

ESTABELECIMENTO DE VOLUMES DE ESPERA EM TEMPO REAL APLICANDO ALGORITMOS GENÉTICOS E REDES NEURAIAS

Mêuser Valença¹

¹Chesf/UNIVERSO-Recife

Rua Gaspar Peres 427/104, CEP 50670-350, CDU

Teresa Ludermit², Anelle Valença²

²Universidade Federal de Pernambuco

Cx. Postal 7851 CEP 50732-970

E-mails: meuserv@yahoo.com.br, tbl@cin.ufpe.br

RESUMO

A operação de reservatórios de armazenamento (no Brasil em especial) visando principalmente à geração energética tem-se deparado no presente com um sério conflito operacional. A população localizada a jusante, dos mesmos, confiando no amortecimento das cheias pelo reservatório, tem procurado aproveitar ao máximo toda a área anteriormente inundada freqüentemente pelas cheias, bem como, exigir controle de descargas não previstas em projeto. Este trabalho tem como objetivo adaptar e testar uma metodologia visando o estabelecimento de regras de operação para o controle ótimo de um reservatório de armazenamento durante um período de cheias. O sistema proposto é caracterizado por apresentar uma arquitetura inteligente híbrida uma vez que utiliza a técnica de algoritmos genéticos para otimização do controle ótimo do reservatório, tendo como base as previsões de vazões afluentes feitas com a técnica de redes neurais construtiva associada a um modelo determinístico de propagação de vazões.

Palavras-chave: redes neurais, volumes de espera, algoritmos genéticos, previsão de vazões, vazão de restrição.

1. INTRODUÇÃO

A operação de reservatórios de armazenamento (no Brasil em especial) visando principalmente a geração Energética tem-se deparado no presente com um sério conflito operacional. A população localizada a jusante, dos mesmos, confiando no amortecimento das cheias pelo reservatório, tem procurado aproveitar ao máximo toda a área anteriormente inundada freqüentemente pelas cheias, bem como, exigir controle de descargas não previstas em projeto.

O conflito operacional ao qual nos referimos decorre, portanto do uso conjunto do reservatório: geração Energética – a operação se desenvolve visando o armazenamento de água – e controle de cheias – a operação se desenvolve visando a formação de espaço de amortecimento.

Atualmente as metodologias utilizadas pelo setor elétrico estabelecem no início de cada período úmido (período de início das chuvas na bacia hidrográfica), os volumes vazios semanais (denominados volumes de espera) necessários para

minimizar os impactos causados pelas cheias. A relevância do trabalho consiste, portanto em realizar uma alocação ótima deste volume de espera em tempo real em função das previsões realizadas, considerando de maneira explícita, em tempo real, o risco de violação dos objetivos de planejamento de longo prazo. Portanto, esta metodologia permitirá considerar de maneira explícita em tempo real o risco de inundação a jusante, permitindo que as autoridades competentes decidam em função de aspectos políticos, sociais e econômicos qual o risco máximo de inundação a jusante, que deverá ser utilizado para derivar a estratégia operacional do reservatório, com vistas a maximizar o volume armazenado ao final da estação de cheias. Em trabalho anterior apresentamos uma versão desta metodologia onde as previsões eram realizadas apenas do 15^o (décimo quinto dia) ao 21^o (vigésimo primeiro) com a técnica de redes neurais. Neste trabalho a previsão de vazões para os primeiros 15 dias é realizada com um sistema híbrido composto por um modelo determinístico de propagação de vazões (modelo SSARR) e redes neurais construtivas que faz a previsão das incrementais.

2. METODOLOGIA

Metodologia atual - O método da curva VOLUME x DURAÇÃO (método explicitamente estocástico) vem sendo adotado pelo setor elétrico desde 1977, BEARD (1963). Este método relaciona cada intervalo de tempo com duração de d dias consecutivos com o máximo volume afluente neste período. Este fica definido como:

$$va(d) = \max \left[\sum_{j=0}^{d-1} (q(t+j) \cdot \Delta t) \right] \quad (1)$$

em que: $v(a)$ = máximo volume afluente para a duração de d dias ; d = duração em dias ; $q(t+j)$ = vazão média diária no dia $t+j$; Δt = intervalo de discretização do tempo (1 dia = 86400 s) ; h = número de dias da estação chuvosa e t = dia.

