

Estratégias Operacionais para Sistemas de Reservatórios via Algoritmos Genéticos (AGs)

Luisa Fernanda R. Reis

Departamento de Hidráulica e Saneamento - EESC - USP - Caixa Postal 359
13560-970 São Carlos, SP - Fone (16) 273-9571 - fernanda@sc.usp.br

Jorge Akutsu

Departamento de Engenharia Civil - UNESP/Bauru - Av. Eng. Luiz Edmundo C. Conde, s/n
17033-360 Bauru, SP - Fone (14) 221-6112 - joakutsu@feb.unesp.br

Recebido: 15/12/01 - revisão: 15/04/02 - aceito: 07/06/02

RESUMO

Os reservatórios geralmente são componentes essenciais dos sistemas de aproveitamentos hídricos, cujo planejamento operacional constitui alvo de investigações.

Tendo em vista o grau de dificuldade inerente ao problema de determinação de estratégias operacionais, crescente à medida que os referidos sistemas têm suas dimensões ampliadas, diversas aproximações vêm sendo propostas para sua resolução.

Atualmente, o crescente emprego das técnicas inspiradas em mecanismos robustos da natureza vem trazendo à tona os Algoritmos Genéticos (AGs) como ferramentas alternativas na resolução de tais problemas. Entretanto, diversas são as possibilidades de tratamento do mesmo problema via AGs, tendo em vista a variedade de possíveis implementações que lhes é característica, além da possibilidade de hibridização com técnicas de programação matemática convencionais, reduzindo o tempo computacional na busca de soluções.

O presente trabalho revisa a literatura pertinente na resolução do problema de operação de reservatórios via AGs e discute as potencialidades do método, através da aplicação para um sistema hidrotérmico hipotético composto de quatro usinas hidrelétricas.

Palavras-chave: operação; sistemas de reservatórios; algoritmos genéticos.

INTRODUÇÃO

Como elementos essenciais a quase todos os sistemas hídricos, os reservatórios são indispensáveis à exploração, utilização e gerenciamento do recurso natural água. Assim sendo, a busca de estratégias operacionais mais apropriadas para os reservatórios constitui tópico de atenção especial no planejamento e gerenciamento de recursos hídricos, cuja importância é ainda maior à medida que crescem a escala e a complexidade dos sistemas hídricos.

Um grande obstáculo à análise de sistemas de múltiplos reservatórios para usos também diversos, dentre os quais a geração de energia elétrica, é a dimensão que o respectivo problema pode assumir, tendo em vista a natureza sequencial do processo de decisão que requer a consideração de todas as variáveis de decisão e estado. Observa-se que a natureza aleatória relativa à ocorrência das afluições naturais constitui uma dificuldade adicional à representação das variáveis de estado, ao mesmo tempo em que a não-linearidade inerente a tais problemas dificulta a sua resolução. Assim, diversas aproximações, que podem ser classificadas em técnicas de simulação e otimização via simplificações tais como agregação seguida de decomposição do respectivo sistema de reservatórios, vêm sendo propostas para análise do problema físico real.

Se, por um lado, aproximações precisam ser empregadas na resolução do problema físico real complexo de ope-

ração de sistemas de reservatórios, por outro lado, novas técnicas de resolução para esse tipo de problema vêm sendo propostas, trazendo à tona os Algoritmos Genéticos (AGs) como ferramentas alternativas à sua resolução.

O reconhecimento da propriedade robustez, que agrega qualidades tais como eficiência e eficácia, inerentes aos processos observados na natureza, ferramentas matemáticas baseadas no conhecimento de mecanismos naturais vêm sendo utilizadas em substituição aos métodos convencionais de otimização nas mais diversas áreas do conhecimento. Nessa categoria de métodos, incluem-se os algoritmos Genéticos (AGs), as redes neurais artificiais (RNAs) e técnicas como Simulated Annealing (SA) e Ant Colony Algorithms (ACAs). As redes neurais artificiais (RNAs) são exemplos de ferramentas baseadas nas funções desenvolvidas pelo cérebro humano, através de mecanismos de transmissão de estímulos e produção de respostas do sistema nervoso, e a técnica de SA baseia-se no mecanismo de anelamento físico de metais. Tanto os ACAs como os AGs pertencem à categoria dos Algoritmos Evolucionários (AEs). Os ACAs imitam o comportamento das colônias de formigas ao estabelecer as trajetórias a serem seguidas na busca de alimentos. Os AGs são técnicas de busca estocásticas que imitam matematicamente os mecanismos de evolução natural, compreendendo os processos de seleção e genética das populações, em analogia com o processo biológico de sobrevivência e adaptação dos indivíduos mais capazes.

Algoritmos Genéticos, os mais populares dentre aqueles pertencentes à família dos AEs, são atualmente enfocados na tentativa de propor estratégias operacionais otimizantes para os sistemas de reservatórios em substituição aos modelos clássicos de otimização e simulação revisados por autores como Yakowitz (1982), Yeh (1985) e Wurbs (1993).

Constituem objetivos do presente trabalho revisar a literatura na resolução do problema de operação de reservatórios via AGs e demonstrar as potencialidades do método, através de um exemplo de aplicação simples para um sistema hidrotérmico hipotético composto de quatro usinas hidrelétricas.

Ensaio computacionais foram realizados e aqui reportados de forma a investigar aspectos não discutidos em trabalhos anteriores que também utilizaram AGs como ferramenta. Assim, o trabalho foi organizado de maneira a formular o problema, enfatizar as diversas possibilidades de implementação que a técnica de AGs oferece, revisar os trabalhos existentes e mostrar alguns resultados obtidos para o sistema analisado, visando oferecer subsídios para pesquisas futuras.

FORMULAÇÃO DO PROBLEMA DE OPERAÇÃO DE SISTEMAS DE RESERVATÓRIOS COM O PROPÓSITO DE GERAÇÃO DE ENERGIA ELÉTRICA

O problema de operação de um sistema hidrotérmico pode ser expresso como de minimização do custo relativo ao déficit esperado causado pela variabilidade dos vetores de afluentes naturais incrementais às usinas A_t ($t = 1, 2, \dots, T$), ao longo do período de planejamento T , supostamente dividido em intervalos de tempo denominados estágios tais como anos, meses, semanas, etc. Se α_t é o valor esperado do custo da operação ótima do sistema de qualquer estágio t até o último estágio T , e X_t é vetor de estado do sistema no início do estágio t , a equação recursiva para a Programação Dinâmica Estocástica (PDE) pode ser posta como (Pereira & Pinto, 1985):

$$\alpha_t = E_{A_t/X_t} \left\{ \min_{U_t} \left[C_t(U_t) + \frac{1}{\beta} \alpha_{t+1}(X_{t+1}) \right] \right\} \quad (1)$$

onde E_{A_t/X_t} representa o valor esperado sobre todos os possíveis vetores de afluentes A_t , condicionado ao vetor de estado X_t ; $C_t(U_t)$ representa o custo de operação associado ao vetor U_t de decisões para o estágio t ; e β é o fator de atualização do capital.

O Problema (1) está sujeito às seguintes restrições:

$$X_{t+1} = f_t(X_t, A_t, U_t) \quad (2)$$

$$g_{t+1}(X_{t+1}) \geq 0 \quad (3)$$

$$h_t(U_t) \geq 0 \quad (4)$$

O conjunto de equações (2) expressa as transições de estado, (3) representa as restrições sobre os volumes dos reservatórios e (4) incorpora os limites sobre as liberações hídricas.

X_t inclui todas as variáveis que podem afetar os resultados da operação: o nível de armazenamento dos reservatórios, V_t , e informações sobre a tendência hidrológica no sistema, em termos das afluições incrementais aos reservatórios durante o presente estágio, A_t . Portanto:

$$X_t = \begin{bmatrix} V_t \\ A_t \end{bmatrix} \quad (5)$$

O vetor de decisão U_t inclui as descargas através das turbinas, Q_t , e vertedouros, S_t . Portanto:

$$U_t = \begin{bmatrix} Q_t \\ S_t \end{bmatrix} \quad (6)$$

As equações de transição (2) correspondem às equações de balanço hídrico e podem ser explicitadas como:

$$V_{t+1}(i) + Q_t(i) + S_t(i) - \sum_{j \in M_i} (Q_t(j) + S_t(j)) = V_t(i) + A_t(i) \quad (7)$$

onde M_i é o conjunto de estações imediatamente a montante da usina i .

