

Otimização Estocástica Implícita e Redes Neurais Artificiais para Auxílio na Operação Mensal dos Reservatórios Coremas - Mãe d'Água

Tatiane Carolyne Carneiro*, Camilo Allyson Simões de Farias*
tatianecarolyne@oi.com.br, camiloallyson@yahoo.com.br

Recebido: 20/07/12 - revisado: 06/01/13 - aceito: 05/08/13

RESUMO

Este trabalho apresenta regras mensais baseadas em Otimização Estocástica Implícita (OEI) e Redes Neurais Artificiais (RNA) para operação de um sistema de reservatórios localizado no sertão paraibano. Este sistema hídrico está inserido no semiárido nordestino, região que sofre periodicamente com a escassez de água. A técnica de OEI consiste em otimizar a operação do sistema usando um conjunto de possíveis cenários de entrada e, posteriormente, na utilização dos dados ótimos gerados para construção de regras operacionais. Neste estudo, utilizou-se RNA para relacionar alocações mensais dos reservatórios com o volume inicial e vazão esperada para o mês corrente. Os cenários sintéticos de vazões afluentes foram obtidos a partir do Método dos Fragmentos (MF). Os resultados gerados pelo MF indicam que o modelo apresenta potencial para simulação estocástica de vazões mensais em regiões semiáridas. As regras operacionais mensais obtidas com o modelo OEI-RNA foram aplicadas para operação dos reservatórios Coremas - Mãe d'Água sob novos cenários de vazões e um índice de vulnerabilidade foi utilizado para fins de análise. Os resultados indicam que o modelo OEI-RNA é superior a regra de operação padrão e similar a um modelo determinístico com o conhecimento de todo o horizonte de operação. Sendo assim, espera-se que este modelo possa servir como suporte na tomada de decisão para operação mensal de reservatórios em regiões semiáridas.

Palavras-chave: Operação de reservatórios. Redes neurais artificiais. Otimização estocástica implícita.

INTRODUÇÃO

O crescimento populacional e consequente aumento das demandas por alimento e energia são os principais responsáveis pela crise da água no mundo. Para o atendimento a essas crescentes demandas, tanto em termos de qualidade como de quantidade, é frequentemente necessário que o sistema hídrico local seja operado e monitorado de forma eficaz (CELESTE; CURI; CURI, 2007; FARIAS, 2009; FARIAS et al., 2006; LOUCKS, 2000; VAJPEYI, 1998). Em regiões semiáridas o manejo se torna ainda mais complexo por causa das altas taxas de evaporação, má distribuição sazonal dos recursos hídricos e baixa pluviometria.

O estado da Paraíba está localizado em uma região semiárida e sofre periodicamente com episódios de seca. Estas secas podem ter seus efeitos minimizados através de um gerenciamento adequado dos recursos hídricos existentes, devendo-se considerar a variabilidade hidrológica tanto no presente quanto no futuro.

Existem diversas técnicas para mitigação dos efeitos das secas, sendo a Otimização Estocástica Implícita (OEI) uma alternativa promissora. Nesse procedimento, um modelo é usado para gerar um certo número de cenários sintéticos de entrada ao sistema (e.g., vazões). O sistema é então otimizado para esses cenários e regras de operação são produzidas por meio de modelos de regressão linear. Na maioria dos casos, estas regras operacionais relacionam alocações com o volume inicial do reservatório e vazões esperadas para um passo à frente (CELESTE et al., 2005; WILLIS; FINNEY; CHU, 1984; YOUNG JR, 1967). Diferente do uso de equações de regressão, esse estudo utiliza Redes Neurais Artificiais (RNA) com o intuito de extrair tendências não-lineares entre as variáveis envolvidas.

As RNA são um ramo da inteligência artificial que surgem para extrair modelos e detectar tendências que são muito complexas para serem percebidas por humanos ou outras técnicas computacionais. Em vez de usar uma abordagem algorítmica, as RNA processam a informação de forma similar ao sistema nervoso biológico. Elas possuem um grande número de elementos fortemente ligados trabalhando em paralelo para resolver um problema específico. Essas ferramentas aprendem através de

* UFCG/Unidade Acadêmica de Ciências e Tecnologia Ambiental

exemplos selecionados cuidadosamente, tornando-se eficazes para solução de sistemas não-lineares, na adaptação a circunstâncias, entre outras várias vantagens (FARIAS, 2009; HAYKIN, 1999; SILVA; SPATTI; FLAUZINO, 2010).

Este trabalho desenvolve e aplica um procedimento capaz de incorporar as incertezas hidrológicas para operação sustentável de reservatórios localizados na região semiárida do estado da Paraíba, Brasil. O processamento dessas incertezas será realizado através da técnica de OEI combinada com RNA.

MATERIAIS E MÉTODOS

Área de estudo

Os procedimentos e modelos desenvolvidos nessa pesquisa foram aplicados para operação do sistema hídrico Coremas - Mãe d'Água.

Os reservatórios Coremas - Mãe d'Água estão situados no extremo sudoeste da Paraíba, na bacia do Rio Piancó, que é uma sub-bacia do Rio Piranhas. A região conta com uma temperatura média anual superior a 24°C e precipitação média anual abaixo de 900 mm, sendo que 60% deste valor concentra-se entre os meses de fevereiro e abril. A evaporação potencial anual é superior a 2.300 mm, com as maiores taxas mensais no período de setembro a dezembro (LIMA, 2004). A tabela 1 apresenta as evaporações médias mensais observadas no Tanque Classe A do posto climatológico de Coremas.