A partir da série histórica de vazões naturais médias diárias e admitindo uma vazão defluente máxima que não cause dano a jusante (vazão de restrição), pode-se definir, para o período chuvoso de cada ano hidrológico, o volume vazio necessário para absorver cheias com qualquer duração. Este volume, denominado volume de espera, pode ser representado pela seguinte expressão:

$$ve(i) = \max[va(d) - d \cdot qr \cdot \Delta t] \quad (2)$$

sendo: $ve(i)$ = volume de espera para o período chuvoso do ano hidrológico; qr = vazão de restrição e $d = 1, 2, 3, \dots, h$.

As durações associadas a este volume são chamadas duração crítica. Um possível critério para obtenção do volume de espera a ser alocado seria selecionar o máximo volume de espera levantado na série histórica. Como, contudo, nada garante que o histórico se repetirá no futuro, ou mesmo, que seja viável a alocação deste volume, a solução mais comum leva a um estudo de frequência e à adoção de uma distribuição teórica de probabilidades.

As principais dificuldades com esta metodologia são:

- Escolha da melhor distribuição de probabilidades a utilizar.
- Não considera implicitamente a variação do potencial de cheia com o decorrer da estação chuvosa.

O método das trajetórias críticas (método implicitamente estocástico) foi desenvolvido com o objetivo de superar as limitações acima citadas, referentes ao método da curva volume X duração. O método das trajetórias críticas foi desenvolvido no CEPEL por KELMAN (1987), GTHO (1998) e permite determinar para cada dia da estação chuvosa, o volume de espera (volume vazio) associado a uma probabilidade de ocorrência p' , previamente estabelecida. É utilizado um algoritmo recursivo sobre as vazões naturais médias diárias do local a ser estudado. Partindo-se de um volume de espera nulo no final do último dia do período chuvoso, no dia h de um ano i , da vazão média diária neste dia e da descarga de restrição, determina-se o volume no início deste dia da seguinte forma:

$$ve(h, i) = \max[0, (q(h, i) - qr) \cdot \Delta t] \quad (3)$$

onde: ve = volume de espera ; h = índice do último dia do período chuvoso; $q(h, i)$ = vazão média diária no dia h do ano i ; qr = descarga de restrição e Δt = intervalo de tempo.

Ao início do penúltimo dia, o volume de espera deverá ser igual a:

$$ve(h - 1) = \max[0, (q(h - 1, i) - qr) \cdot \Delta t + ve(h, i)] \quad (4)$$

De uma forma geral, então, dispondo-se sempre do volume necessário no início do dia posterior, pode-se, recursivamente, determinar os volumes necessários nos dias anteriores:

$$ve(h - i) = \max[0, (q(h - i, i) - qr) \cdot \Delta t + ve(h, i)] \quad (5)$$

A evolução do volume de espera ao longo do tempo para o i -ésimo ano denomina-se trajetória crítica. Portanto, para cada ano i obtém-se uma trajetória crítica, de tal forma que a envoltória das mesmas garantirá que em nenhum instante, não importando o ano ocorrido, a vazão defluente será superior a descarga de restrição. A envoltória é definida por:

$$v'(t) = \max[ve(t, i); i = 1, 2, \dots, n] \quad (6)$$

em que: $t = 1, 2, 3, \dots, h$.

Como a seqüência de vazões futuras não é conhecida, adota-se, assim como no caso da curva volume X duração, uma abordagem probabilística, sendo que neste caso o universo de possíveis seqüências de vazões futuras é obtido através de séries sintéticas de vazões. A utilização de séries sintéticas faz-se necessário, haja vista, que as séries históricas nos locais de interesse não ultrapassam geralmente 70 anos de histórico. Como, provavelmente, a alocação da envoltória obtida das séries sintéticas de vazões seria inviável, é necessário a aceitação de alguma probabilidade p' de insucesso no controle de cheia. Define-se, então, um conjunto de k trajetórias críticas que não serão consideradas na determinação da envoltória de volumes de espera. A eliminação das k trajetórias críticas é realizada segundo critério que prioriza a retirada de trajetórias que apresentam as menores taxas de reenchimento para cada um dos tempos de retorno considerados.