A carga energética no período t , L_t , deve ser suprida pela geração hídrica, térmica, GT_t , e energia importada de outros sistemas, IMP_t , a custo elevado.

$$\sum_{i \in N} (\rho_i \cdot Q_t(i)) + GT_t + IMP_t = L_t \quad (8)$$

onde N corresponde ao conjunto das usinas hidroelétricas do sistema e ρ_i é a produtividade da cada usina i .

As restrições de estado do sistema (3) geralmente são representadas por limites inferiores e superiores sobre os volumes dos reservatórios, representados pelos vetores V_{\min} e V_{\max} , respectivamente:

$$V_{\min} \leq V_{t+1} \leq V_{\max} \quad (9)$$

As restrições sobre as variáveis de decisão correspondem aos limites superiores para as descargas turbinadas, $Q_{\max,t}$, inferiores para as descargas totais, $U_{\min,t}$ e superiores para a geração térmica, $GT_{\max,t}$:

$$Q_t \leq Q_{\max,t} \quad (10)$$

$$Q_t + S_t \geq U_{\min,t} \quad (11)$$

$$GT_t \leq GT_{\max,t} \quad (12)$$

Nota-se que no problema de otimização definido acima pelas Equações (1) e (7) a (12), $p_i = p(V_i(i), V_{t+1}(i), Q_i(i), S_i(i))$ é função dos volumes inicial e final e da vazão turbinada da estação i , tornando a Equação (8) não-linear.

O MÉTODO DOS ALGORITMOS GENÉTICOS (AGs)

Embora a PDE seja a ferramenta natural para resolução do problema formulado, conhecidas limitações tais como a “maldição da dimensionalidade” inviabilizam-na.

Os AGs diferem dos métodos de busca clássicos, pois partem de um conjunto de soluções alternativas aleatórias denominado população, onde cada indivíduo (cromossomo) representa uma solução para o problema em mãos, que reúne um conjunto de atributos na forma de códigos. Tais atributos permitem que os indivíduos sejam avaliados e ordenados de acordo com o critério explicitado pela Função Objetivo (F.O.) ou de aptidão, de acordo com a qual, são reproduzidos ou não. Para criar uma nova população, cromossomos chamados descendentes são formados pela união de dois cromossomos pais da geração atual, através do operador recombinação (*crossover*), e, em seguida modificados, através do operador mutação (*mutation*). Assim, novas populações são formadas sucessivamente, mantendo as soluções (cromossomos) mais aptas e descartando as menos qualificadas, para que seja mantido o mesmo tamanho da população inicial, até a convergência para uma solução “ótima”.

A tecnologia de AGs, cujos detalhes podem ser obtidos em livros texto como Goldberg (1987), Michalewicz (1994) e Gen & Cheng (1997), apresenta vantagens sobre os métodos de busca tradicionais por utilizar regras de probabilidade na transição de um conjunto de soluções de uma iteração para outra, além de possuir flexibilidade quanto aos tipos de funções objetivo, sem exigências quanto a propriedades como continuidade e existência das derivadas. As múltiplas soluções mais aptas produzidas pelos AGs são consideradas “próximas da ótima”. Maior confiança com respeito à otimalidade da solução obtida pode ser estabelecida pela aplicação repetida dos AGs ao problema, partindo-se de conjuntos de soluções iniciais aleatórias distintas e verificando-se a repetitividade das soluções.

Visando a resolução do problema formulado via AGs, é conveniente que os princípios básicos da ferramenta sejam aqui elucidados com o propósito de auxiliar os leitores não familiarizados com a técnica.

A terminologia dos AGs refere-se aos indivíduos ou cromossomos de uma população para representar as soluções alternativas. Os cromossomos reúnem unidades chamadas genes, que representam as variáveis de decisão do problema em estudo, dispostos em fila de maneira que cada gene controla a herança de uma ou mais características do indivíduo a que pertence. A posição de um gene é chamada loco e seu valor alelo. O código genético de um gene é denominado genótipo e o conjunto decodificado de

variáveis de decisão é o fenótipo do cromossomo. Cada cromossomo representa completamente uma solução potencial para o problema de otimização e as populações criadas sucessivamente são chamadas gerações. Tais gerações são criadas mediante à seleção de indivíduos de uma população para serem pais, cujos filhos darão origem à próxima geração.

Assim, a implementação de AGs para resolver um problema particular requer:

- a escolha da sistemática de representação dos grupos de variáveis de decisão que representam completamente soluções potenciais para o problema em mãos, cujos valores se pretende determinar;
- a geração de uma população inicial de soluções alternativas geralmente aleatórias para o problema;
- a definição do módulo de avaliação da performance das soluções, denominada Função Objetivo (F.O.) ou de Aptidão;
- a especificação dos operadores genéticos para a realização dos mecanismos de seleção, recombinação e mutação; e
- a escolha dos parâmetros dos AGs tais como probabilidades de recombinação e mutação, tamanho da população, etc.

Representação das soluções

Os cromossomos, que são representações das soluções, podem ser codificados de diversas maneiras (binários, inteiros, reais, etc.), dependendo da conveniência.

Tipos de AGs

O conjunto completo de cromossomos em qualquer estágio da otimização representa uma geração, sendo que a população inicial de indivíduos ou soluções alternativas é gerada aleatoriamente no início do processo de otimização. Existem duas principais maneiras de acordo com as quais o processo iterativo evolui, produzindo populações subsequentes (Michalewicz, 1994):

- criando-se indivíduos filhos (novas soluções candidatas) em número suficiente para substituir a população presente, cujo procedimento é chamado substituição *geracional*, ou
- criando-se um número reduzido de indivíduos filhos em substituição aos piores p indivíduos da presente iteração ($p \geq 1$), de acordo com um procedimento chamado *steady-state*. Assim, poucos membros da população são modificados em cada iteração.

Seleção de pais

Os indivíduos pais de uma geração são escolhidos de maneira a maximizar a probabilidade de produção de filhos

mais aptos ou adaptados, ou seja, que representem melhores soluções para o problema em estudo. Assim, o operador seleção determina os indivíduos a sofrerem recombinação e mutação, proporcionalmente ao seu valor de aptidão. O método mais comumente utilizado é o da roleta, também conhecido como amostragem estocástica com substituição. Observa-se que dessa maneira indivíduos representantes de valores de aptidão pobres podem ser selecionados.

Técnicas de seleção alternativas existem como aleatória uniforme e por torneio (Goldberg & Deb, 1990). A seleção tipo torneio faz os indivíduos competirem diretamente, com base nos respectivos valores da função de aptidão (*fitness*). Uma maneira simples de implementá-lo é escolher aleatoriamente apenas dois indivíduos e preservar o melhor deles para a próxima geração, repetidamente até que uma nova geração seja formada.

A seleção baseada na ordenação (*rank*) das soluções dentro da população, ao invés dos valores da função de aptidão, é também utilizada, uma vez que a ordenação introduz uma escala uniforme automática.

Diversas são as propostas para a escala dos valores da função de aptidão na população. Dentre elas destaca-se a escala linear, fazendo que o melhor valor da função de aptidão assuma um valor a vezes superior à média e o valor menor $1/a$ vezes menor que a média da população. A constante a possui valor geralmente compreendido entre 1,5 e 2,5. Essa sistemática evita a reprodução excessiva e a consequente rápida convergência para um eventual grande valor da função de aptidão das iterações iniciais, quando tais valores podem ser muito distintos. Ao mesmo tempo, possibilita que as pequenas diferenças nos valores de F.O. sejam acentuadas próximo da convergência para um ótimo local, quando tais diferenças tornam-se muito pequenas (Meier & Barkdoll, 2000).

Recombinação

A recombinação ou cruzamento é o mecanismo de criação de indivíduos (novas soluções) filhos através da recombinação de indivíduos pais (soluções atuais). É o operador que torna os AGs diferentes dos outros algoritmos evolucionários. Geralmente é realizada através da simples permuta ou da combinação de características correspondentes entre soluções pais, sendo que o primeiro esquema mostra-se adequado ao caso de soluções representadas através de código binário, enquanto que o segundo é mais utilizado quando o alfabeto de representação de soluções é real.

