

## Redes RBF Aplicadas à Simulação da Operação de Usinas Hidroelétricas

Donato da Silva Filho, Adriano Alber de França Mendes Carneiro, Aluizio Fausto Ribeiro Araújo

Escola de Engenharia de São Carlos - USP

Departamento de Engenharia Elétrica

CP 359 - 13560-970 São Carlos - SP

E-mails: donato@sel.eesc.sc.usp.br, adriano@sel.eesc.sc.usp.br, aluizioa@sel.eesc.sc.usp.br

### Abstract

*This paper is concerned with the application of Artificial Neural Networks (ANNs) techniques to the coupled operation of Hydroelectric Power Plants (HPPs). The optimal behavior of Hydroelectric Power Systems depends on both the relative position of each HPP along the cascade and the relationships among the hydro plants. The main purpose of this work is to apply ANNs to learn these relationships, aiming to use them to simulate the optimal operation of the hydroelectric system. The used ANN architecture is the Radial Basis Function network. The proposed methodology is applied to a real system: seven large HPPs located in the Brazilian Southeast System. The achieved results show that the methodology is highly promising, and studies with larger systems need to be carried out.*

### 1. Introdução

Coordenar a operação de um sistema hidroelétrico consiste em determinar quanto cada usina deve gerar a cada instante, a fim de que o sistema consiga atender à carga que lhe é solicitada, a um mínimo custo, respeitando critérios de confiabilidade. Trata-se de uma tarefa bastante complexa, principalmente porque estes sistemas usualmente são altamente interligados, tanto elétrica quanto hidraulicamente.

As características peculiares de cada hidroelétrica, tais como diferentes arranjos físicos e posições relativas distintas dentro das cascatas, fazem com que seja praticamente impossível desenvolver regras gerais para simular suas operações [1].

Agregada a estas dificuldades, a operação de um sistema hidroelétrico é um problema dinâmico, uma vez que decisões tomadas no presente determinam, de forma direta, as condições operativas do futuro.

Na realidade, no instante presente nunca é possível saber precisamente se as decisões tomadas foram ótimas ou não; tudo irá depender das seqüências de aflúncias que ainda irão ocorrer. Por outro lado, se forem consideradas seqüências de aflúncias de períodos passados ou séries sintéticas de aflúncia,

pode-se adotar uma abordagem determinística. Neste caso, determina-se quanto cada usina deveria gerar a cada instante para que a operação durante o período de aflúncias conhecidas fosse ótima.

Apesar deste tipo de análise ser fictício, ele é muito importante na realização de uma análise do comportamento dos reservatórios, observando-se como eles relacionam-se entre si [2]. Este trabalho pretende extrair estas relações através de Redes Neurais Artificiais, e então utilizá-las em simulações da operação de um sistema real.

Um algoritmo de programação não-linear, especialmente desenvolvido para a realização da operação determinística de Sistemas Hidrotérmicos de Potência, é utilizado para otimizar a operação de um conjunto de usinas, considerando-se várias condições hidrológicas distintas [3]. Os resultados destas simulações são então processados e utilizados no treinamento de uma Rede Neural Artificial com Funções de Base Radial (Rede RBF) [4, 5].

Após treinada, a Rede RBF é integrada a um simulador da operação do sistema hidroelétrico, onde a cada instante de tempo é necessário que ela decida quanto cada usina deve gerar para que uma demanda solicitada seja atendida. As simulações não são determinísticas e, a cada intervalo de simulação, as decisões devem ser tomadas sem nenhum conhecimento sobre o futuro. Como a rede foi treinada com dados provenientes de operações ótimas, espera-se que suas decisões produzam comportamentos similares.

As trajetórias de energia armazenada no sistema produzidas pelo simulador neural são comparadas às produzidas pelo programa otimizador, e pela coordenação hidroelétrica através de uma regra heurística. Quanto mais próxima a trajetória de energia da operação através da Rede RBF estiver da trajetória de energia determinada pelo programa otimizador, mais eficiente será a operação neural [6].

A próxima seção apresenta os princípios da operação econômica adotada pelo programa otimizador. A Seção 3 mostra a arquitetura de Rede RBF utilizada e discute seu algoritmo de treinamento. A simulação do sistema hidroelétrico encontra-se na Seção 4, e a Seção 5 discute alguns resultados obtidos. Finalmente, a Seção 6 contém alguns comentários e conclusões finais.

