

Verificação da Eficiência e Eficácia de um Algoritmo Evolucionário Multi-objetivo na Calibração Automática do Modelo Hidrológico IPH II

Juan Martín Bravo, Walter Collischonn & Carlos Eduardo Morelli Tucci

Instituto de Pesquisas Hidráulicas, UFRGS

jumarbra@yahoo.com.ar, collischonn@iph.ufrgs.br, tucci@iph.ufrgs.br

Recebido: 03/09/08 - revisado: 24/10/08 - aceito: 13/07/09

RESUMO

Os complexos processos do ciclo hidrológico podem ser representados por meio da modelagem hidrológica, sendo os modelos que simulam o processo de transformação da chuva em vazão os mais utilizados. Esses modelos são baseados em equações matemáticas que descrevem, de forma simplificada, o comportamento hidrológico da bacia e possuem parâmetros que devem ser definidos através de um processo de calibração. A calibração manual, por tentativa e erro pode ser uma tarefa tediosa, sobretudo quando o usuário do modelo é inexperiente. A calibração automática, por sua vez, utiliza técnicas numéricas de otimização baseadas no uso intensivo de computadores. Esse trabalho apresenta um algoritmo evolucionário multi-objetivo de otimização desenvolvido por Vrugt et al. (2003) e aplicado na calibração automática do modelo hidrológico IPH II. Os resultados obtidos são promissores, o algoritmo conseguiu uma aproximação uniforme do frente de Pareto nos diferentes testes realizados, mantendo os extremos da mesma bem representados. Ainda mostrou algumas vantagens sobre outro algoritmo evolucionário multi-objetivo atualmente utilizado na calibração automática do modelo hidrológico IPH II.

Palavras-chave: calibração automática, modelo hidrológico, algoritmo evolucionário multi-objetivo, MOSCEM-UA, IPH II.

INTRODUÇÃO

Os modelos hidrológicos que simulam a transformação da chuva em vazão são ferramentas que representam, de forma simplificada, os diversos processos do ciclo hidrológico que interagem numa bacia hidrográfica. Esses modelos são baseados em equações matemáticas que possuem parâmetros que caracterizam o comportamento hidrológico de bacia (Tucci, 1998). Alguns desses parâmetros representam abstrações da realidade e, em consequência, não podem ser medidos. Nessas circunstâncias, o ajuste dos valores dos parâmetros é realizado através do processo de calibração, com base nas informações hidrológicas existentes.

O objetivo da calibração é encontrar os valores dos parâmetros do modelo que permitam uma boa representação do comportamento hidrológico da bacia. A vazão no exutório da bacia engloba os diversos processos hidrológicos e por isso é geralmente utilizada na avaliação do processo de calibração. Dessa forma, espera-se que uma boa representação do comportamento hidrológico da bacia seja encontrada quando as vazões calculadas pelo modelo reproduzam, com boa precisão, às vazões observadas.

Uma das técnicas pioneiras de calibração é a calibração manual por tentativa e erro. Essa técnica é um processo iterativo, onde o usuário do modelo altera os valores dos parâmetros em cada simulação. Esse processo continua até que o usuário decida que o resultado encontrado é satisfatório na comparação entre as vazões calculadas e observadas. Uma das grandes vantagens desse procedimento é permitir que o usuário agregue ao processo sua experiência e conhecimento sobre o modelo. Porém, a calibração manual pode ser um processo muito lento, repetitivo e tedioso, especialmente quando o modelo utilizado tem um grande número de parâmetros e o usuário é inexperiente (Collischonn e Tucci, 2003). Isto acontece porque muitas vezes é difícil deduzir a lógica pela qual os parâmetros deveriam ser ajustados para melhorar a representação (Sorooshian e Gupta, 1995).

Com o objetivo de tornar mais rápido e eficiente o processo de calibração, foram desenvolvidas técnicas de otimização que se baseiam na utilização intensiva de computadores para a calibração automática de modelos hidrológicos. Para avaliar os resultados do processo de calibração foram propostas diferentes medidas de desempenho baseadas, geralmente, nos erros entre as vazões calculadas e observadas. Em uma primeira abordagem, cada uma das medi-

das de desempenho era utilizada de forma isolada durante a calibração, dando origem à *calibração automática mono-objetivo*. Como resultado deste processo, um único conjunto de parâmetros era obtido ao se maximizar uma única medida de desempenho.

Porém, na modelagem hidrológica não existe um único conjunto de parâmetros capaz de representar todos os processos hidrológicos, devido às incertezas: nos dados, nas simplificações do modelo e na representatividade dos valores dos parâmetros. O conceito de equifinalidade, introduzido por Beven e Binley (1992), estabelece a possibilidade de existência de vários conjuntos de parâmetros que de forma apropriada resultarão na resposta desejada. Isto fica mais evidente quando com um determinado conjunto de parâmetros é obtido um bom ajuste dos picos dos hidrogramas e com outro obtém-se também bom ajuste dos períodos de estiagens.

A *calibração automática multi-objetivo* procura a maximização de várias medidas de desempenho em forma simultânea, gerando vários conjuntos de parâmetros como resultado do processo. Diferentes algoritmos numéricos de otimização foram desenvolvidos na calibração automática multi-objetivo de modelos hidrológicos, sendo os algoritmos evolucionários os que têm recebido maior atenção nas últimas décadas.

Neste artigo é descrito um algoritmo de calibração automática multi-objetivo de modelos hidrológicos baseado em um algoritmo evolucionário. O algoritmo original foi desenvolvido por Vrugt et al. (2003) e aplicado no modelo SAC-SMA, ou Sacramento, e outros (por exemplo, Schoups et al., 2005; Johnsen et al., 2005; Pande et al., 2005; Bos e Vreng, 2006). Esse trabalho apresenta a descrição do algoritmo bem como uma aplicação usando o modelo hidrológico IPH II (Tucci, 1998).

CALIBRAÇÃO MULTI-OBJETIVO DE MODELOS HIDROLÓGICOS

A vazão estimada pelo modelo hidrológico, em cada intervalo de tempo, depende do valor da precipitação (P_t) e do valor dos parâmetros (θ). Isto é:

$$\hat{Q}_t(\theta) = F[P_t, \theta] \quad (1)$$

onde $F[.]$ é o modelo hidrológico e $\hat{Q}_t(\theta)$ é vazão estimada no intervalo de tempo t .

Existindo dados observados das variáveis de saída (Q), pode ser calculada a diferença entre os valores simulados e observados que representa o erro cometido na estimativa do modelo:

$$E(\theta)_t = Q_t - \hat{Q}_t(\theta), \quad t = 1, 2, \dots, NT \quad (2)$$

onde NT é o número de intervalos de tempo da simulação.

As medidas de desempenho dos modelos hidrológicos estabelecem diferentes formas de avaliar $E(\theta)$ e são chamadas de funções-objetivo $G(E(\theta))$.

