



Universidade Federal do Rio Grande do Sul  
Instituto de Pesquisas Hidráulicas  
Programa de Pós-Graduação em Recursos Hídricos e  
Saneamento Ambiental



**CARLOS ANTONIO ECHEVERRIA MARTINEZ**

CALIBRAÇÃO AUTOMÁTICA DE MODELO HIDROLOGICO COM ALGORITMO BASEADO NO  
COMPORTAMENTO DE FORMIGAS

**Orientador:** Juan Martín Bravo

PORTO ALEGRE

Fevereiro, 2014



Universidade Federal do Rio Grande do Sul  
Instituto de Pesquisas Hidráulicas  
Programa de Pós-Graduação em Recursos Hídricos e  
Saneamento Ambiental



CARLOS ANTONIO ECHEVERRIA MARTINEZ

**CALIBRAÇÃO AUTOMÁTICA DE MODELO HIDROLOGICO COM ALGORITMO BASEADO NO  
COMPORTAMENTO DE FORMIGAS**

**Orientador:** Prof. Dr. Juan Martín Bravo

**BANCA EXAMINADORA**

Profa. Dra. Luiza Fernanda Ribeiro Reis	EESC/USP
Prof. Dr. Daniel Gustavo Allasia Piccili	UFSM
Prof. Dr. Walter Collischonn	IPH/UFRGS

PORTO ALEGRE

Fevereiro, 2014

*“Muchos de nuestros sueños parecen al principio imposibles, luego pueden parecer improbables, y luego, cuando nos comprometemos firmemente, se vuelven inevitables. ¿Si no vas por todo, por que vas?”*

# AGRADECIMENTOS

A minha família, que me apoiou desde o momento zero em que eu decidi trocar de vida e vir para este maravilhoso país e continuar com os meus estudos. Minha mãe e o meu pai que me deram uma educação baseada em valores que não tem preço. Sem eles, isto não seria possível.

Ao meu orientador, o Dr. Juan Martin Bravo, que me recebeu com a melhor predisposição e boa vontade desde o primeiro momento que pisei terra gaúcha, que me ajudou em todo momento na parte acadêmica como na parte humana, simplesmente uma grande pessoa e profissional. Pessoa digna de admirar. Juan: “Vamos los Pumas”

Aos meus amigos paraguaios: Federico González, Marcos Riquelme e David Diaz de Vivar, Gregorio Godoy e Marcos Ramirez, que sempre me apoiaram em todo momento que eu precisei, são grandes pessoas e de um coração imenso.

Ao colega Mino Sorribas, quem me recebeu em Porto Alegre sem me conhecer e me deu uma atenção digna de admirar, os meus colegas do “cafofo”, que sempre foram boa companhia em todos os sentidos, a minha “hermana gaúcha” Juliana Kaiber, que sempre foi um apoio e por ser uma pessoa de confiança para todo. Meu colega Leonardo Monteiro e minha amiga Patrícia Martin, duas grandes pessoas com quem vivi momentos incríveis, duas pessoas integras e legais.

Aos amigos paraguaios residentes Federico Monte Domecq e Margarita Pereira, que me apoiaram sempre, mais ainda no momento mais difícil, eles estiveram ai.

Ao professor David de Motta Marques, por me abrir as portas da sala de modelagem ecológica, conhecida carinhosamente como o “cafofo”, pois graças a minha presença ai consegui ganhar tanto no lado acadêmico como no humano.

Agradecimento especial ao meu prezado colega Rafael Cavalcanti, que sempre me apoiou em todo momento e me abriu as portas da casa para eu poder concluir esta dissertação. Graças a este acontecimento conheci a Eugenio Bastos e Almir Nunes, duas pessoas maravilhosas.

A professora Beatriz Camaño, por toda a ajuda brindada antes e durante o mestrado, obrigado pela paciência de sempre professora.

Ao IPH, por me dar essa imensurável educação e um excelente plantel de professores, que são todos muito capazes, aos meus professores da UCA, Julián Báez, Lisa Lugo e Fabiola Adam, pelo apoio durante a graduação e a pós.

A Bibiana Colossi pela revisão e correção do português, muito obrigado.