Tabela 1 - Evaporação média mensal no Tanque Classe A

Evaporação Média (mm)	Jan	Fev	Mar	Abr	Mai	Jun
	272,3	215,4	204,1	182,4	183,1	182,2
	Jul	Ago	Set	Out	Nov	Dez
	219,9	271,9	299,6	332,9	319,0	310,6

Fonte: SCIENTEC, 1997.

O sistema hídrico Coremas - Mãe d'Água é composto pela junção de dois açudes, que quando atingem um determinado nível, se tornam um só reservatório. Nesta pesquisa, assim como no trabalho de Celeste, Curi e Curi (2009), o sistema é modelado como um reservatório equivalente, ou seja, o volume é considerado como a soma dos volumes individuais dos reservatórios. As vazões afluentes ao reservatório equivalente são a soma das vazões de entrada nos dois reservatórios.

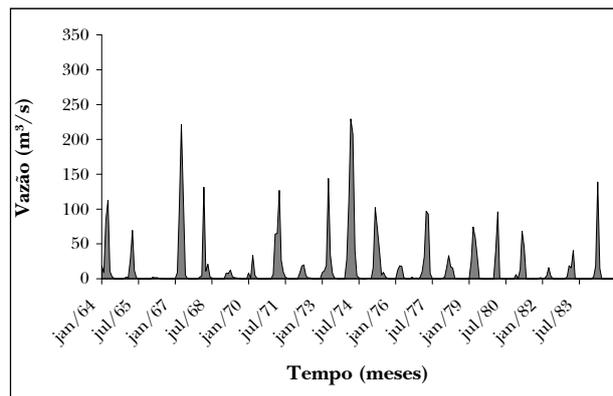


Figura 1 - Hidrograma mensal de vazões observadas afluentes ao sistema Coremas - Mãe d'Água para o período de 1964 a 1984

A maior parte das vazões afluentes aos reservatórios são provenientes de três grandes tributários: Riacho Aguiar, Riacho Emas e Rio Piancó. A figura 1 apresenta o hidrograma mensal de vazões de entrada no sistema Coremas - Mãe d'Água.

A figura 2 ilustra a localização dos reservatórios Coremas - Mãe d'Água e seus tributários.

Geração estocástica de vazões

Para aplicação do modelo de OEI é necessária a implementação de um modelo para geração sintética de vazões afluentes ao sistema hídrico com propriedades estatísticas similares às dos dados observados. O modelo escolhido para geração sintética de vazões desse estudo é o Método dos Fragmentos (MF), que tem sido vastamente utilizado para simulação estocástica de afluições (ARAÚJO; CAMPOS, 1991; CELESTE; CURI; CURI, 2007; SVANIDZE, 1980).

O MF tem como princípio básico desagregar vazões anuais em vazões mensais segundo uma forma padronizada. O primeiro passo consiste em calcular os fragmentos dividindo-se as vazões de cada mês pela soma de todas as vazões mensais do respectivo ano, como mostrado na Equação 1.

$$f(i, j) = \frac{Q(i, j)}{\sum_{j=1}^{12} Q(i, j)} \quad (1)$$

onde $f(i, j)$ e $Q(i, j)$ são, respectivamente, o fragmento e a vazão observada do mês j do ano i .