Algumas funções-objetivo dão maior peso a erros de pico e outras nas vazões de estiagem. As equações 3 a 6 apresentam exemplos de funções-objetivo, sendo F_1 o desvio padrão, F_2 o desvio padrão do inverso das vazões, F_3 o desvio absoluto médio e F_4 o coeficiente de Nash e Sutcliffe:

$$F_1 = \sqrt{\frac{\sum_{t=1}^{NT} (Q_t - \hat{Q}_t(\theta))^2}{NT}} \quad (3)$$

$$F_2 = \sqrt{\frac{\sum_{t=1}^{NT} \left(\frac{1}{Q_t} - \frac{1}{\hat{Q}_t(\theta)}\right)^2}{NT}} \quad (4)$$

$$F_3 = \frac{\sum_{t=1}^{NT} |Q_t - \hat{Q}_t(\theta)|}{NT} \quad (5)$$

$$F_4 = 1 - \frac{\sum_{t=1}^{NT} (Q_t - \hat{Q}_t(\theta))^2}{\sum_{t=1}^{NT} (Q_t - \bar{Q})^2} \quad (6)$$

onde Q_t é a vazão observada no intervalo de tempo t , $\hat{Q}_t(\theta)$ é a vazão calculada no intervalo de tempo t , \bar{Q} é a média das vazões observadas e NT é o número de intervalos de tempo da simulação.

A calibração multi-objetivo consiste na minimização (ou maximização) de duas ou mais funções-objetivo no processo de ajuste dos valores dos parâmetros do modelo.

Na calibração multi-objetivo se apresentam dois tipos de soluções: (1) soluções dominadas, com as quais são obtidos valores piores, em todas as funções-objetivo, se comparadas às outras soluções; (2) soluções não-dominadas ou ótimas de Pareto, com as quais são obtidos valores das funções-objetivo que,

comparados a todas as restantes soluções, serão melhores em uma ou mais funções-objetivo e piores em outra ou outras.

O grupo de soluções não-dominadas é o alvo da calibração multi-objetivo. Esse grupo forma uma superfície (no espaço das funções-objetivo) conhecida como frente de Pareto. O frente de Pareto define o *trade-off* entre as funções-objetivo e é definido sem estabelecer uma preferência relativa subjetiva para minimizar (ou maximizar) alguma das funções-objetivo a custa de outras.

A Figura 1 apresenta um exemplo simples de calibração multi-objetivo de um modelo teórico que possui dois parâmetros (θ_1, θ_2), considerando a minimização de duas funções-objetivo (F_I, F_{II}). Observa-se nessa figura que um determinado conjunto de parâmetros (representado por um ponto no espaço dos parâmetros) tem associado um ponto no espaço das funções-objetivo. O conjunto de parâmetros identificado pelo ponto B (espaço dos parâmetros) define o ótimo de F_I (ponto b no espaço das funções-objetivo). Por sua vez, o conjunto de parâmetros A, diferente de B, define o ótimo de F_{II} (ponto a).

A curva (espaço das funções-objetivo) cujos extremos são os pontos a e b é o frente de Pareto e identifica todas as soluções não-dominadas (por exemplo, c e d). As soluções não-dominadas são definidas por conjuntos de parâmetros diferentes a A e a B, e são identificados pela reta que liga os pon-

tos A e B no espaço dos parâmetros. Observa-se ainda na Figura 1(b) que partindo desde o ponto a para o b, a melhora em uma função-objetivo será contrabalançada pela deterioração na outra.

O frente de Pareto é integrado por infinitos pontos. Dadas as características das funções-objetivo utilizadas na calibração automática de modelos hidrológicos são utilizadas técnicas numéricas no processo (Tucci, 1998). As técnicas numéricas definem uma aproximação do frente de Pareto. Essa aproximação do frente de Pareto trata de identificar o maior número de soluções não-dominadas para que exista uma boa representação do mesmo.

ALGORITMOS EVOLUCIONÁRIOS MULTI-OBJETIVOS

Os algoritmos evolucionários são técnicas numéricas de otimização e busca inspirados em analogias com a natureza, as quais incluem, geralmente, o processo de evolução de seres vivos e o comportamento social de animais e insetos. Aquelas técnicas baseadas no processo de evolução de seres vivos seguem o princípio de seleção natural e sobrevivência do mais apto, introduzido por Charles Darwin (Goldberg, 1989; Lacerda e Carvalho, 1999; Coelho, 2003) e são o foco desse trabalho.

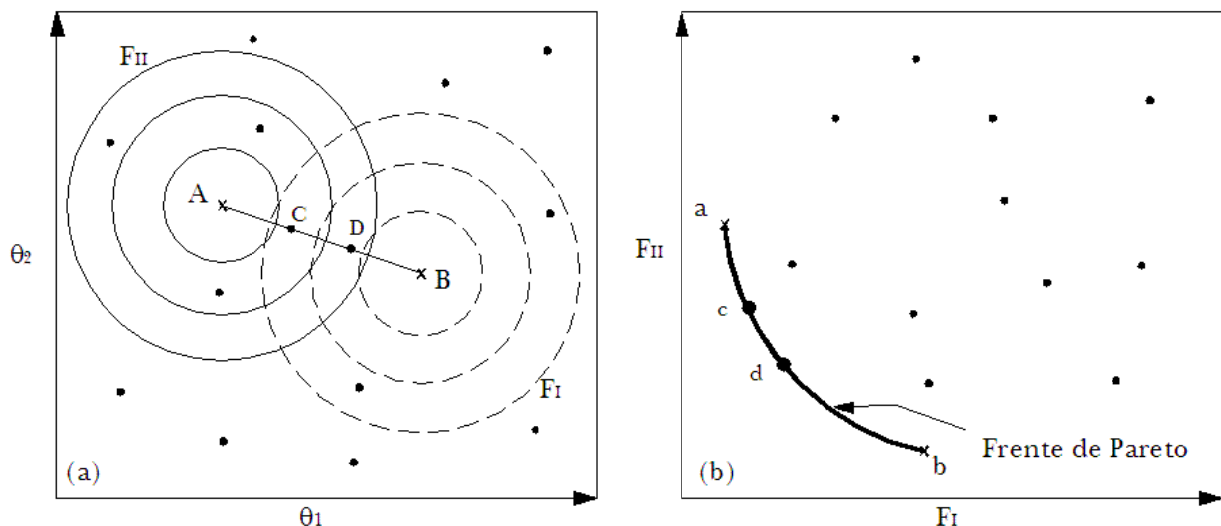


Figura 1 - Calibração multi-objetivo de um modelo teórico com dois parâmetros considerando a minimização de duas funções-objetivo. (a) Espaço dos parâmetros, (b) Espaço das funções-objetivo.

Um algoritmo evolucionário multi-objetivo parte de uma população inicial de soluções candidatas, aleatoriamente distribuídas no espaço factível, que evolui em direção a uma aproximação do frente de Pareto através de sucessivas iterações e avaliações das funções-objetivo. A chance de um indivíduo da população ser selecionado para participar no processo de evolução depende do valor de aptidão do indivíduo. Quanto melhor o valor de aptidão de um indivíduo, maior é a probabilidade de ser escolhido para participar do processo de evolução. A aptidão é, geralmente, definida com base na proximidade de uma solução candidata à aproximação do frente de Pareto. Soluções não-dominadas têm melhores aptidões, as soluções dominadas, entretanto, apresentam piores aptidões. As formas de calcular a aptidão e a técnica utilizada no processo de evolução são onde se apresentam as maiores diferenças entre os algoritmos evolucionários multi-objetivos.

