
INTERPRETAÇÃO LINGÜÍSTICA DA OPERAÇÃO ÓTIMA DE UMA USINA HIDROELÉTRICA ATRAVÉS DE REDES NEURAIS NEBULOSAS ADAPTÁVEIS

D. Silva Fo.*

donato@sel.eesc.sc.usp.br

S. Soares Fo.†

dino@denisis.fee.unicamp.br

R. Ballini†

ballini@eco.unicamp.br

A.A.F.M. Carneiro*

adriano@sel.eesc.sc.usp.br

*Laboratório de Sistemas de Energia Elétrica, Departamento de Engenharia Elétrica, Escola de Eng. de São Carlos, Universidade de São Paulo, CP 359, 13560-970, São Carlos - SP - Brasil.

†Departamento de Teoria Econômica, Instituto de Economia, Universidade Estadual de Campinas, CP 6135, 13083-970, Campinas - SP - Brasil.

‡Departamento de Engenharia de Sistemas, Fac. de Eng. Elétrica e de Computação, Universidade Estadual de Campinas, CP 6101, 13083-970, Campinas - SP - Brasil.

ABSTRACT

This paper presents a methodology to linguistically explain the optimal operation of a hydroelectric power plant. It consists on an optimal control approach in which a Neural Fuzzy Network works in parallel with a deterministic optimization model. The knowledge acquired by the network throughout the training phase is written as a set of fuzzy rules and the optimal operation can be interpreted by simple sentences of the type *if <antecedent> then <consequent>*. The results show that the network is able to learn the numerical decisions of the optimization model and can translate the numerical data into sentences that can be easily understood by human beings.

KEYWORDS: Hydroelectric power systems, intelligent control, optimization, fuzzy hybrid systems, linguistic support.

RESUMO

Este artigo apresenta uma metodologia para interpretação lingüística da operação ótima de uma usina hidroelétrica. Trata-se de uma abordagem de controle ótimo na qual uma Rede Neural Nebulosa trabalha em paralelo com um otimizador determinístico. Após a fase de treinamento, o conhecimento adquirido pela rede é transformado em uma base de regras do tipo *se <antecedente> então <conseqüente>*, o que permite que a operação ótima seja interpretada lingüisticamente através de regras simples. Os resultados mostram que a rede utilizada é capaz de aprender as decisões numéricas do otimizador e pode funcionar como uma espécie de intérprete, traduzindo os dados numéricos em sentenças que podem ser facilmente compreendidas por seres humanos.

PALAVRAS-CHAVE: Sistemas hidroelétricos, controle inteligente, otimização, sistema híbrido nebuloso, suporte lingüístico.

Artigo submetido em 20/12/2000

1a. Revisão em 7/11/2002

Aceito sob recomendação do Ed. Assoc. Prof. Glauco N. Taranto

1 INTRODUÇÃO

A geração de eletricidade no Brasil provém fundamentalmente de usinas hidroelétricas. Isto faz com que a determinação do cronograma de geração das usinas ao longo de um horizonte de planejamento plurianual seja estocástica, uma vez que as afluências futuras não podem ser previstas com precisão absoluta. O problema também é classificado como dinâmico, pois as decisões de operação tomadas em um intervalo de tempo alteram a disponibilidade de água dos intervalos futuros. Além disso, tanto a função objetivo quanto outras funções utilizadas na modelagem são não-lineares, o que classifica o problema como não-linear.

Tradicionalmente, a resolução deste problema de longo prazo vem sendo realizada pelo Setor Elétrico Brasileiro através de Programação Dinâmica Estocástica (Fortunato et al., 1985), (Pereira, 1985). Como esta técnica apresenta a conhecida “maldição da dimensionalidade”, é necessário que o número de variáveis do problema seja reduzido. Com esta finalidade, as várias usinas hidroelétricas são representadas de forma agregada em um único reservatório equivalente, ao qual aflui e do qual deflui energia ao invés de água (Arvanitidis and Rosing, 1970). A agregação do sistema faz com que a visualização do comportamento individualizado das usinas seja perdida e introduz simplificações na modelagem das vazões, onde são utilizados modelos regressivos de ordem 1, nem sempre eficientes para este tipo de tarefa (Ballini et al., 1999). Evoluções deste modelo propõem a aplicação de Programação Dinâmica Estocástica Dual na resolução do problema de longo prazo. Embora a eficiência computacional deste método de resolução seja melhor que a da Programação Dinâmica Primal, os problemas listados anteriormente continuam a existir.

