

## Ajuste Multiobjetivo dos Parâmetros de um Modelo Hidrológico

Walter Collischonn, Carlos Eduardo Morelli Tucci

Instituto de Pesquisas Hidráulicas – UFRGS, Av. Bento Gonçalves, 9500. Caixa Postal 15029 CEP 91501-970  
Porto Alegre - RS - Brasil - [cllschonn@portex.ufrgs.br](mailto:cllschonn@portex.ufrgs.br)

Recebido: 01/08/02 – revisão: 23/01/03 – aceito: 01/07/03

### RESUMO

Modelos hidrológicos chuva – vazão são utilizados em diferentes áreas dos recursos hídricos. Estes modelos possuem parâmetros que caracterizam uma determinada bacia e necessitam ser ajustados com dados observados de vazão. A calibração de modelos hidrológicos pode ser uma tarefa tediosa quando realizada por tentativa e erro, especialmente quando o usuário do modelo é pouco experiente. Já o ajuste automático é realizado por otimização através de técnicas iterativas, que possuem as seguintes limitações: solução com mínimos locais; solução matemática encontrando parâmetros distantes da realidade física, limitações das funções objetivo, entre outros. Este artigo apresenta um método de calibração automática, recentemente proposto por Yapo et al. (1998), que simplifica o processo de calibração, mas mantém algumas características desejáveis da calibração manual, em especial a consideração de várias funções objetivo ao mesmo tempo. São apresentados resultados utilizando o modelo IPH2 em uma bacia de 989 km<sup>2</sup> no estado de Santa Catarina, considerando, ao mesmo tempo, até três funções objetivo.

**Palavras-chave:** modelo hidrológico, calibração automática.

### TÉCNICAS DE AJUSTE DE PARÂMETROS

O ajuste dos parâmetros de um modelo hidrológico é uma etapa do uso do mesmo que envolve o maior esforço para seu usuário devido à necessidade de maior entendimento do comportamento do modelo e dos parâmetros e aos problemas com a qualidade e representatividade dos dados hidrológicos.

Nos problemas práticos de calibração de modelos hidrológicos, não existe um conjunto único de parâmetros capaz de representar os processos hidrológicos, devido às incertezas inerentes aos dados, das simplificações do modelo e da representatividade dos parâmetros. Existem várias combinações de parâmetros que apresentam resultados semelhantes entre si e relativamente próximos aos dados observados. Entre estes conjuntos é praticamente impossível definir qual é o mais adequado, o que origina o conceito de *equifinalidade*, conforme Beven e Binley (1992).

Matematicamente, a calibração é um problema de infinitas soluções igualmente possíveis já que existem mais equações do que incógnitas, podendo existir soluções que atendam às equações, mas não representam a realidade lógica do problema e mesmo dos valores esperados dos parâmetros. De outro lado, existirão várias soluções que possuem justificativa técnica e resposta adequada para o problema, e entre as quais não é possível, em geral, distinguir a mais aceitável ou a melhor.

### Tentativa e erro

A primeira técnica utilizada pelos hidrólogos para a determinação dos parâmetros, pela robustez e simplicidade é o *método da tentativa e erro*. A habilidade do usuário é essencial no uso deste procedimento, o que dificulta muito a sua transferência para vários usuários. Os críticos diriam que é essencial entender o modelo para usá-lo, mas existe uma diferença entre entender o modelo e possuir habilidade para encontrar uma solução por tentativa.

O ajuste manual é realizado por tentativa e erro, em repetidas execuções do modelo e análises dos resultados. A cada tentativa o usuário analisa o ajuste de vazões mínimas, a forma do hidrograma calculado, o ajuste dos picos de cheias em termos de valor máximo, volume, forma e tempo de ocorrência. Além disso, ele pode observar os valores que tomam algumas funções objetivo, como: (a) relação entre os volumes calculados e observados (equação 1); (b) o erro padrão (equação 2); (c) o coeficiente de Nash-Sutcliffe (equação 3); (e) o erro padrão do inverso da vazão (equação 4).

$$\Delta V = \frac{\sum(Q_{\text{cal}}(t)) - \sum(Q_{\text{obs}}(t))}{\sum(Q_{\text{obs}}(t))} \quad (1)$$

$$\text{RMSE} = \sqrt{\frac{\sum(Q_{\text{obs}}(t) - Q_{\text{cal}}(t))^2}{n}} \quad (2)$$

$$NS = 1 - \frac{\sum (Q_{obs}(t) - Q_{cal}(t))^2}{\sum (Q_{obs}(t) - \bar{Q}_{obs})^2} \quad (3)$$

$$RMSEI = \sqrt{\frac{\sum \left( \frac{1}{Q_{obs}(t)} - \frac{1}{Q_{cal}(t)} \right)^2}{n}} \quad (4)$$

onde  $Q_{obs}(t)$  é a vazão observada no tempo  $t$ ;  $Q_{cal}(t)$  é a vazão calculada no tempo  $t$ ;  $n$  é o número de intervalos de tempo; e  $\sum$  indica somatório entre  $t=1$  e  $t=n$ .

Estas funções procuram avaliar a qualidade do ajuste, sendo que algumas são mais sensíveis aos erros nas vazões máximas (RMSE e NS), outras são especialmente utilizadas para avaliar o ajuste nas vazões mínimas (RMSEI), enquanto o erro dos volumes ( $\Delta V$ ) é complementar e avalia o desvio geral do volume total calculado em relação ao observado (Tucci, 1998).

O usuário experiente, que já calibrou o mesmo modelo para muitas bacias diferentes, conta com sua experiência e o conhecimento sobre a sensibilidade de cada um dos parâmetros. O usuário experiente já sabe, de antemão, as modificações que devem ser feitas nos valores dos parâmetros para alterar determinados aspectos do hidrograma calculado. Quando existe este conhecimento, a calibração manual pode ser rápida e é uma etapa relativamente simples da aplicação do modelo.

A calibração manual pode, portanto, ser relativamente rápida e, ao mesmo tempo, considerar múltiplos objetivos de forma implícita. Os problemas surgem quando o usuário do modelo não é experiente. Neste caso, a calibração automática pode ser a solução. Outra situação em que a calibração automática é interessante ocorre quando se deseja que dois usuários diferentes encontrem sempre o mesmo conjunto de parâmetros durante calibrações independentes. Neste caso, a técnica de calibração automática utilizada deve ter a capacidade de encontrar, de forma eficaz, o ótimo global. No entanto, o uso desta técnica não isenta o hidrólogo da responsabilidade de conferir a validade dos parâmetros.

### Calibração automática

A alternativa ao método de tentativas foi o das técnicas de otimização, inicialmente utilizadas na década de 70 para este tipo de modelo (Tucci, 1998). Os primeiros métodos utilizados eram baseados em técnicas iterativas como o método univariacional, rotação das coordenadas (Rosembrock, 1960), do gradiente mínimo, entre outros. As principais dificuldades destes métodos são: (a) a função objetivo nem sempre retrata bem o ajuste desejado, apresentando anomalias na vizinhança da solução; (b) a solução

pode convergir para parâmetros inconsistentes, já que existem infinitas soluções matematicamente possíveis, mas irreais do ponto de vista físico; (c) o mínimo obtido pode ser local e não global, pois depende muito do ponto de partida; (d) quando o número de parâmetros cresce muito, por exemplo quando se divide a bacia em um grande número de sub-bacias, e a série simulada envolve muitos intervalos de tempo, o processo pode ser lento e o usuário perde a noção do desejado ótimo; (e) quando existem muitas incertezas nos dados observados, as mesmas são transferidas para o ajuste, o que pode provocar resultados absurdos; (f) interdependência entre os parâmetros; (g) descontinuidade da função objetivo devido às características da estrutura do modelo.

