pela soma de blocos com grau variando de 1 a d. Aqui, está sendo utilizado o bloco p (Figura 2) para representar qualquer um desses blocos. Portanto, usando-se esta arquitetura, uma função desconhecida f em R^N pode ser aproximada por uma rede NSRBN, através da seguinte expressão:

$$f(x) = \sigma_{net(o)} \left(\sum_{p=1}^d f_p(x) \right) \quad (2.9)$$

em que: $\sigma_{net(o)}$ uma função de ativação adequada para a unidade de saída.

Por outra lado, a construção das redes NSRBN é feita de forma incremental, de maneira que pode-se representá-la em uma forma similar a de um bloco (Equação 2.7), conforme apresenta-se a seguir. Considere o passo do algoritmo para o qual se adiciona-se à rede o bloco de ordem d, f_d , tendo-se anteriormente adicionado os blocos f_0, f_1, \dots, f_{d-1} . Fazendo-se $f_0 \equiv 0$, uma função f pode ser representada por:

$$f(x) = \sigma_{net(o)} \left(\sum_{p=0}^{d-1} f_p(x) + f_d(x) \right) \quad (2.10)$$

na qual os pesos dos blocos f_0, f_1, \dots, f_{d-1} são congelados ao adicionar-se o bloco de ordem d, f_d .

Isso posto, pode-se escrever $f(x)$ da seguinte forma:

$$f(x) = \sigma_{net(o)} \{ c_0 + c_1 (\sigma_{net(1)} + \theta_1) + c_2 (\sigma_{net(2)} + \theta_2)^2 + \dots + c_d (\sigma_{net(d)} + \theta_d)^d \} \quad (2.11)$$

na qual o vetor $c = [c_1, c_2, \dots, c_d]$ representa os pesos das unidades escondidas para as unidades de saída e a constante c_0 está representando

todos os blocos congelados até a ordem d-1. A Equação 2.8 é, portanto, idêntica a uma regressão logística não-linear quando a função de ativação utilizada é a sigmóide logística tradicional.

A potencialidade dessas redes está fundamentada nas características impostas pela regressão sigmóide não-linear na unidade de saída. Esse algoritmo construtivo tem como base um método de aprendizagem construtiva (também chamado de auto-organização na teoria das redes GMDH). O princípio construtivo pode ser formulado como segue: quando um modelo incrementa gradualmente sua complexidade, certos critérios, que são chamados de critérios de seleção ou função objetivo e que têm a propriedade de complemento externo, passam através de um valor mínimo global. O encontro deste mínimo indicará a existência de um modelo de complexidade ótima.

Portanto, usando-se essa arquitetura proposta uma função qualquer $f(x)$ pode ser aproximada pelo uso direto de uma rede NSRBN por dividir $f(x)$ em blocos homogêneos de ordem 1 até o bloco de ordem d. Dessa forma, a função total $f(x)$ (polinômio completo) pode ser aproximada pela

soma das funções parciais $f_p(x)$, $p=1, \dots, d$ (polinômios homogêneos), de maneira incremental podendo ser representada matematicamente por:

$$f(x) = g(\hat{f}_1(x) + \hat{f}_2(x) + \dots + \hat{f}_p(x) + \dots + f_d(x)) \quad (2.12)$$

O modelo proposto tem como princípio manter congelados os pesos de todos os blocos anteriores ao atualmente otimizado, de tal forma que o número de pesos a ser otimizado a cada grau de complexidade não aumente explosivamente, como no algoritmo combinatorial tradicional. O algoritmo de abordagem construtiva procede como se descreve seguir. Seja p um

passo do algoritmo para o qual o bloco $f_p(x)$ é adicionado à rede, então uma função qualquer $f(x)$ é sucessivamente aproximada por:

$$f(x) = g(f_1(x)); \quad (2.13)$$

$$f(x) = g(\hat{f}_1(x) + f_2(x));$$

...

...

$$f(x) = g(\hat{f}_1(x) + \hat{f}_2(x) + \dots + f_p(x)) \quad (2.14)$$

em que os pesos dos blocos $\hat{f}_{p-1}(x)$ são congelados quando o bloco de ordem p é adicionado à rede e g representa uma função de ativação adequada para a unidade de saída.