Um dos aspectos destas técnicas computacionais é a inabilidade de promover um entendimento direto das relações existentes entre as variáveis do modelo. A complexidade dos métodos e dos processos envolvidos na construção do reservatório equivalente, na tomada de decisões do modelo agregado e na desagregação das metas de geração entre as usinas faz com que a visualização da lógica e das relações físicas entre as variáveis seja perdida.

O objetivo deste trabalho é propor o desenvolvimento de uma metodologia capaz de transpor a deficiência de interpretação de resultados destas técnicas. Adicionalmente, o método proposto pode ser utilizado como uma ferramenta simples e eficiente para a operação mensal dos reservatórios. Trata-se de uma abordagem de controle inteligente na qual um algoritmo de aprendizagem trabalha em paralelo com um “operador eficiente” de

uma usina hidroelétrica (Brown and Harris, 1994), (Silva et al., 1999).

O sistema inteligente utilizado é uma Rede Neural Nebulosa Adaptável, proposta por (Figueiredo and Gomide, 1997), isomórfica a um sistema de conhecimento nebuloso baseado em regras e treinada com os dados do operador eficiente. Ao final de seu processo de treinamento, a base de regras permite que as decisões do operador sejam interpretadas linguisticamente, com regras do tipo *se <antecedente> então <conseqüente>* (Pedrycz and Gomide, 1998).

Na próxima seção são apresentados o sistema de controle inteligente e o detalhamento dos componentes do interpretador linguístico. A Seção 3 mostra a aplicação da metodologia proposta em uma usina hidroelétrica real e, finalmente, na Seção 4 são apresentadas as conclusões.

2 SISTEMA DE CONTROLE INTELIGENTE

O sistema de controle inteligente proposto pode ser visualizado na Figura 1. A planta a ser controlada é uma usina hidroelétrica; o operador eficiente adotado é um modelo determinístico especialmente desenvolvido para a operação de sistemas hidrotérmicos de geração; e o sistema inteligente utilizado é um modelo de rede neural nebulosa adaptável, isomórfica a um sistema de conhecimento nebuloso baseado em regras, treinada com os dados do operador eficiente. Ao final deste processo de treinamento, a base de regras criada permite que as decisões do operador sejam interpretadas linguisticamente. Cada um destes componentes é apresentado a seguir.

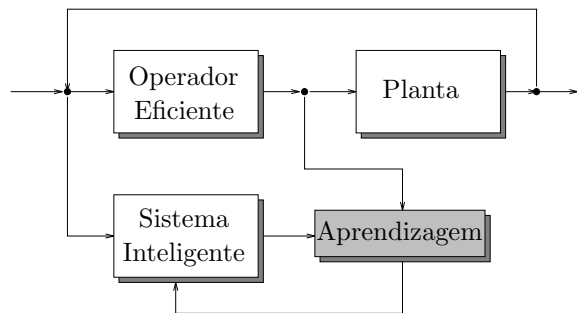


Figura 1: Modelo do interpretador linguístico.

2.1 Planta

Uma usina hidroelétrica apresenta como principais componentes uma barragem, responsável pela formação do reservatório; uma casa de máquinas, onde estão instalados os grupos turbina-gerador; um canal de fuga, através

do qual a água é reconduzida ao curso normal do rio; e um vertedouro que permite a liberação direta de água, sem passagem pela casa de força.

A potência gerada numa usina, Equação (1), é função da vazão turbinada e das alturas de montante e jusante, as quais são funções não-lineares do volume armazenado e da vazão defluente, respectivamente.

$$f(x, q, v) = k[h_{mon}(x) - h_{jus}(v + q) - pc]q \quad (1)$$

onde k é uma constante, x o volume do reservatório, q a vazão turbinada, v a vazão vertida, h_{mon} o nível d'água a montante do reservatório, h_{jus} o nível d'água a jusante da barragem e pc a perda de carga nos condutos forçados. A máxima potência que pode ser gerada em uma usina equivale, teoricamente, à soma da capacidade máxima dos geradores, conhecida como potência instalada.