**Mínimos locais:** Uma importante parcela das críticas ocorre porque os primeiros métodos de calibração automática que surgiram na literatura são de mínimos locais e tendem a calibrar o modelo com grupos diferentes de parâmetros dependendo do ponto de início do processo de busca (Johnston e Pilgrim, 1976; Pickup, 1977). Isto significa que, em duas aplicações idênticas à mesma bacia e ao mesmo período de tempo, o método de calibração pode encontrar valores de parâmetros diferentes, o que aumenta muito a incerteza no uso do modelo. Isto ocorre porque as superfícies de resposta das funções objetivo normalmente utilizadas são não lineares e descontínuas (Duan et al., 1992; Xiong e O'Connor, 2000). Sobre estas superfícies de resposta as técnicas de calibração baseadas em busca local tendem a gerar resultados pouco confiáveis.

Estes problemas foram reduzidos com a introdução de uma nova geração de métodos na década de 80 (Brazil, 1988) baseada na geração de números aleatórios associados com os métodos univariacionais (Beard, 1966; Tucci, 1998). Com o uso dos algoritmos genéticos este processo ganhou ainda melhor direção no sentido de soluções adequadas pela varredura orientada das soluções (Duan et al., 1992, Sorooshian e Gupta, 1995). Isto somente foi possível porque os computadores aumentaram muito a sua velocidade de cálculo, já que são todos métodos baseados em sucessivas tentativas.

Um teste importante que o método de calibração automática deve superar é a calibração de um modelo utilizando uma série sintética de vazões. A série sintética é obtida executando o modelo, com os parâmetros fixos em valores escolhidos, e com uma série qualquer 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. Um bom algoritmo de calibração automática deve encontrar valores dos parâmetros do modelo exatamente iguais aos que foram utilizados para gerar a série sintética. Infelizmente, grande parte dos algoritmos largamente utilizados não consegue superar nem este teste básico de qualidade.

Os algoritmos conhecidos como “de busca local” costumam ser atraídos por ótimos locais.

Nem mesmo o uso repetido de um algoritmo de busca local é eficaz na busca do ótimo global, como ficou demonstrado no caso do algoritmo denominado MSX, baseado em múltiplas inicializações do algoritmo Simplex de Nelder e Mead (Sorooshian e Gupta, 1995). Inicializado 50 vezes para cada otimização, o algoritmo MSX não foi capaz de encontrar o ótimo global dos parâmetros do modelo Sacramento (Burnash, 1995) em nenhum dos 10 testes realizados.

Nos últimos dez anos, porém, importantes desenvolvimentos vêm ocorrendo tanto na definição de novas funções objetivo (Yu e Yang, 2000) como no desenvolvimento de algoritmos de otimização global (Wang, 1991; Duan et al., 1992; Duan et al., 1994; Yapo et al., 1998, Bonabeau et al., 2000, Abbaspour et al., 2001, Kuczera e Parent, 1998). Estes desenvolvimentos devem contribuir para reduzir, ao menos parcialmente, os pontos fracos da calibração automática.

**Função objetivo:** Uma outra parcela considerável das críticas à calibração automática está relacionada às funções objetivo que são utilizadas. Ainda são incipientes as tentativas de definir funções objetivo que podem ser comparadas à função objetivo implícita no processo de calibração manual. As funções objetivo normalmente utilizadas na calibração automática não contemplam toda a complexidade considerada na calibração manual (Boyle et al., 2000).

Todos estes métodos sempre trataram o problema de otimização de modelos hidrológicos através de uma única função objetivo implícita. A função objetivo deve ser representativa quanto à qualidade dos resultados desejados. Várias destas funções foram propostas e testadas e geralmente a função quadrática da diferença das vazões apresentou melhor resultado porque não apresenta importantes singularidades. No entanto, quando se escolhe uma função pode-se obter resultados tendenciosos. Por exemplo, a função quadrática tende a priorizar os valores maiores na medida em que se minimiza o desvio quadrático das vazões.

Na simulação de séries contínuas existe, em geral, uma característica multi-objetivo para o uso do modelo hidrológico, pois deseja-se representar bem os períodos de cheia e de estiagem e não um em detrimento do outro.

A otimização multi-objetivo é um novo estágio do uso destas técnicas no ajuste dos modelos hidrológicos (terceira geração). Neste artigo é descrita uma técnica de calibração automática multi-objetivo de modelos hidrológicos baseada em um algoritmo genético. A técnica original foi desenvolvida por Yapo et al. (1998) e aplicada no modelo NWS-RFS, ou Sacramento, e outros (Sorooshian et al., 1998; Gupta et al. 1998). Este trabalho apresenta a

descrição da técnica bem como uma aplicação usando o modelo hidrológico IPH2 (Tucci, 1998), calibrado considerando, ao mesmo tempo, até três funções objetivo. A partir dos bons resultados obtidos calibrando o modelo IPH2, a técnica foi aplicada também para calibrar um modelo hidrológico distribuído de grandes bacias (Collischonn, 2001; Collischonn e Tucci, 2001b; Collischonn e Tucci, 2002).

**Uso das técnicas de otimização:** A demanda por métodos de calibração automática vem aumentando, com o surgimento de uma nova geração de modelos em programas de computador amigáveis e com a generalização de seu uso em empresas de consultoria e instituições governamentais ligadas aos recursos hídricos. Cada vez mais os modelos hidrológicos estão disponíveis para serem usados por pessoas com pouca formação na área de simulação, e com pouco conhecimento teórico sobre o modelo que estão aplicando e sobre as suas limitações. A apresentação de resultados através de uma atraente interface gráfica também estimula ao uso indiscriminado dos resultados (Gan e Biftu, 1996). Para atrair usuários e para aumentar a confiabilidade destes modelos, procedimentos de calibração automática certamente vão fazer parte destes programas e, neste caso, é necessário utilizar as melhores técnicas disponíveis para reduzir a incerteza e evitar resultados absurdos.

## OTIMIZAÇÃO DOS PARÂMETROS

Os parâmetros são valores que caracterizam um sistema, mas seus valores não podem ser determinados diretamente através de medições. Neste texto os parâmetros são considerados diferentes das variáveis que *descrevem quantitativamente um fenômeno ou acontecimento* – por exemplo a vazão ou a precipitação.

A calibração é realizada modificando os valores dos parâmetros até que o hidrograma calculado reproduza o hidrograma observado com boa precisão.

### Calibração automática mono-objetivo

Entre os algoritmos de otimização mais recentes está o algoritmo SCE-UA (Duan et al., 1992; Diniz, 1999). Este algoritmo combina técnicas de busca aleatória, algoritmos genéticos e otimização simplex de Nelder e Mead (Nelder e Mead apud Pres et al., 1995). O algoritmo SCE-UA tem sido utilizado em modelos chuva-vazão de vários níveis de complexidade, com até 18 parâmetros para calibração (Eckhardt e Arnold, 2001) e já foi comparado com outros métodos de calibração automática por diversos autores, sempre mostrando vantagens significativas. Outra característica positiva verificada é a persistência do método, que atinge, em geral, o mesmo ponto ótimo, mesmo

quando são alterados alguns parâmetros e a semente do processo de geração de números aleatórios (Duan et al., 1992; Franchini et al., 1998; Collischonn e Tucci, 2001a). Isto é uma forte indicação, embora não seja uma prova, de que o ponto encontrado é o ótimo global.

Como qualquer algoritmo genético, o algoritmo SCE-UA opera com uma população de pontos que “evolui” em direção ao ótimo global através de sucessivas iterações e avaliações da função objetivo. Cada um destes pontos é definido pelos valores dos parâmetros e é um candidato ao ótimo.

