

## CALIBRAÇÃO AUTOMÁTICA GLOBAL DO MODELO IPH-2

Walter Collischonn<sup>1</sup> e Carlos E. M. Tucci<sup>2</sup>

**Resumo** A calibração automática de modelos conceituais chuva - vazão é uma ferramenta que pode simplificar a aplicação destes modelos em diversas situações práticas, e que será cada vez mais empregada com a popularização dos modelos hidrológicos decorrente do surgimento de uma nova geração de modelos e programas computacionais mais amigáveis. Este trabalho apresenta uma breve descrição dos métodos de calibração de parâmetros de modelos hidrológicos e uma descrição detalhada do algoritmo SCE – UA. O algoritmo SCE – UA foi implementado para a otimização de duas funções simples, e para a calibração do modelo chuva - vazão IPH2 em uma bacia hidrográfica na região central do Brasil, utilizando vazões sintéticas e reais. São analisadas também as funções objetivo que podem ser utilizadas na calibração automática, destacando-se a função de Yu e Yang (2000), que pretende permitir um ajuste mais homogêneo de hidrogramas observado e calculado para várias faixas de vazão. Os resultados confirmam que o algoritmo SCE – UA é eficaz na busca do ótimo global, mas não confirmam as qualidades atribuídas à função objetivo de Yu e Yang.

**Abstract** Automatic calibration of conceptual rainfall–runoff models is a tool that can simplify model application in several practical situations, and that will be even more used when these models become more popular, following a new generation of more user friendly models and computer programs. This paper presents a brief description of hydrological models calibration methods and a detailed description of the SCE-UA algorithm. The algorithm was applied to optimize two simple functions and to calibrate the IPH-2 rainfall – runoff model in a Brazilian watershed, using synthetic and measured hydrographs. Two objective functions were also compared, with emphasis on the Yu and Yang (2000) function, which was supposed to result in a closer adjustment of the calculated and observed hydrographs in a broader range of flow values. Our results confirmed the robustness of the SCE-UA algorithm, but showed that the Yu and Yang objective function may be not so good as argued by its authors.

---

<sup>1</sup> Instituto de Pesquisas Hidráulicas; Universidade Federal do Rio Grande do Sul; Av. Bento Gonçalves, 9500; Caixa Postal 15029; CEP 91501-970 Porto Alegre, RS; [collschonn@vortex.ufrgs.br](mailto:collschonn@vortex.ufrgs.br)

<sup>2</sup> [tucci@if.ufrgs.br](mailto:tucci@if.ufrgs.br)

**Palavras-Chave** calibração; otimização, modelos chuva - vazão

## INTRODUÇÃO

Os modelos hidrológicos de transformação chuva - vazão são importantes ferramentas na área de recursos hídricos. Sua utilização mais aceita ocorre na extensão de séries de vazão em rios, para diferentes projetos de utilização recursos hídricos. Isto ocorre porque, em geral, as séries de dados de precipitação são mais longas que as séries de dados de vazão.

Além da extensão de séries de vazão, os modelos chuva – vazão são úteis para melhor compreender o sistema físico, prever vazões em tempo atual, dimensionar obras hidráulicas e, ainda que de forma incipiente e incerta, avaliar os efeitos de modificações de uso do solo.

Uma das etapas fundamentais da aplicação de um modelo chuva vazão é a calibração dos parâmetros do modelo em uma bacia onde se dispõe de dados de vazão observados. Esta calibração é realizada modificando os valores dos parâmetros até que o hidrograma calculado reproduza o hidrograma observado com boa precisão. Para isto o usuário normalmente utiliza a avaliação visual, em gráficos, verificando se as vazões calculadas e observadas tem valores próximos nos períodos de cheia e estiagem, se a recessão do hidrograma está bem apresentada, se o valor do pico da cheia está próximo do observado e se ao picos de vazão calculado e observado estão próximos. Adicionalmente podem ser utilizadas funções objetivo, que procuram quantificar a qualidade do ajuste dos hidrogramas (Tucci, 1998).

Quando o modelo utilizado tem um grande número de parâmetros e o usuário tem pouca experiência, o processo de calibração pode ser lento e tedioso. Para tornar mais rápido e eficiente este processo foram criados os métodos de calibração automática.

A calibração automática é criticada por hidrólogos mais experientes (Burnash, 1995), para os quais:

- conjuntos de parâmetros que produzem um bom valor da função objetivo podem ser conceitualmente absurdos, ou inválidos;
- o modelo calibrado com algoritmos automáticos deixa de ser uma poderosa ferramenta de análise da bacia e passa a ser uma caixa preta, destinada a produzir os melhores valores da função objetivo;
- ao utilizar uma técnica de calibração automática o usuário do modelo perde a sensibilidade sobre o comportamento do modelo e tende a não compreender plenamente as suas limitações;
- atingir um melhor valor de uma função objetivo qualquer não necessariamente implicará em representar melhor o comportamento da bacia;

- o usuário do modelo tem, na calibração automática, uma forma de aprendizado, que não existe na calibração automática;
- nem sempre o tempo necessário para a calibração é inferior com algoritmos automáticos.

Uma parcela considerável das críticas à calibração automática está relacionada às funções objetivo que são utilizadas na calibração automática. 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).

Outra parcela das críticas ocorre porque os primeiros métodos de calibração automática que surgiram na literatura estavam baseados em técnicas de otimização local. Estes métodos, como o Rosenbrock (Tucci, 1998), por exemplo, tendem a calibrar o modelo com grupos diferentes de parâmetros dependendo do ponto de início do processo de busca (Johnston e Pilgrim, 1976). 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). Sobre estas superfícies de resposta as técnicas de calibração baseadas em busca local tendem a gerar resultados pouco confiáveis.

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; Yapo et al., 1998, Thyer et al., 1999). Estes desenvolvimentos devem contribuir para reduzir, ao menos parcialmente, os pontos fracos da calibração automática.

Além disso, os modelos hidrológicos de transformação chuva – vazão começam a ser utilizados em versões mais amigáveis, e cada vez mais os modelos hidrológicos estão disponíveis para serem usados por pessoas com pouca formação na área de simulação. Os modelos estão sendo programados para ambiente Windows, com interface gráfica, e com apresentação de resultados que estimulam o uso indiscriminado dos resultados (Gan e Biftu, 1996). 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.