A Tabela 1 apresenta valores numéricos para os dados de modelagem da usina hidroelétrica de Emborcação, localizada no rio Paranaíba, da empresa Centrais Elétricas de Minas Gerais - CEMIG. Esta usina será utilizada posteriormente na realização dos testes com a metodologia proposta.

Tabela 1: Principais dados da usina de Emborcação.

Característica	Valor
Potência Instalada [MW]	1200.0
Volume Mínimo [hm^3]	4669.0
Volume Máximo [hm^3]	17190.0
Nível Mínimo a Montante [m]	615.0
Nível Máximo a Montante [m]	660.0
Nível Médio a Jusante [m]	529.7
Engolimento Máximo [m^3/s]	1048.0
Vazão Defluente Mínima [m^3/s]	80.0
Rendimento Médio Turbina/Gerador	0.87
Perda de Carga Média [m]	1.3
Vazão Afluente Máxima [m^3/s]	2529.9
Vazão Afluente Média [m^3/s]	489.0
Vazão Afluente Mínima [m^3/s]	77.0

2.2 Operador Eficiente

O operador eficiente utilizado neste trabalho é um modelo determinístico especialmente desenvolvido para o Planejamento da operação de sistemas hidrotérmicos de potência, cujo objetivo é determinar como as usinas hidroelétricas devem ser operadas em cada intervalo do horizonte de planejamento, de forma que o custo de operação seja mínimo (Carvalho and Soares, 1987).

O sistema hidrotérmico tem como custo de operação o custo do sistema complementar, dado pela função $C(\cdot)$, a qual depende da demanda média, $D(t)$, e da geração hidráulica total, $H(t)$, pois quanto maior a geração hidráulica, menor será a complementação térmica $E(t)$ necessária. Para a realização dos estudos, a função $E(t)$ inclui o custo do déficit e assim, o custo de operação em cada intervalo de tempo t é dado por:

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

$$s.a. : \begin{cases} E(t) = D(t) - H(t), & \text{para } D(t) \geq H(t) \\ E(t) = 0, & \text{para } D(t) < H(t) \end{cases}$$

A geração hidráulica total $H(t)$ é dada pelo somatório das gerações de todas as usinas hidroelétricas:

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

sendo N o número de usinas hidroelétricas; e $f_i(t)$ a função de geração hidroelétrica da usina i , definida em (1).

De acordo com esta abordagem, uma vez especificada a demanda em cada intervalo, o planejamento hidrotérmico passa a ser um problema tratado exclusivamente através das usinas hidroelétricas. Como a geração de energia depende basicamente dos volumes armazenados em seus reservatórios e das vazões turbinadas, o objetivo da operação pode ser reescrito como a determinação do volume e da vazão turbinada de cada usina ao longo do horizonte de planejamento, de forma que o custo de operação seja mínimo.

O modelo determinístico faz com que a planta seja operada em condições idealizadas de funcionamento, onde as vazões afluentes durante todo o período são conhecidas. Esta situação torna-se particularmente interessante, mesmo sendo fictícia, pois a resposta do modelo corresponde ao melhor desempenho que a planta poderia ter.

Para ilustrar o efeito da aplicação do modelo determinístico é utilizada a usina de Emborcação em um horizonte de doze meses, com aflúências iguais às médias mensais do histórico, e com demanda constante e igual à potência instalada da usina.

O primeiro fato a ser observado, é que o ano hidrológico do sistema sudeste brasileiro, onde Emborcação está lo-




Figura 3: Rede neural nebulosa.

calculado o nível de ativação H^i , definido por:

$$H^i(\mathbf{u}) = T\{P_j^i\} \quad (5)$$

3. *Agregação das Regras:* A saída do sistema de inferência é calculado por:

$$y(\mathbf{u}) = \frac{\sum_{i=1}^N H^i(\mathbf{u}) g^i}{\sum_{i=1}^N H^i(\mathbf{u})} \quad (6)$$

Pode-se verificar que este sistema de inferência é isomórfico à RNN mostrada na Figura 3. Como toda rede neural, esta rede também é definida a partir da interconexão de unidades simples de processamento, conhecidas como neurônios. O modelo de um neurônio genérico é apresentado na Figura 4.