No início do procedimento, é gerada, aleatoriamente, uma amostra de pontos espalhados no espaço hiperdimensional, que define a região onde os parâmetros são considerados válidos. Cada parâmetro do modelo hidrológico pode ser gerado em um intervalo de valores que vai de um limite mínimo até um limite máximo, definido pelo usuário.

Ao longo do procedimento, a amostra de pontos evolui em conjunto, até que os pontos se concentrem em uma região muito pequena, ou mesmo sobre um ponto do espaço, em que está localizado o ponto ótimo. O algoritmo SCE – UA combina técnicas de: (a) busca aleatória; (b) algoritmos genéticos e (c) método simplex de Nelder e Mead (busca local – figura 1).

Duan et al. (1992) compararam o SCE-UA aos métodos de otimização de busca sistemática, busca aleatória, busca aleatória adaptativa, combinação do método simplex com busca aleatória adaptativa e com o método simplex de inicialização múltipla (MSX), utilizando um modelo hidrológico simplificado e uma série sintética de vazões observadas. Estes autores concluíram que o algoritmo SCE-UA é mais eficiente do que todos os outros, atingindo com segurança o ótimo global de um problema de calibração hipotético, com apenas um terço do tempo computacional do melhor método alternativo (MSX).

Sorooshian et al. (1993) compararam o algoritmo SCE-UA e o método simplex com inicialização múltipla (MSX) para calibração dos parâmetros do modelo chuva - vazão Sacramento (Burnash, 1995), que é utilizado pelo NWS para a previsão hidrológica em diversas bacias dos EUA. O método MSX pode ser considerado um aperfeiçoamento de métodos de otimização como o de Rosenbrock, porque a busca pelo melhor conjunto de parâmetros inicia por um grande número de pontos iniciais diferentes, mas mesmo assim os autores concluíram que o algoritmo SCE-UA é mais eficiente para calibração de modelos hidrológicos. Em diversos testes com o modelo Sacramento, o método SCE-UA atingiu valores significativamente mais baixos (melhores) da função objetivo durante a calibração, embora os resultados durante a verificação sejam semelhantes para os dois métodos considerados.

O algoritmo SCE-UA foi testado e comparado em aplicações com 4 diferentes modelos chuva – vazão e em 8

bacias de tamanhos e climas diferentes por Gan e Biftu (1996), e mostrou ser mais eficiente do que o método Simplex de Nelder e Mead, e do que o método Simplex com inicialização múltipla (MSX).




Figura 1 - Passos de reflexão e contração de um sub-complexo (adaptado de Sorooshian e Gupta, 1995).

Abdulla et al. (1999) utilizaram o método SCE-UA para calibrar 4 dos parâmetros do modelo ARNO (Todini, 1996) em 24 bacias, com áreas variando entre 62 e 5.270 km<sup>2</sup>, nos EUA. O algoritmo SCE – UA foi comparado aos métodos Simplex e “Simulated Annealing” ou Simulação de Cristalização (Press et al., 1995; Kuczera e Parent, 1998), e mostrou melhores resultados quanto à função objetivo atingida, quanto à sensibilidade ao valor da semente do processo aleatório e quanto à variação da faixa de valores possíveis dos parâmetros.

O algoritmo SCE-UA também foi comparado ao método SA-SX, que é uma combinação dos métodos “Simulated Annealing” e Simplex de Nelder e Mead, por Thyer et al. (1999). Estes autores mostraram que o algoritmo SCE-UA é mais robusto e mais eficiente do que SA-SX, sendo que robustez significa a capacidade de encontrar sempre o mesmo ponto ótimo em uma série de tentativas independentes, e eficiência significa a capacidade de encontrar o ponto ótimo em um mínimo número de avaliações da função (iterações do modelo hidrológico).

Em relação aos algoritmos genéticos “puros”, que utilizam números binários (Lacerda e Carvalho, 1999), o SCE-UA também apresenta vantagens, como mostra o trabalho de Franchini et al. (1998).

Portanto, o algoritmo SCE-UA apresenta vantagens em relação aos algoritmos de otimização mono-objetivo com os quais tem sido comparado. Mesmo assim, este algoritmo é bastante limitado se comparado à calibração manual, porque considera apenas uma função objetivo.

### Calibração automática multi-objetivo

Na calibração automática multi-objetivo o objetivo é otimizar, ao mesmo tempo, várias funções, que avaliam vários aspectos da qualidade do ajuste entre hidrogramas

calculados e observados. Algumas técnicas de calibração multi-objetivo são apresentadas nos trabalhos de Yapo et al. (1998); Gupta et al. (1998); Boyle et al. (2000); Beldring (2002) e Madsen (2000).

Dadas as imperfeições dos modelos e dos dados de entrada, é praticamente impossível encontrar um conjunto de parâmetros que produza, ao mesmo tempo, valores ótimos de várias funções objetivo diferentes. Quase sempre, a opção pela otimização de uma função objetivo implicará na não otimização de outra. Esta é a situação normalmente enfrentada na calibração de modelos chuva vazão, quando um conjunto de parâmetros resulta em um bom ajuste dos picos de vazão, porém apresenta maus resultados durante os períodos de estiagem.

A principal característica de um problema de otimização multi-objetivo é que a solução, em geral, não será única. Isto é, um conjunto de parâmetros A corresponderá ao ótimo da função F1 e um conjunto de parâmetros B, diferente de A, corresponderá ao ótimo da função F2. Existirão ainda muitos conjuntos de parâmetros (C e D, por exemplo) que, embora não correspondam ao ótimo de F1 nem de F2, podem ser considerados aceitáveis. Os conjuntos de parâmetros aceitáveis são tais que, partindo da solução C para a solução D, a mudança para melhor em uma função objetivo será contrabalançada pela deterioração em outra, e não existirá nenhuma solução E que seja, ao mesmo tempo, melhor em F1 e F2 do que C ou D. Se não houver nenhuma informação adicional que permita dar maior importância a uma das duas funções objetivo, todas as soluções intermediárias devem ser consideradas boas.

Devido a estas características, a solução de um problema de otimização multi-objetivo não é um ponto, mas uma região, denominada região de Pareto, ou região de soluções não inferiores ou não dominadas (Yapo et al., 1998).

A Figura 2 apresenta um problema simples de otimização multi-objetivo de duas funções de apenas uma variável. Na Figura 2, F1 e F2 são funções da variável  $x$ , tais que F1 tem o valor mínimo em  $x_1=4$  e F2 tem o mínimo em  $x_2=6$ . A região entre  $x_1$  e  $x_2$  é tal que as alterações na variável  $x$  melhoram o valor de F1 e pioram o de F2, ou vice-versa. A região de Pareto deste problema é a região marcada com pontos entre  $x_1=4$  e  $x_2=6$ .

A definição da região de Pareto soluciona o problema de otimização, na medida em que divide as infinitas soluções possíveis em “boas” e “más”. As soluções classificadas como “boas” podem passar por uma análise posterior por parte do usuário do modelo, que pode adotar uma ou mais delas.

A otimização mono-objetivo pode ser utilizada de forma iterativa para resolver o problema multi-objetivo, ou seja, encontrar a região de Pareto correspondente. Madsen

(2000) apresenta uma metodologia baseada no método de calibração automática SCE-UA, descrito no item anterior. O problema multi-objetivo é reduzido a um problema mono-objetivo através do uso de coeficientes, ou pesos, atribuídos a cada uma das funções objetivo. Através do uso repetido do método de calibração automática, com pesos diferentes para cada função objetivo a cada calibração, são encontrados diversos pontos que definem, aproximadamente, a região de Pareto do problema de calibração multi-objetivo.

A técnica de otimização utilizada por Madsen (2000) implica em avaliar a função objetivo um número exageradamente grande de vezes. Técnicas mais eficientes foram apresentadas por Yapo et al. (1998) e Erickson et al. (2002). Estas técnicas utilizam o conceito de “hierarquização de Pareto” ou *Pareto ranking*, para encontrar, em apenas um procedimento de otimização, vários pontos na região de Pareto. A técnica de Yapo et al. (1998) será descrita mais detalhadamente adiante neste texto.