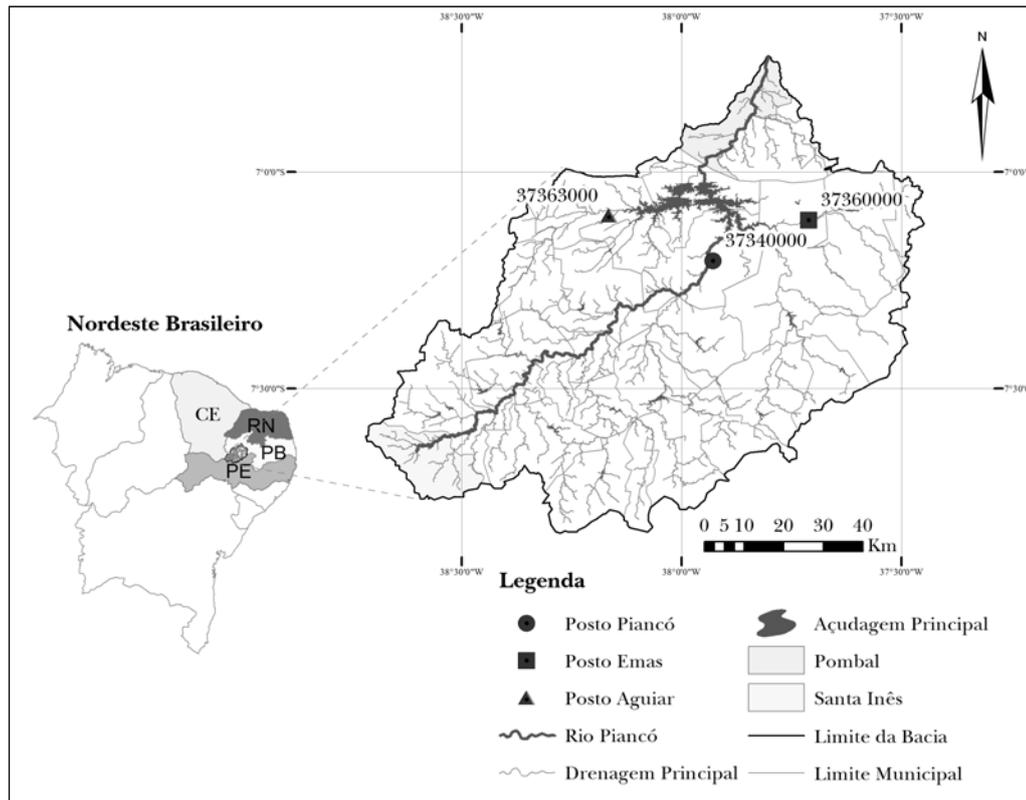


Figura 2 -Localização dos reservatórios Coremas - Mãe d'Água na bacia hidrográfica do Rio Piancó

O segundo passo consiste em avaliar as vazões anuais históricas quanto à dependência linear e, caso sejam serialmente dependentes, utilizar modelos estatísticos para produzir uma série de resíduos independente. Após esta etapa, os resíduos da série de vazões anuais históricas são modelados a uma função de densidade de probabilidade (f.d.p.) adequada.

A nova geração de vazões anuais se procede através da simulação aleatória de números pela f.d.p. modelada e pela posterior aplicação da função inversa do modelo estatístico responsável pela extração das dependências lineares. Por fim, as vazões anuais geradas são desagregadas seguindo o procedimento apresentado em Celeste, Curi e Curi (2007). Este procedimento consiste em dispor as vazões anuais dos dados históricos em ordem crescente para o estabelecimento de classes. A primeira classe tem limite inferior igual a zero e a última classe tem limite superior igual a infinito. As classes intermediárias, neste caso, são definidas pelas médias de duas vazões sucessivas. Após a definição destes limites, cada vazão anual sintética pertencerá a

uma classe correspondente e as vazões mensais são obtidas por meio da multiplicação dos fragmentos daquela classe pelo valor anual sintético.

Regras operacionais OEI-RNA

O modelo de OEI combinado com RNA consiste das seguintes etapas:

1. Gerar M sequências de N meses de valores de vazões afluentes ao sistema hídrico através do MF;
2. Para cada sequência de N meses, encontrar as alocações ótimas de água a partir de um modelo de otimização determinístico;
3. Usar o conjunto de dados otimizados para desenvolver regras de operação baseadas em RNA.

Na etapa (3), a alocação de água é relacionada com o volume no início do mês e vazão afluente no período corrente.

Modelo determinístico

Esse modelo assume que o principal objetivo da operação é encontrar as alocações de água que melhor satisfazem as demandas sem comprometer o funcionamento do sistema. O problema de otimização consiste em minimizar a seguinte função-objetivo:

$$\min \sum_{t=1}^N \left[\frac{R(t) - D(t)}{D(t)} \right]^2 \quad (2)$$

onde N é o horizonte de operação em meses; $R(t)$ é a alocação no mês t ; e $D(t)$ a demanda no mês t .

Alocações e volumes de cada período são relacionados com vazão afluyente, evaporação e vertimento pela equação da continuidade:

$$\begin{aligned} S(1) &= S_0 + Q(1) - R(1) - E(1) - Sp(1) \\ S(t) &= S(t-1) + Q(t) - R(t) - E(t) - Sp(t); \forall t = 2, \dots, N \end{aligned} \quad (3)$$

onde $S(t)$ é o volume do reservatório equivalente no final do mês t ; S_0 é o volume inicial do reservatório; $Q(t)$ é a vazão afluyente ao sistema durante o mês t ; $E(t)$ é a evaporação sobre a superfície líquida do reservatório durante o mês t ; e $Sp(t)$ é o vertimento que eventualmente pode ocorrer ao longo do mês t .

As limitações físicas do sistema definem as restrições para alocações, volume e vertimento como seguem:

$$0 \leq R(t) \leq D(t); \quad \forall t \quad (4)$$

$$S_{\text{morto}} \leq S(t) \leq S_{\text{max}}; \quad \forall t \quad (5)$$

$$E(t) \geq 0; \quad \forall t \quad (6)$$

$$Sp(t) \geq 0; \quad \forall t \quad (7)$$

onde S_{max} e S_{morto} são os volumes máximo e morto do reservatório equivalente, respectivamente.

Modelo de redes neurais artificiais

Esse modelo é responsável pela derivação das regras mensais a partir dos resultados ótimos gerados pelo modelo determinístico. Para isto, esse

modelo é utilizado na calibração de 12 RNA, uma para cada mês do ano.

Arquitetura e Topologia

O modelo de redes neurais consiste de um *perceptron* formado por uma camada de entrada, uma oculta e uma de saída. A camada de entrada da RNA é composta por dois neurônios, que são o volume inicial do reservatório $S(t-1)$ e a vazão afluyente corrente $Q(t)$. O número de neurônios na camada oculta NE é obtido através de um procedimento baseado em tentativa e erro. O valor de alocação $R(t)$ é o único neurônio da camada de saída.

