

## 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  $D(\cdot)$  a ser atendida e uma geração hidroelétrica total  $H(\cdot)$ , 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  $\mathcal{R}^n$ .

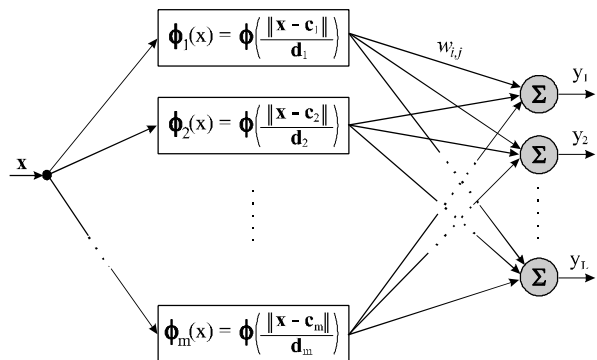


Figura 2 : Estrutura de uma Rede RBF

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 aflúncias 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