Dentro das aplicações com sucesso de algoritmos evolucionários multi-objetivos nas áreas de recursos hídricos existem diferentes aplicações de algoritmos genéticos. Algoritmos genéticos multi-objetivos têm sido utilizados, por exemplo, no desenho de um sistema de reservatórios de detenção (Yeh e Labadie, 1997), na determinação da taxa de remoção de cargas poluidoras (Burn e Yulianti, 2001), na configuração ótima de plantas de potabilização da água (Vink e Schot, 2002) e em problemas de monitoramento de águas subterrâneas (Cieniawski et al., 1995).

Mais recentemente têm sido desenvolvidos novos algoritmos genéticos multi-objetivos, como a família de modelos NSGA, NSGAI (Non-Dominated Sorted Genetic Algorithm, Deb et al., 2002) e ϵ -NSGAI (Epsilon Dominance NSGAI, Kollat e Reed, 2006). Este último tem-se apresentando como um dos algoritmos evolucionários de melhor desempenho na calibração automática multi-objetivo do modelo hidrológico SAC-SMA (Sacramento Soil Moisture Accounting model, Burnash, 1995), conforme os testes efetuados por Tang et al (2006). Ainda nesses testes, o algoritmo evolucionário SPEA2 (Strength Pareto Evolutionary Algorithm, Zitzler e Thiele, 1999) apresentou resultados equivalentes aos obtidos com o ϵ -NSGAI.

Yapo et al. (1998) desenvolveram o MOCOM-UA (Multiobjective Complex Evolution Method – Universidade de Arizona) sendo aplicado na calibração de diferentes modelos hidrológicos como, por exemplo, apresentado em Sorooshian et al. (1998), Gupta et al. (1998) e Collischonn e Tucci (2003).

Vrugt et al. (2003) apresentaram o MOSCEM-UA (Multiobjective Shuffled Complex Evolution Metropolis – Universidade de Arizona). O MOSCEM-UA foi desenvolvido com o objetivo de melhorar algumas deficiências detectadas no MOCOM-UA quando utilizado para calibrar modelos com muitos parâmetros (Vrugt et al., 2003). O MOSCEM-UA combina uma estratégia probabilística de busca e evolução conhecida como *covariance-annealing*, a mistura de complexos (os complexos são subconjuntos de soluções candidatas) e uma regra de atribuição de aptidão baseada nos conceitos de dominância e não-dominância de Pareto. O MOSCEM-UA foi também aplicado na calibração de modelos hidrológicos, como apresentado no texto original de Vrugt et al (2003) e em, por exemplo, Schoups et al. (2005), Johnsen et al. (2005), Pande et al. (2005), Bos e Vreng (2006), Barros (2007).

O algoritmo MOSCEM-UA é utilizado nesse trabalho para a calibração automática multi-objetivo do modelo IPH II, e descrito separadamente, no texto.

ALGORITMO MOSCEM-UA

O algoritmo MOSCEM-UA (Vrugt et al., 2003) inicia com a definição dos limites mínimos e máximos dos valores que os n parâmetros a serem calibrados podem tomar, definindo uma região ou hipercubo.

A seguir, são gerados, a partir de uma distribuição de probabilidades definida (geralmente uniforme), ns conjuntos de parâmetros ou pontos na região válida que definem uma população de soluções candidatas. Cada ponto é dado pelos valores dos n parâmetros e para cada um dos pontos as nf funções-objetivo são avaliadas.

Uma vez obtidos os valores das funções-objetivo, os conjuntos de parâmetros são avaliados e hierarquizados pelos critérios de dominância e não-dominância descritos anteriormente. A hierarquização é baseada na aptidão das soluções e realizada em duas etapas. Na primeira etapa, cada ponto recebe o valor de um índice com base no conceito de classificação de soluções em problemas multi-objetivos dado por Goldberg (1989), seguindo os passos a seguir (Figura 2(a)):

- a) Identifica-se, dos ns pontos, aqueles que são dominados e os que são não-dominados.
- b) Aos pontos que são não-dominados atribua um índice igual a um.

- c) Os pontos com o índice igual a um são retirados temporariamente da população e os pontos restantes são novamente analisados.
- d) Aos pontos que são não-dominados nesta segunda análise, atribua um índice igual a dois.
- e) Os pontos com o índice igual a dois também são retirados e os pontos restantes são analisados.
- f) Os passos se repetem até que se encontre um grupo de pontos em que não podem ser definidos dominados e não-dominados, sendo atribuído a esses pontos o maior valor do índice.

Na segunda etapa é calculado o ranking dos diferentes pontos da população (Figura 2(b)), conforme apresentado por Vrugt et al. (2003). O ranking dos pontos com índice igual a um (soluções não-dominadas) é dado pela equação 7:

$$a_j^{\text{nãodom}} = \frac{\text{ndom}_j}{\text{ns}} \quad (7)$$

onde $a_j^{\text{nãodom}}$ é o ranking do ponto não-dominado j , ndom_j é o número de pontos dominados pelo ponto j e ns é o número de pontos da população. Observa-se na equação 7, que o ranking das soluções não-dominadas é sempre menor ou igual a um.

O ranking de cada ponto dominado é calculado pela somatória do ranking de todas as soluções não-dominadas que dominam esse ponto, incrementada do valor de seu índice restado menos um, isto é:

$$a_i^{\text{dom}} = \sum_{j=1}^{\text{nnãodom}_i} a_j^{\text{nãodom}} + \text{indice}_i - 1 \quad (8)$$

onde a_i^{dom} é o ranking do ponto dominado i , nnãodom_i é o número de pontos não-dominados que dominam ao ponto i . O ranking dos pontos dominados é sempre superior a um.

Ao final da etapa de hierarquização, cada um dos pontos tem um ranking, que indica, aproximadamente, a qualidade relativa das funções-objetivo associadas. Quanto menor o valor do ranking de uma solução, melhor é sua aptidão. Quanto melhor a aptidão, mais próximo o ponto está da aproximação do frente de Pareto. A Figura 2 apresenta um exemplo com nove pontos hierarquizados, conforme o valor de duas funções-objetivo, que devem ser minimizadas.

Posteriormente os pontos da população são ordenados por valor crescente do ranking, isto é, o primeiro ponto possui o menor ranking (melhor aptidão), o segundo ponto possui o segundo menor ranking (segunda melhor aptidão) e assim por diante, o último ponto é o que apresenta a pior aptidão (maior valor do ranking), gerando uma matriz de resultados ordenados $D(\text{ns}, \text{nf})$.

A população de pontos é dividida em q conjuntos, chamados de complexos ($C_i, i=1, \dots, q$), cada um contendo m ($m=\text{ns}/q$) pontos, tais que o primeiro complexo contém todos os $q(j-1)+1$ pontos ordenados de D , o segundo complexo contém todos os $q(j-1)+2$ pontos ordenados de D , e assim por diante, onde $j = 1, 2, \dots, m$. Dessa forma, cada complexo possui soluções boas (baixo valor do ranking) e ruins (maiores valores do ranking).

Posteriormente são iniciadas q seqüências paralelas ($S_i, i=1, \dots, q$), cada uma delas começando no ponto que exhibe melhor aptidão de cada complexo. Cada uma dessas seqüências evolui com base num processo de *reprodução*, explicado mais adiante. Os complexos são reunidos em determinados números de iterações, de forma periódica, e a população misturada de forma a permitir a troca de informação entre os diversos complexos. A população é ordenada, novos complexos são formados e o processo de evolução continua até obter uma aproximação do verdadeiro frente de Pareto.