3.0 ESTUDO DE CASO

Ao aplicar os métodos descritos selecionaram-se os aproveitamentos de Furnas no rio Grande, Itumbiara no rio Paranaíba, Itaipu no rio Paraná, Três Marias no rio São Francisco, Tucuruí no rio Tocantins, Foz do Areia no rio Iguaçu, Passo Real no rio Jacuí e o trecho incremental entre Três Marias e Sobradinho.

Analisaram-se duas seqüências de previsões mensais para 12 meses à frente, entre os períodos maio de 1999 a abril de 2000 e entre novembro de 1999 a outubro de 2000, representando previsões em períodos seco e úmido respectivamente. Para comparação dos resultados foram analisados, o desvio padrão (DP), erros absoluto médio (EAM), relativos médios (ERM(%)) e relativos máximos (E_{max}(%)). As tabelas 1 a 8 mostram os erros obtidos para os dos modelos e para os postos de aproveitamentos Furnas, Itumbiara, Itaipu, Três Marias, Tucuruí, Foz do Areia, Passo Real e a incremental entre Três Marias e Sobradinho, respectivamente.

Tabela 1- Resultados para a UHE Furnas

	MAI/1999 – ABR/2000		NOV/1999 – OUT/2000	
	PREVAZ	RN	PREVAZ	RN
DP	79,2	84,7	176,0	83,0
EAM	225,2	198,5	361,3	179,6
ERM(%)	46,1	28,0	29,8	17,3
E _{max} (%)	151,0	100,3	71,8	37,9

Tabela 2 - Resultados para a UHE Itumbiara

	MAI/1999 – ABR/2000		NOV/1999 – OUT/2000	
	PREVAZ	RN	PREVAZ	RN
DP	102,4	64,6	100,4	76,2
EAM	303,1	156,0	268,4	198,5
ERM(%)	36,7	15,4	23,4	20,3
E _{max} (%)	78,0	47,3	54,2	89,4

Tabela 3 - Resultados para a UHE Itaipu

	MAI/1999 – ABR/2000		NOV/1999 – OUT/2000	
	PREVAZ	RN	PREVAZ	RN
DP	585,7	423,1	851,8	678,9
EAM	1629,0	1100,2	2047,9	1890,2
ERM(%)	17,9	14,8	18,5	15,2
E _{max} (%)	39,8	28,7	57,7	48,6

Tabela 4 - Resultados para a UHE Três Marias

	MAI/1999 – ABR/2000		NOV/1999 – OUT/2000	
	PREVAZ	RN	PREVAZ	RN
DP	74,2	52,9	165,6	146,7
EAM	196,3	145,9	379,1	188,3
ERM(%)	57,0	42,9	49,4	42,9
E _{max} (%)	182,7	146,9	152,5	146,9

Tabela 5 - Resultados para a UHE Tucuruí

	MAI/1999 – ABR/2000		NOV/1999 – OUT/2000	
	PREVAZ	RN	PREVAZ	RN
DP	1502,0	1323,4	1662,3	1423,9
EAM	3477,5	2987,9	3975,6	3124,8
ERM(%)	19,8	17,3	21,6	18,7
E _{max} (%)	45,4	42,3	49,0	44,7

Tabela 6 - Resultados para a UHE F. Areia

	MAI/1999 – ABR/2000		NOV/1999 – OUT/2000	
	PREVAZ	RN	PREVAZ	RN
DP	105,7	98,6	132,8	110,7
EAM	297,9	232,1	364,2	258,0
ERM(%)	69,7	48,2	79,1	50,9
E _{max} (%)	162,5	145,3	161,1	152,7

Tabela 7 - Resultados para a UHE Passo Real

	MAI/1999 – ABR/2000		NOV/1999 – OUT/2000	
	PREVAZ	RN	PREVAZ	RN
DP	19,0	17,3	28,0	17,3
EAM	54,6	47,3	76,0	77,3
ERM(%)	38,5	29,5	43,3	32,8
E _{max} (%)	79,5	89,7	85,4	84,3

Tabela 8 - Resultados para a incremental TM-SB

	MAI/1999 – ABR/2000		NOV/1999 – OUT/2000	
	PREVAZ	RN	PREVAZ	RN
DP	69,3	44,4	163,2	52,3
EAM	208,8	73,3	433,2	129,5
ERM(%)	19,0	3,1	24,8	10,4
E _{max} (%)	41,3	15,4	39,8	37,6

Nas Figuras 3 e 4 observam-se de forma gráfica os Erros Médios Relativos, constatando-se que os resultados utilizando as Redes Neurais foram melhores para todas as usinas.