Ao CNPq, pela bolsa de estudos, essencial para concluir este curso e esta dissertação.

A todo o rugby gaúcho. Pessoas que quero destacar: Danilo Tomasi, Mateus Gobatto, João Giacomello, Luis Francisco Flores, Moisés Cavalleri, Martin Castillo, Marcelo Poletto e Daniel Mendez. E ao meu grande parceiro e amigo, um agradecimento especial: Jardel Vettorato.

# RESUMO

É amplamente conhecida a crescente utilização de modelos hidrológicos com o fim de representar simplificadamente os complexos processos do ciclo hidrológico em bacias hidrográficas. O ajuste destes modelos passa por uma etapa de calibração onde os valores de seus parâmetros são definidos.

Novas ferramentas de otimização vem sendo desenvolvidas com o passar do tempo e surge a necessidade de avaliar seu desempenho na calibração automática de modelos hidrológicos que utilizamos no dia-a-dia como, por exemplo, o IPH II. Nesse contexto, nessa pesquisa foi desenvolvido um algoritmo baseado no comportamento de colônias de formigas, denominado ACO-IPH. Os algoritmos baseados no comportamento de colônia de formigas, desde a sua concepção foram projetados para fins de otimização e testados, até a atualidade, em diversas aplicações, onde apresentaram desempenhos aceitáveis, embora as aplicações na calibração de modelos hidrológicos sejam escassas.

O algoritmo ACO-IPH foi inicialmente testado em funções matemáticas com ótimos conhecidos apresentando um bom desempenho em termos de eficiência e eficácia. Posteriormente foi acoplado ao modelo hidrológico IPH II como uma alternativa na calibração automática mono-objetivo e verificado seu desempenho e as simplificações e limitações de sua utilização. Uma vez acoplado, o algoritmo foi testado na calibração automática do modelo IPH II utilizando uma série sintética de vazões e, posteriormente, utilizando séries reais de vazões em quatro bacias hidrográficas. O desempenho do algoritmo foi avaliado em termos de eficácia e eficiência, para três diferentes funções-objetivo e utilizando como critério de comparação o algoritmo SCE-UA.

Os diferentes testes executados na calibração automática do modelo hidrológico IPH II mostraram que o ACO-IPH consegue encontrar boas soluções, porém não consegue apresentar um desempenho, em termos de eficiência e eficácia, comparável a algoritmos do estado da arte atual, como o algoritmo SCE-UA. A perda de eficiência do ACO-IPH em comparação ao SCE-UA é a mais importante, podendo demorar, em média, até 10 vezes mais até a convergência.

# ABSTRACT

It is widely known the increasing use of hydrologic models in order to represent the complex processes of the hydrological cycle in watersheds. To adjust these models a calibration step is necessary, where the values of its parameters are defined.

New optimization tools have been recently developed that could be used for the automatic calibration of hydrologic models as the IPH II. In this study an algorithm was developed based on the behavior of ant colonies, named ACO-IPH. Since its conception, the mathematical algorithms based on ants foraging behavior were designed for optimization purposes and tested, until today, in several applications, where it showed acceptable performance, although the applications for the calibration of hydrologic models are scarce.

The ACO-IPH algorithm was initially tested on mathematical functions where the global optimum was known showing a good performance in terms of efficiency and effectiveness. Then it was coupled to the hydrologic model IPH II as an alternative for the single-objective automatic calibration. Several indices were estimated to assess the ACO-IPH performance after analyzing the simplifications and limitations of its use. Once coupled to the IPH II model, the algorithm was tested in the calibration processes using synthetic streamflow series and later using real series of observed streamflows in four watersheds. The algorithm's performance was assessed in terms of effectiveness and efficiency for three different objective functions and using as a basis of comparison the SCE-UA algorithm.

The different tests performed in automatic calibration of hydrological model IPH II showed that ACO-IPH can find good solutions, but cannot reach the efficiency and effectiveness of other evolutionary algorithms like the SCE-UA. The loss of effectiveness of ACO-IPH compared to the SCE-UA is the most relevant. The ACO-IPH took, on average, 10 times longer to convergence.