## 2. Operação Ótima Determinística

Assume-se que a geração de energia de um Sistema Hidrotérmico de Potência provém de duas fontes básicas: Usinas Hidroelétricas e Usinas Térmicas. No caso do sistema brasileiro, basicamente hidráulico, o sistema térmico atua de forma complementar.

Segundo a modelagem adotada, as usinas térmicas são representadas de forma agregada, com um custo de geração  $C(.)$  proporcional à geração térmica  $E(.)$ . Já as usinas hidroelétricas são modeladas de forma individualizada, possuindo uma função geração expressa pela eq. (1) [2].

$$f_i(v_i, q_i, z_i) = k_i \cdot [h_{mon,i}(v_i) - h_{jus,i}(u_i)] \cdot q_i \quad (1)$$

sendo:

- $v_i(t)$  - volume de água do reservatório  $oi$  no intervalo  $t$ ;
- $q_i(t)$  - vazão turbinada pela usina  $i$  no intervalo  $t$ ;
- $z_i(t)$  - vazão vertida pela usina  $i$  no intervalo  $t$ ;
- $u_i(t)$  - defluência total da usina no intervalo  $t$ , calculada pela soma  $u_i(t) = z_i(t) + q_i(t)$ ;
- $k_i$  - constante que inclui aceleração da gravidade, densidade da água, rendimento turbina-gerador e coeficientes para conversão de unidades;
- $h_{mon,i}(\cdot)$  - nível a montante da usina  $i$ , função do volume de água armazenado em seu reservatório;
- $h_{jus,i}(\cdot)$  - nível a jusante da usina  $i$ , função de sua defluência total.

A Figura 1 ilustra esquematicamente uma usina hidroelétrica. O volume e a defluência de cada usina são submetidos a restrições físicas, ou restrições decorrentes de outros usos dos rios, tais como navegação, saneamento, etc.

$$\begin{aligned} v_{min,i} &\leq v_i(t) \leq v_{max,i} \\ q_{min,i} &\leq q_i(t) \leq q_{max,i} \end{aligned} \quad (2)$$

As funções  $h_{mon}$  e  $h_{jus}$  são polinômios, e a geração de um sistema com  $N$  HPPs, no intervalo  $ot$  é dada por:

$$H(t) = \sum_{i=1}^N f_i(v_i(t), q_i(t), z_i(t)) \quad (3)$$

Assume-se a hipótese de que o custo de operação do sistema hidroelétrico é nulo. Isso faz com que o custo

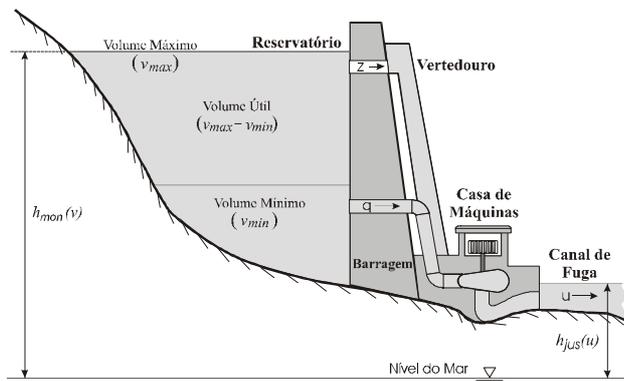


Figura 1 : Esquema de uma usina hidroelétrica

de operação do SHP, o qual deve ser minimizado, seja igual ao custo de operação do sistema térmico. Considerando-se uma demanda  $D(.)$  a ser atendida e uma geração hidroelétrica total  $H(.)$ , a geração térmica pode ser escrita como [6]:

$$E(t) = D(t) - H(t) \text{ for } D(t) \geq H(t) \quad (4)$$

$$E(t) = 0 \text{ for } D(t) < H(t) \quad (5)$$

Adotando-se um custo de geração proporcional ao quadrado da geração térmica, e tendo como objetivo minimizar este custo durante todo o intervalo de planejamento  $[1, T]$ , obtém-se:

$$C(t) = C[E(t)^2] \quad (6)$$

$$\text{Min} \sum_{t=1}^T C(t) \quad (7)$$

A solução do problema de otimização determinado pela eq. (7) e sujeito às restrições (2) é obtida através de programação não-linear, com algoritmo especial de fluxo em rede [3].