Este trabalho apresenta uma breve descrição dos métodos de calibração de parâmetros de modelos hidrológicos e uma descrição detalhada do algoritmo SCE – UA, que têm sido citado, repetidamente, na literatura como um método de calibração automática global confiável, eficaz e eficiente. O algoritmo SCE – UA é implementado para a otimização de duas funções simples, e para a calibração do modelo chuva - vazão IPH2 (Tucci, 1998) em uma bacia hidrográfica no Estado de Goiás, utilizando vazões sintéticas e reais. São analisadas também as funções objetivo que podem

ser utilizadas na calibração automática, destacando-se uma função objetivo que pretende permitir um ajuste mais homogêneo de hidrogramas observado e calculado para várias faixas de vazão.

Paralelamente, este trabalho está sendo estendido para a calibração automática multi-objetivo de modelos hidrológicos. Os autores estão utilizando as metodologias de Madsen (2000), Boyle (2000), Yu e Yang (2000), Gupta et al. (1998) e Yapo et al. (1998) para a calibração automática multi-objetivo de um modelo de simulação chuva-vazão em grandes bacias (Collischonn e Tucci, 2001).

## **MÉTODOS DE CALIBRAÇÃO**

A calibração de parâmetros de modelos chuva – vazão têm por objetivo encontrar os valores dos parâmetros do modelo que gerem um hidrograma calculado semelhante ao observado, para um determinado período de aplicação. A semelhança entre os hidrogramas observado e calculado é avaliada de forma qualitativa, visualizando um gráfico, ou de forma quantitativa, utilizando uma ou mais funções objetivo.

Na calibração manual é utilizada a técnica da tentativa e erro, aliada sempre à experiência anterior do usuário. Quando o usuário é inexperiente, a calibração manual pode ser extremamente demorada e pouco eficaz. Além disso, não existe um critério objetivo de parada, isto é, o usuário não sabe exatamente quando a calibração está suficientemente boa e quando ele deve parar de calibrar o modelo (Sorooshian e Gupta, 1995).

Os critérios utilizados na calibração manual também são um tanto subjetivos e, em consequência, usuários diferentes encontram conjuntos de parâmetros diferentes com o mesmo modelo, na mesma bacia e no mesmo período de tempo (Beven e Binley, 1992).

A calibração automática surgiu como alternativa para contornar a falta de usuários experientes, acelerar o processo de calibração e torná-lo menos subjetivo e, portanto, passível de repetição.

A calibração automática é uma ferramenta que visa determinar o conjunto ótimo dos valores dos parâmetros de um modelo hidrológico com a mínima interferência do usuário. A experiência do usuário é substituída, em grande parte, por uma técnica iterativa e por uma função objetivo. O objetivo da calibração automática é, portanto, minimizar ou maximizar o valor de uma função objetivo que mede a qualidade do ajuste dos hidrogramas (Sorooshian e Gupta, 1995).

Um número expressivo de algoritmos de calibração automática é descrita em textos sobre modelos hidrológicos (Tucci, 1998; Sorooshian e Gupta, 1995). No contexto deste trabalho é interessante apenas a definição das diferenças entre algoritmos de busca local e busca global, uma descrição sucinta do método Simplex de Nelder e Mead (Nelder e Mead apud Sorooshian e Gupta,

1995), e breves introduções aos algoritmos de busca aleatória e aos algoritmos genéticos. Estes conceitos são fundamentais para a melhor compreensão do algoritmo SCE – UA, descrito adiante no texto.

Os algoritmos de busca local são os mais comuns. A busca é realizada iterativamente a partir de um ponto inicial, sempre seguindo uma direção de valores decrescentes da função objetivo (no caso de minimização). Estes algoritmos são rápidos e eficientes na busca de mínimos ou máximos de funções unimodais (com apenas um ponto ótimo).

Dois dos métodos de busca local mais conhecidos são o método de Rosenbrock (Tucci, 1998) e o método Simplex de Nelder e Mead. O algoritmo Simplex de Nelder e Mead é um método de otimização não-linear e não deve ser confundido com o método simplex de programação linear.

A estratégia de busca do método Simplex de Nelder e Mead é descrita abaixo e na figura 1, conforme Sorooshian e Gupta (1995), no caso da minimização do valor de uma função .

1. Selecione aleatoriamente  $n+1$  pontos, onde  $n$  é o número de parâmetros a otimizar no espaço possível de valores dos parâmetros. Este grupo de  $n+1$  pontos é denominado simplex.
2. Identifique o ponto com o pior valor de função objetivo e calcule o centróide dos outros  $n$  pontos.
3. Crie um novo ponto refletindo as coordenadas do pior ponto através de um “espelho” colocado no centróide dos  $n$  melhores pontos (figura 1a). Se o valor da função objetivo é menor no novo ponto, denominado ponto de “reflexão”, do que no pior dos  $n+1$  pontos, então siga no passo 4, caso contrário, siga no passo 5.
4. Crie um ponto de “expansão” refletindo as coordenadas do pior ponto através de um “espelho” colocado no centróide dos  $n$  melhores pontos, mas estenda a reflexão em duas vezes a distância original (figura 1b). Se o valor da função objetivo é menor no novo ponto do que no ponto de reflexão calculado no passo 3, então substitua o pior ponto do simplex pelo ponto de expansão, caso contrário, substitua-o pelo ponto de reflexão. Siga no passo 7.
5. Crie um novo ponto, denominado ponto de “contração”, a meio caminho entre o pior ponto e o centróide (figura 1c). Se o valor da função no ponto de contração for menor do que no pior ponto, substitua o pior ponto pelo ponto de contração no simplex e siga no passo 7, caso contrário, siga no passo 6.
6. Contraia o simplex movimentando todos os pontos do simplex (exceto o melhor de todos) até meio caminho entre sua posição original e a do melhor ponto (figura 1d).
7. Repita os passos 1 a 6 até que o tamanho do simplex seja menor do que algum limite.

Os algoritmos de busca local não são muito satisfatórios para a calibração de modelos hidrológicos porque, normalmente, as funções objetivo têm superfícies de resposta que são multimodais, isto é, há diversos locais em que o valor da função é um mínimo ou máximo local.