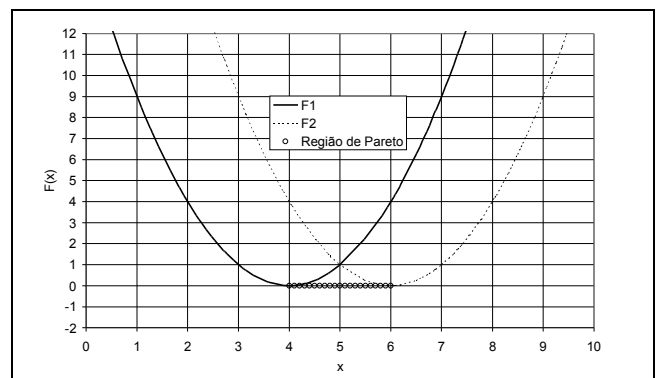


Figura 2 - Problema de otimização multi-objetivo de duas funções da mesma variável.

O algoritmo de Yapo et al. (1998) é denominado MOCOM-UA (*Multiple-Objective Complex Evolution* - Universidade do Arizona) e é uma variação do algoritmo SCE-UA (Duan et al., 1992), desenvolvido para problemas mono-objetivo. O algoritmo MOCOM-UA também está baseado em técnicas de algoritmos genéticos e no algoritmo simplex de Nelder e Mead.

O algoritmo MOCOM-UA inicia com a definição dos limites mínimos e máximos dos valores que os  $n$  parâmetros a serem calibrados podem tomar, definindo uma região ou hiper-cubo.

A seguir, são gerados, aleatoriamente,  $ns$  conjuntos de parâmetros ou pontos na região válida. Cada ponto é dado pelos valores dos  $n$  parâmetros e, para cada um dos pontos, as  $nf$  funções objetivo são avaliadas, gerando uma matriz de resultados  $F(ns, nf)$ .

Uma vez obtidos os valores das funções objetivo, os conjuntos de parâmetros são avaliados e hierarquizados pelos critérios de dominância e não dominância, descritos

antes. A hierarquização é realizada seguindo os passos a seguir:

1. Toma-se os **ns** pontos ou conjuntos e identifica-se aqueles que são dominados e os que são não dominados.
2. Aos pontos que são não dominados atribui-se o índice 1.
3. Os pontos com o índice 1 são retirados e os pontos restantes são novamente analisados.
4. Aos pontos que são não dominados nesta segunda análise, atribui-se o índice 2.
5. Os pontos com o índice 2 também são retirados e os pontos restantes são analisados.
6. Os passos se repetem até que se encontre um grupo de pontos em que não podem ser definidos dominados e não dominados. Estes pontos recebem o índice MAXR, onde MAXR é o número de passos necessários para não existir mais dominância entre os pontos.

Ao final da etapa de hierarquização, cada um dos pontos tem um índice, que indica, aproximadamente a qualidade relativa das funções objetivo associadas. Quanto menor o valor do índice, mais próximo o ponto está da região de Pareto. A Tabela 1 apresenta um exemplo com 6 pontos hierarquizados, conforme o valor de duas funções objetivo, que devem ser minimizadas. Neste exemplo, os pontos 1 e 2 são não-dominados; o ponto 3 é dominado pelo ponto 2; o ponto 4 é dominado pelo ponto 1; o ponto 5 é dominado pelo ponto 3 e o ponto 6 é dominado pelo ponto 5.

**Tabela 1 - Exemplo de um conjunto de pontos e os índices associados, segundo o valor das funções objetivo.**

| Número do ponto | Função objetivo 1 | Função objetivo 2 | Índice |
|-----------------|-------------------|-------------------|--------|
| 1               | 102,5             | 0,045             | 1      |
| 2               | 98,1              | 0,047             | 1      |
| 3               | 99,3              | 0,048             | 2      |
| 4               | 103,0             | 0,046             | 2      |
| 5               | 101,1             | 0,050             | 3      |
| 6               | 101,3             | 0,051             | 4      |

A etapa de evolução dos pontos ocorre gerando  $N_{MAXR}$  complexos (grupos de pontos), onde  $N_{MAXR}$  é o número de pontos que recebem o pior índice durante a hierarquização. Cada complexo é constituído por **n+1** pontos, sendo um deles retirado do grupo de  $N_{MAXR}$  pontos com o pior índice, e os outros **n** selecionados aleatoriamente dos pontos restantes, de acordo com a probabilidade associada a cada ponto, dada pela equação 6, e com reposição.

$$p_i = \frac{(MAXR - r_i + 1)}{\sum_{j=1}^{ns} (MAXR - r_j + 1)} \tag{5}$$

onde  $p_i$  é a probabilidade associada a cada ponto e  $r_i$  é o índice atribuído a cada ponto durante a hierarquização e MAXR é o pior índice encontrado no conjunto. Esta equação atribui uma probabilidade, a cada ponto, de que este ponto participe do processo de evolução. Os pontos com índice mais baixo estarão, mais provavelmente, representados nos complexos que vão gerar os novos pontos. A forma da função da equação 5, para um exemplo em que MAXR = 6 e ns = 29, é apresentada na Figura 4.

A equação 6 atribui uma probabilidade, a cada ponto, de que este ponto participe do processo de evolução. Os pontos com índice mais baixo estarão, mais provavelmente, representados nos complexos que vão gerar os novos pontos.

A formação de um complexo num exemplo simples, com ns = 5 e n = 2 é apresentada na Figura 4, onde o problema é otimizar as funções dadas pelas equações 6 e 7.

$$F1 = -((x-1)^2 + (y-2)^2) \tag{6}$$

$$F2 = -((x-2)^2 + (y-1)^2) \tag{7}$$

A função F1 (linha contínua na Figura 3) tem um valor máximo em x=1 e y=2. A função F2 (linha tracejada na Figura 3) tem o valor máximo em x = 2 e y = 1. A reta entre estes dois pontos define a região de Pareto do problema. Qualquer ponto sobre esta reta é uma boa solução.

No exemplo os pontos estão distribuídos no plano X-Y conforme a Figura 3a. A hierarquização revela que os pontos B e C são não dominados e, por isso, estes pontos recebem o índice 1. O ponto A é dominado pelo ponto B e o ponto E é dominado pelo ponto C. Os pontos A e E recebem o índice 2. Por fim, o ponto D é dominado por todos os outros pontos e recebe o índice 3 (Figura 3b). Neste caso o valor de MAXR é igual a 3 e há apenas um ponto que recebe este índice, por isso  $N_{MAXR} = 1$ , e assim deve ser gerado apenas um complexo. Utilizando as probabilidades calculadas pela equação 6, são escolhidos para participar deste complexo os pontos B e C (além do ponto D), conforme a Figura 3c.

A evolução dos complexos é realizada pelo método simplex de Nelder e Mead (*apud Press et al*, 1995), de forma semelhante ao algoritmo SCE-UA (ver Figura 1), porém com várias funções objetivo. O pior ponto do complexo é identificado (um dos  $N_{MAXR}$  pontos com o pior índice) e o




Figura 3 - Ilustração das etapas de hierarquização e evolução de um complexo do algoritmo MOCOM-UA, durante a otimização de um problema de duas funções objetivo (F1 = curvas de nível em linha contínua; F2 = curvas de nível em linha tracejada) e de dois parâmetros (adaptado de Yapó et al., 1998): a) pontos gerados aleatoriamente; b) pontos classificados (valores menores para pontos mais próximos da região de Pareto); c) formação de um complexo; d) definição do centróide dos melhores pontos; e) passo de reflexão; f) passo de contração.

centróide (ponto G) dos pontos restantes é calculado (Figura 3d). Os passos de reflexão (ponto R na Figura 3e) e contração (ponto K na Figura 3f) são avaliados conforme a dominância, isto é, o ponto de reflexão é aceito se estiver dentro da região válida e se ele for não dominado em relação aos outros n pontos que foram utilizados para definir o centróide. Caso contrário, o ponto de contração é aceito imediatamente.