## 3. Rede Neural RBF

As Redes RBF são modelos de Redes Neurais Artificiais inspirados pelas respostas "localmente sintonizáveis" de alguns neurônios biológicos. Estas células, encontradas em muitas partes dos sistemas nervosos biológicos, respondem a características selecionadas de algumas regiões finitas do espaço dos sinais de entrada [4].

As Redes RBF têm uma estrutura de alimentação direta, composta por uma camada escondida de  $m$  unidades localmente sintonizáveis, as quais são completamente interconectadas a uma camada de saída com  $L$  unidades lineares, tal como ilustrado na Fig. 2. Todas as unidades da camada escondida recebem o vetor  $\mathbf{x}$  de entrada,  $n$ -dimensional e real, e processam-no de acordo com uma Função de Base Radial  $f_i$ :

$$f_i(\mathbf{x}) = f_i\left(\frac{\|\mathbf{x} - \mathbf{c}_i\|}{d_i}\right) \quad (8)$$

onde  $\mathbf{c}_i \in \mathcal{R}^n$  é o centro da RBF  $f_i$ ,  $d_i \in \mathcal{R}$  é o fator de escala para o raio  $\|\mathbf{x} - \mathbf{c}_i\|$ , e  $\|\cdot\|$  é tipicamente a norma Euclidiana sobre  $\mathcal{R}^n$ .

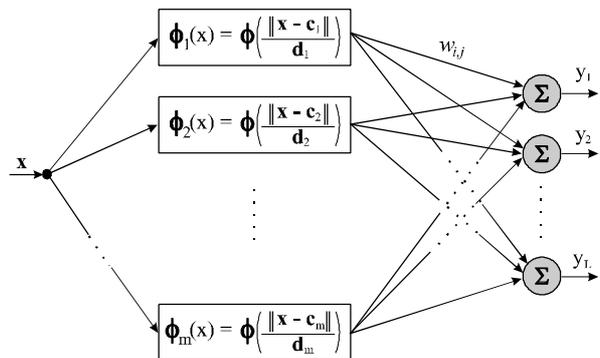


Figura 2 : Estrutura de uma Rede RBF

Cada função  $f_i$  é estritamente positiva e radialmente simétrica, com um único máximo quando  $\mathbf{x} = \mathbf{c}_i$ . Neste trabalho serão consideradas as funções Gaussiana e Multiquadrática Inversa, calculadas pelas eqs. (9) e (10), respectivamente.

$$f_i(r) = e^{-r^2/2} \quad (9)$$

$$f_i(r) = 1 / \sqrt{r^2 + 1} \quad (10)$$

$r$  é o raio da função, já alterado pelo fator de escala:

$$r = \frac{\|\mathbf{x} - \mathbf{c}_i\|}{\mathbf{d}_i} \quad (11)$$

Dado um vetor de entrada  $\mathbf{x} \in \mathfrak{R}^n$ , a saída da rede será um vetor  $\mathbf{y} \in \mathfrak{R}^L$ , cuja  $l$ -ésima componente é determinada pela eq. 12.

$$y_l(\mathbf{x}) = \sum_{j=1}^m w_{jl} \cdot f_j(\mathbf{x}) \quad (12)$$

Neste caso,  $w_{jl}$  é o peso da conexão entre a  $j$ -ésima unidade da camada escondida e a  $l$ -ésima unidade da camada de saída.

As Redes RBF são apropriadas para realizar mapeamentos contínuos ou contínuos por partes de funções de valores reais,  $f: \mathfrak{R}^n \rightarrow \mathfrak{R}^L$ . Estas aproximações incluem, como caso especial, os problemas de classificação de padrões. O grau de precisão das aproximações pode ser controlado por quatro parâmetros: o tipo de função de base radial, o número de unidades da camada escondida, a localização dos centros e dos raios, e o ajuste dos pesos que conectam a camada escondida à camada de saída [4].

Considerando que o tipo de função de base radial e o número de unidades da camada escondida tenham sido previamente escolhidos, o método de treinamento adotado é dividido em duas partes. Na primeira, a camada escondida é treinada de forma não-supervisionada, através do algoritmo *k-clustering*; por este algoritmo são especificados os centros e os raios da camada escondida. A segunda etapa de treinamento é supervisionada e consiste em ajustar os pesos  $w_{ij}$  através da regra delta-generalizada [5].