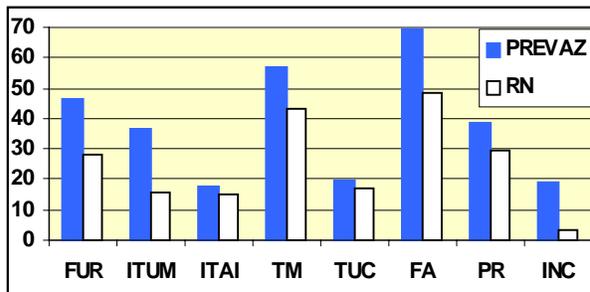


Figura 3 -Erro Médio Relativo-Mai/1999 - Abr/2000

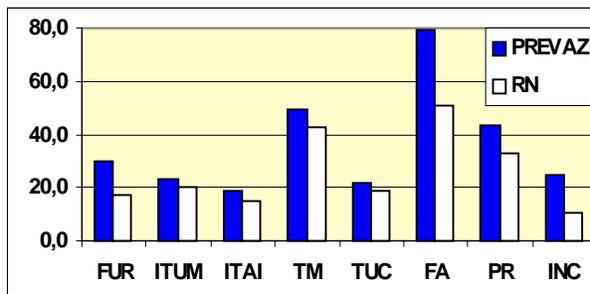


Figura 4 -Erro Médio Relativo-Nov/1999-Out/2000

Com isso, cabe destacar a importância de se investir em tecnologia de Redes Neurais para a previsão de séries temporais, podendo inclusive acrescentar outras variáveis de entrada, como são as meteorológicas.

4.0 CONCLUSÕES E RECOMENDAÇÕES

As Redes Neurais apresentam-se como alternativa à metodologia estocástica tradicional na previsão de séries temporais.

A técnica de Redes Neurais - NSRBN foi testada em base mensal para oito locais, essenciais para o Setor Elétrico e representativos de bacias com grande diversidade hidrológica, sendo o erro médio relativo percentual médio apresentado em todos os casos menor que aquele obtido com o uso do modelo PREVAZ, baseado em modelagem autoregressiva médias móveis periódica.

O uso dos modelos para diversos meses consecutivos e em diferentes locais poderá sinalizar para alguns locais surpresas indesejáveis, como por exemplo, valores de erro máximo percentuais bastante elevados, mesmo com a utilização de técnica de Redes Neurais, perdendo para a metodologia tradicional nos casos de Passo Real no período maio/1999 a abril/2000 e de Itumbiara no período novembro/1999 a outubro/2000.

Deve-se investir em aprimorar os modelos baseados em redes neurais na tentativa de se obter redes melhor treinadas e com o uso de variáveis de entrada mais variadas como são, por exemplo, as informações meteorológicas.

5.0 BIBLIOGRAFIA

- [1] BOX, G.E.P., JENKINS, G.M., Times Series Analysis - forecasting and control, Holden-Day 1976.
- [2] M. J. S. Valença and T. B. Ludermir. Multiplicative-Additive Neural Networks with Active Neurons. International Joint Conference on Neural Networks (IJCNN), IEEE, Book of Summaries (2073), Washington, DC, July 1999.
- [3] M. J. S. Valença and T. B. Ludermir. Self-organization Sigmoidal Blocks Networks. International Joint Conference on Neural Networks (IJCNN), IEEE, Book of Summaries (2086), Washington, DC, July 1999.
- [4] M. J. S. Valença and T. B. Ludermir. Uma Rede Neural Construtiva com Atualização dinâmica dos Pesos. IV Congresso Brasileiro de Redes Neurais, pages 114-117, ITA, São José dos Campos, Julho 1999.
- [5] M. J. S. Valença. Analysis and Design of the constructive neural networks for complex systems modeling (in portuguese). Ph.D Thesis, UFPE, Brazil, 1999.
- [6] M. J. S. Valença and T. B. Ludermir. Self-organization Neurons Blocks Networks. International Conference on Computational Intelligence and Multimedia Applications (ICCIMA), IEEE, pages 60-64, New Delhi, India, September 1999.