Figura 1: Ilustração do algoritmo Simplex de Nelder e Mead (Sorooshian e Gupta, 1995).

Duan et al. (1992) identificaram, em testes com o modelo Sacramento (Burnash, 1995), vários problemas que dificultam a calibração automática de modelos chuva – vazão. Segundo estes autores,

1. a superfície de resposta de funções objetivo de modelos chuva –vazão apresenta várias regiões de atração, para as quais os métodos automáticos podem convergir;
2. cada região de atração contém muitos mínimos locais que podem estar próximos ou não do ótimo global;
3. a superfície de resposta não é necessariamente contínua nem suave e as suas derivadas são descontínuas;
4. a sensibilidade da função objetivo aos parâmetros não é constante e tende a decrescer na proximidade dos pontos de ótimo;
5. os parâmetros interagem de forma não linear e
6. a função objetivo é freqüentemente não convexa nas imediações do ótimo.

Devido a estas características da superfície de resposta da função objetivo, o ponto onde o algoritmo vai chegar depende do ponto, ou dos pontos, em que iniciou o procedimento, e em cada aplicação o algoritmo pode resultar em uma calibração diferente do modelo.

Os modelos de busca global foram desenvolvidos na tentativa de superar esta limitação. Entre os métodos de busca global estão os métodos aleatórios, os algoritmos genéticos e algumas combinações de técnicas que incluem estes dois tipos.

Os métodos aleatórios estão baseados na busca aleatória do ótimo global. No método mais simples, denominado pesquisa uniforme aleatória (Tucci, 1998), são gerados  $n$  pontos no espaço permitido dos parâmetros e o ponto com o melhor resultado da função objetivo é adotado como ótimo. Uma evolução em relação a este método é a pesquisa aleatória com adaptação (Tucci, 1998), que intensifica a busca do ótimo, iterativamente, na vizinhança do último ponto ótimo encontrado.

O método aleatório pode ser utilizado para gerar múltiplos pontos de início para algum algoritmo de busca local. O algoritmo MSX, descrito por Duan et al. (1992), por exemplo, combina o algoritmo Simplex de Nelder e Mead à busca aleatória de pontos de início de busca.

Os métodos aleatórios são, em geral, pouco eficientes. O número de iterações e de avaliações da função objetivo é, quase sempre, exagerado para uma aplicação prática na calibração de modelos hidrológicos (Duan et al., 1992, Thyer et al., 1999).

Os algoritmos genéticos utilizam os conceitos de seleção natural e mutação, tomados emprestados da biologia (Lacerda e Carvalho, 1999). Estes métodos seguem a seguinte metodologia (Wang, 1991): 1) indivíduos mais aptos tendem a sobreviver e reproduzir; 2) os indivíduos gerados são parecidos, mas não completamente iguais aos indivíduos geradores.

A bibliografia de otimização por algoritmos genéticos está repleta de termos emprestados da biologia, como reprodução, filhos, seleção natural, espécies, casais, pais e evolução. Em parte, este empréstimo de vocabulário é justificado, muito embora alguns procedimentos que incluem técnicas de algoritmos genéticos sejam pouco parecidos com a seleção natural, em que as condições ambientais condicionam a direção e a velocidade em que ocorre a evolução. De fato, muitas vezes os métodos de otimização que incluem algoritmos genéticos são mais parecidos aos métodos de seleção artificial, como na situação de um fazendeiro que procura cruzar os animais de forma a otimizar determinado aspecto de interesse econômico, como a porcentagem de gordura da carne, o ganho de peso em um ano, a resistência ao frio ou às doenças.

Um algoritmo de busca global que vem recebendo atenção na bibliografia nos últimos anos é o SCE – UA, desenvolvido na Universidade do Arizona, e que será descrito adiante no texto.

## **O ALGORITMO SCE – UA**

O algoritmo SCE-UA foi inicialmente descrito por Duan et al. (1992), que analisaram a superfície de resposta de funções objetivo aplicadas a problemas de calibração de modelos hidrológicos e constataram que, devido às características desta função de resposta, os métodos de calibração automática por busca local, como Rosenbrock e Simplex de Nelder e Mead, tendem a encontrar sempre apenas pontos ótimos locais. Para contornar este problema, Duan et al. (1992) criaram um método baseado na combinação de técnicas de busca aleatória, algoritmos genéticos e otimização local, denominado SCE-UA. O nome SCE é derivado das iniciais de Shuffled Complex Evolution, o que pode ser traduzido por “Evolução de Complexos Misturados” (Diniz, 1999). As letras UA provém de University of Arizona, instituição de origem dos autores do algoritmo.

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.

Durante o procedimento é gerada 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 1) busca aleatória; 2) algoritmos genéticos e 3) método simplex de Nelder e Mead (busca local). Os passos do algoritmo, conforme descritos por Sorooshian e Gupta (1995), são apresentados a seguir.

1. *Início*: São selecionados os valores dos parâmetros  $p$  e  $m$ , que definem, respectivamente, o número de complexos (blocos em que está dividida a amostra de pontos) e o número de pontos em cada complexo. O tamanho da amostra ( $s$ ) é igual ao produto de  $p$  e  $m$ . Se  $n$  é o número de variáveis do problema de otimização (os parâmetros do modelo hidrológico, por exemplo), então os valores de  $p$  e  $m$  devem ser tais que:  $p \geq 1$  ; e  $m \geq n + 1$ .
2. *Geração da amostra*: São gerados  $s$  grupos de parâmetros do modelo hidrológico, entre os limites máximo e mínimo definidos para cada parâmetro, formando um conjunto  $\mathbf{D}$ . Estes grupos caracterizam pontos no espaço hiperdimensional e são escolhidos aleatoriamente, utilizando uma distribuição uniforme.
3. *Hierarquização dos pontos*: Os pontos gerados no passo 2 são avaliados com a função objetivo, isto é, o modelo hidrológico é executado uma vez para cada um dos  $s$  pontos da amostra. Os pontos são reorganizados na amostra, em ordem crescente de função objetivo, de maneira que o primeiro ponto apresente o menor (melhor) valor da função objetivo.
4. *Divisão em complexos*: A amostra  $\mathbf{D}$  de  $s$  pontos é dividida em  $p$  complexos, cada um contendo  $m$  pontos. A divisão é feita de maneira que cada um dos complexos tenha pontos bons (baixos valores da função objetivo) e pontos ruins (altos valores da função objetivo). A divisão em complexos segue a regra  $A^k = \{x_j^k, f_j^k\}$  onde  $x_j^k = x_{k+p \cdot (j-1)}$  e  $f_j^k = f_{k+p \cdot (j-1)}$ , para  $j = 1, \dots, m$ . Onde  $k$  é o número do complexo, que varia de 1 a  $p$ ;  $j$  é o número do ponto dentro do complexo, que varia de 1 a  $m$ ;  $x$  é o grupo de parâmetros e  $f$  é o valor da função objetivo, sendo que  $x$  e  $f$  estão originalmente organizados em uma amostra de tamanho  $s$ , isto é,  $x_i$  e  $f_i$  ( $i = 1, \dots, s$ ).