O algoritmo de evolução de cada seqüência do MOSCEM-UA, chamado *covariance-annealing*, foi descrito por Vrugt et al. (2003) como segue:

- a) Início: são selecionados os valores do número de passos de evolução em cada complexo antes do misturado (L) e o fator de escala (γ) que influi na probabilidade de aceitação dos pontos candidatos gerados.
- b) Geração dos pontos candidatos: é calculada a matriz de covariância Cov^i dos parâmetros de C_i e gerado o ponto candidato com base numa distribuição normal multivariada centrada na marca atual (último valor da seqüência i , espaço dos parâmetros) através da seguinte equação:

$$\theta_i^{(t+1)} = N(\theta_i^{(t)}, Cov^i) \quad (9)$$

onde $\theta^{(t)}$ é a marca atual de S_i , $N(\cdot)$ é o operador de distribuição normal e $\theta^{(t+1)}$ é o ponto candidato gerado na seqüência i .

- a) Regra de aceitação tipo algoritmo Metrópolis (Metrópolis et al. (1953) *apud* Vrugt et al., 2003):
1. Seleção do patamar de aceitação: de forma aleatória é escolhido um patamar (Z) com base em uma distribuição de probabilidades uniforme no intervalo $[0,1]$.
 2. Cálculo do ranking do ponto candidato (a_i^{t+1}) usando os pontos em C_i e a marca atual de S_i .
 3. Cálculo do quociente α com base na seguinte equação:

$$\alpha = \left(\frac{a_i^t}{a_i^{t+1}} \right)^{\gamma \cdot a_i^{t+1}} \quad (10)$$

onde γ é o fator de escala e a_i^t é o ranking da marca atual de S_i .

1. Se $\alpha \geq Z$ o ponto candidato é aceito e passa a ser o valor da marca da seqüência na próxima iteração. Caso contrário é rejeitado e na próxima iteração a seqüência permanece na posição atual, sendo $\theta_i^{(t+1)} = \theta_i^{(t)}$.
2. Substituir o pior ponto de C_i com $\theta_i^{(t+1)}$.

O algoritmo MOSCEM-UA tem quatro parâmetros que devem ser definidos pelo usuário: o tamanho da população de pontos (ns), o número de seqüências e complexos (q), que em conjunto determinam o número de pontos em cada complexo m (ns/q), o número de passos de evolução em cada complexo antes do misturado (L) e o fator de escala (γ).

O parâmetro L representa o número de passos de evolução de cada complexo, ou seja, o número de vezes que são criadas novas soluções candidatas em cada complexo, antes do misturado de todos os complexos na população. Por sua vez, o parâmetro γ governa a probabilidade de aceitação de soluções candidatas que possuem um ranking menor que o correspondente à marca atual da seqüência na qual se encontra o complexo. Quanto maior o valor do fator de escala γ , menor a probabilidade de aceitação dessas soluções candidatas.

Nos testes efetuados foi adotado um valor de L igual ao número de parâmetros do modelo hidrológico e $\gamma=0,50$ (ambos os valores recomendados pelos autores do algoritmo). Dessa forma os únicos parâmetros do algoritmo que devem ser definidos pelo usuário são o tamanho da população ns e o número de complexos q .

O código computacional do algoritmo MOSCEM-UA utilizado nesse trabalho foi desenvolvido em Fortran e em duas versões. A primeira versão é um programa seqüencial preparado para execução em computadores com um único processador. Por sua vez, na segunda versão, foram incorporadas linhas de sentenças de OpenMP para a execução em paralelo em um computador previsto de múltiplos processadores com memória compartilhada.

O OpenMP surgiu como uma alternativa aos métodos tradicionais de programação em paralelo com o objetivo de permitir o desenvolvimento de códigos computacionais capazes de utilizar o hardware já existente nos computadores. Não é uma nova linguagem de programação, trata-se de um conjunto de diretivas de compilação, bibliotecas e variáveis que podem ser utilizadas para programação em paralelo (Hermanns, 2002; Chapman et al., 2008).

O OpenMp permite: (1) criar equipes de t -*threads* para execução em paralelo; (2) especificar como compartilhar as tarefas entre os membros da equipe; (3) declarar as variáveis privadas e compartilhadas; (4) sincronizar e estabelecer tarefas exclusivas entre as *threads*. Uma *thread* é uma entidade que pode executar, de forma independente, um conjunto de instruções.

ESTUDOS DE CASO

Na avaliação da eficiência e eficácia do algoritmo MOSCEM-UA foram efetuados três testes considerando problemas de otimização multi-objetivo com complexidade crescente.

No primeiro exercício foi resolvido um problema teórico de otimização considerando três funções-objetivo, proposto em Vrugt et al. (2003) e cuja solução teórica é conhecida de trabalhos anteriores.

No segundo e terceiro exercício, o algoritmo MOSCEM-UA é utilizado na calibração automática do modelo IPH II. O modelo IPH II está descrito em Tucci (1998), e trata-se de um modelo hidrológico concentrado com sete parâmetros que podem ser calibrados. Nesses exercícios, os resultados obtidos foram comparados aos correspondentes ao algoritmo MOCOM-UA (Yapo et al., 1998), com base na versão desenvolvida e testada por Collischonn e Tucci (2003). O algoritmo MOCOM-UA é atualmente utilizado na calibração automática desse modelo hidrológico.

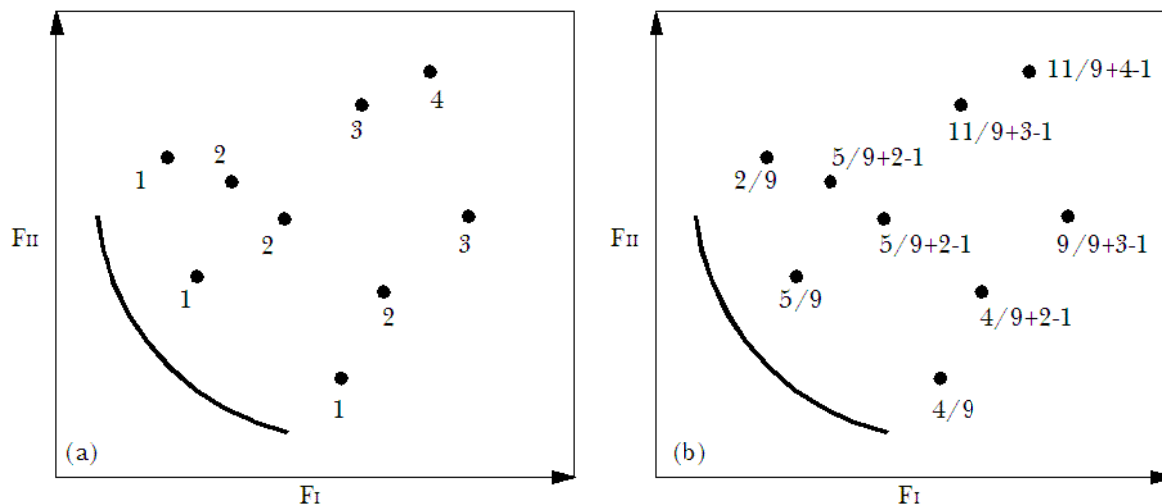


Figura 2 - Processo de hierarquização de uma população de soluções. (a) Atribuição do índice, (b) Atribuição do ranking.