O modelo de rede neural nebulosa apresenta uma arquitetura de propagação direta com cinco camadas. A primeira camada é composta de M neurônios, cada um associado a uma variável de entrada.

A segunda camada contém N regras, e cada regra possui M neurônios (número de entradas). Esta camada realiza o primeiro estágio de inferência chamado de cálculo dos antecedentes.

Para cada regra i da segunda camada, um neurônio na terceira camada realiza a agregação dos antecedentes. Ou seja, a terceira camada contém N neurônios e esta camada realiza o segundo estágio de inferência.




Figura 4: Modelo geral do neurônio.

A quarta camada possui dois neurônios os quais são conectados com os neurônios da terceira camada. O operador de agregação associado com estes neurônios é a soma algébrica. Um dos neurônios conecta-se com os neurônios da camada anterior através dos pesos sinápticos g^i , sendo sua saída o numerador da Equação (6). O outro neurônio é conectado aos neurônios da camada anterior por pesos unitários, o que equivale ao denominador desta mesma equação.

Finalmente, a última camada contém um único neurônio que calcula o quociente dos sinais de entrada (Equação (6)).

O algoritmo de aprendizagem consiste na apresentação dos pares de entrada/saída desejada à rede. Assume-se que os conjuntos nebulosos são representados por funções de pertinência do mesmo tipo e simétricas, completamente definidas por valores modais e de dispersão. Estes parâmetros devem ser aprendidos durante o treinamento, assim como os pesos sinápticos da quarta camada.

A cada padrão apresentado à rede, as regras nebulosas da terceira camada competem entre si para verificar se o padrão atual pertence a alguma regra já existente ou se uma nova regra necessita ser criada. Esta característica é particularmente interessante porque as regras criadas não precisam incorporar todos os termos lingüísticos possíveis das variáveis de entrada, reduzindo sensivelmente a dimensão do conjunto de regras.

Se o padrão apresentado for classificado pela rede, $H^i(\mathbf{u}(t)) \neq 0$ para algum $i \in \{1, \dots, N\}$, e o módulo da diferença entre a saída calculada pela rede e a saída desejada for menor que um certo erro tolerável $\delta > 0$, os parâmetros são ajustados de forma a reforçar a aprendizagem. Se o desempenho não for satisfatório ou se o padrão não for classificado ($H^i(\mathbf{u}(t)) = 0, \forall i \in 1, \dots, N$), uma nova regra é adicionada à rede e os parâmetros são ajustados (Figueiredo and Gomide, 1997).

Os termos lingüísticos associados às variáveis de entrada são criados automaticamente quando uma nova regra é

insirida, uma vez que o centro das funções de pertinência da segunda camada correspondem aos valores dos padrões.

É interessante observar que esta estratégia de aprendizagem fornece uma maneira automática de aprender os parâmetros de um modelo nebuloso sem a necessidade de um especialista.

3 APLICAÇÃO

Para que a RNN interprete os resultados do modelo determinístico de otimização da operação é necessário que sejam definidas quais variáveis serão utilizadas. Como entradas da rede, antecedentes das regras, utilizam-se o volume do reservatório (variável de estado), determinado pelo modelo de otimização, e a vazão afluente de um mês. A saída da rede, conseqüente da regra, é definido como a vazão turbinada, o que acaba especificando a decisão de geração da usina. Estas definições fazem com que o volume e as vazões afluente e turbinada sejam interpretadas como variáveis lingüísticas. O ajuste dos parâmetros associados a estas variáveis é realizado através do treinamento da rede.

As funções de pertinência utilizadas são do tipo exponencial, o erro tolerável adotado é $\delta = 0.1$ e a *t-norma* utilizada na terceira camada é o produto algébrico.

3.1 Análise dos Dados

A planta utilizada na aplicação é a usina de Emborcação, descrita na Seção 2. O operador eficiente foi aplicado ao longo de um horizonte de planejamento de 660 meses, com início em maio de 1931 e término em abril de 1986, produzindo a trajetória de volume mostrada na Figura 5. As variações cíclicas anuais da quantidade de água armazenada no reservatório têm por objetivo amortecer as variações sazonais das vazões afluentes e produzir vazões defluentes que variam menos ao longo do ano, Figura 6, proporcionando gerações mais uniformes e reduzindo o custo de operação. Como resultado desta aplicação têm-se os valores ótimos de volume e vazão turbinada pela usina em cada intervalo.