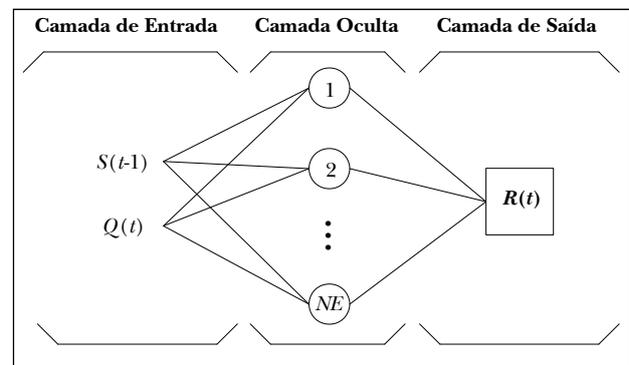


Figura 3 - Estrutura das RNA responsáveis pela definição das regras de operação

A rede é do tipo *feedforward*, ou seja, o fluxo de informações se dá para frente, da camada de entrada para oculta e da camada oculta para a de saída. A figura 3 mostra a estrutura do modelo de rede neural desse estudo.

Nesse modelo, cada elemento do vetor de entrada está conectado aos neurônios da camada oculta, e cada neurônio da camada oculta está conectado ao elemento de saída. Todo neurônio da camada oculta possui um somatório que coleta os valores das entradas multiplicados pelos pesos de suas conexões mais um limiar, resultando no chamado campo local induzido. Cada campo local induzido é submetido a uma função de ativação para que se torne o valor de entrada do neurônio da camada de saída. O neurônio da camada de saída possui o mesmo esquema dos neurônios da camada oculta e o seu campo local induzido, depois de submetido a uma função de ativação, se torna o valor de saída final da RNA.

Funções de ativação do tipo sigmóide são usadas para os neurônios da camada oculta e uma função linear é utilizada para o neurônio de saída (HAYKIN, 1999).

Calibração

Os dados originais são convenientemente escalonados para melhorar a eficiência na calibração do modelo de RNA. Esse processo consiste em normalizar as entradas e saídas desejadas de forma que tenham média igual a zero e desvio padrão unitário (BEALE; HAGAN; DEMUTH, 2012).

O treinamento da rede neural é do tipo supervisionado, i.e., os exemplos são submetidos à rede e os pesos das conexões e limiares são ajustados através das iterações com base em um sinal de erro produzido pela comparação entre o resultado atual da RNA e a saída desejada. Nesse modelo, o ajuste dos pesos e limiares é realizado pelo algoritmo de retropropagação de erro, o qual tem sido utilizado com sucesso em vários campos da engenharia (BEALE; HAGAN; DEMUTH, 2012; HAYKIN, 1999; SILVA; SPATTI; FLAUZINO, 2010). Nessa aplicação, o algoritmo Levenberg-Marquardt (LM) foi usado para retropropagação. Uma explicação detalhada do algoritmo LM pode ser encontrada em Hagan e Menhaj (1994).

O modelo tem a sua calibração encerrada pelo processo conhecido como *Early Stopping Method* (BEALE; HAGAN; DEMUTH, 2012). Este método divide os dados de calibração em dois subconjuntos: um de treinamento e outro de validação. O subconjunto de treinamento é usado para calcular gradientes e ajustar os pesos e limiares. O subconjunto de validação tem seus erros monitorados para evitar a adaptação extrema dos dados e, conseqüentemente, melhorar o grau de generalização da RNA. O treinamento é parado quando o erro no subconjunto de validação cresce por um certo número de iterações.

Regra de operação padrão

Uma das regras de operação mais simples é a conhecida Política de Operação Linear Padrão, do inglês *Standard Linear Operating Policy* (SLOP). Este modelo de simulação, que está mostrado na figura 4, estabelece que quando a quantidade de água disponível é igual ou menor que a demanda, toda água deve ser liberada para atender a demanda; e quando a água disponível supera a demanda, a demanda é atendida e o excesso de água é acumulado no reser-

vatório até atingir o volume máximo e começar a ter vertimento (LOUCKS; STEDINGER, 1981).

O modelo SLOP é aplicado ao estudo de caso para fins de comparação com as regras geradas pelo modelo OEI-RNA.

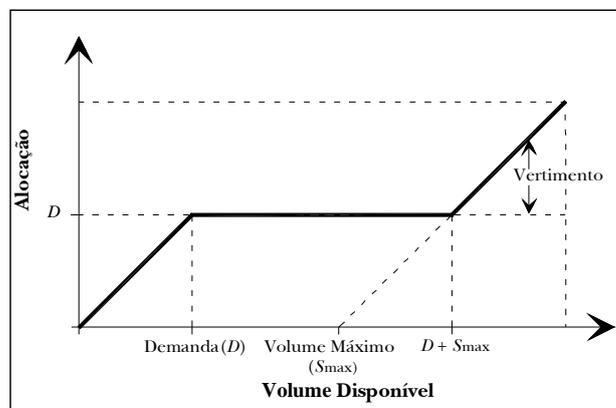


Figura 4 - Política de operação linear padrão

APLICAÇÃO E RESULTADOS

Geração estocástica de vazões

Os dados utilizados nessa pesquisa compreendem valores mensais de vazões observadas nos postos fluviométricos Piancó, Emas e Aguiar entre os anos de 1964 e 1988. Esses dados foram obtidos junto a base de dados HidroWeb da Agência Nacional de Águas (2012) e a partir do trabalho de Câmara (2000). A série de dados utilizada é a soma das vazões correspondentes nos três postos, formando uma única série de vazões. Os fragmentos para essa série de vazões foram calculados conforme a Equação 1.