# SUMÁRIO

<b>1-</b>	<b>INTRODUÇÃO .....</b>	<b>17</b>
1.1-	Justificativa da pesquisa .....	18
1.2-	Objetivo principal .....	19
1.3-	Organização do trabalho .....	19
<b>2-</b>	<b>MODELOS HIDROLÓGICOS.....</b>	<b>20</b>
2.1-	Tipos de modelos .....	20
2.2-	Usos de modelos hidrológicos .....	21
2.3-	Modelo IPH II / WIN_IPH2 .....	23
2.4-	Calibração de modelos hidrológicos .....	27
2.4.1-	Calibração manual.....	27
2.4.2-	Calibração automática .....	27
<b>3-</b>	<b>ALGORITMOS EVOLUCIONARIOS .....</b>	<b>31</b>
3.1-	Algoritmo genético puro .....	33
3.2-	SCE – UA .....	34
3.3-	Algoritmos baseados no comportamento de colônia de formigas .....	38
3.3.1-	Sustento biológico do método.....	40
3.3.2-	ACO desde uma perspectiva computacional .....	41
3.3.3-	Tipos principais de ACO e algumas aplicações .....	42
<b>4 -</b>	<b>METODOLOGIA.....</b>	<b>58</b>
4.1-	Algoritmo ACO-IPH.....	58
4.2-	Testes em funções matemáticas com ótimos conhecidos.....	64
4.3-	Acoplamento do ACO-IPH ao modelo hidrológico IPH-II .....	66
4.4-	Calibração automática de modelo hidrológico.....	68
4.4.1-	Estudos de casos .....	68
4.4.2-	Funções-objetivo .....	70
4.4.3-	Calibração automática com série sintética de vazões.....	70
4.4.4-	Calibração automática com série real de vazões.....	71
4.5-	Medidas de eficiência e eficácia do algoritmo.....	71

<b>5-</b>	<b>RESULTADOS E DISCUSSÃO.....</b>	<b>73</b>
5.1-	Avaliação de desempenho em funções matemáticas .....	73
5.2-	Avaliação de desempenho na calibração automática de modelo hidrológico.....	80
5.2.1-	Considerando série sintética de vazões .....	80
5.2.2-	Considerando séries reais de vazões .....	87
<b>6-</b>	<b>CONCLUSÕES E RECOMENDAÇÕES .....</b>	<b>124</b>
6.1-	Aspectos gerais .....	124
6.2-	Recomendações.....	125
<b>7-</b>	<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>127</b>

# LISTA DE FIGURAS

Figura 1. Discretização espacial de bacias (Tucci, 2005).....	21
Figura 2. Fluxograma geral da metodologia de ajuste de um modelo hidrológico. Adaptado de Wagener <i>et al.</i> (2004).....	23
Figura 3. Fluxograma simplificado do programa IPH II.....	26
Figura 4. Superfície de resposta para uma função com dois parâmetros.....	28
Figura 5. Região de Pareto para calibração automática multi-objetivo para duas FO. ....	30
Figura 6. Fluxograma de um AE genérico.....	32
Figura 7. Fluxograma de um algoritmo genético puro. ....	34
Figura 8. Métodos de geração de novos indivíduos por reflexão (a) e contração (b).....	37
Figura 9. Fluxograma do algoritmo SCE – UA. ....	39
Figura 10. Comportamento biológico exploratório de uma colônia de formigas. Adaptado de Dorigo <i>et al.</i> (1996). ....	41
Figura 11. Exemplo de inicialização com quatro nós e os possíveis links. Dorigo <i>et al.</i> (2006) ....	44
Figura 12. Fluxograma do algoritmo AS.....	45
Figura 13. Fluxograma do algoritmo ACS. ....	48
Figura 14. Fluxograma do algoritmo MMAS.....	51
Figura 15. Estratificação do espaço de busca no algoritmo ACO-IM.....	52
Figura 16. Posicionamento inicial aleatório das formigas nos centros dos estratos da primeira variável.....	53
Figura 17. Ilustração do comportamento da FO crítica. Adaptado de Abbaspour <i>et al.</i> (2001). ....	54
Figura 18. Fluxograma do algoritmo ACO-IM.....	56
<b>Figura 19.</b> Funcionamento da rotina de refinamento do ACO-IPH.....	61
Figura 20. Fluxograma do algoritmo ACO-IPH.....	63
Figura 21. Gráfico tridimensional da função de Hosaki. ....	64
Figura 22. Gráfico tridimensional da função de Schaffer. ....	65
Figura 23. Fluxograma do acoplamento do algoritmo ACO-IPH ao modelo IPH-II. ....	67
Figura 24. Bacia do Rio Tesouras – GO .....	69
Figura 25. Bacia do Rio Canoas – SC.....	69