Figura 4 - Relação entre o índice de um ponto e a probabilidade de escolha para formar um complexo.

Cada complexo evolui uma única vez, gerando  $N_{MAXR}$  novos pontos que substituem os  $N_{MAXR}$  piores pontos anteriores, mantendo a população estável.

A seguir, os pontos são novamente analisados e hierarquizados, e o processo se repete, até que, na etapa de hierarquização, todos os pontos recebam o mesmo índice, ou seja, não é possível definir pontos melhores ou piores. Nesta situação, normalmente, deverá ter sido encontrada uma boa amostra de pontos sobre a região de Pareto, como na Figura 5.

Depois da etapa de calibração, o usuário do modelo pode escolher entre uma das soluções apontadas, com base em algum critério pessoal (Boyle et al., 2000), ou pode utilizar todas ou várias delas para, em sucessivas aplicações do modelo, obter uma amostra de vazões em cada intervalo de tempo e definir uma faixa de incerteza dos resultados com relação aos parâmetros do modelo (Gupta et al., 1998).

O algoritmo MOCOM-UA foi utilizado por Yapó et al. (1998) para calibrar 13 parâmetros do modelo Sacramento (Burnash, 1995) na bacia do rio Leaf, de 1950 km<sup>2</sup>, nos Estados Unidos, utilizando duas funções objetivo. O mesmo modelo foi calibrado com o mesmo algoritmo, na mesma bacia, porém utilizando três funções objetivo, por

Gupta et al. (1998), e por Boyle et al. (2000), utilizando outras três funções objetivo.

Sorooshian et al. (1998) utilizaram o algoritmo para calibrar um módulo de hidrologia superficial de um modelo de circulação atmosférica global em dois locais diferentes, utilizando como primeira função objetivo o erro padrão do fluxo de calor latente, e como segunda função objetivo o erro padrão do fluxo de calor sensível. Desta forma foram calibrados 24 parâmetros e 3 condições iniciais.

O algoritmo é sensível ao número de pontos da população (ns) no que se refere ao tempo de processamento e no resultado final. Quanto maior o número de pontos na população, melhor é a aproximação da região de Pareto e maior o tempo de processamento (Yapo et al., 1998).

As funções objetivo devem, preferencialmente, avaliar aspectos diferentes do hidrograma, como as vazões de cheia e recessão, ou o erro médio quadrado e o erro total do volume. É importante que as funções objetivo tenham correlação relativamente baixa (Gupta et al., 1998).

Um dos aspectos mais interessantes da metodologia de calibração proposta por Yapo et al. (1998) é a possibilidade de avaliar as incertezas associadas aos parâmetros calibrados. Ao final da calibração, o modelo hidrológico pode ser utilizado com todos os conjuntos de parâmetros encontrados, gerando uma família de hidrogramas, que define uma banda de incerteza das vazões previstas, como apresentado em Gupta et al. (1998). A incerteza na vazão pode ser levada ainda para outros resultados, tais como a curva de permanência de vazões.

## RESULTADOS COM O IPH2

O método de calibração automática multi-objetivo MOCOM-UA (Yapo et al., 1998) foi aplicado utilizando o modelo IPH2, cujo uso é bastante difundido no Brasil. O modelo IPH2 está descrito em Tucci (1998), é um modelo concentrado, e tem sete parâmetros que podem ser calibrados. O significado dos parâmetros é como descrito a seguir. O parâmetro  $I_0$  representa a capacidade de infiltração do solo quando está seco;  $I_b$  representa a capacidade de infiltração do solo quando está saturado;  $h$  representa a função de variação da capacidade de infiltração entre  $I_0$  e  $I_b$ ;  $K_s$  é o tempo de retardo do reservatório superficial;  $K_{sub}$  é o tempo de retardo do reservatório subterrâneo;  $R_{máx}$  é o parâmetro que representa a lâmina de água interceptada pela vegetação ou armazenada em poças, que fica facilmente disponível para evaporação; e  $Alf$  o parâmetro que representa escoamento direto de áreas impermeáveis.

Os parâmetros escolhidos para calibrar o modelo foram todos os sete parâmetros que podem ser calibrados, exceto o tempo de concentração, que foi pré-determinado.

Os limites mínimos e máximos dos parâmetros, em que foi permitida a calibração são dados na Tabela 2.




Figura 5 - a) Região de Pareto do problema das equações 6 e 7; b) aproximação da região de Pareto, utilizando o algoritmo MOCOM-UA com ns = 5 pontos (F1 = curvas de nível em linha contínua; F2 = curvas de nível em linha tracejada).

Como base de dados foi utilizada a bacia do rio Canoas, que é um dos formadores do rio Uruguai. Esta bacia está localizada no estado de Santa Catarina, em uma região montanhosa, de solos relativamente rasos sobre rochas basálticas e porções de arenitos, com predominância de campos, florestas esparsas em áreas de maior declividade, e algumas áreas de cultivo e reflorestamento. O clima é um dos mais frios do país, com precipitação média anual de aproximadamente 1700 mm, e com chuvas bem distribuídas ao longo do ano. A evapotranspiração real estimada é de, aproximadamente,  $500 \text{ mm.ano}^{-1}$  e o coeficiente de escoamento de longo prazo próximo de 0,7. O tempo de concentração foi estimado em 2 dias.



Os dados de vazão foram obtidos do posto fluviométrico Vila Canoas (código 71200000), cuja área é de 989 km<sup>2</sup>. Os dados de precipitação foram obtidos dos postos pluviométricos Despraiado (02849023), Urubici (02849021) e Vila Canoas (02749031). A evapotranspiração potencial foi obtida a partir de dados de uma estação climatológica de Urubici, em Santa Catarina. O período de dados considerado foi de 1981 a 1984 e o intervalo de tempo considerado foi de 1 dia.

**Tabela 2 - Limites máximo e mínimo dos valores dos parâmetros do modelo IPH2 para a calibração automática (o significado de cada parâmetro é descrito em Tucci, 1998).**

| Parâmetro | Unidade             | Valor mínimo | Valor máximo |
|-----------|---------------------|--------------|--------------|
| Io        | mm.Δt <sup>-1</sup> | 10           | 300          |
| Ib        | mm.Δt <sup>-1</sup> | 0,1          | 10           |
| h         | -                   | 0,0          | 1,0          |
| Ks        | Δt                  | 0,01         | 10,0         |
| Ksub      | Δt                  | 30,0         | 40,0         |
| Rmáx      | mm                  | 0,0          | 9,0          |
| Alf       | -                   | 0,01         | 20,0         |

Na realidade, a utilização do modelo IPH2 em uma bacia tão grande e com um intervalo de tempo de 1 dia extrapola os limites da aplicabilidade deste modelo, que é mais adequado para bacias pequenas e para intervalos de tempo de cálculo da ordem de algumas horas. Entretanto, o objetivo deste trabalho é apresentar algumas características de um método de calibração que pode ser utilizado em qualquer modelo hidrológico e em qualquer bacia.