A recombinação pode ser realizada de diversas maneiras. Dentre as mais usuais, pode-se citar os cruzamentos de um ponto, dois pontos e uniforme (Wardlaw & Sharif, 1999). O cruzamento de um ponto prevê a criação de cromossomos a partir da troca de genes de determinada posição escolhida aleatoriamente até o comprimento total do *string* (cadeia de códigos representativos de determinada solução). O cruzamento de dois pontos define novos indivíduos a partir da troca de informações genéticas entre

dois pontos aleatoriamente escolhidos dos cromossomos pais. Já o cruzamento uniforme prevê que genes individuais sejam considerados na troca de informações para criação de novos indivíduos, ao invés de blocos de genes ou material genético.

Mutação

A mutação é a sistemática que possibilita a introdução de características genéticas novas às soluções existentes, através da eventual substituição de genes dos indivíduos. Geralmente é realizada bit por bit (no caso de código binário) ou gene por gene (código real), possibilitando que cada bit ou gene seja alterado com uma pequena probabilidade ou taxa p_m entre 0.001 e 0.1, geralmente constante, ou variáveis de acordo com técnicas avançadas de ajuste dinâmico.

Diversas são as possibilidades de mutação. A mutação uniforme é realizada de forma que cada elemento ou gene de um cromossomo possui exatamente a mesma chance de sofrer mutação. A mutação não uniforme é um dos operadores responsáveis pelo refinamento das soluções, através de incrementos controlados nos valores das variáveis de decisão de acordo com a iteração.

A mutação uniforme modificada, segundo Wardlaw & Sharif (1999), permite a modificação de um gene de uma quantia positiva ou negativa especificada. Tais autores empregaram a referida sistemática, mas não especificam claramente o procedimento adotado.

Condição de finalização

Após a aplicação dos operadores de recombinação e mutação, a nova população está pronta para a próxima avaliação, e o ciclo se repete até que a condição de finalização seja considerada satisfeita. O critério de finalização mais simples é realizar um determinado número de iterações. Entretanto não se conhece a priori o número de gerações mais apropriado a determinado tipo de problema. Podem ser usados critérios alternativos de convergência baseados no fato de que, ou a maioria dos cromossomos é idêntica, ou nenhuma melhora significativa no valor da função de aptidão ocorreu para um determinado número de gerações.

Estratégia da reprodução preferencial

Os operadores de seleção e cruzamento tendem a assegurar que o melhor material genético (informações relevantes) e os componentes dos cromossomos mais adaptados sejam levados para frente, para as próximas gerações. Entretanto, dada à natureza probabilística desses operadores, nem sempre é esse o caso.

A estratégia da reprodução preferencial (elitismo) simplesmente assegura que o melhor material genético não seja perdido por mudança. Isso é feito assegurando que o melhor cromossomo de uma geração seja mantido na próxima

geração. Alguns pesquisadores acreditam que o elitismo força a convergência rápida dos AGs, com grande chance de produzir sub-ótimos (Goldberg, 1987). A reprodução preferencial é empregada somente no caso da substituição do tipo geracional, uma vez que a substituição do tipo steady-state substitui somente os piores p filhos (tamanho da população $> p \geq 1$), e então o cromossomo mais apto é preservado em cada iteração subsequente.

Configurações dos AGs e escolha dos parâmetros de controle

Face ao exposto, pode-se dizer que a literatura oferece diversas possibilidades de implementação para os AGs e seus operadores, bem como a definição de seus parâmetros de controle, tais como tamanho da população, probabilidades de recombinação e mutação, condição de finalização e tipo de substituição dos indivíduos pais pelos indivíduos filhos produzidos.

Vantagens e dificuldades associadas ao emprego dos AGs

Uma das dificuldades no uso dos AGs, além do fato de não se ter garantia de determinação do ótimo global, é a falta de padronização na sua utilização. Cada usuário explora os conceitos envolvidos de maneira diferente e a melhor implementação para uma aplicação particular não é tão óbvia, requerendo investigações ou certa experiência por parte do usuário. É prudente que diferentes alternativas e valores para os parâmetros sejam investigados para assegurar que um bom desempenho seja atingido.

Além disso, por se tratarem de técnicas de otimização por busca direta e, portanto, hábeis à resolução de problemas irrestritos, os AGs requerem que as restrições sejam incluídas na função objetivo na forma de penalidades.

De maneira resumida, pode-se dizer que diversas são as vantagens associadas ao emprego dos AGs, dentre as quais destacam-se a simplicidade dos conceitos envolvidos e a facilidade de implementação. Os AGs geralmente apontam diversas boas soluções para os problemas, por realizarem uma busca abrangente através do espaço de soluções.

IMPLEMENTAÇÕES DA TECNOLOGIA DE AGs PARA O PROBLEMA DE OPERAÇÃO DE RESERVATÓRIOS

Apesar do uso difundido dos AGs por pesquisadores da área de recursos hídricos, poucos são os trabalhos enfocando a operação de sistemas de reservatórios.

Os trabalhos de Wardlaw & Sharif (1999) e Sharif & Wardlaw (2000) são exemplos específicos de aplicações de AGs a sistemas de reservatórios. Entretanto, nenhum deles enfoca os aspectos estocásticos do problema.

Wardlaw & Sharif (1999) estudaram diversas possibilidades de implementação de AGs aplicadas a um sistema simples e clássico da literatura. Tratava-se de um sistema de quatro reservatórios, operados durante o horizonte de planejamento de 12 períodos, para os quais as aflúências naturais são supostamente conhecidas. Em conformidade com os autores, a análise de sensibilidade a diversos parâmetros permitiu que a representação real, incorporando a seleção por torneio, reprodução preferencial, recombinação uniforme e mutação uniforme modificada operassem mais eficientemente, produzindo melhores resultados. Eles apontaram ainda a probabilidade de recombinação de 0,70 e a mutação de um gene por cromossomo como sendo mais apropriadas, ao mesmo tempo em que tamanhos da população de 100 ou 200 indivíduos agiram retardando ou acelerando a obtenção das melhores soluções, respectivamente, em termos do número de gerações (iterações) necessárias.

Os autores mencionam ainda que a maneira como os genes são agrupados no cromossomo é importante. De acordo com eles, é preferível agrupar as liberações de vazões por estágio de tal forma que o cromossomo contenha 12 grupos de 4 genes, representando a liberação de cada reservatório em um determinado estágio, para que o material genético (informações relevantes da atual iteração) mais diretamente relacionado seja mantido próximo.

Os parâmetros mais promissores foram também utilizados por Wardlaw & Sharif (1999) para otimização de um sistema de 10 reservatórios, visando demonstrar as potencialidades dos AGs.

Sharif & Wardlaw (2000) estudaram a operação de um sistema hídrico real simples, visando avaliar o impacto provocado pela introdução de novas unidades de reservação, através de cenários distintos que consideraram como objetivos a geração hidrelétrica e a irrigação.

O registro histórico de um ano crítico em termos das aflúências naturais foi utilizado na análise dos problemas operacionais de otimização correspondentes, cuja formulação admite a irrigação como demanda prioritária, com exceção feita ao primeiro cenário, dentre os quatro estudados. Considerou-se a dinâmica do sistema completamente definida pela Equação (7).

Os AGs foram implementados de maneira que as soluções em termos das variáveis de decisão eram representadas por valores reais, no caso, as liberações hídricas de cada reservatório ao longo dos 36 intervalos sucessivos de 10 dias ao longo do horizonte de planejamento de um ano. Assim, o número das variáveis de decisão do problema (comprimento da cadeia representativa das soluções) corresponde ao produto do número de reservatórios pelo número de períodos em que o horizonte de planejamento foi dividido.

A sistemática de AGs implementada por Sharif & Wardlaw (2000) compreendeu a seleção por torneio, o elitismo, o cruzamento uniforme e a mutação uniforme modificada. Um comprimento da população de 100 indivíduos foi adotado, com probabilidade de cruzamento de 0,7 e mutação de 0,028 (1/comprimento da cadeia representativa das soluções).

Os resultados foram comparados com aqueles obtidos via Programação Dinâmica Discreta Diferencial (PDD),

conforme proposta de Heidari et al. (1971), permitindo que se concluísse pela proximidade das respostas em ambos os casos.

Os autores apontaram vantagens específicas dos métodos de AGs aplicados à otimização da operação de reservatórios tais como: não requerer a discretização das variáveis de estado e decisão; não necessitar de trajetórias de estado tentativas iniciais; não precisar que sistemas complexos sejam decompostos; trabalhar com valores numéricos (funções objetivo altamente complexas não introduzem dificuldades, e até mesmo funções descontínuas são aceitáveis); e possibilitar o uso de modelos de simulação para avaliar a função de aptidão das soluções.