Este tipo de treinamento tem se mostrado muito eficiente na redução do tempo de treinamento da rede, apresentando porém uma reduzida capacidade de generalização, a menos que um grande número de funções de base radial seja utilizado.

#### 4. Operação de Hidroelétricas através de Redes RBF

A idéia de utilizar Redes RBF na operação de usinas hidroelétrica é fazer com que os comportamentos diferenciados que os reservatórios possuem durante a operação ótima determinística possam ser “aprendidos” pela rede e utilizados durante a operação normal do sistema, onde as afluições futuras não são conhecidas.

Esta seção é dividida em duas partes: na primeira mostra-se como os parâmetros de entrada e saída da rede foram definidos e, na segunda, mostra-se como a rede é integrada ao meio ambiente através de um simulador.

#### 4.1 Definição dos Parâmetros da Rede

A Rede RBF será responsável pela determinação do estado do sistema a cada intervalo de simulação. Assim, a saída da rede será composta pelos estados dos reservatórios no intervalo  $t$ . Para um sistema com  $N$  usinas, haverá  $N$  saídas da rede, ou seja,  $L = N$ .

A entrada da rede deve ser composta por grandezas capazes de determinar o volume dos reservatórios no instante  $t$ . Uma variável que pode ser utilizada para controlar a variação do estado dos reservatórios é a Energia Armazenada do Sistema no intervalo  $t$ ,  $EAS(t)$ . Assim, se a geração no instante  $t$  for superior à demanda, faz-se  $EAS(t)$  aumentar; isto equivale a fazer com que os reservatórios elevem seus volumes e que menos água seja turbinada, reduzindo a geração. Por outro lado, se a geração for inferior à demanda, a redução de  $EAS(t)$  provoca esvaziamento dos reservatórios, elevando suas turbinagens e, conseqüentemente, suas gerações.

Apenas uma variável de controle não é suficiente, pois seria interessante que as decisões tomadas durante a operação considerassem também o estado no qual o sistema encontra-se. Isso pode ser feito fornecendo-se à rede não somente  $EAS(t)$ , mas também o volume de cada reservatório no intervalo  $t-1$ .

Para normalização destes valores,  $EAS(t)$  é considerada nula quando todos os reservatórios do sistema encontram-se com seus volumes iguais a seus volumes mínimos, e  $EAS(t)$  é considerada 1 quando todos os reservatórios estão cheios.

Os volumes também são normalizados, de forma que quando todos os reservatórios estiverem cheios, a soma de seus volumes normalizados seja igual a 1. Esta normalização é feita de acordo com as eqs. 14 e 15. A Fig. 3 ilustra os vetores de entrada e saída da rede.

$$\bar{x}_i(t) = \frac{v_i(t) - v_{\min,i}}{\mathbf{r}} \quad (13)$$

$$\mathbf{r} = \sum_{i=1}^N (v_{\min,i} - v_{\max,i}) \quad (14)$$

$$\mathbf{x} = \begin{bmatrix} EAS(t) \\ \bar{x}_1(t-1) \\ \bar{x}_2(t-1) \\ \vdots \\ \bar{x}_N(t-1) \end{bmatrix} \quad \mathbf{y} = \begin{bmatrix} \bar{x}_1(t) \\ \bar{x}_2(t) \\ \vdots \\ \bar{x}_N(t) \end{bmatrix}$$