METODOLOGIA PROPOSTA - O reservatório analisado no presente estudo é o reservatório de Sobradinho, localizado no rio São Francisco. Nosso problema é, pois, estabelecer a estratégia operacional ótima deste reservatório durante uma estação de cheias. O objetivo é atender as demandas existentes, mantendo o risco de rompimento da descarga de restrição dentro de um dado limite admissível, ao mesmo tempo em que se pretende maximizar o volume armazenado remanescente ao final da estação chuvosa.

- Formulação Matemática

O problema pode ser formulado como segue:

$$\max\{S(t + 1)\} \quad (7)$$

Sujeito a:

$$S(t + 1) + S(t) + X(t) - d(t) \quad (8)$$

$$0 \leq S(t) \leq SM \quad (9)$$

$$d_m(t) \leq d(t) \leq dM(t) \quad (10)$$

$$P\{d(t) \geq dM(t)\} \leq PM(t) \quad (11)$$

Onde:

$S(t)$ Volume armazenado no reservatório no início do intervalo de tempo t .

$X(t)$ Afluência hídrica ao reservatório durante o intervalo de tempo t .

$d(t)$ Descarga controlada do reservatório, a ser operada de forma a atender o objetivo de maximizar $S(t + 1)$ e manter a probabilidade de superação do volume de espera do volume de espera dentro do limite admissível, durante o intervalo de tempo t .

SM Armazenamento correspondente ao limite máximo operacional.

$dM(t)$ descarga de restrição.

$d_m(t)$ Descarga mínima a ser realizada, para atendimento energético e outros usos.

P Denota probabilidade.

PM Probabilidade máxima admissível de que o armazenamento $S(t)$ seja maior do que SM .

T É o intervalo de tempo final do período de cheias.

2.1 Abordagem com decisões táticas e estratégicas.

A abordagem com decisões táticas e estratégicas consiste em realizar o controle do reservatório no curto prazo (período para o qual as previsões são consideradas de boa qualidade) considerando as Informações sobre o futuro de longo prazo, ou seja, considerando as Informações sobre o futuro de longo prazo, ou seja, considerando os volumes de espera estabelecidos por uma das metodologias de planejamento em uso (método da curva volume X duração ou trajetórias críticas), figura 1.

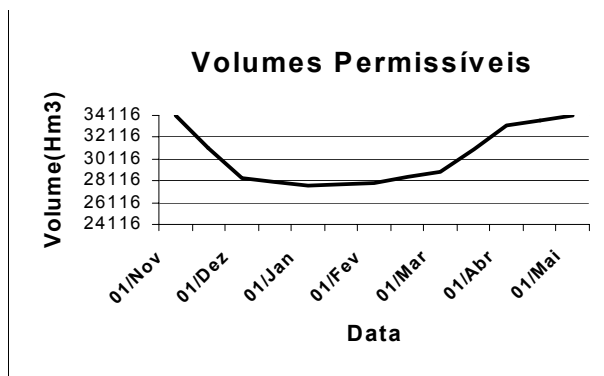


Figura 1 – Volumes permissíveis (metodologia atual)

A metodologia proposta segue as seguintes etapas:

- Informações sobre o futuro de longo prazo, que são os volumes máximos permissíveis estabelecidos pela metodologia atual;
- Estado do sistema, que representa a situação em tempo real do reservatório em termos de volume e vazão defluente;
- Previsão do futuro a curto prazo, que representa as prováveis vazões afluentes para o período para o qual desejamos realizar a otimização;
- Seqüências de decisões a curto prazo (decisões táticas) sem ir contra a estratégia operacional, dentro de certos limites de tolerância, que representa as vazões defluentes a serem liberadas a cada semana (curto prazo), com o objetivo de manter a estratégia para os próximos 21 dias à frente (estratégia de médio prazo), figura 2.

Na figura 2 cada ponto em destaque representa o volume do reservatório no início de cada semana.