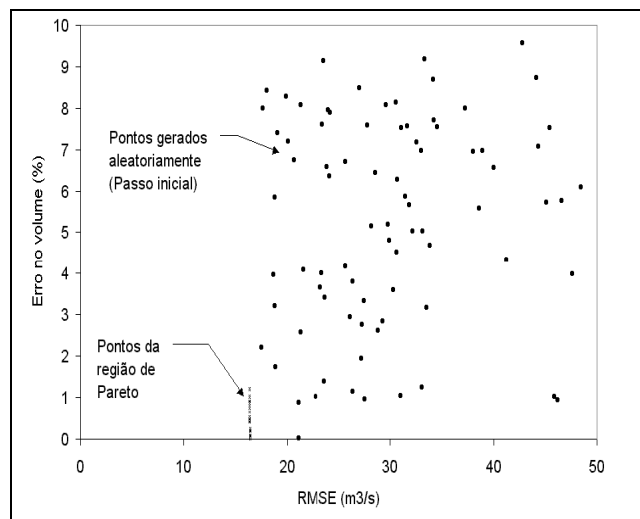
O único parâmetro do algoritmo MOCOM-UA é o tamanho da população. A importância deste parâmetro foi testada utilizando populações de 100, 200 e 800 pontos.

Também foi testada a dependência dos resultados ao número de funções objetivo consideradas. O primeiro conjunto de testes foi realizado considerando apenas duas funções objetivo: o erro padrão (RMSE - equação 2); e o módulo de ΔV, ou erro do volume em valores absolutos (módulo da equação 1). No segundo conjunto de aplicações foram consideradas as duas funções objetivo anteriores mais o erro do inverso das vazões observada e calculada (RMSEI – equação 4), que dá um peso muito grande aos valores de vazão mínima.

**Resultados**

A primeira aplicação do método de calibração foi realizada utilizando apenas as funções objetivo das equações 1 e 3 (respectivamente erro de volume e erro padrão das vazões) e uma população de 800 pontos. A calibração inicia pela geração aleatória de conjuntos de parâmetros, esta população de conjuntos de parâmetros evolui até que seja encontrada uma aproximação da região (curva ou

superfície) de Pareto, quando o algoritmo é finalizado. A Figura 6 apresenta, graficamente, os valores das funções objetivo dos conjuntos de parâmetros do passo inicial (geração aleatória) e do passo final (região de Pareto) para a calibração do modelo IPH2 com 7 parâmetros, duas funções objetivo (módulo de ΔV e RMSE) e uma população de 100 pontos.




**Figura 6 - Pontos das duas funções objetivo dos conjuntos de parâmetros do passo inicial (geração aleatória) e do passo final (região de Pareto).**

A Figura 7 apresenta um detalhe da região de Pareto encontrada na calibração com uma população de 800 pontos. Esta figura mostra a relação entre as duas funções objetivo, para cada um dos conjuntos de parâmetros encontrados. Cada um dos pontos corresponde a um conjunto de parâmetros que pode ser interpretado como um candidato à condição de melhor conjunto para a calibração do modelo. O ponto P1 corresponde ao conjunto que resulta em um menor erro padrão (RMSE). Por outro lado, o ponto P1 apresenta o maior erro absoluto de volume calculado (módulo de ΔV). Já o ponto P2 corresponde ao pior resultado em termos de RMSE e o melhor resultado em termos de volume.

A Figura 7 mostra que a redução de uma função objetivo implica no aumento de outra. De maneira geral, no entanto, todos os conjuntos de parâmetros encontrados apresentam bons resultados com respeito às duas funções objetivo avaliadas. O maior erro de volume é inferior a 3% e os valores do desvio padrão correspondem a valores do coeficiente de Nash-Sutcliffe próximos a 0,88, o que pode ser considerado muito bom.

O resultado da calibração é uma população de pontos, dos quais é necessário, na maior parte das aplicações, escolher apenas um. A decisão sobre o conjunto de parâmetros que deve ser escolhido é facilitada quando existe

uma estimativa da região de Pareto, como a apresentada na Tomando como base esta figura, o usuário do modelo poderia optar pelo ponto P3, por exemplo, que representa um equilíbrio entre as duas funções objetivo consideradas. No entanto, se a intenção é obter um melhor ajuste dos picos de vazão, então o conjunto escolhido poderia estar mais próximo de P1. Em alguns casos não é necessário escolher apenas um dos conjuntos de parâmetros encontrados. Pelo contrário, pode ser interessante utilizar todos os conjuntos em aplicações repetidas do modelo hidrológico, obtendo assim um conjunto de hidrogramas calculados, a partir do qual pode ser avaliada a incerteza dos resultados com relação aos parâmetros do modelo (Sorooshian et al., 1998).




**Figura 7 - Estimativa da região de Pareto do problema de calibração do modelo IPH2 com 7 parâmetros calibráveis, 2 funções objetivo (erro do volume e RMSE) e população de 800 pontos.**

O modelo IPH2 foi calibrado na mesma bacia, utilizando três funções objetivo, para avaliar as estimativas de incerteza na calibração dos parâmetros utilizando o algoritmo multi-objetivo. Foi utilizada uma população de 500 pontos e as funções objetivo utilizadas correspondem às equações 1, 2 e 4. A Figura 8 apresenta os hidrogramas observados e calculados no rio Canoas em Vila Canoas. Nesta figura estão apresentados, além do hidrograma observado, vários hidrogramas calculados com conjuntos de parâmetros diferentes, mas todos eles tendo sido obtidos pelo método de calibração multi-objetivo.

A Figura 9 apresenta um resultado semelhante em um período mais úmido.


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.



**Figura 8 - Hidrogramas de vazão observada (linha preta) e calculada (linhas cinzas) durante um período relativamente seco na bacia do rio Canoas.**

As incertezas dos hidrogramas podem ser propagadas para aplicações como a estimativa de vazões de referência, tais como a  $Q_{90}$ , ou para a estimativa da curva de permanência, como mostra a Figura 10. A estimativa da vazão de referência  $Q_{90}$ , por exemplo, vai de 8,9 a 10,5  $m^3 \cdot s^{-1}$ , sendo que a  $Q_{90}$  observada é de 9,1  $m^3 \cdot s^{-1}$ .



**Figura 9 - Hidrogramas de vazão observada (linha preta) e calculada (linhas cinzas) durante um período úmido na bacia do rio Canoas.**

Outra questão que pode ser abordada de uma forma interessante com a calibração multi-objetivo é a análise da validade do modelo. Esta análise pode ser feita com base na variação dos valores dos parâmetros para satisfazer as diferentes funções objetivo. O modelo ideal permitiria otimizar todas as funções objetivo com valores muito semelhantes dos parâmetros. Quando, por outro lado, a amplitude dos valores encontrados para os parâmetros na região de Pareto for muito grande, então o modelo revela sua incapacidade de representar o fenômeno desejado de

uma forma abrangente, e sua validade pode ser colocada em dúvida. No caso do modelo IPH2, calibrado com duas funções objetivo, a faixa de variação dos parâmetros foi relativamente estreita.

A Tabela 3 apresenta os valores dos parâmetros encontrados por calibração com duas funções objetivo (equações 1 e 2) e população de 800 pontos. Comparando com a Tabela 2, observa-se que os parâmetros  $K_{sub}$  e  $Alf$  estão próximos ao limite superior definido na Tabela 2. Isto indica a necessidade de ampliar os limites de busca para estes parâmetros.




Figura 10 - Curva de permanência de vazões diárias observadas (linha preta) e calculadas (banda cinza).