Um teste importante que o método de calibração automática deve superar é a calibração de um modelo utilizando uma série sintética de vazões (Collischonn e Tucci, 2003). A série sintética é obtida executando o modelo, com os parâmetros fixos em valores escolhidos, e com uma série de dados pluviométricos e outra de dados de evaporação. Esta série gerada pelo modelo é, posteriormente, utilizada como série de vazões observadas para o procedimento de calibração.

Dessa forma, o segundo exercício consistiu na calibração automática do modelo IPH II considerando uma serie sintética. Ao considerar uma série sintética na calibração multi-objetivo são eliminadas as incertezas nos dados e na capacidade de representação do modelo ficando somente a incerteza na calibração dos parâmetros. Esse exercício permite verificar o desempenho do algoritmo MOSCEM-UA em encontrar um frente de Pareto que consiste em um único ponto, já que o conjunto de parâmetros que gera os valores ótimos das funções-objetivo é o mesmo (o escolhido para a gerar a serie sintética).

O terceiro exercício consistiu na calibração automática do modelo IPH II em um caso real, considerando duas funções-objetivo.

Problema multi-objetivo teórico

O desempenho do algoritmo MOSCEM-UA desenvolvido foi avaliado, em primeiro lugar, em um problema teórico apresentado em Vrugt et al. (2003). Nesse problema devem ser minimizadas as três funções-objetivo seguintes que dependem de dois parâmetros:

$$\text{Min: } F_A = \theta_1^2 + \theta_2^2, \tag{11}$$

$$\text{Min: } F_B = (\theta_1^2 - 1) + \theta_2^2 \text{ e} \tag{12}$$

$$\text{Min: } F_C = \theta_1^2 + (\theta_2^2 - 1), \tag{13}$$

$$\text{sujeito a } -2 \leq \theta_1 \leq 2 \text{ e } -2 \leq \theta_2 \leq 2 \tag{14}$$

O conjunto de parâmetros que gera o frente de Pareto desse problema consiste em uma área triangular, no espaço dos parâmetros, com os extremos (0,0), (0,1) e (1,0) para θ_1 e θ_2 , respectivamente.

Na resolução desse problema foram consideradas populações de diferentes tamanhos (ns=30, 50, 100 e 240 indivíduos) e diferentes números de complexos (q= 1, 3, 5, 10, 20). A Figura 3 e a Tabela 1 apresentam os resultados obtidos.

Tabela 1 - Número de soluções não dominadas em função do número de complexos e do tamanho da população após 5000 iterações.

Complexos	Tamanho da população			
	30	50	100	240
1	1043	1122	986	1002
3	3017	----	----	>5000
5	3987	4523	>5000	>5000
10	----	>5000	>5000	>5000
20	----	-----	>5000	>5000




Figura 3 - Conjuntos de parâmetros que geram as soluções não dominadas após 5000 iterações, considerando um tamanho da população $ns = 50$ e um número de complexos igual a 1 (a), 2 (b) e 5 (c).

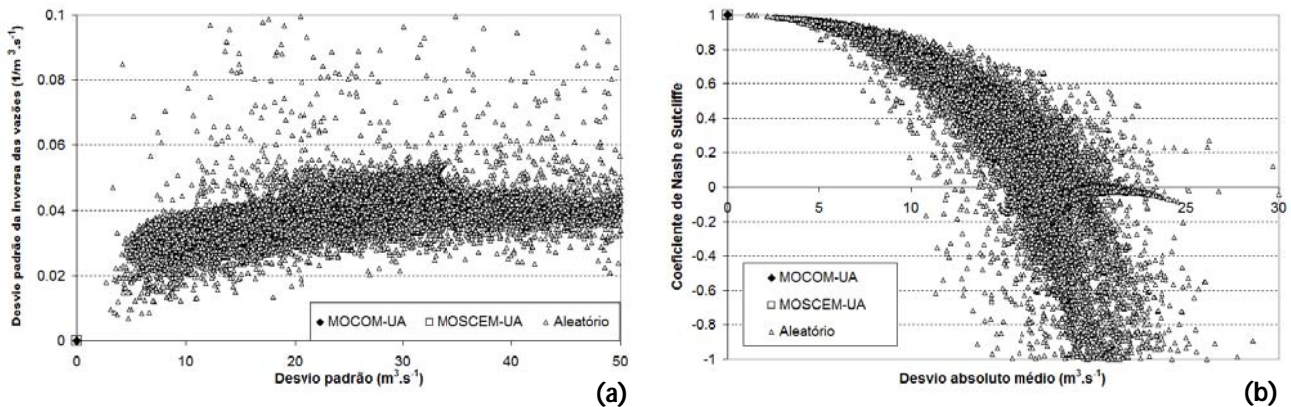


Figura 4 - Resultados do teste baseado na série sintética, no espaço das funções-objetivo e considerando a geração aleatória dos conjuntos de parâmetros, o MOSCEM-UA e o MOCOM-UA. (a) funções-objetivo desvio padrão e desvio padrão da inversa das vazões; (b) funções-objetivo desvio absoluto médio e coeficiente de Nash e Sutcliffe.

Observa-se em todos os casos avaliados que o algoritmo MOSCEM-UA consegue um bom número de soluções não dominadas. O número de soluções não dominadas encontradas parece depender do número de complexos e, ainda, do tamanho da população. Dessa forma, quanto maior o número de complexos e o tamanho da população, maior é o número de soluções não dominadas encontradas.

É importante lembrar que os custos computacionais também se incrementam com o aumento do número de complexos e do tamanho da população. Entretanto, para esse primeiro teste, os diferentes processos iniciados consumiram menos de dois minutos (versão sequencial do algoritmo) e menos de um minuto (versão em paralelo utilizando 4 *threads*)

em um processador Intel® Core(TM)2 Quad CPU, (4 CPUs), 2.4 GHz.

Observa-se ainda na Figura 3 que existe uma boa uniformidade das soluções não dominadas encontradas, não existindo concentrações de soluções em nenhum setor particular dessa região triangular procurada. Ainda com um único complexo essa uniformidade é mantida, embora a densidade das soluções encontradas (Figura 3(a)) seja menor que com um maior número de complexos (Figura 3(b) e (c)).

Resultados com o modelo IPH II

Em cada um dos testes efetuados, diferentes funções-objetivo foram consideradas, conforme

apresentado a seguir. É importante ressaltar que a escolha das funções-objetivo influi nos resultados do processo de calibração automática. Dessa forma, as funções-objetivo que possuem baixa correlação entre si, geralmente são as que fornecem os melhores resultados (Tassi et al., 2006).

Série sintética

Os parâmetros escolhidos para calibrar o modelo foram todos os possíveis, aos quais foram estabelecidos limites mínimos e máximos de variação, conforme a Tabela 2. A série sintética de vazões foi gerada a partir de um conjunto de dados de precipitação e evaporação, disponíveis em uma série real. O intervalo de tempo foi o diário e o período considerado abrange dois anos. Os valores dados aos sete parâmetros para gerar a série foram: $l_0=18,20$; $l_b=2,95$; $H=0,13$; $K_s=5,72$; $K_{sub}=40,25$; $R_{m\acute{a}x}=0,44$; $\alpha=12,66$.