Analisando os dados de volume, vazões afluente e turbinada ao longo do histórico (Figuras 5, 6), constata-se que a especificação de regras gerais para a operação da usina não é trivial, talvez tampouco possível, se forem considerados todos os meses de uma única vez para a elaboração da base de regras. Para ilustrar esta dificuldade, a Figura 7 mostra os valores mínimo, médio e máximo de vazão afluente encontrados no histórico, para cada mês. Através desta figura pode-se verificar,




Figura 5: Trajetória ótima de volume.

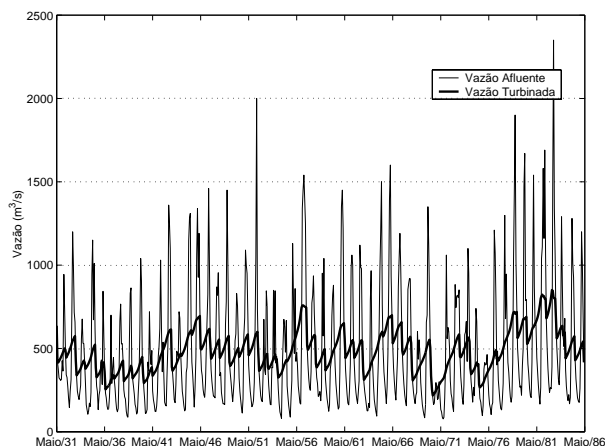


Figura 6: Trajetórias de vazões afluente e defluente.

por exemplo, que uma vazão afluente classificada como *alta* para o mês de setembro pode ser classificada como *excessivamente baixa* para o mês de fevereiro.

A Figura 8 mostra uma análise semelhante para os volumes mensais determinados pelo modelo de otimização. Através desta figura nota-se que o volume máximo alcançado pelo reservatório em cada mês é praticamente igual à sua capacidade máxima de armazenagem. Por outro lado, a proposição *volume é baixo* pode ser uma interpretação completamente diferente para, por exemplo, os meses de novembro e abril ou novembro e março.

Com base nestas diferenças, realiza-se o ajuste de doze modelos de RNN, uma para cada mês do ano. Isso possibilita que as regras sejam construídas de acordo com




Figura 7: Análise mensal dos valores de vazão afluente.




Figura 8: Análise mensal dos valores de volume.

as características de cada período, distinguindo-se não somente valores relativos associados aos termos das variáveis lingüísticas, mas também as diferentes decisões que devem ser tomadas nos períodos de esvaziamento e enchimento do reservatório.

3.2 Resultados

A Tabela 2 mostra o número de regras ajustadas após o treinamento da RNN para cada mês. Pode-se observar que o número de regras varia para cada mês. Isto ocorre porque alguns meses apresentam os valores das entradas da RNN distribuídos uniformemente entre os valores mínimo e máximo do histórico, fazendo com que mais termos sejam associados às variáveis lingüísticas e assim mais regras sejam necessárias.

Para o mês de maio, por exemplo, foram criadas sete regras para descrever a operação da usina, as quais são mostradas na Figura 9. Observe que os componentes das regras, os números reais g_i 's, foram ilustrativamente representados como funções de pertinência para proporcionar uma interpretação de seus valores em relação aos possíveis valores de vazão turbinada. Através desta representação, pode-se, por exemplo, dizer que $g_i = 682 \text{ m}^3/\text{s}$ (regra 4) equivale a uma vazão alta.

Na Figura 9, referente ao volume, observa-se que os centros das funções de pertinência (1), (4), (5) e (7) são bem próximos, podendo ser substituídas por uma função de pertinência equivalente, interpretada pelo termo lingüístico *alto*. De forma Analogamente, as funções (2), (3) e (6) podem ser substituídas por única função, associada

Tabela 2: Número de regras para cada mês.