Tabela 3 - Intervalos dos parâmetros do modelo IPH2 encontrados na calibração automática com duas funções objetivo e população de 800 pontos.

| Parâmetro         | Unidade            | Valor mínimo | Valor máximo |
|-------------------|--------------------|--------------|--------------|
| $I_o$             | $mm.\Delta t^{-1}$ | 24,1         | 25,8         |
| $I_b$             | $mm.\Delta t^{-1}$ | 1,53         | 1,65         |
| $h$               | -                  | 0,60         | 0,62         |
| $K_s$             | $\Delta t$         | 5,56         | 5,62         |
| $K_{sub}$         | $\Delta t$         | 38,5         | 40,0         |
| $R_{m\acute{a}x}$ | $Mm$               | 0,1          | 2,5          |
| $Alf$             | -                  | 19,0         | 20,0         |

No caso da calibração com três funções objetivo, a faixa de variação dos valores dos parâmetros foi maior, confirmando que o grande tamanho da bacia e o intervalo de tempo diário limitam a aplicação do modelo IPH2. A Tabela 4 apresenta os valores dos parâmetros encontrados na calibração com 3 funções objetivo (equações 1, 2 e 4) e população de 1000 pontos. A introdução de uma terceira função objetivo, associada às vazões mínimas, implicou em uma variação muito maior de quase todos os parâmetros.

O único parâmetro do algoritmo de calibração é o tamanho da população ( $ns$ ). Yapo et al. (1998) demonstraram que o tamanho da população influencia os resultados e o tempo de processamento. A análise de Yapo et al. (1998) foi confirmada no caso da calibração do modelo IPH2

com duas funções objetivo, conforme apresentado na Figura 11. Conforme esta figura, a solução encontrada (aproximação da região de Pareto) apresenta valores menores das funções objetivo à medida que a população de pontos aumenta. Nela são apresentados os resultados encontrados com populações de 100, 200 e 800 pontos. Observa-se que o benefício, em termos de valores das funções objetivo, da passagem de 200 para 800 pontos é pouco significativo, especialmente considerando que o tempo de processamento é bastante superior com a população de 800 pontos. Os testes realizados mostraram que uma população de 500 pontos é adequada quando são otimizadas duas funções objetivo e uma população de 1000 pontos é adequada quando são otimizadas três funções objetivo.

Tabela 4 - Intervalos dos parâmetros do modelo IPH2 encontrados na calibração automática com três funções objetivo e população de 1000 pontos.

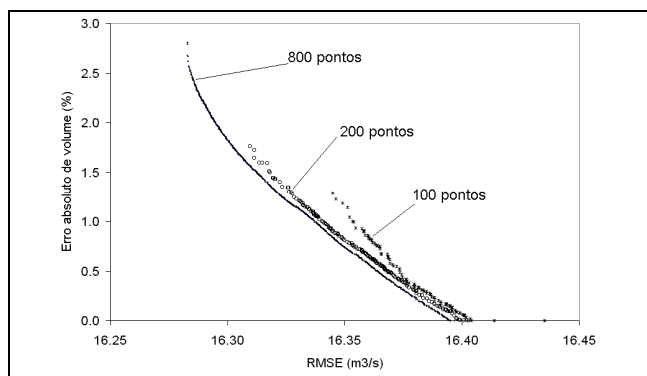
| Parâmetro         | Unidade            | Valor mínimo | Valor máximo |
|-------------------|--------------------|--------------|--------------|
| $I_o$             | $mm.\Delta t^{-1}$ | 12,4         | 27,0         |
| $I_b$             | $mm.\Delta t^{-1}$ | 1,42         | 6,97         |
| $h$               | -                  | 0,01         | 0,76         |
| $K_s$             | $\Delta t$         | 1,45         | 5,94         |
| $K_{sub}$         | $\Delta t$         | 32,7         | 40,0         |
| $R_{m\acute{a}x}$ | $mm$               | 0,15         | 5,60         |
| $Alf$             | -                  | 0,45         | 19,37        |

## CONCLUSÕES

Com o atual desenvolvimento de modelos hidrológicos em programas computacionais amigáveis, destinados ao uso em ambientes não acadêmicos, existe uma demanda por métodos de calibração automática. O uso inadequado destas técnicas pode colocar em risco a qualidade das informações geradas por tais modelos. É importante que os usuários conheçam as limitações dos métodos de calibração automática, especialmente dos métodos de busca local, como o método de Rosenbrock, ou de qualquer outro método de otimização mono-objetivo. É importante também que, na fase atual de desenvolvimento de modelos, caracterizada pela popularização de programas computacionais amigáveis, sejam evitados os métodos de calibração que conduzam a ótimos locais e que se baseiam em apenas uma função objetivo. Alternativamente, devem ser conhecidas e colocadas à disposição as ferramentas mais recentes de otimização, especialmente de otimização multi-objetivo.

Neste estudo foram apresentados os resultados e as vantagens do uso de um método multi-objetivo MOCOM-UA (Yapo et al., 1998) com o modelo hidrológico IPH2. Os resultados dos testes mostraram que a calibração automática multi-objetivo pode ser equivalente a uma boa, porém exaustiva, calibração manual. Além disso, como a

técnica é baseada na evolução de uma população de soluções e não em uma solução única, o resultado é uma população de soluções aceitáveis, que podem ser utilizadas em conjunto, permitindo analisar o efeito da incerteza na determinação dos parâmetros sobre os hidrogramas gerados.



**Figura 11 - Efeito do tamanho da população de pontos sobre os valores das funções objetivo encontradas na calibração.**

A utilização do algoritmo MOCOM-UA é simples, tendo em vista que o único parâmetro deste método de calibração é o tamanho da população, expresso por  $n_s$ . A calibração tende a ser melhor com o aumento do valor de  $n_s$ , porém para  $n_s = 500$  pontos os resultados são plenamente satisfatórios quando são otimizadas duas funções objetivo. Já a otimização de três funções objetivo apresenta resultados melhores com aproximadamente  $n_s = 1000$  pontos, sem comprometer a eficiência em termos de tempo de processamento. No exemplo analisado a utilização de três funções objetivo apresentou resultados pouco superiores aos atingidos quando foram usadas apenas duas. O tempo de processamento de um procedimento de calibração do modelo IPH2 em computadores pessoais foi inferior a 5 minutos mesmo para populações relativamente grandes e para três funções objetivo.

A utilidade desta metodologia deve crescer muito no futuro, em bacias onde outras variáveis do ciclo hidrológico, como a evapotranspiração e o nível da água subterrânea, possam ser medidas sistematicamente, ou em aplicações em que vários modelos são acoplados para busca da solução conjunta, como modelos hidrológicos e de qualidade de água.

## AGRADECIMENTOS

Os autores agradecem a Agência Nacional de Energia Elétrica (ANEEL), que disponibilizou os dados hidrológicos, e aos revisores pelas sugestões.