Logo de acordo com esta figura nosso objetivo é chegar ao final da terceira semana (volume objetivo), flexibilizando-se os volumes permissíveis no início das duas semanas intermediárias, ao mesmo tempo em que se procura obedecer às restrições impostas (físicas e probabilísticas). Neste caso os erros de previsão serão considerados como uma composição dos 2 modelos de previsão utilizados, isto é, o modelos híbrido (redes neurais e SSARR) para as duas primeiras semanas e redes neurais construtivas para a última semana.




Figura 2 – Tática de curto prazo

Formulação Matemática

$$Atingir\{SE(N+1)\} \quad (12)$$

em que: $SE(N+1)$ = volume permissível estratégico de longo prazo (N dias à frente, neste caso 21 dias).

Sujeito a:

$$S(t+1) = S(t) + X(t) - d(t); t = 1, 2, \dots, N \quad (13)$$

$$S_{\min} \leq S(t) \leq S_{\max} \quad (14)$$

$$d_{\min} \leq d(t) \leq d_{\max} \quad (15)$$

$$P[S(N+1) \geq SE(N+1)] \leq PM(t) \quad (16)$$

2.2 Restrição probabilística

A verificação da viabilidade das restrições físicas é imediata. Dificuldade aparece na verificação da restrição da equação de restrição probabilística. Para isto ser possível temos que escrevê-la na seguinte forma:

$$P[S(N+1) > SE(N+1)] = \sum_{x_1}^{\infty} P[x(t) | x'(t)] \quad (17)$$

em que:

$$x_1 = \max\{0, [SE(N+1) - (S(N) - d(N))]\} \quad (18)$$

2.3 Estimativa da Distribuição de Probabilidade Condicional.

$$P(x(t) | x'(t)) \quad (19)$$

A probabilidade de que ocorra x_t tal que tenhamos previsto x'_t

Seus valores serão retirados da parte aleatório do modelo de previsão, através do ajuste de uma distribuição de probabilidade aos erros de previsão.

O modelo de previsão será composto por um sistema híbrido entre um modelo de propagação conceitual modelo SSARR (*Streamflow Synthesis And Reservoir Regulation*) e redes neurais construtivas. Neste trabalho utilizamos uma nova classe de redes neurais *feedforward* de alta ordem, chamada de redes neurais com Blocos de Regressões Sigmóides Não-lineares (NSRBN – *Non-linear Sigmoidal Regression Blocks Networks*) desenvolvida por VALENÇA (1999), VALENÇA e LUDERMIR (2001b). Esta rede é responsável pela previsão das vazões incrementais diárias

que são somadas em cada trecho para serem propagadas com o modelo SSARR para os primeiros 15 dias, bem como são utilizadas para realizar as previsões para os 7 dias restantes de forma a perfazer 21 dias.

Portanto, esta restrição será transformada numa restrição física a ser otimizada de forma iterativa em tempo real, da seguinte maneira:

$$\text{Atingir}\{SE(N+1)\}, 21 \text{ dias à frente} \quad (20)$$

$$SE(N+1) = S(t) + X(t) - d(t) \quad (21)$$

em que: $t=1,2,3, \dots,N$.

Com os modelos de previsão podemos obter o valor da vazão máxima afluente para uma dado risco, isto é:

$$x(t) = x(\text{previsto}) + Q(\text{erro}) \quad (22)$$

onde:

$Q(\text{erro}) = \text{Valor obtido para probabilidade } p(\%)$

Desta forma o volume máximo permissível para o início da última semana será:

$$S(t) \leq SE(N+1) - x(t) + d(t) \quad (23)$$

Seqüência de otimização

- Realizar previsão, 15 dias com modelo híbrido composto de modelo conceitual determinístico e redes neurais e mais 7 dias com Redes Neurais;

- Estabelecer risco admissível de violação do volume objetivo;

- Determinar as defluências que otimiza o problema, considerando as restrições. **A técnica de Algoritmos Genéticos será utilizada com este propósito;**

- Repetir este procedimento a cada semana, de tal forma que apesar de analisar 21 dias à frente a otimização é semanal, ou seja, o resultado é utilizado apenas para a primeira semana.