A série sintética foi utilizada posteriormente como a série de vazões observadas na calibração automática do modelo IPH II utilizando os algoritmos MOSCEM-UA e MOCOM-UA. Em ambos os casos foram utilizados 100 indivíduos na população e no MOSCEM-UA, 10 complexos.

Tabela 2 - Limites máximo e mínimo dos valores dos parâmetros do modelo IPH II para a calibração automática.

Parâmetro	Unidade	Valor mínimo	Valor máximo
l_0	$mm.\Delta t^{-1}$	10	300
l_b	$mm.\Delta t^{-1}$	0,10	10
H	---	0,0001	0,9999
K_s	Δt	0,01	10
K_{sub}	Δt	10	500
$R_{m\acute{a}x}$	mm	0	9
α	---	0,01	20

Foram realizados dois testes, considerando em cada um deles, duas funções-objetivo no processo de calibração (Figura 4). Para comparação e análise foram ainda gerados de forma aleatória, 50.000 conjuntos de parâmetros considerando uma distribuição multivariada uniforme dentro dos limites mínimo e máximo de cada parâmetro (Tabela 2). Os resultados em termos de funções-objetivo são ainda apresentados na Figura 4.

No primeiro teste (Figura 4(a)), foram consideradas as funções-objetivo: desvio padrão (eq. 3) e desvio padrão do inverso das vazões (eq. 4). Ambas funções-objetivo devem ser minimizadas, sendo o valor zero de ambas encontrado para o conjunto de parâmetros que gerou a série sintética.

No segundo teste (Figura 4(b)), foram consideradas as funções-objetivo: desvio absoluto médio (eq. 5) e o coeficiente de Nash e Sutcliffe (eq. 6). Nesse caso, a primeira função-objetivo deve ser minimizada (valor igual a zero para o conjunto de parâmetros que gerou a série sintética) e a segunda maximizada, sendo o valor máximo que esta última pode alcançar igual a um.

Observa-se na Figura 4 que foram encontradas as soluções (0,0) (primeiro teste) e (0,1) (segundo teste) o que significa que o conjunto de parâmetros que gerou a série sintética foi encontrado em ambos os casos. Isso aconteceu tanto com o algoritmo MOSCEM-UA como com o algoritmo MOCOM-UA. Ainda, nenhum conjunto de parâmetros gerado em forma aleatória conseguiu ser igual ao conjunto de parâmetros que gerou a série sintética. Isto fica claro na Figura 4 já que nenhum dos pontos obtidos considerando os parâmetros gerados aleatoriamente se encontra no ótimo de ambas funções-objetivo.




Figura 5 - Resultados da calibração automática multi-objetivo do modelo IPH II.

Série real

Como base de dados foi utilizada a bacia do rio Tesouras, que é um dos formadores do rio Araguaia. Esta bacia está localizada no estado de Goiás,

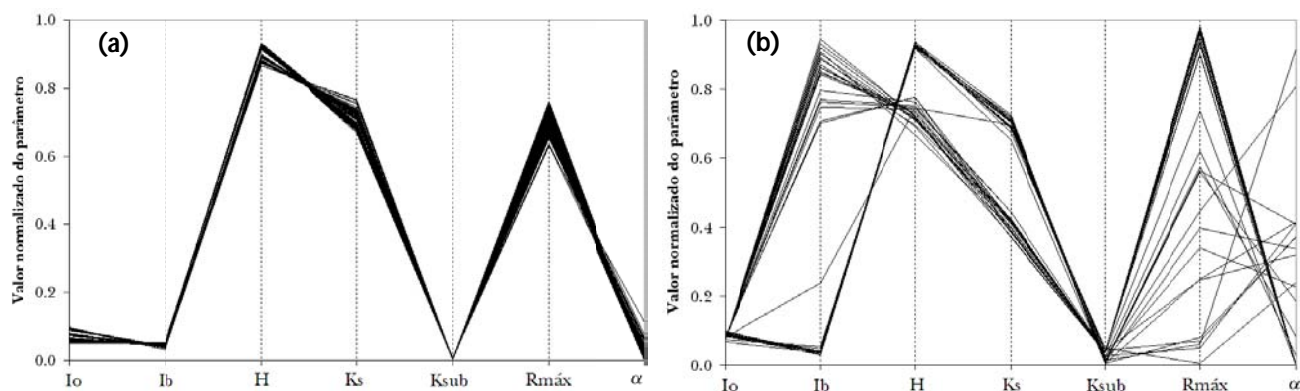


Figura 6 - Gráficos dos valores normalizados dos parâmetros do modelo IPH II utilizando (a) o MOCOM-UA e (b) o MOSCEM-UA. Cada linha desses gráficos representa um conjunto de parâmetros que gerou uma solução não dominada.




Figura 7 - Comparação entre os hidrogramas observados e calculados no período de calibração. (a) Hidrograma calculado utilizando os valores dos parâmetros que geraram o melhor valor do coeficiente de Nash e Sutcliffe; (b) Hidrograma calculado utilizando os valores dos parâmetros que geraram o melhor valor do desvio padrão do inverso das vazões.

Tabela 3 - Valores mínimos e máximos dos parâmetros do modelo IPH II encontrados na calibração automática multi-objetivo utilizando o MOCOM-UA e o MOSCEM-UA.

Parâmetro	Unidade	Faixa de variação viável		Faixa de variação MOCOM-UA		Faixa de variação MOSCEM-UA	
		Valor mínimo	Valor máximo	Valor mínimo	Valor máximo	Valor mínimo	Valor máximo
Io	mm. Δt^{-1}	10	300	24,63	38,18	31,01	38,48
Ib	mm. Δt^{-1}	0,10	10	0,41	0,62	0,442	9,446
H	---	0,0001	0,9999	0,867	0,934	0,671	0,932
Ks	Δt	0,01	10	6,68	7,66	3,708	7,09
Ksub	Δt	10	500	10,03	12,75	16,81	30,50
Rmáx	Mm	0	9	5,68	6,85	0,54	8,83
α	---	0,01	20	0,01	2,277	0,01	18,32

em uma região com relevo relativamente ondulado. Essa região pertence à Depressão do Araguaia, sendo as coberturas vegetais predominantes o cerrado e a pastagem (RADAMBRASIL, 1981). O clima é tropical com duas estações bem definidas: chuvosa, de outubro a março, e seca, de abril a setembro. A precipitação média anual é aproximadamente 1700 mm e a evapotranspiração real estimada, aproximadamente, 1600 mm.ano⁻¹, tendo o coeficiente de escoamento de longo prazo um valor em torno de 0,35.

Os dados de vazão foram obtidos do posto fluviométrico Ponte rio Tesouras (código 25500000), cuja área é de 1817 km².

É importante destacar que a quantidade de dados necessários na calibração automática parece depender da complexidade do modelo (em termos do número de parâmetros a ser estimados) e da qualidade e características dos dados (Wagener et al., 2004). Nesse caso, o período de dados considerado foi de 5 anos e o intervalo de tempo considerado foi de 1 dia.