De acordo com Campos (1996), as vazões anuais de rios intermitentes do nordeste brasileiro são, em geral, serialmente independentes. Portanto, essas séries podem ser diretamente geradas a partir de uma f.d.p. adequada. Celeste, Curi e Curi (2007) utilizou o MF para a mesma bacia hidrográfica desse estudo e obteve bons resultados com a utilização de uma f.d.p. do tipo Gama. Com base no estudo de Celeste, Curi e Curi (2007), optou-se pela geração das vazões anuais a partir de números aleatórios seguindo uma distribuição Gama.

Para testar o MF, 1.000 anos de vazões anuais sintéticas foram geradas e desagregadas em vazões mensais pela multiplicação dos fragmentos correspondentes. As figuras 5 e 6 mostram um comparativo entre as estatísticas mensais (média e desvio

padrão) dos valores sintéticos gerados pelo MF com as das vazões históricas.

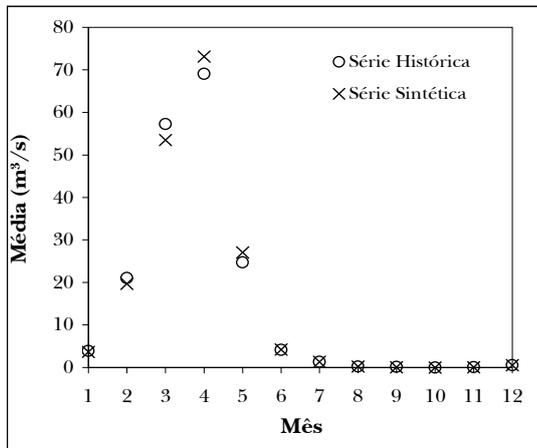


Figura 5 - Comparação entre as médias mensais da série sintética obtida pelo MF com as da série histórica

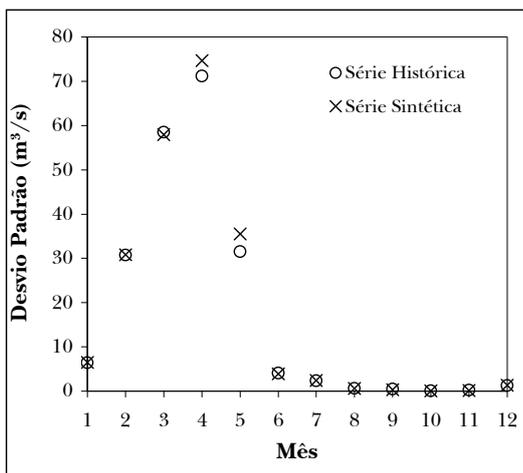


Figura 6 - Comparação entre os desvios padrão mensais da série sintética obtida pelo MF com os da série histórica

Os resultados mostram que os valores das estatísticas da série obtida com o MF são muito próximos das estatísticas dos dados observados, indicando que esse método apresenta ótimo potencial para simulação estocástica de vazões mensais em regiões semiáridas.

Regras operacionais OEI-RNA

As regras operacionais OEI-RNA, ou simplesmente modelo OEI-RNA, foram aplicadas para operação de um reservatório equivalente que repre-

sentou o sistema de reservatórios Coremas - Mãe d'Água, localizado no sertão paraibano.

Para computação da evaporação, considerou-se a área média do espelho d'água do reservatório no mês t multiplicada pela lâmina de evaporação corrigida em t . A correção das lâminas mensais de evaporação se deu pela multiplicação dos valores apresentados na tabela 1 por um fator igual a 0,8. Na prática, um fator de correção entre 0,6 e 0,8 relaciona a evaporação no Tanque Classe A com a evaporação na superfície de um reservatório (TUCCI; BELTRAME, 2012).

Os valores de demanda foram baseados nas vazões máximas disponíveis para o Sistema Curema - Açu, que estão estabelecidas na Resolução nº 687/2004 da Agência Nacional de Águas (2004). Nesse estudo, a demanda hídrica é definida como o somatório das vazões máximas disponíveis para o estado da Paraíba com a vazão mínima requerida no Rio Piranhas na divisa dos estados da Paraíba e do Rio Grande do Norte, totalizando 7,9 m³/s.

Os volumes mínimo e máximo do reservatório equivalente foram ajustados para 46,80 hm³ e 1.358,70 hm³, respectivamente. O volume inicial foi assumido como sendo igual ao volume máximo.

O modelo de OEI foi aplicado para $M = 50$ sequências de $N = 2448$ meses (204 anos) de vazões afluentes ao reservatório, que foram geradas pelo MF. Os primeiros e últimos dois anos de cada sequência foram eliminados para evitar problemas com condições de contorno. Esse processo produziu um total de 120.000 meses (50 sequências de 200 anos) de alocações ótimas.