5. *Evolução dos complexos*: A cada complexo é dada a oportunidade de evoluir, de forma independente, na direção de um ótimo da função objetivo. Esta evolução é realizada de acordo com os passos da Evolução Competitiva Complexa, descrita separadamente adiante no texto.
6. *Mistura dos complexos*: Os complexos  $A^k$  são novamente agrupados no conjunto  $D$ , que contém toda a amostra de  $s$  pontos. Os pontos são reorganizados na amostra, em ordem crescente de função objetivo, de maneira que o primeiro ponto apresente o menor (melhor) valor da função objetivo.
7. *Teste de convergência*: Os pontos da amostra são testados para avaliar se satisfazem um critério de convergência previamente definido. Em caso positivo, o algoritmo se encerra. Caso contrário o procedimento recomeça no passo 4.

A Evolução Competitiva Complexa, necessária para a evolução independente de cada complexo no passo 5 do algoritmo SCE – UA, opera segundo o algoritmo que segue.

1. *Início*: São selecionados valores de  $q$ ,  $\alpha$  e  $\beta$ , que são parâmetros do algoritmo. Os valores são escolhidos de forma que  $2 \leq q \leq m$ ;  $\alpha \geq 1$ ; e  $\beta \geq 1$ .
2. *Atribuição de pesos*: Cada um dos pontos do complexo recebe um peso, proporcional à sua posição na hierarquia do complexo, isto é, pontos com menor valor da função objetivo recebem um peso maior. Os pesos são atribuídos conforme a equação:  $\rho_i = \frac{2 \cdot (m + 1 - i)}{m \cdot (m + 1)}$ ,  $i = 1, \dots, m$ ; onde  $\rho$  é o valor do peso,  $m$  é o número de pontos em cada complexo e  $i$  é a posição do ponto no complexo. Os pesos atribuídos pela equação acima variam linearmente entre o valor máximo, atribuído ao ponto  $i = 1$ , até o valor mínimo, atribuído ao ponto  $i = m$ . No caso de  $m = 10$ , por exemplo, alguns pesos seriam  $\rho_1 = 0,18$ ;  $\rho_5 = 0,11$  e  $\rho_{10} = 0,02$ . A soma dos pesos dos  $m$  pontos do complexo é igual a 1.
3. *Seleção de pais ou “reprodutores”*: Um sub-complexo de  $q$  pontos ( $u_j$   $u = 1, \dots, q$ ) é retirado aleatoriamente de cada complexo. A probabilidade de cada ponto do complexo fazer parte do sub-complexo é dada pelo peso atribuído ao ponto no passo 2. Isto significa que os melhores pontos (com menores valores da função objetivo) são mais facilmente escolhidos, embora todos os pontos do complexo o possam ser.
4. *Geração de novos pontos*:
  - a) Os pontos do sub-complexo são organizados de forma crescente de função objetivo, sendo que o ponto  $j = 1$  ( $u_1$ ) apresenta o menor valor da função objetivo e o ponto  $j = q$  ( $u_q$ ) apresenta o maior valor da função objetivo.

b) É calculado o centróide dos  $q-1$  melhores pontos do sub-complexo, segundo a equação:

$$g = \frac{1}{q-1} \sum_{j=1}^{q-1} u_j .$$

c) As coordenadas de um novo ponto são calculadas. Este novo ponto ( $r$ ) é denominado “ponto de reflexão”, e suas coordenadas são calculadas de acordo com a equação  $r = 2 \cdot g - u_q$ . Este procedimento está ilustrado na descrição do método Simplex de Nelder e Mead.

d) Caso o ponto  $r$  estiver contido entre os limites mínimo e máximo permitidos para cada parâmetro, o valor da função objetivo é calculado e o procedimento segue no passo 4.e. Caso contrário, é definido o menor hipercubo que contém todos os pontos do complexo, e um novo ponto ( $z$ ) é gerado aleatoriamente no interior deste hipercubo. O procedimento segue no passo 4g.

e) Se o valor da função objetivo em  $r$  for menor do que em  $u_q$  ( $f_r < f_q$ ), o novo ponto é  $r$ , e o procedimento segue no passo 4g. Caso contrário, as coordenadas de um novo ponto são calculadas. Este novo ponto ( $c$ ) é denominado “ponto de contração”, e suas coordenadas são calculadas de acordo com a equação  $r = \frac{(g + u_q)}{2}$ .

f) Se o valor da função objetivo em  $c$  for menor do que em  $u_q$  ( $f_c < f_q$ ), o novo ponto é  $c$ . Caso contrário, é definido o menor hipercubo que contém todos os pontos do complexo, e um novo ponto ( $z$ ) é gerado aleatoriamente no interior deste hipercubo.

g) O pior ponto do sub-complexo ( $u_q$ ) é substituído pelo novo ponto ( $r$  ou  $c$  ou  $z$ ) e o procedimento reinicia no passo 4a, um número  $\alpha$  de vezes ( $\alpha$  está definido no passo 1).

5. Os pontos do sub-complexo são devolvidos, modificados, ao complexo.

6. Os passos 1 a 5 são repetidos um número  $\beta$  de vezes, onde  $\beta$  é um parâmetro do algoritmo que pode ser definido pelo usuário e que determina quantas gerações cada complexo produz até ser misturado aos outros complexos.