Mês	No. de Regras
Maio	7
Junho	6
Julho	7
Agosto	11
Setembro	13
Outubro	9
Novembro	13
Dezembro	16
Janeiro	11
Fevereiro	10
Março	8
Abril	6

ao termo *médio*. Nota-se que não há funções de pertinência associadas ao termo *baixo* de volume. Isto mostra que a partir dos dados de treinamento, a rede decidiu que o volume no mês de maio não precisa de termos associados a todo o seu domínio, bastando os termos *médio* e *alto*. Observa-se que neste caso, como trata-se de uma única usina, o agrupamento das funções de pertinência foi feito de forma visual. Para casos mais complexos, pode-se utilizar um algoritmo de agrupamento baseado nas distâncias entre os centros.

Pela distribuição das funções de pertinência da variável vazão afluente (Figura 9), nota-se que não é possível reduzir o número de termos e, assim, os termos foram nomeados de acordo com as posições dos centros das funções de pertinência da seguinte forma: (2)- *muito baixa*, (6)-*baixa*, (1)-*abaixo da média*, (3)-*média*, (5)-*acima da*

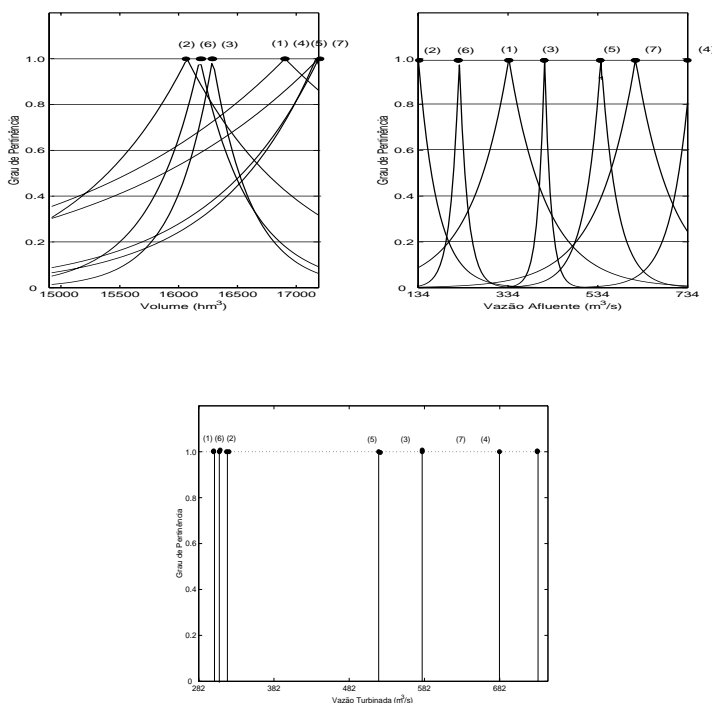


Figura 9: Visualização das regras para o mês de maio.

média, (7)-alta e (4)-muito alta.

Finalmente, para as funções de pertinência associadas à variável vazão turbinada (Figura 9), podem-se agrupar os valores (1), (2) e (6), criando o termo lingüístico *muito baixa*. Para as funções (5), (3), (7) e (4) associam-se, respectivamente, os termos *média*, *acima da média*, *alta* e *muito alta*.

As regras podem ser descritas através dos termos lingüísticos como:

1. Se *volume é alto* E *vazão afluente é abaixo da média* Então *vazão turbinada é muito baixa*;
2. Se *volume é médio* E *vazão afluente é muito baixa* Então *vazão turbinada é muito baixa*;
3. Se *volume é médio* E *vazão afluente é média* Então *vazão turbinada é acima da média*;
4. Se *volume é alto* E *vazão afluente é muito alta* Então *vazão turbinada é muito alta*;
5. Se *volume é alto* E *vazão afluente é acima da média* Então *vazão turbinada é média*;
6. Se *volume é médio* E *vazão afluente é baixa* Então *vazão turbinada é muito baixa*;
7. Se *volume é alto* E *vazão afluente é alta* Então *vazão turbinada é alta*.

Como um dos aspectos a ser observado, a utilização de apenas dois termos lingüísticos no mês de maio para a variável volume introduz reduções significativas no número de regras que são utilizadas para descrever a operação.