Reconhecem, entretanto, a limitação de que cromossomos extensos reduzem a possibilidade de identificação do ótimo, bem como do atendimento das restrições do problema.

Oliveira & Loucks (1997) usaram AGs para produzir políticas operacionais para reservatórios múltiplos em termos dos volumes de armazenamento ou liberações diretamente, em função da época do ano e da disponibilidade hídrica. Eles assumiram as liberações e volumes alvos como funções lineares por partes. Dessa forma, as coordenadas dos pontos de inflexão constituíram o conjunto das variáveis de decisão do problema, para definição das políticas operacionais que maximizassem o desempenho do sistema. Os autores estabeleceram que a regra operacional fosse determinada por quatro segmentos de reta, para os quais três pontos de inflexão deveriam ser determinados via AGs. Eles utilizaram vetores reais para representar as variáveis de decisão. Reprodução preferencial, cruzamento aritmético, mutação e substituição “em bloco” foram adotados para gerar conjuntos sucessivos de políticas operacionais possíveis, avaliadas pelo índice de performance proposto pelos autores.

Sistemas de três reservatórios, cada um tendo uma função critério diferente, foram usados para aplicação do método e os parâmetros que conduziram a melhores resultados foram: tamanho da população (> 40), probabilidade de cruzamento 1 e taxa de mutação na faixa (0,05 a 0,2). Exemplos de aplicação simples de apenas dois reservatórios em série e paralelo foram analisados, assumindo-se duas estações (inverno e verão), para atendimento de propósito único (abastecimento ou geração hidrelétrica).

Conclusões da revisão bibliográfica

A proposta de Oliveira & Loucks (1997) é promissora por propor uma função de avaliação de desempenho para os AGs, através do denominado índice de perda normalizada. Embora evite as dificuldades típicas da representação das soluções através de cromossomos muito longos, impõe que as regras de operação sigam determinada lei, no caso linear.

Assim, a análise de desempenho dos modelos já propostos para a operação de reservatórios a longo prazo, dentre os quais incluem-se aqueles que se utilizam de AGs,

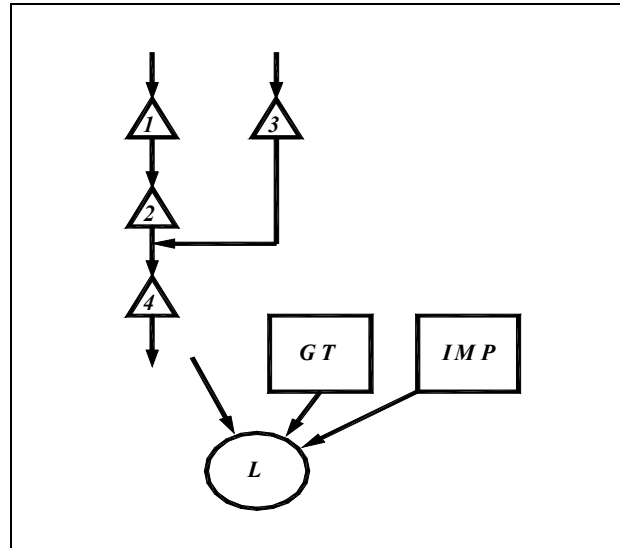


Figura 1. Sistema hidrotérmico de quatro reservatórios; fonte: Pereira & Pinto (1985).

leva a crer que, apesar dos avanços já alcançados, o problema persiste sem o devido enquadramento por requerer que:

- sistemas de grande porte sejam tratados, respeitadas as não-linearidades que lhes são características, bem como os propósitos múltiplos a que são destinados;
- o futuro incerto em termos das afluências naturais seja considerado; e
- regras de operação sejam produzidas para o gerenciamento futuro do sistema, sem que haja necessidade de hipóteses simplificadoras tais como a suposta linearidade proposta por diversos autores.

ESTUDO DE CASO

O sistema simples aqui analisado consiste de quatro estações hidrelétricas que podem ter sua carga complementada por uma termoeletrica (Pereira & Pinto, 1985), GT, conforme esquema da Figura 1, e dados da Tabela 1. A geração termoeletrica tem sua capacidade limitada, podendo ser necessário importar energia de sistemas vizinhos, IMP.

Admitiram-se conhecidos o estado inicial do sistema em termos dos volumes armazenados $V_0 = [50 \ 40 \ 50 \ 50]^T$, bem como as afluências incrementais naturais constantes da Tabela 2.

O problema foi definido como de determinação da estratégia operacional de menor custo, em termos das vazões turbinadas para cada usina hidrelétrica ao longo do tempo (Q_t).

Cada solução alternativa para a operação foi representada por 48 valores reais, agrupados de maneira a refletir as vazões turbinadas nos reservatórios enumerados de 1 a 4 para os períodos consecutivos, do primeiro ao décimo segundo período.

A função de aptidão (F.O.) a ser maximizada foi expressa de maneira a acumular os custos da geração térmica

Tabela 1. Características do sistema.

U. H.	Capacidade armazenamento, $V_{\text{máx}}$	Turbinamento máximo, $Q_{\text{máx}}$	Produtividade ρ (u.e./u.v.)
1	500	100	0.8
2	400	140	
3	500	100	
4	500	240	
U. T.	Capacidade	Custo unitário	
GT	50	1	
IMP	∞	10	

U. H. - Usina Hidroelétrica; U. T. - Usina Termoeletrica; Obs.: a carga (L) é 200 unidades de energia (u.e.) e todos os dados estão em unidades volumétricas (u.v.).

e do importe de energia necessários para suprir a demanda ao longo dos 12 períodos do horizonte de planejamento. Computa também as penalidades relativas ao não atendimento das restrições sobre os volumes finais dos reservatórios, que devem ser iguais aos iniciais, e as ocorrências de volumes negativos em decorrência de estratégias operacionais inadequadas, na forma:

$$\text{Fitness} = \left\{ \begin{array}{l} \sum_{i=1}^{T=12} (GT_i + 10 \cdot \text{IMP}_i) + W \cdot \sum_{j \in \theta_1} [(V_{12,j} - V_{0,j})^2] \\ + W \cdot \sum_{i=1}^{T=12} \sum_{j=1}^{R=4} (V_{i,j})^2 \end{array} \right\}^{-1} \quad (13)$$

onde θ_1 representa o conjunto dos reservatórios cujos volumes no final do período T não correspondem aos do início do período 1; R é o conjunto de reservatórios do sistema; (-) denota valor negativo para o armazenamento e W é o peso ou custo unitário fictício associado às restrições do problema, na forma de penalidades.

A função de aptidão da maneira como definida corresponde portanto ao inverso de um custo fictício, uma vez que inclui penalidades, mencionado ao longo deste trabalho simplesmente como custo.

A função admite ainda que não haja limites sobre o importe de energia de sistemas vizinhos, muito embora se tenha consciência de que episódios de falta de energia possam ocorrer como consequência dessa inverdade. Outras possibilidades, além do escopo deste trabalho, poderiam incluir custos fictícios maiores à medida que o importe tenha sua magnitude aumentada.

Para evitar o esforço repetitivo de determinação dos parâmetros mais adequados a esse tipo de problema, foram adotados os operadores genéticos e parâmetros indicados por Wardlaw & Sharif (1999), a saber: representação real, seleção por torneio, cruzamento aritmético uniforme com probabilidade 70% e mutação uniforme com taxa (1/48), tamanho da população de 100 indivíduos.

Tabela 2. Afluências incrementais naturais (u.v.).

Período (mês)	Reservatório			
	1	2	3	4
1	10	12	10	5
2	8	6	4	2
3	3	5	4	4
4	10	12	10	5
5	8	6	4	2
6	2	9	3	5
7	10	12	10	5
8	7	5	3	9
9	5	4	2	3
10	10	12	10	5
11	7	5	3	9
12	10	11	8	9

RESULTADOS E DISCUSSÃO

Com o objetivo específico de investigar o sistema em estudo, um programa computacional foi desenvolvido e codificado em Fortran, cujos resultados são reportados a seguir.

Maior ênfase foi dada a aspectos não discutidos em trabalhos anteriores, particularmente no que se refere à identificação da ordem de grandeza mais adequada para o valor W e à influência dos volumes armazenados inicialmente nos reservatórios sobre as soluções produzidas.