Figura 3 : Vetores de entrada e de saída da Rede RBF

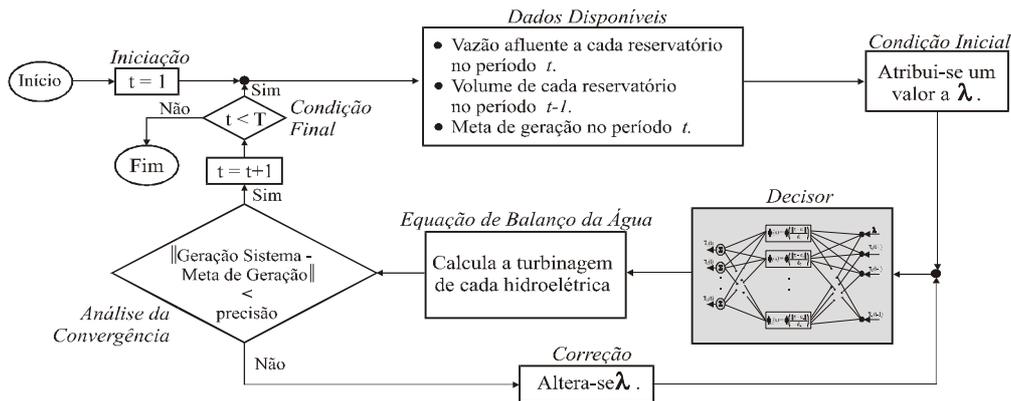


Figura 4 : Esquema do simulador utilizando Rede RBF

Para treinamento da rede, a operação do sistema que será operado com a Rede RBF deve ser otimizada de forma determinística sob várias condições hidrológicas distintas, representativas de todas as situações que podem ser encontradas durante sua operação.

Os resultados destas otimizações são processados para formarem os vetores de entrada e saída da rede. O treinamento é realizado dividindo-se o conjunto de padrões em três conjuntos: treinamento (50% dos padrões), validação (25%) e testes (25%) [5].

Após treinada, a Rede RBF é integrada ao meio ambiente, o que é feito através de um simulador.

## 4.2 Simulador da Operação do Sistema

Dado um conjunto de  $N$  usinas, um horizonte de operação  $[1, T]$  e o estado inicial de cada reservatório, o simulador da operação deve fornecer, a cada intervalo  $\Delta t$ , o quanto cada usina deve gerar com o objetivo do sistema hidroelétrico atender a uma demanda  $D(t)$ .

A grande diferença entre o simulador e o programa otimizador, é que o primeiro tem que tomar decisões, através de algum processo, conhecendo apenas as aflúncias no instante  $t$ , enquanto o programa otimizador conhece as aflúncias ao longo de todo o intervalo  $[1, T]$ .

O esquema do programa simulador é mostrado na Fig. 4. Inicialmente é feito  $t = 1$  e são fornecidos os valores das aflúncias no intervalo  $t$  e o volume dos reservatórios no intervalo  $t-1$ . É atribuído um valor à variável  $\lambda$  e forma-se o vetor de entrada da Rede RBF; a variável  $\lambda$  corresponde à  $EAS(t)$  na entrada da rede e, como será visto adiante, ela passa a determinar a política de enchimento e esvaziamento dos reservatórios.

A partir dos valores de entrada, a Rede RBF fornece uma saída, determinando o estado dos reservatórios no intervalo  $t$ . Comparando o volume de cada reservatório nos intervalos  $t-1$  e  $t$  e possuindo os dados de aflúncia, determina-se a vazão turbinada de cada reservatório e, conseqüentemente, suas gerações. Se a geração total for igual à demanda  $D(t)$ , incrementa-se  $t$ ; caso contrário, altera-se o valor de  $\lambda$  da seguinte forma:

- Se a geração for maior que  $D(t)$ , há excesso de turbinagem. Para reduzir a turbinagem armazena-se

mais água, ou seja, aumenta-se a energia armazenada do sistema, representada pela variável  $\lambda$ .

- Se a geração for menor que  $D(t)$  deve-se utilizar a água armazenada nos reservatórios para elevar a geração. Isto equivale a reduzir  $\lambda$ .

O procedimento é repetido, até que  $t = T$ . É interessante notar o papel da Rede RBF: ela pode ser vista como o “cérebro” do simulador, uma vez que ela toma as decisões de como os reservatórios irão comportar-se.

## 5. Aplicação

### 5.1 Sistema Teste

O sistema teste utilizado, Fig. 5, é composto por sete usinas hidroelétricas do Sistema Sudeste Brasileiro. As operações ótimas determinísticas foram realizadas. Foram realizadas otimizações com períodos de cinco anos, discretizados mensalmente.

### 5.2 Resultados

Para o treinamento da Rede RBF foram utilizadas várias arquiteturas, variando o número de unidades da camada escondida e o tipo de função de base radial. Para realização dos testes com o simulador será utilizada uma rede com 60 unidades na camada escondida e função de base radial multiquadrática inversa.