2.4 Modelo de previsão de vazões

Para realização da metodologia proposta, utilizamos 2 modelos de previsão, o primeiro é um modelo de previsão que agrega o modelo de propagação SSARR para os trechos entre Três Marias e Sobradinho e um modelo de redes neurais construtivas que faz a previsão das vazões incrementais entre os diversos trechos do rio e um segundo que é um modelo estocástico de vazões para o qual faz-se uso exclusivo das redes neurais construtivas, VALENÇA (2000), VALENÇA e LUDERMIR (2001a), VALENÇA e LUDERMIR (2001b). Este modelo híbrido com redes neurais construtivas e modelo SSARR foi batizado por nós de PLANEURO. Com este objetivo utilizamos aqui o modelo de redes neurais compostas por blocos de sigmóides auto-organizáveis que apresentou os melhores resultados quando comparados com as metodologias estatísticas tradicionais VALENÇA e LUDERMIR (1999a), VALENÇA e LUDERMIR (1999b), VALENÇA e LUDERMIR (1999c), VALENÇA *et al* (2001). As Redes NSRBN foram propostas por Valença na sua tese de Doutorado em 1999, VALENÇA (1999).

2.5 Técnica de otimização (algoritmos genéticos)

A técnica de Algoritmos Genéticos será utilizada com este propósito. Os AGs pertencem à classe dos métodos de busca estocástica, entretanto operam sobre uma população de soluções, GOLDBERG (1989).

Para usar um AG, devemos codificar soluções numa estrutura que possa ser armazenada no computador. Este objeto é o Genótipo.

2.5.1 Sequência de otimização

- Escolher população inicial de cromossomos;
- Avaliar cada cromossomo da população;
- Criar novos cromossomos aplicando mutação e crossover a pares de cromossomos pais;
- Eliminar os indivíduos menos aptos, deixando mais espaço para novos cromossomos;
- Inserir novos cromossomos na população;
- Se convergiu, parar e retornar melhor cromossomo. Senão, ir para o passo 2.

Fase de reprodução

- N indivíduos da população são selecionados aleatoriamente (favorecendo os mais aptos);
- Pares de indivíduos selecionados são combinados;
- São produzidos descendentes (próxima geração);
- Indivíduos mais aptos serão provavelmente selecionado várias vezes;
- Indivíduos menos aptos podem nem ser selecionados;
- Cromossomos são combinados utilizando operadores genéticos.
 - Crossover
 - Mutação

2.5.2 Seleção

- Escolhe preferencialmente, embora não exclusivamente, indivíduos com maiores notas de aptidão (procurar manter a diversidade da população);
- Método da Roleta escolhe indivíduos para fazer parte da próxima geração, através de um sorteio;
- Cada indivíduo da população é representado na roleta proporcionalmente ao seu índice de aptidão;
- Elitismo para que os melhores indivíduos não desapareçam da população pela manipulação dos operadores genéticos.

2.5.3 Crossover (figura 3)

- Recombinação de características dos pais durante a reprodução;
- Permite que as próximas gerações herdem essas características;
- Funcionamento: pega dois indivíduos e divide seus cromossomos em uma posição aleatória;
- É o operador genético predominante, a taxa de crossover deve ser maior que a taxa de mutação (taxa de crossover: $0.6 < P_c < 1.0$, caso crossover não seja aplicado, descendentes são iguais aos pais);
- É a operação mais importante para exploração rápida do espaço de busca.



Figura 3 – Exemplo de CROSSOVER

2.5.4 Mutação (figura 4)

Introdução e manutenção da diversidade genética (aplicado a cada indivíduo após crossover);

Altera randomicamente um ou mais componentes de uma estrutura escolhida;

Assegura que a probabilidade de se chegar a qualquer ponto do espaço de busca nunca será zero;

Operador genético secundário (taxa de mutação pequena $P_m \cong 0.001$).

Antes da Mutação: 1 1 1 0 0

1 1 1 0 0

Depois da Mutação: 1 1 0 0 0

Figura 4 – Exemplo de MUTAÇÃO

2.5.5 Convergência

- GA estiver corretamente implementado, a população evolui em gerações sucessivas;

- Aptidão do melhor indivíduo e do indivíduo médio aumenta em direção a um ótimo global.