No processo de calibração foi considerada a maximização do coeficiente de Nash e Sutcliffe (eq. 4) e a minimização do desvio padrão do inverso das vazões (eq. 2). Os algoritmos MOSCEM-UA e MOCOM-UA foram utilizados no processo considerando 500 indivíduos na população e, no caso do MOSCEM-UA, 25 complexos.

A Figura 5 apresenta a aproximação do frente de Pareto obtida com o MOCOM-UA e com o MOSCEM-UA para 100.000 iterações. Observa-se nessa figura que existem pontos comuns na parte superior das aproximações do frente de Pareto encontradas. Entretanto, o extremo inferior do frente de Pareto não é bem representado pelo MOCOM-UA. O MOSCEM-UA consegue encontrar uma melhor aproximação do frente de Pareto a qual apresenta uma descontinuidade na parte central.

Quanto à eficiência de ambas as técnicas, o algoritmo MOCOM-UA levou, em média, 10 minutos para efetuar um processo de calibração. O algoritmo MOSCEM-UA na sua versão sequencial consumiu, em média, 26 minutos. Por sua vez, o algoritmo MOSCEM-UA na sua versão em paralelo levou, em média, 21 minutos utilizando 2 *threads* e 15 minutos utilizando 4 *threads* ao executar um processo de calibração.

Os resultados apresentados na Figura 6 e na Tabela 3 ainda mostram que ambos os algoritmos encontraram soluções comuns. Entretanto, o algoritmo MOCOM-UA não conseguiu encontrar o conjunto de parâmetros que combina maiores valores do I_b e do α e valores mais baixos de H e K_s que

geraram as soluções não dominadas na parte inferior da aproximação de Pareto obtida pelo algoritmo MOSCEM-UA. Isto pode ser considerado um benefício do algoritmo MOSCEM-UA, que consegue manter os extremos do frente de Pareto bem representados no processo de calibração automática do modelo IPH II.

Na análise dos valores dos parâmetros obtidos por calibração automática pode-se observar ainda que o parâmetro R_{\max} se mostrou como o menos sensível no caso analisado.

A modo de exemplo, o ajuste obtido entre as vazões observadas e calculadas, em 650 dias do período de calibração, é apresentado na Figura 7. Os hidrogramas calculados foram obtidos utilizando os valores dos parâmetros que geraram o melhor valor do coeficiente de Nash e Sutcliffe (correspondente à solução localizada no extremo superior do frente de Pareto) na Figura 7(a) e os valores dos parâmetros que geraram o melhor valor do desvio padrão do inverso das vazões (correspondente à solução localizada no extremo inferior do frente de Pareto).

Observa-se na Figura 7 que o hidrograma calculado em (a) apresenta um bom ajuste nos maiores valores de vazão. Entretanto, as recessões do hidrograma apresentam, geralmente, valores menores que os observados e as vazões mínimas são superestimadas, embora o ajuste continue sendo bom. A Figura 7(b) mostra que o hidrograma calculado apresenta um bom ajuste das recessões e estiagens, sendo os picos de vazão, geralmente subestimados. Entre essas duas soluções extremas poderia ser escolhido outro conjunto de parâmetros, dentre aqueles que definiram soluções na aproximação do frente de Pareto, gerando um hidrograma calculado que apresentaria um certo compromisso entre ambas as soluções.




Figura 8 - Hidrogramas de vazão observada (linha preta) e calculadas (banda cinza) no período analisado.

As incertezas na calibração dos parâmetros avaliadas através da calibração multi-objetivo podem-se estender aos resultados do modelo hidrológico. Nesse caso, todos os conjuntos de parâmetros que geraram soluções não dominadas são utilizados para gerar hidrogramas calculados, como apresentado na Figura 8.

O conjunto de hidrogramas calculados define, em cada intervalo de tempo, um intervalo de vazões que pode ser entendido como uma banda de incerteza associado à calibração dos parâmetros. Obviamente existem outras fontes de incerteza e, por isso, nem sempre a banda de incerteza contém o hidrograma observado. Entretanto, a incerteza associada à calibração dos parâmetros é razoavelmente bem estimada sendo que alguns hidrogramas ajustam melhor os picos e outros as estiagens e recessões.

CONCLUSÕES

A calibração automática multi-objetivo permite a avaliação das incertezas na calibração dos parâmetros dos modelos hidrológicos. Dessa forma, o conhecimento do desempenho de diferentes técnicas disponíveis para esses fins é sumamente importante.

Esse trabalho apresentou um algoritmo evolucionário multi-objetivo de otimização desenvolvido por Vrugt et al. (2003) e denominado MOSCEM-UA. O algoritmo MOSCEM-UA foi aplicado na calibração automática do modelo hidrológico IPH II.

Dois testes foram realizados na calibração automática do modelo IPH II e o algoritmo MOCOM-UA foi utilizado na comparação dos resultados. O primeiro teste foi baseado numa série sintética e ambos os algoritmos conseguiram encontrar as soluções do problema.

No segundo teste, uma série real foi utilizada sendo obtidos bons ajustes entre as vazões observadas e calculadas pelo modelo IPH II com base nos conjuntos de parâmetros que geraram soluções na aproximação do frente de Pareto.

A aproximação do frente de Pareto obtida pelo algoritmo MOSCEM-UA apresentou uma maior uniformidade, sobretudo nos extremos, que a obtida com o MOCOM-UA, a técnica atualmente utilizada na calibração automática do modelo IPH II. Isto pode ser considerado um benefício do algoritmo MOSCEM-UA, que consegue manter os extremos do frente de Pareto bem representados no processo de calibração automática do modelo IPH II.

Dessa forma, os resultados obtidos são promissores. A utilização do MOSCEM-UA é simples, tendo em vista que somente dois parâmetros desse algoritmo devem ser definidos pelo usuário: o tamanho da população e o número de complexos. A calibração tende a ser melhor com o aumento de ambos os valores desses parâmetros. Entretanto, o aumento dos valores desses parâmetros produz uma diminuição da eficiência do MOSCEM-UA pelo aumento do tempo de processamento, porém para uma população de 500 indivíduos e considerando 25 complexos os resultados são plenamente satisfatórios quando são otimizadas duas funções-objetivo.

AGRADECIMENTOS

O primeiro autor agradece à Universidade Nacional do Nordeste (UNNE, Argentina) pelo financiamento de seus estudos de mestrado no qual foi iniciada essa pesquisa e ao CNPQ pela bolsa de doutorado concedida.