O primeiro teste feito com a rede treinada visa determinar o papel de cada usina no sistema. Para tanto, construiu-se a Tabela 2, onde os volumes iniciais dos

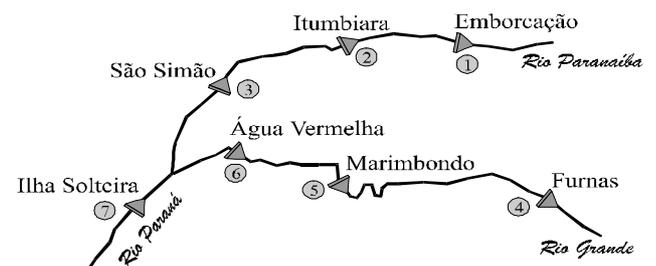


Figura 5 : Sistema teste

reservatórios são expressos como porcentagem do volume útil. Inicialmente, faz-se  $t = 0$  e estabelece-se que todos os reservatórios estarão cheios; logo,  $\lambda$  será 1. Os volumes são então normalizados de acordo com as eqs. (13) e (14) e são fornecidos à rede, juntamente com  $\lambda = 0,9$ , produzindo os estados dos reservatórios e  $mt = 1$ . O resultado é novamente fornecido à rede, porém com  $\lambda = 0,8$ , e obtém-se o estado do sistema em  $t = 2$ . O processo é repetido até que se consiga preencher a Tabela 2.

Os dados mostrados na Tabela 2 constituem as trajetórias de esvaziamento e enchimento dos reservatórios, de acordo com a variação de  $\lambda$  ao longo do tempo. A Fig. 6 mostra estas trajetórias para as usinas do rio Paranaíba. De acordo com as curvas apresentadas, a usina de montante, Emborcação, reduz seu volume tão logo a energia armazenada no sistema decresce; isto é feito com o objetivo de amortecer as variações sazonais das afluentes. O reservatório mais a jusante, São Simão, mantém-se praticamente cheio para os valores de  $\lambda$  apresentados, assegurando produtividade máxima a menos que a situação do sistema torne-se crítica, com valores de  $\lambda$  ainda menores que os apresentados. Por outro lado, a usina intermediária, Itumbiara, possui um comportamento que situa-se entre os dos dois grupos apresentados. Estes comportamentos são explicados pelos princípios da operação ótima dos reservatórios [2,6,7].

A influência de  $v_i(t-1)$  sobre  $v_i(t)$  pode ser notada pela forma assimétrica das curvas da Fig. 6 em torno de  $t=6$ . Por exemplo, para  $t = 4$  e  $t = 8$ ,  $\lambda$  é igual 0,6. Entretanto, o reservatório de Itumbiara possui armazenagens diferentes. Esta diferença é causada pelo vetor de entrada com os volumes em  $t-1$ .

O desempenho das Redes RBF será avaliado através de simulações da operação acoplada do Sistema Teste. Os testes serão realizados na seguinte seqüência:

- **Passo 1:** escolhe-se um período de cinco anos do histórico de afluentes.
- **Passo 2:** determina-se a operação ótima determinística do sistema teste ao longo deste período. Dentre os vários resultados desta operação tem-se a geração total do sistema ao longo dos 60 intervalos mensais, com os reservatórios cheios e em  $t = 0$  e  $t = 60$ .
- **Passo 3:** adota-se como meta de geração dos casos de simulação a geração ótima obtida no Passo 2.
- **Passo 4:** simula-se a operação conjunta através das Redes RBF, fazendo todos os reservatórios cheios em  $t = 0$  e deixando que o simulador determine a evolução dos volumes dos reservatórios ao longo do tempo.
- **Passo 5:** repete-se o Passo 4, realizando porém a coordenação hidroeétrica através da regra de operação

Tabela 1 : Trajetórias de enchimento e esvaziamento dos reservatórios. Volumes expressos em % do volume útil.