Analisando a relação entre as variáveis *vazão afluente* e *vazão turbinada*, constata-se que as regras indicam que a usina deve armazenar água. Embora não seja evidente, esta decisão é intuitiva. Isto porque o mês de maio marca o início do período seco e a operação ótima mostra que o reservatório deve estar cheio neste mês para que haja água suficiente para garantir vazões regularizadas durante a estiagem.

Considerando o mês de dezembro, período de enchimento do reservatório, as regras indicam que as vazões defluentes devem ser menores que as vazões afluentes. Como exemplos de regras determinadas pela rede pode-se citar:

1. Se *volume é acima da média* E *vazão afluente é alta* Então *vazão turbinada é acima da média*;
2. Se *volume é acima da média* E *vazão afluente é acima da média* Então *vazão turbinada é baixa*;
3. Se *volume é médio* E *vazão afluente é acima da média* Então *vazão turbinada é baixa*;

Os resultados para os outros meses mostram que a rede conseguiu definir os períodos de enchimento e esvaziamento do reservatório ao longo de seu ciclo anual de operação.

4 CONCLUSÕES

Neste trabalho apresentou-se uma abordagem de controle inteligente ao problema de operação plurianual de uma usina hidroelétrica.

O objetivo do trabalho foi fazer com que o sistema inteligente utilizado, uma rede neural nebulosa adaptável, interpretasse os resultados de um operador eficiente, um modelo determinístico de otimização, e produzisse um conjunto de regras que viabilizasse a interpretação lingüística destes valores. A grande variação encontrada entre os dados de vazão e volume ao longo dos meses fez com que fosse utilizada uma base de regras para cada mês do ano, descrevendo mensalmente as relações entre os antecedentes, volume da usina e vazão afluente, e o conseqüente, vazão turbinada.

Os resultados mostraram que o sistema inteligente conseguiu atuar como uma espécie de "intérprete", traduzindo as decisões numéricas do modelo de otimização e

interpretando de forma simples as relações entre as variáveis utilizadas.

Trabalhos futuros prevêem a interpretação lingüística da operação ótima de sistemas de grande porte, compostos por vários reservatórios. Além disso, pretende-se aplicar a base de regras a modelos de simulação.

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

- Arvanitidis, N. V. and Rosing, J. (1970). Composite representation of a multireservoir hydroelectric power system, *IEEE Transactions on Power Apparatus and Systems* **2**(PAS-89): 319–326.
- Ballini, R., Soares, S. and Andrade, M. G. (1999). Seasonal streamflow forecasting via a neural fuzzy system, *Proceedings of IFAC'99*, Vol. k, pp. 81–86.
- Brown, M. and Harris, C. (1994). *Neurofuzzy Adaptive Modelling and Control*, Prentice Hall, London, UK.
- Carvalho, M. F. and Soares, S. (1987). An efficient hydrothermal scheduling algorithm, *IEEE Transactions on Power Systems* **2**(PWRS-1): 537–542.
- Figueiredo, M. and Gomide, F. (1997). Adaptive neuro fuzzy modelling, *Proceedings of FUZZY-IEEE'97*, pp. 1567–1572.
- Fortunato, L. A. M., Neto, T. A. A., Barreto, L. A. and Ferreira, C. (1985). Operation planning studies of the brazilian generation system, *IFAC Symposium on Planning and Operation of Electric Energy System - Preprints*, pp. 193–200.
- Pedrycz, W. and Gomide, F. (1998). *An Introduction to Fuzzy Sets: Analysis and Design*, MIT Press, Cambridge.
- Pereira, M. V. F. (1985). Optimal scheduling of hydrothermal systems - an overview, *IFAC Symposium on Planning and Operation of Electric Energy System - Preprints*, pp. 1–9.
- Silva, D. F., Carneiro, A. A. F. M. and Araújo, A. F. R. (1999). A digital neural simulator for the energetic operation of hydroelectric power systems, *Proceedings of the Third International Conference on Power System Digital Simulators*.
- Soares, S. and Carneiro, A. A. M. F. (1991). Optimal operation of reservoirs for electric generation, *IEEE Transactions on Power Delivery* **3**(6): 1101–1107.
- Yager, R. and Filev, D. (1994). *Essentials of Fuzzy Modeling and Control*, Wiley Interscience, New York.