2.5.6 Escolha dos parâmetros

- Escolhidos de acordo com o problema;

- Quantos cromossomos em uma população (poucos: efeitos pequenos do crossover; muitos: aumenta tempo de computação);

- Taxa de mutação (baixa: mudanças lentas; alta: traços desejados não são mantidos, caos).

2.5.7 Sequência de otimização

- Escolher população inicial de cromossomos;

- Avaliar cada cromossomo da população;

- Criar novos cromossomos aplicando mutação e crossover a pares de cromossomos pais;

- Eliminar os indivíduos menos aptos, deixando mais espaço para novos cromossomos;

- Inserir novos cromossomos na população;

- Se convergiu, parar e retornar melhor cromossomo. Senão, ir para o passo 2.

3. APLICAÇÃO

Com objetivo de testar a metodologia proposta, realizamos a simulação do reservatório de Sobradinho, para 4 períodos distintos: o período de novembro de 1983 a abril de 1984 e novembro de 1989 a abril de 1990, que caracterizam períodos de baixas vazões, enquanto o período de novembro de 1978 a abril de 1979 quando ocorreu a maior cheia do histórico e o período de

novembro de 1945 a abril de 1946, quando ocorreu uma cheia com período de retorno similar a que se deseja controlar.

O processo algoritmo genético, para este problema tem como função objetivo, atingir o volume de planejamento para 21 dias à frente. A população de soluções (indivíduos) são as vazões defluentes a cada instante de tempo (médias diárias ou semanais).

Portanto, o objetivo consiste em atingir o volume objetivo 21 dias à frente, otimizando-se as vazões defluentes, obedecendo as restrições impostas, físicas e probabilísticas. Neste caso as simulações foram realizadas assumindo-se um risco de 5%, para violação do volume objetivo.

Os elementos principais do algoritmo são: a função objetivo e seu valor a ser atingido (volume objetivo 21 dias a frente); os cromossomos ajustáveis (vazões a defluir nas próximas semanas); o tipo de cromossomo utilizado (neste caso contínuo) e as constantes utilizadas (neste caso valores máximos e mínimos de volumes do reservatório). Para este problema utilizamos as seguintes opções para o AG:

Tamanho da população (neste caso 50); Comprimento do cromossomo (neste caso iniciamos com 8 e terminamos com 16-bits); A taxa de crossover (igual aqui a 0,90); A taxa de mutação (neste caso igual a 0,01); A taxa de renovação da população (igual a 0,98); A estratégia de seleção (elitista) e o operador diversidade. As figuras 5 e 6 apresentam os resultados comparativos entre as duas metodologias.

Os resultados das simulações mostram claramente a vantagem da metodologia, haja vista, que com esta abordagem conseguimos chegar ao fim do período de chuvas em 1984 com o reservatório cheio o que não ocorre com a metodologia de simulação com volumes de espera estático (planejamento). A curva de cor azul que representa a metodologia atual mesmo com 15 dias de previsão determinística (modelo de simulação MSRCE-modelo de simulação de reservatórios), não foi capaz de reencher o reservatório. Por outro lado, a curva verde, representativa da otimização com algoritmos genéticos é capaz de reencher o reservatório, tendo-se um ganho de volume da ordem de 1,7 bilhões de m^3 . Nesta simulação não foi necessário liberar vazões superiores à restrição de 8000 m^3/s . A mesma vantagem, apesar de menor escala acontece para o período de 1989/90, neste caso nenhuma das metodologias garante o reenchimento, entretanto com a metodologia proposta o reservatório atinge um volume significativamente superior.




Figura 5 – Volumes permissíveis em tempo real e planejados (1983/1984)

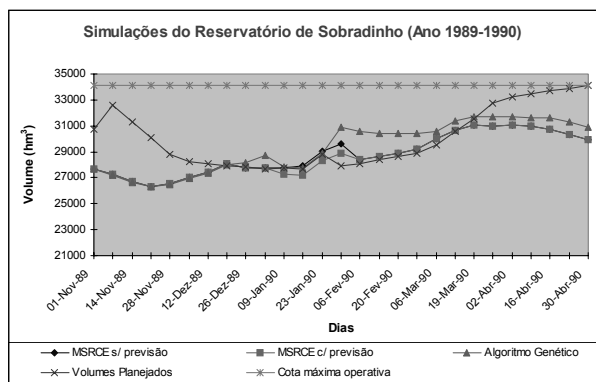


Figura 6 – Volumes permissíveis em tempo real e planejados (1989/1990)