T	$\lambda$	$v_1$	$v_2$	$v_3$	$v_4$	$v_5$	$v_6$	$v_7$
0	1,0	100	100	100	100	100	100	100
1	0,9	84,8	100	100	84,8	100	100	100
2	0,8	70,1	96,7	100	66,0	100	100	100
3	0,7	57,1	100	100	48,0	100	100	100
4	0,6	47,7	91,8	100	30,7	100	100	100
5	0,5	36,4	84,6	100	12,6	100	100	100
6	0,4	29,0	54,1	100	9,5	90,5	100	100
7	0,5	44,0	54,3	100	26,8	86,8	100	100
8	0,6	55,3	68,2	100	43,6	100	100	100
9	0,7	64,2	88,6	100	51,6	100	100	100
10	0,8	74,0	100	100	56,9	100	100	100
11	0,9	81,1	100	100	69,3	100	100	100
12	1,0	100	100	100	97,3	100	100	100

em paralelo. Esta regra estabelece que todos os reservatórios devem permanecer com o mesmo volume útil percentual [7].

- **Passo 6:** comparam-se as trajetórias da Energia Armazenada no Sistema para cada um dos diferentes modos de realizar a coordenação hidroeétrica. Como todos os reservatórios iniciaram-se cheios e tiveram que atender à mesma demanda, a regra que determinar energias armazenadas finais maiores é mais eficiente, pois “gastou” menos água.

As Figs. 7, 8 e 9 mostram as trajetórias de Energia Armazenada no Sistema para diferentes períodos do histórico de afluentes e para vazões iguais à MLT (Média de Longo Termo). A legenda *Paralelo* refere-se à operação com a regra de operação em paralelo; a legenda *PNL* refere-se ao resultado do programa otimizador, e a legenda *RBF* refere-se à simulação com Rede *RBF*.

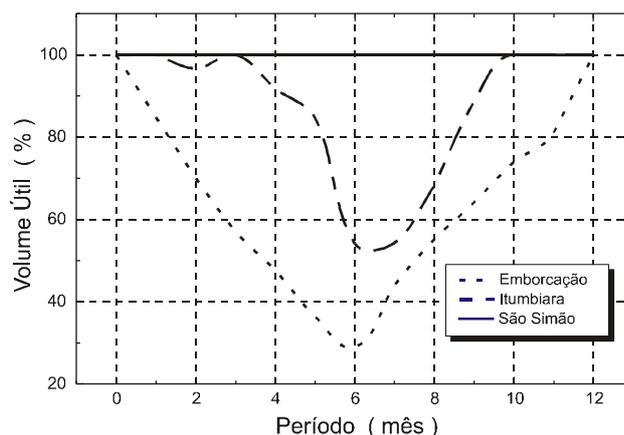


Figura 6 : Trajetórias de volume para as usinas do rio Paranaíba

Tabela 2 : Resultados de algumas simulações da operação conjunta do Sistema Teste

Energia Armazenada no Sistema, em %, para $t = 60$ .					
	MLT	1931 a 1936	1947 a 1952	1971 a 1976	1980 a 1985
<b>Paralelo</b>	35,8	68,1	47,5	20,6	95,6
<b>PNL</b>	100	100	100	100	100
<b>Rede RBF</b>	97,1	83,3	73,3	88,4	98,5

Para facilitar a análise quantitativa dos resultados tem-se ainda a Tabela 2.

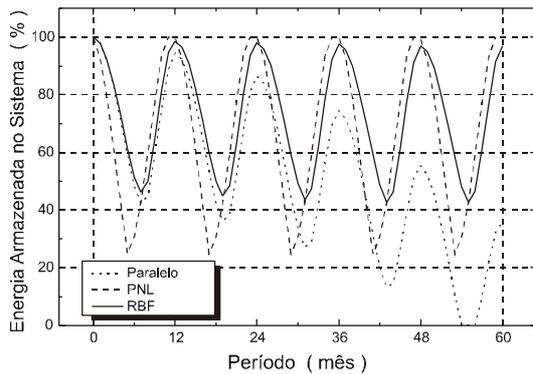


Figura 7 : Energia Armazenada no Sistema para afluência igual à MLT

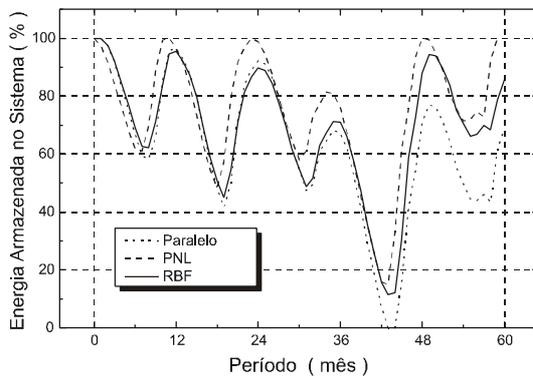


Figura 8 : Energia Armazenada no Sistema para afluência do período de 1931 a 1936