Duan et al. (1994) indicam valores adequados para os parâmetros do algoritmo SCE-UA, como  $\alpha$ ,  $\beta$ ,  $m$ ,  $p$  e  $q$ , para a calibração de modelos hidrológicos. Os valores utilizados neste trabalho foram  $m = 17$ ;  $p = 15$ ;  $q = 15$ ;  $\beta = 15$ ;  $\alpha = 1$ ; para a calibração de 7 parâmetros.

Segundo seus autores, o algoritmo SCE – UA imita o processo de evolução natural. Os  $s$  pontos da amostra constituem uma população de uma espécie. Esta população está dividida em diversas comunidades, que são os complexos. A cada uma das comunidades é dada a oportunidade de evoluir de forma independente, por um determinado período. Após um número de gerações pré-determinado ( $\beta$ ), as comunidades se encontram, são misturadas e uma nova divisão é feita. Este

processo de mistura permite o compartilhamento de informações que cada comunidade adquiriu de forma independente (Sorooshian e Gupta, 1995).

Seguindo ainda com a analogia biológica, cada um dos membros de uma comunidade é um candidato a “pai”, com potencial em participar no processo de reprodução. Um sub-complexo retirado de um complexo é como um casal biológico. A diferença é que o sub-complexo pode ter mais de 2 membros.

Para garantir que o processo seja competitivo, é necessário que os melhores “pais” tenham maior probabilidade de gerar “filhos” do que os piores. Para isso, a qualidade dos “pais” e, conseqüentemente, a probabilidade de gerar “filhos”, é avaliada pelo valor da função objetivo.

A maior diferença do algoritmo em relação ao processo de evolução natural é que a evolução das gerações é guiada artificialmente. Pela utilização do algoritmo de Nelder e Mead nos passos de 4b a 4g, a evolução ocorre no sentido em que se espera um menor valor da função objetivo. Neste caso, a analogia está mais próxima de um melhoramento de espécies artificial do que de um processo de seleção natural.

Apenas em alguns casos, quando o processo de melhoramento artificial (pontos de reflexão e de contração) não geram melhores resultados, é que o processo aleatório domina a “reprodução”. Segundo Sorooshian e Gupta (1995), este pequeno grau de aleatoriedade amplia a capacidade do algoritmo de varrer o espaço possível na busca do ótimo global.

O algoritmo SCE – UA foi testado e comparado com outros métodos de calibração automática por diversos autores, e sempre mostrou vantagens significativas, resultando em valores mais baixos (melhores) da função objetivo com relativa rapidez. Outra característica positiva verificada é a persistência do método, que atinge, em geral, o mesmo ponto mesmo quando são alterados alguns parâmetros e a semente do processo de geração de números aleatórios. Isto é uma forte indicação, embora não seja uma prova, de que o ponto encontrado é o ótimo global.

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 em combinação 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). Apesar disso, segundo estes autores, melhores resultados durante a fase de calibração não significam, necessariamente, melhores resultados durante a fase de verificação.

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 5270 km<sup>2</sup>, nos EUA. O algoritmo SCE – UA foi comparado aos métodos Simplex e “Simulated Annealing”, e mostrou melhores resultados quanto à função objetivo atingida e 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” ou Simulação de Cristalização (Press et al., 1995) 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).

### **Exemplo simples de aplicação**

Um exemplo de aplicação do algoritmo a uma situação mais simples do que a calibração de um modelo hidrológico serve para compreender melhor o procedimento utilizado no algoritmo SCE – UA. A figura 2 apresenta uma seqüência de passos do algoritmo na busca do ótimo global da função de Hosaki (equação 1).

$$H = \left( \left( 1 - 8 \cdot x_1 + 7 \cdot x_1^2 - \left( \frac{7}{3} \right) \cdot x_1^3 + \left( \frac{1}{4} \right) \cdot x_1^4 \right) \cdot x_2^2 \right) \cdot \text{EXP}(-x_2) \quad (1)$$

Esta função tem duas variáveis ( $x_1$  e  $x_2$ ) e, no intervalo definido por  $0 < x_1 < 5$  e  $0 < x_2 < 5$ , apresenta um ótimo local em  $x_1 = 1$   $x_2 = 2$ , e um ótimo global em  $x_1 = 4$   $x_2 = 2$ .

O algoritmo é utilizado com 3 complexos e 8 pontos em cada complexo, num total de 24 pontos. Os valores de  $\alpha$  e  $\beta$  são, respectivamente, 1 e 5.

Inicialmente são gerados valores aleatórios das variáveis  $x_1$  e  $x_2$ , entre 0 e 5. Os pontos aleatórios gerados são os círculos na figura 2. Pode se observar que, casualmente, não há nenhum círculo próximo dos mínimos local e global e que os pontos cobrem toda a área permitida.




Figura 2: Ilustração da evolução de pontos na busca do ótimo da função de Hosaki pelo método SCE – UA.

Já no segundo passo, ao final da primeira etapa de “Evolução Competitiva Complexa”, os pontos (quadrados) passam a se concentrar nas proximidades do ótimo global ( $x_1 = 4$   $x_2 = 2$ ). No passo 3, já existe uma concentração significativa de pontos próximos ao ótimo global, mas ao mesmo tempo está sendo explorada a região do ótimo local ( $x_1 = 1$   $x_2 = 2$ ). Na figura 2 podem ser vistas 3 pontos (cruzinhas) próximos ao ótimo local e pelo menos 6 próximos ao ótimo global. Finalmente, no passo 10, todos os pontos estão concentrados em uma mancha densa na região do ótimo global.

A utilização de um grande número de pontos que evoluem na direção do ótimo pode auxiliar a análise de algumas características da função objetivo. Um ponto ótimo mal definido, localizado ao longo de um vale é apenas levemente superior aos pontos vizinhos ao longo do vale. Esta situação é freqüente na calibração de modelos hidrológicos, quando alguns parâmetros do modelo apresentam pouca sensibilidade.

A equação 2, abaixo, é a soma de duas parábolas, uma variando em  $x_1$  e a outra em  $x_2$ . O ponto ótimo (menor valor da função) está localizado em  $x_1=x_2=2,5$ . Não existem ótimos locais, porém o ponto ótimo é muito melhor definido ao longo de um eixo paralelo a  $x_1$  do que de  $x_2$ . A segunda derivada, que indica grau de concavidade, em relação a  $x_1$  é igual a 2 e em relação a  $x_2$  é de apenas  $2 \cdot 10^{-5}$ . A função resultante tem a forma de um vale ao longo de um eixo paralelo a  $x_2$ , passando por  $x_1=2,5$ .

$$F = x_1^2 - 5 \cdot x_1 + \frac{x_2^2 - 5 \cdot x_2}{100000} \quad (2)$$

Utilizando o algoritmo SCE – UA, conforme é apresentado na figura 3, a região do ponto ótimo é encontrada, porém, mesmo no passo 10 ainda está definida como um extenso intervalo de  $x_2= 1,5$  a  $x_2 = 3,3$ .