Identificação do valor W

Partiu-se do princípio que a mutação uniforme modificada apresenta desempenho superior à sistemática aleatória convencional, por impedir que boas soluções sejam perturbadas. Assim, foram utilizadas funções contínuas para estabelecer a magnitude (Δ) da perturbação das variáveis de decisão durante a mutação. Após algumas tentativas de pouco sucesso com a função linear, optou-se por introduzir uma função contínua, inspirada na proposta de Savic et al. (1997), na forma:

$$\Delta = \frac{50}{e^{-Y(X+ITER)} + 1} \quad (14)$$

onde Y e X são parâmetros a serem ajustados e ITER a iteração de AGs considerada.

Assumindo-se as perturbações de 50% a 1% da vazão turbinada máxima dos respectivos reservatórios, para as iterações 0 e 500, respectivamente, os parâmetros da Equação (13) foram avaliados como: Y = -0,0248 e X = -343,427.

Três populações iniciais de soluções distintas foram utilizadas para investigação do peso W, conforme indicam os gráficos da Figura 2. Tais gráficos, construídos com o eixo das abscissas em escala logarítmica, permitem que se observe uma tendência geral simultânea de redução dos

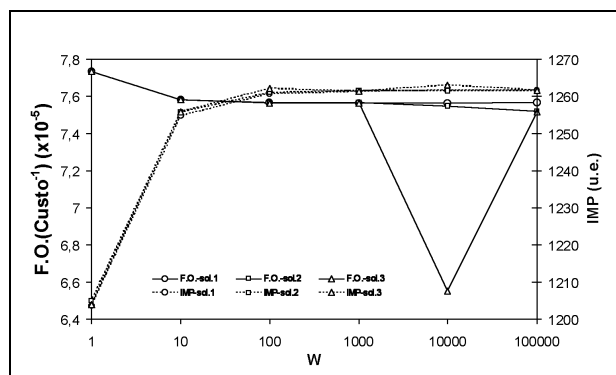


Figura 2. Melhores valores de IMP e F.O. obtidos para diversas ordens de grandeza de W.

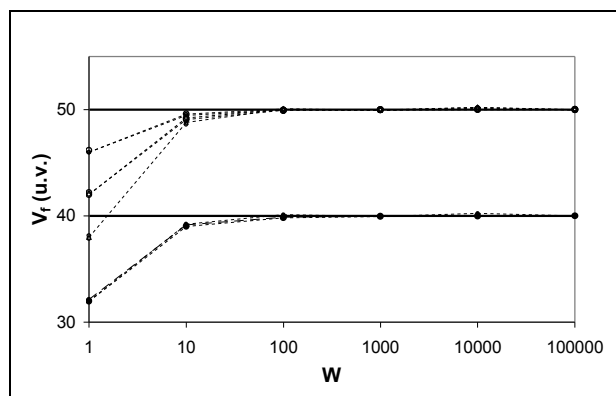


Figura 3. Volumes armazenados nos reservatórios no final do período de planejamento.

valores da função objetivo e elevação dos valores importe de energia à medida que W tem seu valor aumentado. Nota-se que valores elevados de W não garantem melhores valores para a função de aptidão. Na verdade, tendem a apontar soluções mais pobres, pelo fato da busca evitar com maior rigor a região do espaço de soluções que viola as restrições do problema. Sendo desejáveis valores tanto maiores quanto possíveis para a função de aptidão, recorre-se às informações constantes da Figura 3 como complementares à escolha de W.

A Figura 3, com eixo das abscissas em escala logarítmica, exibe os valores dos volumes finais atingidos nas simulações feitas para diversos valores de W e populações de soluções iniciais. Evidencia o papel do valor W em reduzir os desvios entre volumes iniciais e finais obtidos, tanto para os reservatórios 1, 3 e 4, que devem atingir o volume final de 50 u.v. (condição inicial), quanto para o reservatório 2, que deve atingir o volume final de 40 u.v. (condição inicial). A análise conjunta das Figuras 2 e 3, construídas com os melhores resultados obtidos nas buscas via AGs, permitiu a identificação de $W = 100$, dentre os investigados, como sendo o valor para o qual o máximo valor da função de aptidão ocorre, tendo as restrições sobre os volumes finais dos reservatórios consideradas atendidas. Assim, as análises seguintes utilizam o valor $W = 100$.

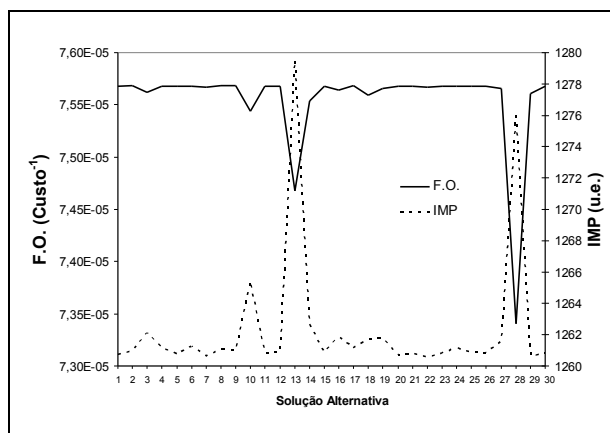


Figura 4. Valores da F.O. e IMP para as soluções obtidas.

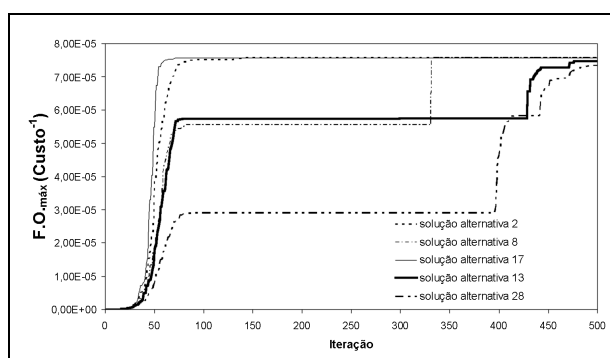


Figura 5. Evolução de F.O. ao longo das iterações.

Tabela 3. Estatística sobre F.O. (Custo⁻¹) e IMP.

	F.O.	IMP
Máximo	7,5682E-05	1279,52
Média	7,5547E-05	1262,38
Mínimo	7,3404E-05	1260,56
Desvio padrão	4,4552E-07	4,30

Observa-se que as restrições sobre os volumes negativos foram atendidas para valores de W iguais ou superiores a 10.

Soluções obtidas a partir de conjuntos de soluções iniciais distintos

Um mínimo estatisticamente representativo de trinta soluções alternativas foi produzido via AGs, a partir de soluções iniciais candidatas distintas. Os resultados obtidos em termos do valor de aptidão ou Função Objetivo (F.O.) e do importe de energia (IMP) são apresentados através do gráfico da Figura 4 e da Tabela 3, onde se pode observar a variabilidade de tais respostas.

Conforme indicações da Figura 4, os maiores valores da função de aptidão não estão associados aos menores valores de importe de energia (alternativas 7 e 22). Eles

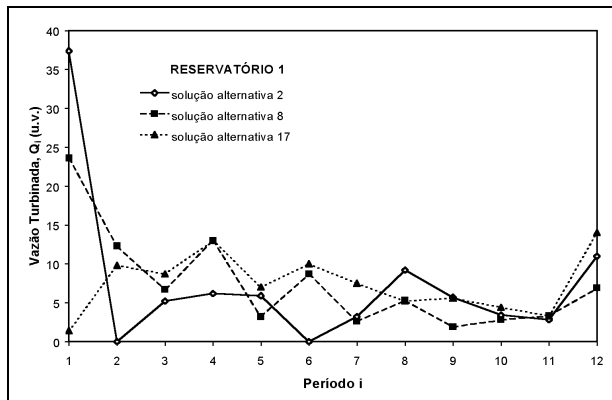


Figura 6. Variação da vazão turbinada do reservatório 1.

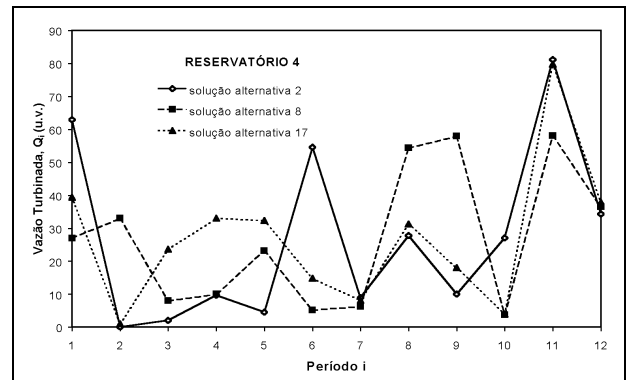


Figura 9. Variação da vazão turbinada do reservatório 4.