REFERÊNCIAS

- BARROS, F.V.F. Uso de algoritmos evolucionários na calibração de modelos hidrológicos e na operação de sistemas de reservatórios. Dissertação de mestrado, Universidade Federal do Ceará, 177 p., 2007.
- BEVEN, K.; BINLEY, A. The future of distributed models: model calibration and uncertainty prediction. *Hydrological Processes*, v 6, p. 279-298, 1992.
- BOS, A.; VRENG, A. Parameter optimization of the HYMOD model using SCEM-UA and MOSCEM-UA. *Modelling Geo-Ecological Systems Computational Bio- and Physical Geography*. University of Amsterdam, 43p., 2006.
- BURN, D.H., YULIANTI, J.S. Waste-load allocation using genetic algorithms. *Journal of Water Resources Planning and Management*, v 127, n 2, p. 121-129, 2001.
- BURNASH, R.J.C. The NWS river forecast system catchment modelling. In: Singh, V. J. (editor) *Computer models of watershed hydrology*. Water Resources Publications, Highlands Ranch. 1130 p., 1995.
- CHAPMAN, B.; JOST, G.; PAS, R. *Using OpenMP: portable shared memory parallel programming*. MIT Press, Massachusetts, 353 p., 2008.
- CIENIAWSKI, S.E., EHEART, J.W., RANJITHAN, S. Using genetic algorithms to solve a multiobjective ground-

- water monitoring problem. *Water Resources Research*, v 31, n 2, p. 399-409, 1995.
- COELHO, L. S. F. Notas em matemática aplicada 2. Fundamentos, potencialidade e aplicações dos algoritmos evolucionários. SBMAC, 99 p., 2003.
- COLLISCHONN, W.; TUCCI, C.E.M. Ajuste multi-objetivo dos parâmetros de um modelo hidrológico. *Revista Brasileira de Recursos Hídricos*, v 8, n 3, p. 27-39, 2003.
- DEB, K.; PRATAP, A.; AGARWAL, S.; MEYARIVAN, T. A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II. *IEEE Trans. on Evol. Comput.*, v 6, n 2, p. 182-197, 2002.
- GOLDBERG, D.E. Genetic algorithms in search, optimization and machine learning. Addison Wesley Longman, Boston, 412 p., 1989.
- GUPTA, H.V.; SOROOSHIAN, S.; YAPO, P.O. Toward improved calibration of hydrologic models: Multiple and noncommensurable measures of information. *Water Resources Res.*, v 34, n 4 p. 751-763, 1998.
- HERMANN, M. Parallel programming in Fortran 95 using OpenMP, Universidad Politécnica de Madrid, 71 p., 2002.
- JOHNSON, K.P.; MENGELKAMP, H.T.; HUNEKE, S. Multi-objective calibration of the land surface scheme TERRA/LM using LITFASS-2003 data, *Hydrology and Earth System sciences*, v 9, n 6, p. 586-595, 2005.
- KOLLAT, J.B.; REED, P.M. Comparing state-of-the-art evolutionary multi-objective algorithms for long-term groundwater monitoring design. *Advances in Water Resources*, v 29, p. 792-807, 2006.
- LACERDA, E.G.M.; CARVALHO, A.C.P.L.F. Introdução aos algoritmos genéticos. In: GALVÃO, C.O.; VALENÇA, M.J. S. Sistemas inteligentes: aplicações a recursos hídricos e sistemas ambientais. UFRGS/ABRH. Porto Alegre, 1999.
- METRÓPOLIS, N.A.; ROSENBLUTH, A.W.; ROSENBLUTH, M.N.; TELLER, A.H.; TELLER, E. Equations of state calculations by fast computing machines. *Journal of Chemical Physics*, v 21, n 6, p. 1087-1092, 1953.
- PANDE, S.; BASTIDAS, L.A.; ROSERO, E.; MCKEE, M.; SHUTTLEWORTH, W.J.; ROCHA, H.R.; MILLER, S. Effect of Data Uncertainty on Parameter Uncertainty within a Multi-Objective Parameter Estimation Framework, 2005 AGU Fall Meeting, 5-9 dec. San Francisco-USA.
- RADAMBRASIL. Levantamento de recursos naturais, v 25. Folha SD 22. Goiás, 1981.
- SCHOUPS, G.; HOPMANS, J.W.; YOUNG, C.A.; VRUGT, J.A.; WALLENDER, W.W. Multi-criteria optimization of a regional spatially-distributed subsurface water flow model, *Journal of Hydrology*, v 311, p. 20-48, 2005.
- SOROOSHIAN, S.; GUPTA, V.K. Model calibration In: Singh, V. J. (editor) *Computer models of watershed hydrology*. Water Resour. Pub., Highlands Ranch. 1130 p., 1995.
- SOROOSHIAN, S.; GUPTA, H.V.; BASTIDAS, L.A. Calibration of hydrologic models using multi-objectives and visualization techniques. Final Report EAR 9418147. Dep. Hydrol. and Water Resource, UA, 78p, 1998.
- TANG, Y.; REED, P.; WAGENER, T. How effective and efficient are multiobjective evolutionary algorithms at hydrologic model calibration? *Hydrology and Earth System Sciences*, v 10, p. 289-307. 2006.
- TASSI, R.; BRAVO, J.M.; MELLER, A.; COLLISCHONN, W. Avaliação do impacto de diferentes funções-objetivo na calibração automática multi-objetivo do modelo IPH II. XXII Congresso Latinoamericano de Hidráulica, Guayana, Venezuela, out. 2006, 1 CD.
- TUCCI, C.E.M. Modelos hidrológicos. ABRH Editora da UFRGS. Porto Alegre. 669 p., 1998.
- VINK, K.; SCHOT, P. Multiple-objective optimization of drinking water production strategies using a genetic algorithm. *Water Resources Research*, v 38, n 9, 20, 2002.
- VRUGT, J.A.; GUPTA, H.V.; BOUTEN, W.; SOROOSHIAN, S. A Shuffled Complex Evolution Metropolis algorithm for optimization and uncertainty assessment of hydrologic model parameters. *Water Resour. Res.*, v 39, n 8. 2003.
- WAGENER, T.; WHEATER, H.; GUPTA, H.V. Rainfall-Runoff modeling in gauged and ungauged catchments. Imperial College Press. 306 p., 2004.
- YAPO, P.O.; GUPTA, H.V.; SOROOSHIAN, S. Multiobjective global optimization for hydrologic models. *Journal of Hydrology*, v 204, p. 83-97, 1998.
- YEH, C.H.; LABADIE, J.W. Multiobjective watershed-level planning of storm water detention systems. *Journal of Water Resources Planning and Management*, v 123, n 6, p. 336-343, 1997.
- ZITZLER, E.; THIELE, L. Multiobjective Evolutionary Algorithms: A Comparative Case Study and the Strength Pareto Approach. *IEEE Trans. on Evol. Comput.*, v 3, n 4, p. 257-271, 1999.

Verification of the Efficiency and Efficacy of a Multi-Objective Evolutionary Algorithm in the Automatic Calibration of the IPH II Hydrological Model

ABSTRACT

The complex processes of the hydrological cycle can be represented through hydrological modeling, being the models that simulate the rainfall-runoff process the most

used of them. These models are based in mathematical equations that describe, in a simplified way, the hydrological behavior of the basin and possess parameters that must be defined through a process of calibration. The manual calibration, by trial and error, can be a tedious task, especially when the model's user is inexperienced. The automatic calibration, however, utilizes numerical optimization techniques based in the intensive use of computers. This study presents a multi-objective evolutionary algorithm of optimization developed by Vrugt et al. (2003) and applied in the automatic calibration of the IPH II hydrological model. The obtained results are encouraging: the algorithm produced a uniform approach of the Pareto Front in all the different tests carried out, keeping well represented its extremities. Additionally this method displayed some advantages over another multi-objective evolutionary algorithm currently used for the automatic calibration of the IPH II hydrological model.

Keywords: *automatic calibration, evolutionary algorithm, hydrological modeling, MOSCEM-UA, IPH II*