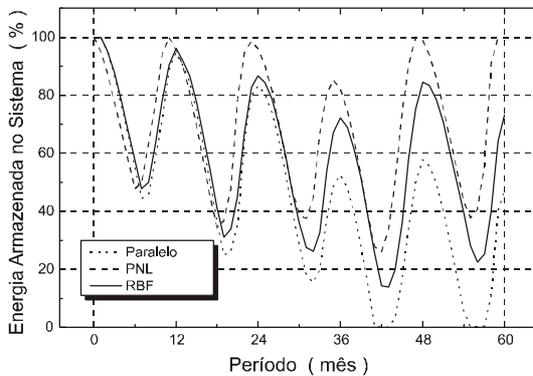


Figura 9 : Energia Armazenada no Sistema para afluência do período de 1947 a 1952

Pelos resultados obtidos constata-se que a coordenação das usinas hidroelétricas através da Rede RBF é bastante eficiente, no sentido de conseguir chegar ao final dos horizontes de simulação com energias armazenadas elevadas.

Além disso, as trajetórias de energia armazenada ao longo do horizonte de operação mostram uma tendência da operação com a Rede RBF em seguir o algoritmo de PNL.

## 6. Conclusões

Este artigo apresentou uma metodologia para simulação da operação de usinas hidroelétricas utilizando Redes Neurais Artificiais, mais

especificamente, Redes RBF. A rede neural teve que reproduzir as complexas relações existentes entre os reservatórios de um sistema hidroelétrico durante suas operações ótimas.

O treinamento da rede é feito a partir de resultados da operação ótima determinística, sobre diversas condições hidrológicas distintas, e os testes de desempenho são desenvolvidos através de um simulador da operação, que utiliza a Rede RBF para tomar decisões.

De forma geral, a partir dos resultados obtidos com um subsistema do Sistema Sudeste Brasileiro, pode-se concluir que a rede RBF conseguiu assimilar o comportamento ótimo da operação do Sistema Teste, a ponto de apresentar uma excelente performance durante as simulações.

Os testes mostraram que o simulador neural possui uma forte tendência em seguir os resultados da otimização determinística, otimizando o uso dos recursos hídricos disponíveis para geração de energia.

Melhorias podem ser realizadas no modelo atual, principalmente no treinamento da rede. A rede também pode ser alimentada com outras informações, que podem ajudá-la a tomar decisões baseadas não apenas no estado dos reservatório, mas também nas próprias condições de afluência, por exemplo.

## 7. Agradecimentos

Os autores agradecem ao apoio financeiro da FAPESP - Fundação de Amparo à Pesquisa do Estado de São Paulo.

## Referências

- [1] A.J. Wood and B.F. Wollenberg. Power Generation, Operation and Control. John Wiley and Sons, New York, 1984.
- [2] A.A.F.M. Carneiro and S. Soares. Optimal operation of reservoirs for electric generation. IEEE Trans. Power Delivery, 3(6): 1101-1107, 1991.
- [3] A.A.F.M. Carneiro, S. Soares and P.S. Bond. A large scale Application of a Deterministic Hydrothermal Scheduling Algorithm. IEEE Transactions on Power Systems, 5(1): 537-542, 1990.
- [4] M. H. Hassoun. Fundamentals of Artificial Neural Networks. MIT Press, Cambridge, 1995.
- [5] J. Hertz, A. Krogh, and R.G. Palmer. Introduction to the theory of neural computation. Redwood City, 1991.
- [6] A.A.F.M. Carneiro, A.C.P.L.F. Carvalho, P.T. Leite, D. Silva Filho, and M. Kadowaki. Optimal Operation Planning of Hydrothermal Systems Using Artificial Intelligence Techniques, In Proceedings of the VI SEPOPE - Symposium of Specialists in Electric Operational and Expansion Planning, Salvador - BA, Brazil, 1998 (CD-ROM).
- [7] S. Soares and A.A.F.M. Carneiro. Reservoir Operation Rules for Hydroelectric Power System Optimization. In Proceedings of the 1993 Athens Power Tech - IEEE/NTVA, pages 965-969.