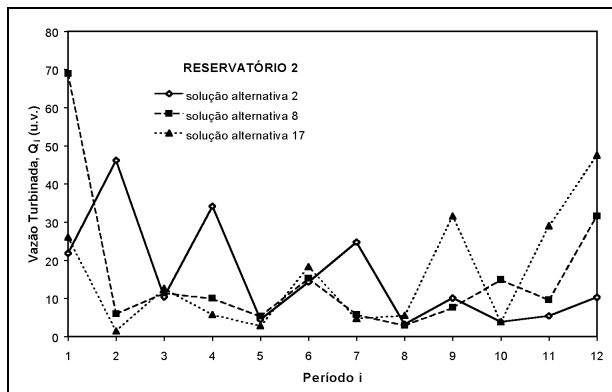


Figura 7. Variação da vazão turbinada do reservatório 2.

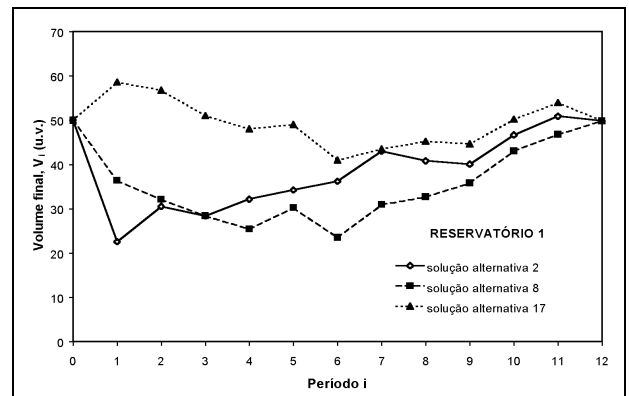


Figura 10. Variação do armazenamento no reservatório 1.

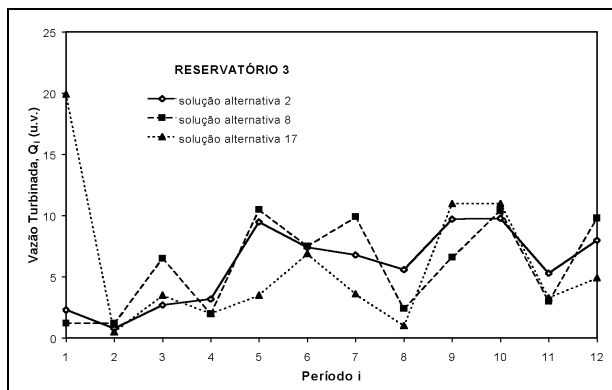


Figura 8. Variação da vazão turbinada do reservatório 3.

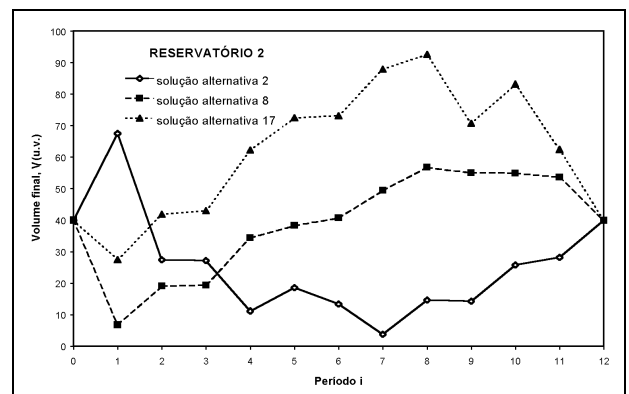


Figura 11. Variação do armazenamento no reservatório 2.

melhor atendem às condições de minimização do importe de energia e das restrições do problema, em conformidade com a função de aptidão adotada. Observa-se que as soluções 13 e 28 são mais pobres, por representar custos maiores. F.O. expressa (Custo^{-1}).

Os gráficos da Figura 5 mostram a evolução dos valores máximos da função de aptidão obtidos ao longo das iterações de AGs, para as seqüências que produziram as melhores (2, 8 e 17) e piores (13, 28) soluções, dentre as 30 geradas. Tais gráficos sugerem que a convergência possa ser verificada para um número de iterações superior a 500,

no caso das soluções alternativas mais pobres, 13 e 28. Wardlaw & Sharif (1999) já haviam estabelecido que 1000 iterações são necessárias à convergência para população de 100 soluções alternativas.

As Figuras 6 a 13 indicam a progressão dos volumes armazenados no final dos períodos do horizonte de planejamento de 12 meses e das vazões turbinadas mensais obtidas para as melhores soluções identificadas, correspondentes às soluções alternativas 2, 8 e 17. Elas mostram a multiplicidade de soluções apontadas em termos das variáveis de decisão e estado, para aproximadamente o mesmo valor da

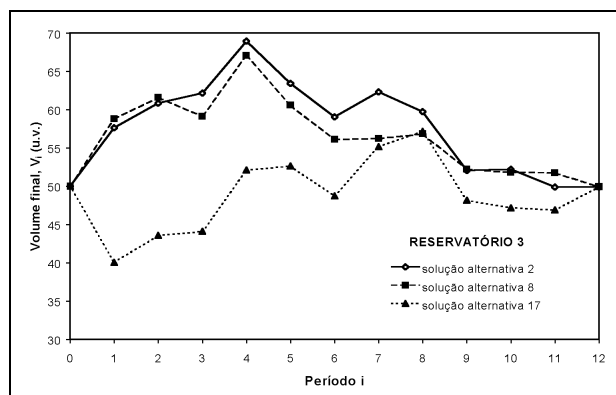


Figura 12. Variação do armazenamento no reservatório 3.

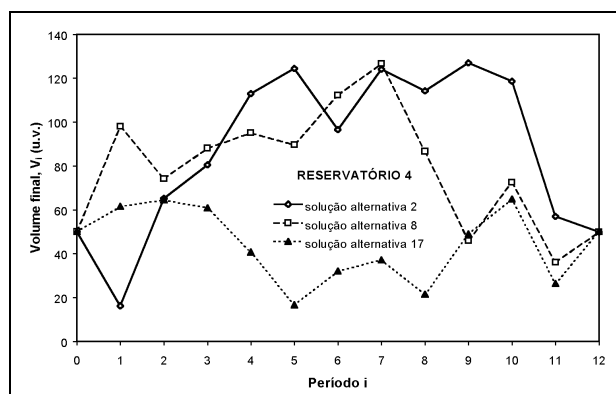


Figura 13. Variação do armazenamento no reservatório 4.

função de aptidão, permitindo que se conclua que a análise da repetitividade das soluções é de fundamental importância.

Análise do número de iterações como critério de parada

As simulações realizadas permitiram que se verificasse que, como era de se esperar, quanto maior o número de iterações, menor a variabilidade das respostas obtidas em termos dos máximos valores da função de aptidão para conjuntos de soluções iniciais aleatórias distintas. Assim, as Figuras 14, 15 e 16 e as Tabelas 4, 5 e 6 ilustram o comportamento das soluções alcançadas em 250 ($S = -0,0496$; $X = -171,714$), 500 ($s = -0,0248$; $x = -343,427$) e 1000 ($S = -0,0124$; $X = -682,855$) iterações, para volumes armazenados inicialmente distintos. Essas informações mostram que o aumento no número de iterações tende a reduzir a variação dos valores de F.O. máximo em torno da média dos valores produzidos nos 30 testes. Não se verificou, entretanto, melhora nos valores máximos de F.O. obtidos para 500 iterações, ao simularem-se as 1000 iterações.

Análise de sensibilidade aos volumes armazenados no início do período

As Figuras 14, 15 e 16 permitem que se analise também o efeito dos volumes armazenados nos reservatórios

Tabela 4. Estatística de F.O. (Custo⁻¹) $\times 10^{-5}$ e IMP ($V_0 = 10\%V_{\text{máx}}$).