## REFERÊNCIAS

- ABBASPOUR, K. C.; SCHULIN, R.; VAN GENUCHTEN, M. Th. 2001 Estimating unsaturated soil hydraulic parameters using ant colony optimization. *Advances in Water Resources* Vol. 24 pp. 827-841.
- ABDULLA, F. A.; LETTENMAIER, D. P.; LIANG, X. 1999 Estimation of the ARNO model baseflow parameters using daily streamflow data. *Journal of Hydrology*, Vol. 222 pp. 37-54.
- BEARD, L. 1966 *Optimization techniques for hydrologic engineering*. Technical paper N0. 2 Hydrologic Engineering Center, Davis.
- BELDRING, S. 2002 Multi-criteria validation of a precipitation – runoff model. *Journal of Hydrology* Vol. 257 pp. 189-211.
- BEVEN, K.; BINLEY, A. 1992 The future of distributed models: model calibration and uncertainty prediction. *Hydrological Processes*, Vol. 6 pp. 279-298.
- BINABEAU, E.; DORIGO, M.; THERAULAZ, G. 2000 Inspiration for optimization from social insect behaviour. *Nature* Vol. 406 July pp.39-42.
- BOYLE, D. P.; GUPTA, H. V.; SOROOSHIAN, S. 2000 Toward improved calibration of hydrologic models: Combining the strengths of manual and automatic methods. *Water Resources Research* Vol. 36, No. 12 pp. 3663-3674.
- BRAZIL, L. E. 1988 *Multilevel calibration strategy for complex hydrologic simulation models*. PHD Dissertation Colorado State University, Fort Collins.
- BURNASH, R. J. C. 1995 *The NWS river forecast system catchment modelling*. In: Singh, V. J. (editor) *Computer models of watershed hydrology*. Water Resources Publications, Highlands Ranch. 1130 p.
- COLLISCHONN, W. 2001 *Simulação hidrológica de grandes bacias*. Tese de Doutorado. IPH UFRGS.
- COLLISCHONN, W.; TUCCI, C. E. M. 2001a Calibração automática global do modelo IPH2. *Anais XIV Simpósio Brasileiro de Recursos Hídricos*. Aracaju SE.
- COLLISCHONN, W.; TUCCI, C. E. M. 2001b Simulação hidrológica de grandes bacias. *Revista Brasileira de Recursos Hídricos*. Vol. 6 No. 1.
- COLLISCHONN, W.; TUCCI, C. E. M. 2002 Previsão sazonal de vazão na bacia do rio Uruguai 1: ajuste e verificação do modelo hidrológico. Artigo submetido à *Revista Brasileira de Recursos Hídricos*.
- DINIZ, L. S. 1999 *Calibração de modelos hidrológicos*. In: Galvão, C. O.; Valença, M. J. S. 1999 *Sistemas inteligentes*. Porto Alegre: Editora da Universidade da UFRGS – ABRH.
- DUAN, Q.; SOROOSHIAN, S.; GUPTA, V. 1992 Effective and efficient global optimization for conceptual rainfall-runoff models. *Water Resources Research* Vol. 28 No. 4. pp. 1015-1031.
- DUAN, Q.; SOROOSHIAN, S.; GUPTA, V. 1994 Optimal use of the SCE – UA global optimization method for calibrat-

- ing watershed models. *Journal of Hydrology*, Vol 158 pp. 265-284.
- ECKHARDT, K.; ARNOLD, J. G. 2001 Automatic calibration of a distributed catchment model. *Journal of Hydrology*, Vol. 251 pp. 103-109.
- ERICKSON, M.; MAYER, A.; HORN, J. 2002 Multi-objective optimal design of groundwater remediation systems: application of the niched Pareto genetic algorithm (NPGA) *Advances in Water Resources* Vol. 25 pp. 51-65.
- FRANCHINI, M.; GALEATI, G.; BERRA, S. 1998 Global optimization techniques for the calibration of conceptual rainfall runoff models. *Hydrological Sciences Journal* Vol. 43 No. 3 pp. 443-458.
- GAN, T. Y.; BIFFU, G. F. 1996 Automatic calibration of conceptual rainfall – runoff models: optimization algorithms, catchment conditions and model structure. *Water Resources Research*, Vol. 32 No. 12 pp. 3513-3524.
- GUPTA, H. V.; SOROOSHIAN, S.; YAPO, P. O. 1998 Toward improved calibration of hydrologic models: Multiple and noncommensurable measures of information. *Water Resources Research*, Vol. 34 No. 4 pp. 751-763.
- KUCZERA, G., PARENT, E. 1998 Monte Carlo assessment of parameter uncertainty in conceptual catchment models: the Metropolis algorithm. *Journal of Hydrology*, Vol. 211 pp. 69-85.
- JOHNSTON, P. R.; PILGRIM, D. H. 1976 Parameter optimization for watershed models. *Water Resources Research*, Vol. 12 No. 3 pp. 477-486.
- LACERDA, E. G. M.; Carvalho, A. C. P. L. F. 1999 *Introdução aos algoritmos genéticos*. In: Galvão, C. O.; Valença, M. J. S. 1999 *Sistemas inteligentes*. Porto Alegre: Editora da Universidade da UFRGS – ABRH.
- MADSEN, H. 2000 Automatic calibration of a conceptual rainfall – runoff model using multiple objectives. *Journal of Hydrology* Vol 235 pp. 276-288.
- PICKUP, G. 1977 Testing the efficiencies of algorithms and strategies for automatic calibration of rainfall-runoff models. *Hydrological Sciences Bulletin*, Vol. 22 No. 2 pp. 257-274.
- PRESS, W. H.; TEUKOLSKY, S. A.; VETTERLING, W. T.; FLANNERY, B. P. 1995 *Numerical Recipes in FORTRAN*. Cambridge : Cambridge University.
- ROSENBROCK, H. 1960 An automatic method for finding the greatest or best value of a function. *Computer Journal* Vol. 3 p. 175.
- SOROOSHIAN, S.; GUPTA, H. V.; BASTIDAS, L. A. 1998 *Calibration of hydrologic models using multi-objectives and visualization techniques*. Final Report EAR 9418147. Dep. Hydrology and Water Resources, University of Arizona 78p
- SOROOSHIAN, S.; DUAN, Q.; GUPTA, V. 1993 Calibration of rainfall –runoff models: Application of global optimization to the Sacramento soil moisture accounting model. *Water Resources Research* Vol. 29 No. 4 pp. 1185-1194.
- SOROOSHIAN, S.; GUPTA, V. K. 1995 *Model calibration* In: Singh, V. J. (editor) *Computer models of watershed hydrology*. Water Resources Publications, Highlands Ranch. 1130 p.
- THYER, M.; KUCZERA, G.; BATES, B. 1999. Probabilistic optimization for conceptual rainfall-runoff models: A comparison of the shuffled complex evolution and simulated annealing algorithms. *Water Resources Research*, Vol. 35 No. 3, pp. 767-773.
- TODINI, E. 1996 The ARNO rainfall – runoff model. *Journal of Hydrology*, Vol. 175 pp. 293-338.
- TUCCI, C. E. M. 1998 *Modelos hidrológicos*. ABRH Editora da UFRGS. Porto Alegre. 669 p.
- WANG, Q. J. 1991 The genetic algorithm and its applications to calibrating conceptual rainfall-runoff models. *Water Resources Research*, Vol. 27 No. 9, pp. 2467-2471.
- XIONG, L.; O'CONNOR, K. M. 2000 Analysis of the response surface of the objective function by the optimum parameter curve: how good can the optimum parameter values be? *Journal of Hydrology*, Vol 234 pp. 187-207.
- YAPO, P. O.; GUPTA, H. V.; SOROOSHIAN, S. 1998 Multi-objective global optimization for hydrologic models. *Journal of Hydrology*, Vol. 204 pp. 83-97.
- YU, P.S.; YANG, T.C. 2000 Fuzzy multi-objective function for rainfall-runoff model calibration. *Journal of Hydrology*, Vol. 238 p. 1-14.

**Multi-objective calibration of an hydrological model using a genetic algorithm**

**ABSTRACT**

Rainfall runoff hydrologic models are widely used for water resources availability analysis, where or when there is more rainfall than river discharge data. Generally these models are conceptual, and cannot be applied without parameter calibration, when observed and calculated hydrographs must be compared. If the model user is not experienced, manual calibration may be a lengthy task. On the other hand, automatic calibration is limited by the low conceptual significance of the parameter values that may be found, especially when local search algorithms are used, which can find parameter sets that result in poor fitting of the observed hydrographs. Furthermore, almost all automatic calibration methods assess the quality of the hydrograph fitting by a single objective function. Manual calibration, on the other hand, allows the experienced user to consider many aspects of the hydrograph fitting at the same time. This paper presents an automatic calibration method, recently proposed by Yapó et al. (1998), that simplifies the calibration procedure, and maintains some manual calibration characteristics, specially the evaluation of multiple objective functions at the same time. Results are shown using the IPH2 rainfall runoff model applied with data of a 989 km<sup>2</sup> basin in Santa Catarina, and considering up to three objective functions in the same calibration run.

Key-words: hydrological model, automatic calibration.