Figura 3: Ilustração da evolução de pontos na busca do ótimo de uma função pouco sensível a  $x_2$  pelo método SCE – UA.

É claro que o ponto ótimo é encontrado em um número maior de passos, mas o que se observa é que, graças ao conceito de população de pontos, o algoritmo pode ser utilizado também como uma ferramenta para analisar o comportamento da função objetivo. Além disso, em aplicações de calibração de modelos hidrológicos, o tipo de resposta apresentada na figura 3 pode permitir a avaliação da sensibilidade do modelo aos parâmetros e para aprofundar o conhecimento do comportamento do próprio modelo.

## A FUNÇÃO OBJETIVO

Na calibração de modelos hidrológicos chuva – vazão, a função objetivo é uma medida objetiva do grau de semelhança entre o hidrograma observado e o hidrograma calculado. A função objetivo é um elemento fundamental na calibração automática. É desejável uma função automática que possa representar toda a complexidade considerada na calibração manual. Tucci (1998) apresenta uma série de funções objetivo que podem ser utilizadas para a calibração de modelos chuva – vazão.

A função objetivo normalmente utilizada é a soma dos desvios quadrados (equação 3), ou o coeficiente de Nash Sutcliffe (equação 4). Estas duas funções objetivo são equivalentes e tendem a valorizar os períodos de cheia, em detrimento dos períodos de estiagem. Em consequência o ajuste dos hidrogramas não é bom para as vazões baixas.

$$SDQ = \sum (Q_{obs}(t) - Q_{cal}(t))^2 \quad (3)$$

$$R2 = 1 - \frac{\sum (Q_{obs}(t) - Q_{cal}(t))^2}{\sum (Q_{obs}(t) - \overline{Q_{obs}})^2} \quad (4)$$

Recentemente foi proposta uma função objetivo idealizada para resultar em bons ajustes gerais dos hidrogramas, tanto nas vazões baixas como nas altas (Yu e Yang, 2000). Esta função objetivo é calculada da seguinte forma:

1. Inicialmente o hidrograma observado é analisado e são calculados os valores da curva de permanência  $Q_0\%$ ,  $Q_1\%$ ,  $Q_{10\%}$ ,  $Q_{20\%}$ ,  $Q_{30\%}$ ,  $Q_{40\%}$ ,  $Q_{50\%}$ ,  $Q_{60\%}$ ,  $Q_{70\%}$ ,  $Q_{80\%}$ ,  $Q_{90\%}$  e  $Q_{100\%}$ . Cada par de valores característicos sucessivos da curva de permanência define um intervalo, totalizando 11 intervalos de vazão.
2. Para cada intervalo de tempo verifica em qual intervalo de vazão (i) encontra-se a vazão observada. Armazena a diferença relativa acumulada no intervalo de vazão i, de acordo com a equação 5 (n é o número total de vazões que caem no intervalo i).

$$DRA_i = \frac{1}{n} \sum_{j=1}^n \left| \frac{Q_{obs(j)} - Q_{cal(j)}}{Q_{obs(j)}} \right| \cdot 100 \quad (5)$$

3. Calcula o valor da função de aceitabilidade do intervalo ( $M_i$ ), de acordo com a figura 4.
4. Calcula o valor da função objetivo usando a equação 6.




Figura 4: Função de aceitabilidade do erro de volume no intervalo de vazões  $i$ .

$$F = 1 - \min_{i=1}^{11} M_i \quad \text{equação (6)}$$

De acordo com Yu e Yang, esta função objetivo permite um ajuste mais homogêneo dos hidrogramas, sem valorizar excessivamente as vazões altas ou baixas.

## APLICAÇÃO

O modelo IPH-2 foi aplicado à bacia do rio Tesouras, no estado de Goiás, no período de 1982 a 1986. Esta bacia tem uma área de 1817 km<sup>2</sup>, e no período analisado apresenta precipitação média anual de 1645 mm e vazão média de longo período de 33,7 m<sup>3</sup>.s<sup>-1</sup>.

Os detalhes do modelo chuva – vazão IPH-2 são apresentados em Tucci (1998). O modelo têm 8 parâmetros que podem ser calibrados. Neste trabalho, entretanto, o tempo de concentração foi considerado fixo em 3 dias, restando para calibração os outros 7 parâmetros. Os limites máximo e mínimo considerados na calibração dos parâmetros estão na tabela 1. O intervalo de tempo de cálculo foi de 1 dia.

Tabela 1: Limites dos parâmetros do modelo IPH2

	I0	Ib	h	Ks	Kbas	Rmax	Alf
mínimo	10,0	0,1	0,01	0,01	10,0	1,0	0,01
máximo	300,0	5,00	1,00	10,0	500,0	5,0	20,0

## Testes com séries sintéticas

A única forma de checar se um método de calibração pode atingir o ótimo global é testa-lo usando uma série de vazões geradas pelo próprio modelo. Neste caso, o conjunto de valores de



parâmetros que o método de calibração deve atingir para ser um candidato a método de calibração global é o conjunto de parâmetros que foi utilizado para gerar a série sintética.

O modelo IPH-2 foi executado com o conjunto de parâmetros apresentado na tabela 2, para gerar uma série de vazões sintéticas. A seguir o modelo foi calibrado de forma automática, utilizando a série sintética como a série de vazões observadas, e conjuntos iniciais aleatórios de parâmetros. Como pode ser visto na figura 5 para o parâmetro I0 do modelo IPH-2, o algoritmo de calibração atinge rapidamente o valor verdadeiro dos parâmetros. Em 10 aplicações sucessivas o algoritmo de calibração atingiu sempre o ótimo global (conjunto de parâmetros que gerou a série sintética), em menos do que 10.000 avaliações da função objetivo.