Iterações	250	500	1000
F.O. médio	7,528128	7,554748	7,557052
F.O. máximo	7,568218	7,568235	7,568234
(importe energia)	(1260,970)	(1261,022)	(1261,016)
D.P.	0,126242	0,044575	0,030569
C.V.	0,016769	0,00590	0,004045

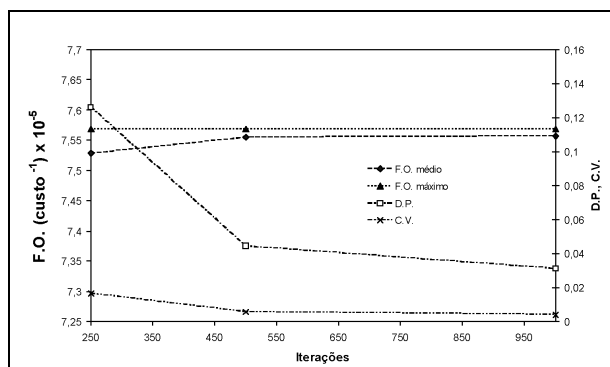


Figura 14. Evolução da função de aptidão com as iterações $V_0 = 10\%V_{\text{máx}}$.

no início do período de planejamento, mostrando que, da mesma forma que o número de iterações, o volume inicial 50% reduziu a variação dos valores de F.O. máximo em torno da média dos valores obtidos para as 30 simulações.

ANÁLISE DA OPERAÇÃO PARA PERÍODOS MAIS EXTENSOS

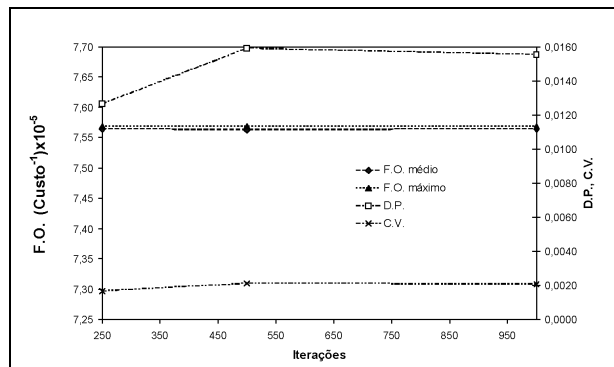
Foram realizadas ainda algumas análises admitindo-se que a sequência hidrológica determinística da Tabela 2 se repita sequencialmente, para um horizonte de planejamento de 24 períodos. Observa-se que o problema correspondente tem o número das suas variáveis de decisão ampliado para 96 (4×24), o que equivale a admitir um horizonte de planejamento de 12 períodos para um sistema composto de oito reservatórios.

Fixando-se o valor $W = 100$ e o tamanho da população em 200 indivíduos, 1000 iterações de AGs foram realizadas para volumes iniciais de 10, 50 e 100% de $V_{\text{máx}}$, cujos resultados são apresentados de maneira reduzida na Tabela 7 e Figura 17. Esses resultados confirmam a tendência da redução da variabilidade das respostas expressa pelo espalhamento dos valores da função de aptidão máxima em torno da média dos valores atingidos para as 30 simulações. Tal comportamento pode ser explicado pelo fato da condição de armazenamento inicial ($V_0 = 50\%V_{\text{máx}}$) em si não requerer soluções nas proximidades das regiões que implicam em volumes negativos nos reservatórios ou volumes finais diferentes dos iniciais.

Definiu-se ainda o problema operacional como de determinação da estratégia operacional para períodos mais

Tabela 5. Estatística de F.O. (Custo⁻¹) x 10⁻⁵ e IMP (V₀ = 50%V_{máx}).

Iterações	250	500	1000
F.O. médio	7,563336	7,562621	7,563826
F.O. máximo	7,568192	7,568234	7,568235
(importe energia)	(1260,942)	(1261,005)	(1261,022)
D.P.	0,012643	0,015896	0,015512
C.V.	0,001672	0,002102	0,002051

Figura 15. Evolução de F.O. com as iterações V₀ = 50% V_{máx}.

extensos, admitindo-se que a mesma seqüência hidrológica determinística se repita seqüencialmente.

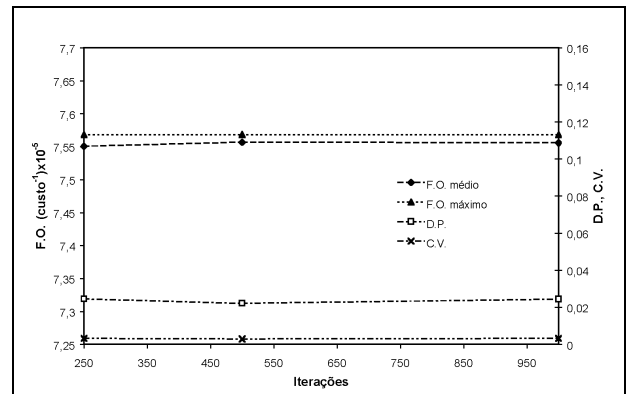
Com o propósito de realizar comparações foi construída a Tabela 8 que reporta os valores máximos de F.O. assim obtidos para um único conjunto de 500 soluções iniciais, realizando o número fixo de 2500 iterações. Observa-se que tais valores foram fixados, apesar da consciência da necessidade de redimensionamento dos mesmos à medida que o número de variáveis de decisão aumenta.

O exame dos valores constantes da Tabela 8 permite que se conclua que mesmo o custo médio (13225,36 unidades anuais) relativo ao valor de F.O. mais pobre, não é significativamente superior ao mínimo identificado para o horizonte de 12 períodos (13213,11 unidades), no caso de volumes finais e iniciais de 100% V_{máx}, em negrito na mesma tabela. Esse é um indício de robustez do método em indicar boas soluções para os problemas.

O gráfico da Figura 18 mostra o decaimento gradual de F.O. à medida que o número de variáveis de decisão é incrementado para os volumes iniciais de 10 e 50% V_{máx}. Já para volumes iniciais de 100% V_{máx}, os valores de F.O. oscilaram, com tendência de decremento. A mesma figura possibilita também uma idéia sobre o tempo de processamento computacional para os diversos períodos de planejamento (12 meses a 120 meses), considerando-se os volumes finais e iniciais de 10% V_{máx}. Observa-se na figura que o tempo de processamento máximo atingido foi de aproximadamente 2,3 horas, destinado ao processamento do horizonte de planejamento de 10 anos (120 meses), para a determinação de 480 variáveis de decisão.

Tabela 6. Estatística de F.O. (Custo⁻¹) x 10⁻⁵ e IMP (V₀ = 100%V_{máx}).

Iterações	250	500	1000
F.O. médio	7,550693	7,556781	7,555771
F.O. máximo	7,568006	7,568182	7,568133
(importe energia)	(1261,189)	(1261,007)	(1261,149)
D.P.	0,024513	0,022144	0,024341
C.V.	0,003246	0,00293	0,003221

Figura 16. Evolução de F.O. com as iterações V₀ = 100% V_{máx}.

CONCLUSÕES

O presente trabalho tratou do problema da operação de sistemas de reservatórios usando a tecnologia de Algoritmos Genéticos (AGs). Para tanto, foi desenvolvido um código FORTRAN com o propósito de produzir os resultados aqui reportados, tomando como ponto de partida os parâmetros anteriormente estabelecidos por Wardlaw & Sharif (1999): representação real, seleção por torneio, cruzamento aritmético uniforme com probabilidade 70% e mutação uniforme com taxa (1/48), e tamanho da população de 100 indivíduos.

Foram explorados aspectos como o valor mais adequado ao peso das restrições e a influência do volume de armazenamento inicial dos reservatórios na identificação das soluções, que permitiram diversas conclusões.

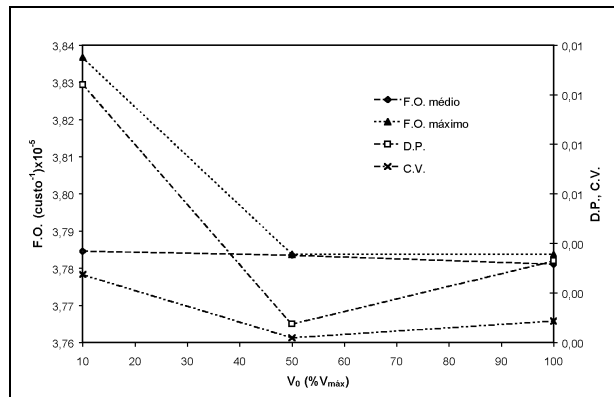
Foi demonstrada a importância de utilizarem-se valores adequados para W, o peso ou custo fictício relativo às restrições, no sentido de garantir o atendimento das mesmas, sem prejuízo das soluções.