4. CONCLUSÕES

A análise das metodologias foi realizada com dois objetivos: maximizar a geração de energia elétrica e atendimento as metas estabelecidas de controle de cheias. Os resultados obtidos para os dois eventos analisados mostram claramente que o método proposto apresentou resultados significativamente superiores, no que diz respeito a geração de energia. Quanto ao controle de cheias, caracterizado aqui pelo número de falhas, que representa o número de dias em que a vazão defluente (vertida + turbinada) excedeu a vazão de restrição que é igual a 8000 m³/s, os resultados foram similares, ou seja, ambas as metodologias passaram 36 dias acima deste valor.

Logo podemos concluir que a metodologia proposta (volume de espera dinâmico) através de um sistema inteligente nestes casos simulados tem grande vantagem em relação a metodologia atual (volumes de espera estáticos) uma vez que permite uma maior flexibilidade de reenchimento do reservatório sem causar prejuízos ao controle de cheias.

5. Referências

BEARD, L. R., (1963), *Flood Control Operation of Reservoir*, Journal of the Hydraulics Division, ASCE, Volume 89, Proc. Paper 3380, pp 8-10, 21-23.
 OLDBERG, D. E. (1989). *Genetic Algorithms in Search, optimization, and Machine Learning*. Reading, MA:

Addison-wesley, 412 pp..
 GTHO, (1998), *Prevenção de Cheias nos Aproveitamentos do Sistema Interligado - 1997/1998*.
 VALENÇA, M. J. S. (1999). *Análise e Projeto de Redes Neurais com Abordagem Construtiva para Modelagem de Sistemas Complexos*. Tese de Doutorado, UFPE, Brasil.
 VALENÇA, M. J. S. e LUDERMIR, T. B. (1999a). *Multiplicative-Additive Neural Networks with Active Neurons*. International Joint Conference on Neural Networks (IJCNN), IEEE, Book of Summaries (2073), Washington, DC, July.
 VALENÇA, M. J. S. e LUDERMIR, T. B. (1999b). *Self-organization Sigmoidal Blocks Networks*. International Joint Conference on Neural Networks (IJCNN), IEEE, Book of Summaries (2086), Washington, DC, July.
 VALENÇA, M. J. S. e LUDERMIR, T. B. (1999c). *Uma Rede Neural Construtiva com Atualização dinâmica dos Pesos*. IV Congresso Brasileiro de Redes Neurais, pp. 114-117, ITA, São José dos Campos, Julho.
 VALENÇA, M. J. S. e LUDERMIR, T. B. (2000). *Neural Networks vs. PARMA Modelling: case studies of river flow prediction*. VI Symposium on Neural Networks (SBRN), Published by the IEEE Computer Society, pp. 113-116, Rio de Janeiro, Brazil, November.
 VALENÇA, M. J. S. e LUDERMIR, T. B. (2001a). *Constructive Neural Networks in Forecasting Weekly River Flows*. International Conference on Computational Intelligence and Multimedia Applications (ICCIMA), accepted, Published by the IEEE Computer Society, Yokosuka City, Japan.
 VALENÇA, M. J. S. e LUDERMIR, T. B. (2001b). *Multivariate Modelling of Water Resources Time Series Using Constructive Neural Networks*. V Congresso Brasileiro de Redes Neurais, pp. 163-168, PUC, Rio de Janeiro, Abril.
 VALENÇA, M. J. S. e LUDERMIR, T. B. (2001c). *Redes Compostas por Blocos de Regressões Sigmóides Não-Lineares: uma eficiente rede de alta ordem com aplicações na previsão de séries temporais*. V Congresso Brasileiro de Redes Neurais, pp. 67-72, PUC, Rio de Janeiro, Abril.
 VALENÇA, M. J. et al (2001). *Previsão de Vazões de Longo Prazo Utilizando Redes Neurais*. XVI Seminário Nacional de Produção e Transmissão de Energia Elétrica, Grupo IX, pp. 1-6, CD-ROM.