Pode-se dizer, portanto, que o algoritmo SCE-UA é um método de calibração global em um problema de calibração do modelo IPH-2 a uma série de vazões sintéticas (geradas pelo próprio modelo). Este resultado é importante quando se considera que, em análises feitas por Pickup (1977), os métodos de calibração de Rosenbrock, Simplex de Nelder e Mead, Davidon e Powell não atingiram o ótimo global em um problema da calibração do modelo chuva – vazão Boughton, utilizando séries de vazões sintéticas. Além disso, os quatro métodos testados calibraram o modelo com conjuntos de parâmetros diferentes, embora tenham iniciado no mesmo ponto.

Tabela 2: Valores dos parâmetros do modelo IPH2 para geração da série sintética.

I0	Ib	h	Ks	Kbas	Rmax	Alf
50,0	1,0	0,8	5,0	100,0	4,0	2,0

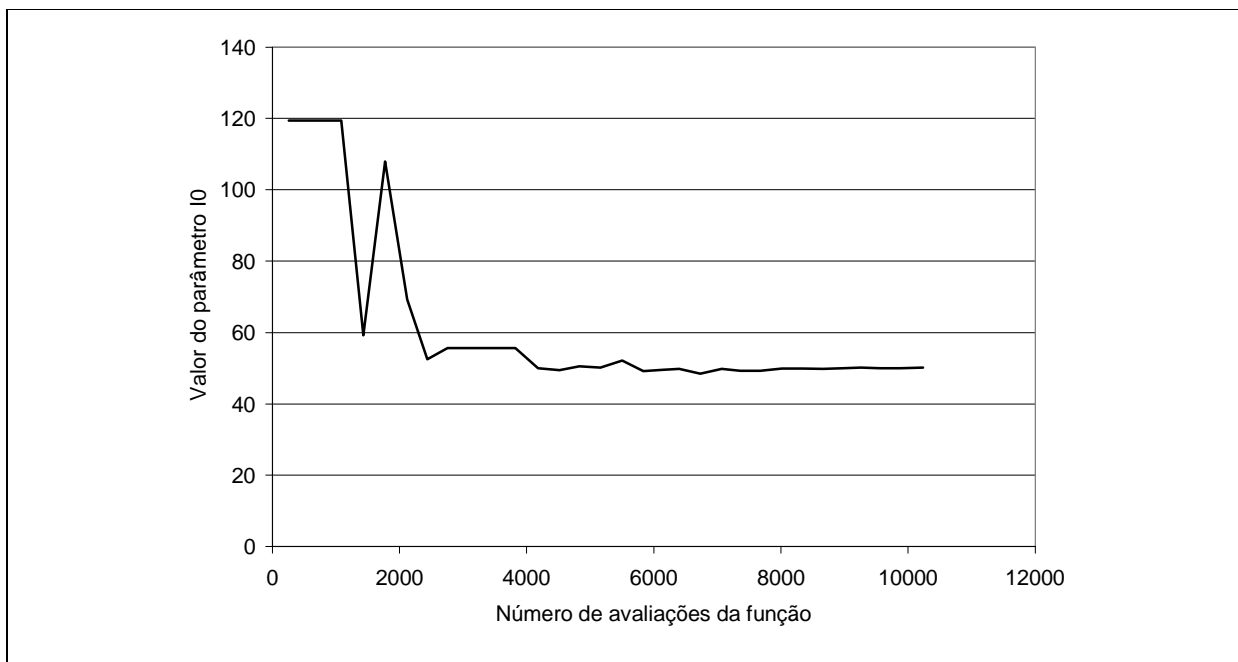


Figura 5: Evolução do parâmetro I0 ao longo do processo de calibração automática.

## Testes com séries reais

O algoritmo foi testado com séries reais de vazões observadas. Na tabela 3 estão os valores dos parâmetros encontrados em 10 execuções independentes do programa. A função objetivo utilizada foi a soma dos desvios quadrados. Existem fortes evidências de que o algoritmo encontrou o ótimo global, embora não exista garantia disso.

Tabela 3: Valores dos parâmetros encontrados em 10 calibrações consecutivas.

Calibração	I0	Ib	h	Ks	Kbas	Rmax	Alf	R2
1	36,04	0,46	0,93	7,52	11,11	2,80	19,99	0,85915
2	36,04	0,46	0,93	7,52	11,16	2,80	19,99	0,85915
3	36.03	0.46	0.93	7,52	11,05	2,80	19,99	0,85915
4	35.91	0.46	0,93	7.56	11.95	2.81	19.69	0,85915
5	36.02	0.46	0,93	7.52	11.09	2.80	19.98	0,85915
6	36.04	0.46	0.93	7.52	11.14	2.80	19.99	0,85915
7	36.04	0.46	0,93	7.52	11.12	2.80	19.99	0,85915
8	36.05	0.46	0,93	7.52	11.13	2.80	19.99	0,85915
9	36.03	0.46	0,93	7.52	11.11	2.79	19.99	0,85915
10	36.04	0.46	0,93	7.52	11.16	2.80	19.99	0,85915

## Testes com a função objetivo de Yu e Yang

A figura 6 apresenta o resultado da calibração do modelo IPH2 na bacia do rio Tesouras utilizando o algoritmo SCE – UA com as funções objetivo 1) soma dos desvios quadrados (SDQ) e 2) função de Yu e Yang.

Observa-se na figura 6 que a função de Yu e Yang foi um pouco melhor no ajuste das vazões extremamente baixas.

Quando calibrado com a função SDQ, o modelo não conseguiu representar as vazões baixas que ocorrem no período de inverno de todos os anos a partir de 1983. No auge da estiagem a vazão calculada é cerca de 10 vezes superior à observada. Já a função de Yu e Yang (2000) teve melhores resultados no auge da estiagem, porém resultou em um mau ajuste do início da recessão do hidrograma.

Tabela 4: Valores dos parâmetros do modelo IPH2 calibrados com a função de Yu e Yang.