Tabela 2 - Correlações entre alocações observadas e calculadas pelas RNA mensais

	Jan	Fev	Mar	Abr	Mai	Jun
Calibração	0,63	0,64	0,62	0,65	0,63	0,66
Teste	0,61	0,63	0,62	0,64	0,62	0,65
	Jul	Ago	Set	Out	Nov	Dez
Calibração	0,66	0,67	0,63	0,64	0,64	0,67
Teste	0,64	0,66	0,65	0,66	0,65	0,69

Os dados ótimos de volume inicial, vazão afluente e alocação para os meses de janeiro a dezembro foram agrupados e utilizados para modelagem de 12 RNA, uma para cada mês do ano. As RNA foram calibradas utilizando-se 85% dos dados (70% para treinamento e 15% para validação) e testadas com os 15% restantes. Os melhores resultados foram

obtidos com 25 neurônios ($NE = 25$) na camada oculta para todas as RNA. A tabela 2 apresenta as correlações entre alocações observadas e calculadas pelas RNA para os períodos de calibração e teste.

As correlações, tanto para os dados de calibração quanto para os de teste, foram acima de 0,60 para todas as RNA. Esse resultado mostra que as redes neurais mapearam satisfatoriamente os dados de entrada e saída, tendo em vista a complexidade da relação entre as variáveis envolvidas.

Tabela 3 - Índices de vulnerabilidade para todos os modelos

	Modelo Determinístico	SLOP	Modelo OEI-RNA
S#1	0,76	5,16	1,15
S#2	0,98	5,10	1,46
S#3	1,19	6,28	1,68
S#4	0,00	0,00	0,11
S#5	10,24	21,74	14,88
S#6	0,00	0,00	0,07
S#7	0,00	0,00	0,08
S#8	0,48	4,63	1,39
S#9	0,68	4,02	1,60
S#10	4,15	13,98	6,89

Para verificar o desempenho do modelo OEI-RNA, as regras operacionais foram aplicadas e avaliadas para 10 novas sequências com 25 anos de afluições mensais geradas pelo MF. Resultados obtidos com o modelo de otimização determinístico e com o SLOP foram utilizados para fins de comparação. Para essa análise, os primeiros e últimos dois anos das sequências também foram eliminados. Os primeiros anos são suprimidos para reduzir a influência da escolha do volume inicial do reservatório nos resultados dos modelos. Os últimos anos são eliminados por representarem o fim do horizonte de operação e, portanto, induzem o modelo determinístico ao uso de toda reserva de água disponível uma vez que não considera as demandas para os meses subsequentes. A tabela 3 apresenta os resultados de um índice de vulnerabilidade, assumido como sendo igual à função-objetivo mostrada na Equação 2, para todos os modelos avaliados. O índice de vulnerabilidade representa a magnitude das falhas ao atendimento das demandas considerando todo o horizonte de operação N . Em cada mês t , a

vulnerabilidade calculada varia entre 0 e 1, com o valor 0 indicando o atendimento total a demanda e o valor 1 retratando que nenhuma alocação foi disponibilizada. Como resultado, o índice de vulnerabilidade, ou somatório das vulnerabilidades de $t = 1$ até o final do horizonte de operação N , pode assumir valores entre 0 e N . Quanto menor o valor do índice de vulnerabilidade, menos vulnerável será considerada a regra de operação avaliada para o sistema hídrico.

Uma investigação dos resultados apresentados na Tabela 3 mostra que as regras do modelo OEI-RNA foram menos vulneráveis que o SLOP para a maioria das simulações, com exceção das simulações S#4, S#6 e S#7, situações em que sempre houve disponibilidade de água ao longo do horizonte de operação. Este resultado era esperado, uma vez que o modelo OEI-RNA tenta diminuir as alocações antes dos períodos secos e, diferente do SLOP, não libera toda a água disponível sempre que possível. Vale ressaltar que a vulnerabilidade do modelo OEI-RNA para esses casos foi muito pequena em relação às demais simulações. O modelo determinístico apresentou os melhores resultados porque fornece valores “ideais” de alocações uma vez que conhece as afluições para todo o horizonte de operação. Portanto, esse modelo possui melhores meios para derivar regras operacionais superiores.

As figuras 7, 8 e 9 mostram resultados de alocações obtidas por todos os modelos entre o terceiro e o vigésimo terceiro ano dentro da série de 25 anos para a simulação S#1. A correlação com respeito às alocações entre os resultados obtidos pelo modelo OEI-RNA e o modelo determinístico para simulação S#1 foi de 0,78. A correlação do SLOP com o modelo determinístico foi de apenas 0,40. Comparando os resultados do modelo OEI-RNA com o SLOP, pode-se notar que o modelo OEI-RNA tenta mitigar os déficits concentrados que acontecem com o SLOP pela redução das alocações antes dos períodos secos de forma a diminuir a magnitude destes déficits e, conseqüentemente, a vulnerabilidade do sistema. Análises das figuras 7 e 9 mostram que o modelo OEI-RNA tenta alocar água de maneira similar à operação com o modelo sob previsão perfeita. Estes resultados indicam que as regras derivadas são satisfatórias, uma vez que o modelo OEI-RNA tem informações apenas sobre o volume inicial e de vazão afluyente para o mês corrente, enquanto o modelo determinístico tem conhecimento de vazões para todo o horizonte de operação.