Figura 26. Bacia do Rio Itu – RS.....	69
Figura 27. Bacia do Rio Preto – BA.....	69
Figura 28. Percentagem de convergência do algoritmo ACO-IM e ACO-IPH na função de Hosaki. .....	74
Figura 29. Tempo de convergência do algoritmo ACO-IM e ACO-IPH na função de Hosaki.....	75
Figura 30. Percentagem de falhas dos algoritmos ACO-IM e ACO-IPH na função de Hosaki.....	75
Figura 31. Ciclo de convergência do algoritmo ACO-IM e ACO-IPH na função de Hosaki.....	75
Figura 32. Formigas com valor de FO de convergência para a função de Hosaki.....	76
Figura 33. Percentagem de convergência dos algoritmos ACO-IM e ACO-IPH na função de Schaffer.....	78
Figura 34. Tempo de convergência dos algoritmos ACO-IM e ACO-IPH na função de Schaffer...	78
Figura 35. Percentagem de falhas dos algoritmos ACO-IM e ACO-IPH na função de Schaffer.....	79
Figura 36. Ciclo de convergência dos algoritmos ACO-IM e ACO-IPH na função de Schaffer. ....	79
Figura 37. Formigas com valor de FO de convergência nos algoritmos ACO-IM e ACO-IPH para a função de Schaffer. ....	79
Figura 38. Convergência na série sintética de vazões com os algoritmos ACO-IPH e SCE-UA....	82
Figura 39. Tempo de convergência na série sintética de vazões com os algoritmos ACO-IPH e SCE-UA.....	83
Figura 40. Ciclos de convergência na série sintética de vazões com os algoritmos ACO-IPH e SCE-UA.....	84
Figura 41. População com valor de FO de convergência na série sintética de vazões com os algoritmos ACO-IPH e SCE-UA.....	85
Figura 42. Convergência da função KGE nas quatro bacias analisadas. ....	89
Figura 43. Convergência da função NS nas quatro bacias analisadas.....	90
Figura 44. Convergência para a função IQ nas quatro bacias analisadas.....	91
<b>Figura 45.</b> Tempo de convergência para a função KGE nas quatro bacias analisadas. ....	92
Figura 46. Tempo de convergência da função NS nas quatro bacias analisadas.....	93
Figura 47. Tempo de convergência para a função IQ nas quatro bacias analisadas.....	94
<b>Figura 48.</b> Ciclos de convergência para a função KGE nas quatro bacias analisadas.....	95
Figura 49. Ciclos de convergência para a função NS nas quatro bacias analisadas.....	96
Figura 50. Ciclos de convergência para a função IQ nas quatro bacias analisadas.....	97

Figura 51. População com valor de FO de convergência para a função KGE nas quatro bacias analisadas. ....	98
Figura 52. População com valor de FO de convergência para a função NS nas quatro bacias analisadas. ....	99
Figura 53. População com valor de FO de convergência para a função IQ nas quatro bacias analisadas. ....	100
Figura 54. Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função KGE – Rio Tesouras. ....	104
Figura 55. Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função KGE – Rio Preto. ....	105
Figura 56. Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função KGE – Rio Itú. ....	106
Figura 57. Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função KGE – Rio Canoas. ....	107
Figura 58. Curvas de permanência das vazões simuladas das quatro bacias analisadas para FO = KGE. a) Bacia do Rio Tesouras; b) Bacia do Rio Preto; c) Bacia do Rio Itú; d) Bacia do Rio Canoas. ....	108
Figura 59. Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função NS – Rio Tesouras. ....	112
Figura 60. Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função NS – Rio Preto. ....	113
Figura 61. Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função NS – Rio Itú. ....	114
Figura 62. Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função NS – Rio Canoas. ....	115
Figura 63. Curvas de permanência das vazões simuladas das quatro bacias analisadas para FO = NS. ....	116
Figura 64. Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função IQ – Rio Tesouras. ....	119
Figura 65. Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função IQ – Rio Preto. ....	120
Figura 66. Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função IQ – Rio Itú. ....	121