I0	Ib	h	Ks	Kbas	Rmax	Alf
76.76	.19	.70	4.60	22.14	2.89	.02

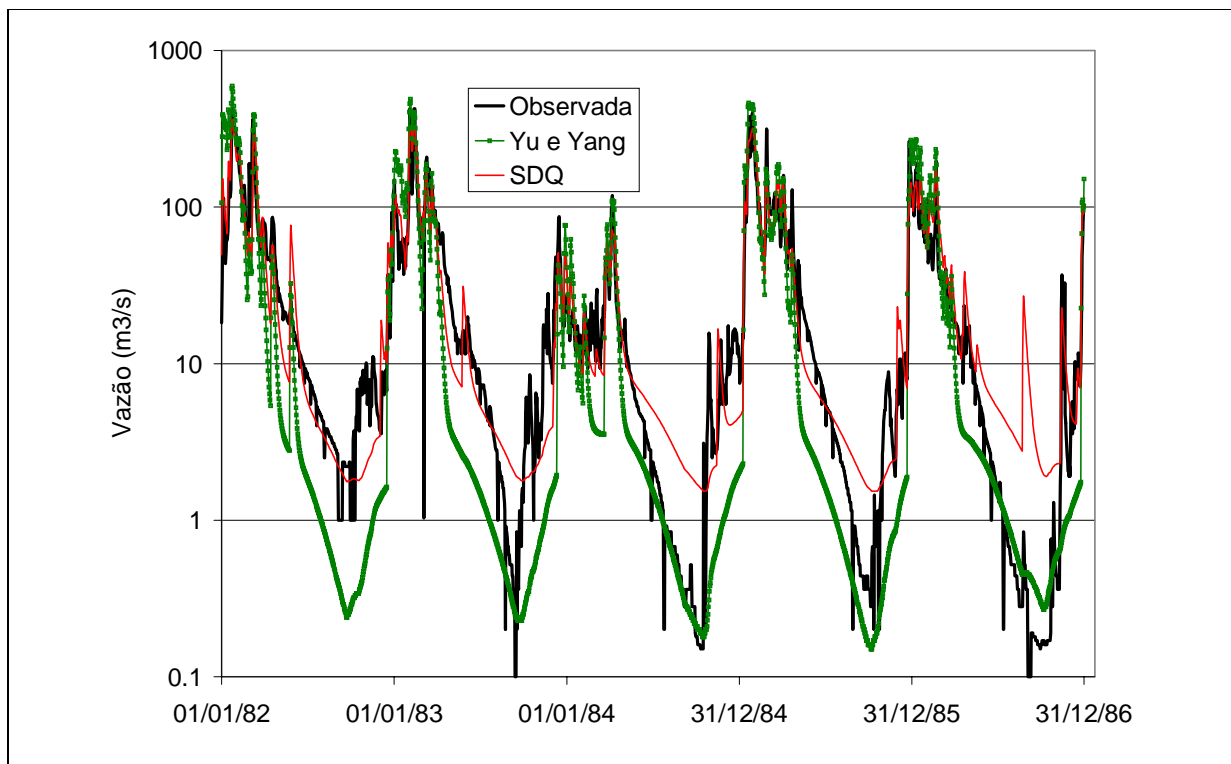


Figura 6: Ajuste dos hidrogramas utilizando as funções objetivo de Yu e Yang e a soma dos desvios quadrados.

## CONCLUSÕES

Este trabalho apresentou uma aplicação do algoritmo SCE – UA (Duan et al., 1992) para a calibração automática do modelo hidrológico IPH2 (Tucci, 1998). O modelo foi aplicado em uma bacia de 1827 km<sup>2</sup> localizada no estado de Goiás, num período de 6 anos.

Um conjunto de parâmetros arbitrário foi definido e com este o modelo foi utilizado para gerar uma série de vazões, utilizadas posteriormente como vazões observadas para a calibração, numa primeira fase de testes do algoritmo. Nesta fase o algoritmo foi capaz de atingir o ótimo global em 10 testes seguidos, sempre em menos de 10.000 avaliações da função.

Numa segunda fase foram utilizadas séries de vazões observadas. Nesta situação o ótimo global não é conhecido, o que não permite concluir que a metodologia de calibração tenha atingido o ótimo global, mas em 10 testes seguidos o algoritmo SCE – UA atingiu sempre o mesmo conjunto

de parâmetros. Isto indica que o modelo atingiu um ponto que pode não ser o ótimo global mas é, pelo menos, um forte candidato.

Também foi avaliada a função objetivo de Yu e Yang (2000), a qual foi proposta com o objetivo de ajustar mais uniformemente o hidrograma, imitando, parcialmente, a calibração manual. Os resultados mostram que, embora tenha resultado em um melhor ajuste das vazões baixas no auge da estiagem em quase todos os anos, a função objetivo de Yu e Yang (2000) não resultou em um melhor ajuste do hidrograma como um todo.

De acordo com os resultados deste trabalho e com as avaliações de diversos outros autores em trabalhos recentes (Thyer et al., 1999; Abdulla et al., 1999; Gan e Biftu, 1996; Sorooshian et al., 1993), pode se dizer que o algoritmo SCE-UA é a melhor opção, atualmente, para a calibração automática de modelos hidrológicos. Recomenda-se que o algoritmo seja incluído como ferramenta de calibração padrão nos modelos hidrológicos chuva – vazão que estão sendo desenvolvidos atualmente para uso em agências e instituições governamentais, especialmente se os programas computacionais forem amigáveis e o uso for generalizado, incluindo profissionais com pouca experiência na área.

Atualmente, este trabalho está sendo estendido para a calibração automática multi-objetivo de modelos hidrológicos. Os autores estão utilizando as metodologias de Madsen (2000), Boyle (2000), Yu e Yang (2000) e Yapo et al. (1998) para a calibração automática multi-objetivo de um modelo de simulação chuva-vazão em grandes bacias (Collischonn e Tucci, 2001).

## **REFERÊNCIAS**

- 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.
- Beven, K.; Binley, A. 1992 The future of distributed models: model calibration and uncertainty prediction. *Hydrological Processes*, Vol. 6 pp. 279-298.
- Boyle, D. P.; Gupta, H. V.; Sorooshian, Soroosh 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.
- 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.; Tucci, C. E. M. 2001 Simulação hidrológica de grandes bacias. *Revista Brasileira de Recursos Hídricos*, Vol. 6 No. 1.

- 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 calibrating watershed models. *Journal of Hydrology*, Vol 158 pp. 265-284.
- Gan, T. Y.; Biftu, 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.
- 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 efficiency 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.
- 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. C. 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.

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.