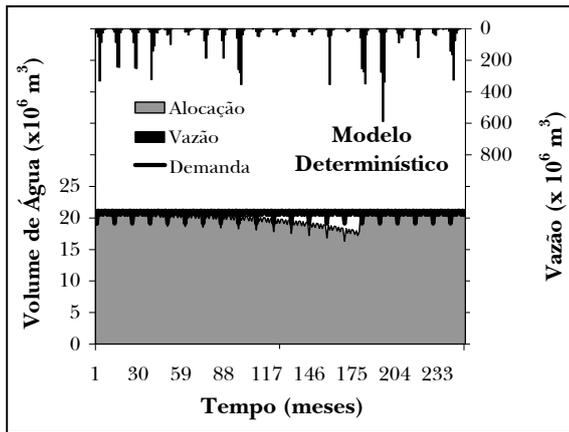


Figura 7 - Alocações de água com o modelo determinístico

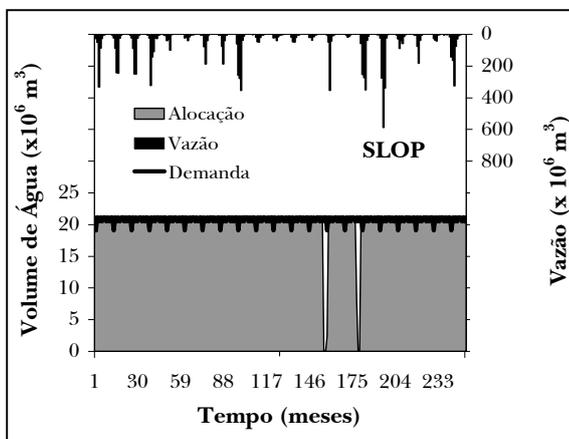


Figura 8 - Alocações de água com o SLOP

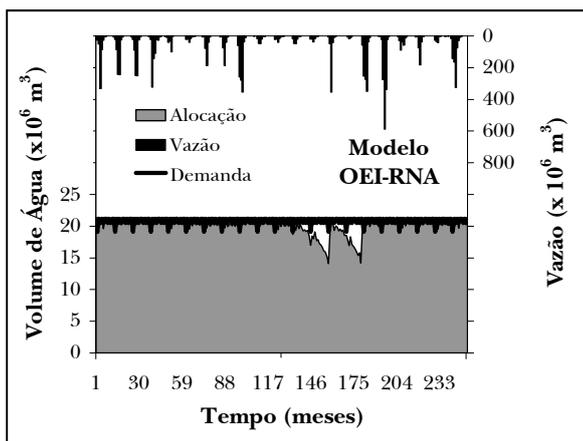


Figura 9 - Alocações de água com as regras operacionais OEI - RNA

CONCLUSÃO

Esse estudo formulou e aplicou regras operacionais mensais baseadas em Otimização Estocástica Implícita (OEI) e Redes Neurais Artificiais (RNA) para os reservatórios interligados Coremas - Mãe d'Água.

As regras operacionais OEI-RNA foram aplicadas para operar o sistema considerando-se 10 cenários mensais sintéticos e foram avaliadas segundo um critério de vulnerabilidade. Os resultados das regras OEI-RNA foram superiores aos encontrados pela política de operação padrão e equivalentes aos obtidos por um modelo determinístico sob previsão perfeita de vazões afluentes.

O modelo determinístico apresentou os melhores resultados, porém, necessita conhecer todo o horizonte de operação, o que o torna impraticável para operação em tempo real. Por outro lado, as regras operacionais OEI-RNA se mostraram as mais adequadas, uma vez que apresentaram resultados semelhantes aos do modelo determinístico e necessitam de informações apenas sobre o volume inicial e vazão afluente para o mês corrente. Sendo assim, espera-se que estas regras possam servir como suporte na tomada de decisão para operação mensal de reservatórios em regiões semiáridas.

AGRADECIMENTOS

Este trabalho foi realizado com apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq (Processo n.º 475778/2010-3). Os autores também agradecem a Artur Moisés Gonçalves Lourenço pela ajuda na confecção das figuras.

REFERÊNCIAS

AGÊNCIA NACIONAL DE ÁGUAS. Disponível em: <http://hidroweb.ana.gov.br>. Acesso em: 27 maio 2012.

AGÊNCIA NACIONAL DE ÁGUAS. *Resolução n. 687, de 03 de dezembro de 2004*. Dispõe sobre o Marco Regulatório para a gestão do Sistema Curema-Açu e estabelece parâmetros e condições para a emissão