Apesar do sucesso da função contínua aqui proposta para expressar a perturbação dos valores das variáveis de decisão durante a mutação, os limites fixos adotados de 50 a 1% devem ser melhor investigados.

Reafirmou-se a necessidade de se estabelecer confiança nas soluções obtidas com base na análise da repetitividade das soluções, partindo-se de soluções iniciais aleatórias distintas. Vale observar aqui que as técnicas de programação não-linear também requerem que a busca se

Tabela 7. Estatística de F.O. (Custo⁻¹) x 10⁻⁵ e IMP.

V_0 (% V_{\max})	10	50	100
F.O. médio	3,784583	3,783473	3,781105
F.O. máximo	3,783706	3,783706	3,783698
(importe energia)	(2522,613)	(2522,631)	(2522,701)
D.P.	0,003343	0,000745	0,003296
C.V.	0,000884	0,000197	0,000872

Figura 17. Estatística de F.O. para diversos V_0 .

processe a partir de diversas soluções iniciais, para que maior confiança nas soluções atingidas seja estabelecida.

A condição de armazenamento inicial a ser atingida no final do horizonte de planejamento revelou-se decisiva na determinação das soluções. Assim, o armazenamento de 50% possibilitou uma menor variabilidade das soluções obtidas a partir de diversas soluções iniciais.

Observou-se o decremento de F.O. à medida que o número de variáveis de decisão é incrementado, não produzindo, porém, custos médios significativamente superiores ao mínimo identificado para o horizonte de 12 períodos. Assim, os resultados produzidos para horizontes de planejamento mais longos (de 24 a 120 períodos) prestaram-se à demonstração da robustez e das potencialidades do método em identificar boas soluções para o problema.

Finalmente, o estudo confirmou as evidências da literatura de que a sistemática natural de representação das soluções para o problema, nos moldes propostos por Wardlaw & Sharif (1999) e Sharif & Wardlaw (2000), aqui analisada, deve ser melhorada, visando a aplicação de sistemas de reservatórios de grande porte e a inclusão de aspectos estocásticos. Considerando, por exemplo, o horizonte de planejamento de cinco anos de operação na base mensal para o Sistema Sul-Sudeste Brasileiro, com aproximadamente 40 usinas, cada solução seria representada por um cromossomo de 2400 (40 x 5 x 12) genes. Isto sem mencionar aspectos como incertezas hidrológicas.

A exemplo do modelo desenvolvido por Oliveira & Loucks (1997), novas sistemáticas de representação do problema físico real, especialmente se aliadas à hibridização com técnicas de programação matemática já consagradas, podem produzir resultados mais satisfatórios, sob esforço computa-

Tabela 8. Valores de F.O. (Custo anual médio⁻¹) x 10⁻⁵ para horizontes de planejamento diversos.

Horizonte (períodos)	Variáveis	$V_0 = 10\%V_{\max}$	$V_0 = 50\%V_{\max}$	$V_0 = 100\%V_{\max}$
12	48	7,568236	7,568236	7,568239
24	96	7,567412	7,567412	7,567412
36	144	7,567137	7,567137	7,567134
48	192	7,567	7,567	7,562772
60	240	7,566915	7,566915	7,55964
72	288	7,566864	7,566864	7,565106
84	336	7,566825	7,566818	7,563717
96	384	7,566798	7,566784	7,561233
108	432	7,566768	7,566773	7,562321
120	480	7,566756	7,566757	7,563028

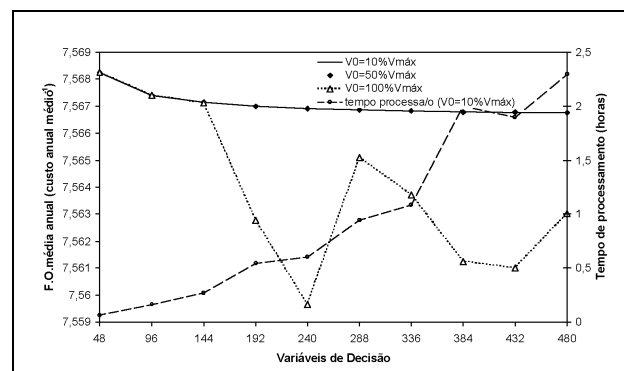


Figura 18. Evolução do valor de F.O. com o número de variáveis.

cional reduzido na resolução do problema. Tais estratégias vêm sendo estudadas pelos autores deste trabalho.

AGRADECIMENTOS

Os autores agradecem às Universidades de São Paulo (USP) e Estadual Paulista (UNESP) e à Fundação de Pesquisa do Estado de São Paulo (FAPESP) pelo suporte financeiro oferecido para o desenvolvimento dos programas de pós-doutorado na Universidade de Exeter, Inglaterra, durante o qual os estudos relacionados a este trabalho foram realizados.

Agradecem também aos revisores anônimos da RBRH pelas sugestões no sentido de melhorar o texto original.

REFERÊNCIAS

- GEN, M. & CHENG, R. (1997). *Genetic algorithms and engineering design*. Canada, John Wiley e Son.
- GOLDBERG, D. E. (1987). *Genetic algorithm in search, optimisation and machine learning*, Addison-Wesley, Reading, Mass.
- GOLDBERG, D. E. & DEB, K. (1990). A comparative analysis of selection schemes used in genetic algorithms. *Foundations*

- of genetic algorithms, Morgam Kaufman, San Mateo, Calif., p.69-93.
- HEIDARI, M.; CHOW, V. T.; KOKOTOVIC, P. V. & MEREDITH, D. D. (1971). Discrete differential approach to water resources systems optimization. *Water Resources Research*, 7(2), p.273-283.
- MEIER, W. & BARKDOLL, B. D. (2000). Sampling design for network model calibration using genetic algorithms. *Journal of Water Resources Planning and Management*, ASCE, vol. 126, n°4, p.245-250.
- MICHALEWICS, Z. (1994). *Genetic Algorithm + data structures = evolution programs*, 2°ed., Springer-Verlag, New York.
- OLIVEIRA, R. & LOUCKS, D. P. (1997). Operating rules for multireservoir systems. *Water Resources Research*, vol. 33, n°4, p.839-852.
- PEREIRA, M. V. F. & PINTO, L. M. V. G. (1985). Stochastic optimization of a multi-reservoir hydroelectric system: a decomposition approach. *Water Resources Research*, 21(6), p.779-792.
- SAVIC, D. A.; WALTERS, G. A. & SCHWAB, M. (1997). *Multiobjective genetic algorithm for pumping scheduling in water supply*. In: AISB'97, Manchester, 1997. Evolutionary Computing workshop, Manchester, p.59.
- SHARIF, M. & WARDLAW, R. (2000). Multireservoir systems optimization using genetic algorithm: case study. *Journal of Computing in Civil Engineering*, vol. 14, n°4, p.255-263.
- WARDLAW, R. & SHARIF, M. (1999). Evaluation of genetic algorithms for optimal reservoir system operation. *Journal of Water Resources Planning and Management*, ASCE, vol. 125, n°1, p.25-33.
- WURBS, R. A. (1993). Reservoir-system simulation and optimization models. *Journal of Water Resources Planning and Management*, ASCE, 119(4), p.455-472.
- YAKOWITZ, S. (1982). Dynamic programming applications in water resources. *Water Resources Research*, 18(4), p.673-696.
- YEH, W. W. -G. (1985). Reservoir management and operation models: a state-of-the-art review. *Water Resources Research*, 21(12), p.1797-1818.

Operational Strategies for Reservoir Systems via Genetic Algorithms (GAs)

ABSTRACT

Reservoirs are generally essential components of water resources systems and their operational planning constitutes a target of investigation.

In view of the characteristic degree of difficulty related to the operational strategy determination, increasing according to the system dimensions, several approaches have been proposed for their resolution.

Currently, the increasing use of techniques inspired by robust mechanisms of nature has presented Genetic Algorithms (GAs) as alternative tools to solve such problems. However, there are several possible implementation procedures, besides the possibility of hybridization with conventional mathematical programming techniques, which help reduce the computing effort in the search of good solutions.

The present study aims at reviewing the relevant literature related to the procedures used to solve reservoir operation problems by using Genetic Algorithms (GAs) and demonstrating the potentials of the method through a simple example of application to a hypothetical hydrothermal system with four hydroelectric plants. It is organized to formulate the problem, emphasize the different possibilities of implementing GA techniques, review existing studies and present some results obtained for the system analyzed system in order to foster further research.

Key Words: operation; reservoir systems; genetic algorithms.