- de outorga preventiva e de direito de uso de recursos hídricos e declaração de uso insignificante. [S.l.]: ANA, 2004.
- ARAÚJO, J. K.; CAMPOS, J. N. B. Utilização do método dos fragmentos no estudo da disponibilidade hídrica de açudes no semi-árido. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 9., 1991, Rio de Janeiro. *Anais...* Porto Alegre: ABRH, 1991. v. 1. p. 467-474.
- BEALE, M.; HAGAN, M.; DEMUTH H. *Neural network toolbox 7.0.3: user's guide*. Natick, USA: The MathWorks, 2012. 404 p.
- CÂMARA, E. P. *Otimização da água do reservatório Coremas/Mãe d'Água para múltiplos usos*. 2000. Dissertação (Mestrado) - Universidade Federal da Paraíba, Campina Grande, 2000.
- CAMPOS, J. N. B. *Dimensionamento de Reservatórios: o método do diagrama triangular de regularização*. Fortaleza: Edições UFC, 1996.
- CELESTE, A. B.; CURTI, W. F.; CURTI, R. C. Análise de métodos para geração sintética de vazões. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 17., 2007, São Paulo. *Anais...* Porto Alegre: ABRH, 2007. p. 1-18,
- CELESTE, A. B.; CURTI, W. F.; CURTI, R. C. Implicit stochastic optimization for deriving reservoir operating rules in semiarid Brazil. *Pesquisa Operacional*, v. 29, n. 1, p. 223-234, 2009.
- CELESTE, A. B.; SUZUKI, K.; KADOTA, A.; SANTOS, V. S. Derivation of reservoir operating rules by implicit stochastic optimization. *Annual Journal of Hydraulic Engineering*, v. 49, n. 2, p. 1111-1116, 2005.
- FARIAS, C. A. S. *Derivation of hedging rules and forecasts by artificial neural networks for optimal real-time management of an integrated water resources system*. 2009. 127 f. Thesis (Doctoral) - Ehime University, Matsuyama, Japão, 2009.
- FARIAS, C. A. S.; CELESTE, A. B.; SAKATA, Y.; KADOTA, A.; SUSUKI, K. Use of Monte Carlo optimization and artificial neural networks for deriving reservoir operating rules, *Annual Journal of Hydraulic Engineering*, v. 50, n. 1, p. 25-30, 2006.
- HAGAN, M. T.; MENHAJ M. B. Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, v. 5, n. 6, p. 989-993, 1994.
- HAYKIN S. *Neural networks: a comprehensive foundation*. 2nd ed. Upper Saddle River: Prentice Hall, 1999.
- LIMA, C. A. G. *Análise e sugestões para diretrizes de uso das disponibilidades hídricas superficiais da bacia hidrográfica do Rio Piancó, situada no Estado da Paraíba*. 2004. Tese (Doutorado) - Universidade Federal de Campina Grande, Campina Grande, PB, 2004.
- LOUCKS, D. P. Sustainable water resources management. *Water International, IWRA*, v. 25, n. 1, p. 3-10, 2000.
- LOUCKS, D. P.; STEDINGER, J. R.; HAITH, D. A. *Water resources systems planning and analysis*. Englewood Cliffs, USA: Prentice Hall, 1981.
- SILVA, I. N.; SPATTI, D. H.; FLAUZINO R. A. *Redes neurais artificiais para engenharia e ciências aplicadas*. São Paulo: Artliber, 2010.
- SCIENTEC. Associação para Desenvolvimento da Ciência e Tecnologia. *Plano Diretor de Recursos Hídricos da Paraíba: Bacias do Piancó e do Alto Piranhas*. [S.l.]: SEPLAN, 1997.
- SVANIDZE, G. G. *Mathematical Modeling of Hydrologic Series: for Hydroelectric and Water Resources Computations*. Fort Collins, Colorado: Water Resources Publications, 1980.
- TUCCI, C. E. M.; BELTRAME, L. F. S.: Evaporação e evapotranspiração. In: TUCCI, C. E. M. (Org.). *Hidrologia: Ciência e aplicação*. 4. ed. Porto Alegre: Editora da UFRGS/ABRH, 2012. p. 253-288.
- VAJPEYI, D. K. *Water resource management: a comparative perspective*. USA: Praezer Publishers, 1998.
- WILLIS, R.; FINNEY, B. A.; CHU, W.-S. Monte Carlo optimization for reservoir operation. *Water Resources Research*, v. 20, n. 9, p. 1177-1182, 1984.
- YOUNG JR, G. K. Finding reservoir operating rules. *Journal of the Hydraulic Division*, v. 93, n. HY6, p. 297-321, 1967.

Implicit Stochastic Optimization And Artificial Neural Networks To Support The Monthly Operation Of Coremas - Mãe d'Água Reservoirs

ABSTRACT

This paper presents monthly operating rules based on Implicit Stochastic Optimization (ISO) and Artificial Neural Networks (ANN) for the operation of a system of reservoirs in the backlands of Paraíba, Brazil. This water system is located in the Northeast of Brazil, a semiarid region that undergoes periodical water scarcity. The ISO technique consists of optimizing the system operation using a set of possible scenarios as input and then utilizing the optimal outcomes in order to construct reservoir operating rules. In this study, ANN were used for relating reservoir releases to initial storage and current inflows. The synthetic scenarios of reservoir inflows were generated by the Fragment Method (FM). The results obtained by the FM indicate that this approach has a potential for the stochastic simulation of monthly flows in semiarid regions. The monthly operating rules obtained by the ISO-ANN model were applied to the operation of Coremas - Mãe d'Água reservoirs under new scenarios of inflows and a vulnerability index was used to analyze the results. The outcomes suggest that the ISO-ANN model is superior to the standard rules of operation and similar to the application of a determinist model with the knowledge of inflows for the entire operating horizon. As a consequence, this model may support the decision-making process for monthly operation of reservoirs in semiarid regions.

Keywords: *reservoir operation, artificial neural networks, implicit stochastic optimization.*