Figura 67. Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função IQ – Rio Canoas..... 122

Figura 68. Curvas de permanência das vazões simuladas das quatro bacias analisadas para FO = IQ. .... 123

# LISTA DE TABELAS

Tabela 1. Atualização automática e efeito da FO crítica.....	55
Tabela 2. Bacias utilizadas na calibração automática com o algoritmo ACO-IPH. Fonte: Hidroweb. .....	68
Tabela 3. Valores iniciais dos parâmetros do algoritmo ACO-IPH na função de Hosaki.....	73
Tabela 4. Valores iniciais dos parâmetros do algoritmo ACO-IPH na função de Schaffer. ....	77
Tabela 5. Limites mínimo e máximo dos parâmetros do modelo IPH II para calibração automática. .....	80
Tabela 6. Valores iniciais dos parâmetros do algoritmo ACO-IPH para a série sintética. ....	81
Tabela 7. Resultados da calibração da série sintética para KGE em MH concentrado .....	86
Tabela 8. Resultados da calibração da série sintética para NS em MH concentrado. ....	86
Tabela 9. Resultados da calibração da série sintética para IQ em MH concentrado. ....	87
Tabela 10. Valores iniciais dos parâmetros do algoritmo ACO-IPH para a série real. ....	88
Tabela 11. Resultados obtidos para KGE e parâmetros do IPH-II nas quatro bacias analisadas.	103
Tabela 12. Resultados obtidos para NS e parâmetros do IPH-II nas quatro bacias analisadas...	111
Tabela 13. Resultados obtidos para IQ e parâmetros do IPH-II nas quatro bacias analisadas....	118

# LISTA DE SÍMBOLOS

ACO: algoritmo baseado em colônia de formigas

AE: algoritmo evolucionário

AS: sistema de formigas (do inglês Ant System)

ACS: sistema de colônia de formigas

TSP: problema do caixeiro viajante

AGP: algoritmo genético puro

AG: algoritmo genético

SCE-UA: algoritmo de evolução de complexos misturados

MOCOM-UA: algoritmo de evolução complexa multi-objetivo

MOSCEM-UA: algoritmo de evolução complexa multi-objetivo metrópoles

ARS: busca aleatória adaptativa

URS: busca aleatória uniforme

IPH II: modelo hidrológico concentrado desenvolvido no Instituto de Pesquisas Hidráulicas

WIN\_IPH2: programa com interface visual do modelo IPH II

SHE: sistema hidrológico europeu

HTA: histograma tempo-área

$R_{max}$ : capacidade de armazenamento máximo em um reservatório de perdas

$I_0$ : taxa de infiltração no momento em que é atingida a saturação superficial e começa a haver escoamento

$I_b$ : condutividade hidráulica aparente do solo a

$k$ : parâmetro empírico do modelo IPH II relacionado ao tipo de solo

$t_c$ : tempo de concentração

$K_s$ : tempo de retardo do escoamento superficial, do método reservatório linear simples

$A_{imp}$ : percentagem de área impermeável de uma bacia hidrográfica

$K_{sub}$ : tempo médio de esvaziamento do reservatório de escoamento subterrâneo, do método reservatório linear simples

MMAS: algoritmo máximo-mínimo de colônia de formigas

MACO: algoritmo de múltipla colônia de formigas

ACS/GA: algoritmo híbrido sistema de colônia de formigas com algoritmo genético

AntNet: algoritmo de rede de formigas

CACO: algoritmo de otimização contínua de colônia de formigas

Beam-ACO: algoritmo híbrido baseado em colônia de formigas com colônia de abelhas

ACO-Simplex: algoritmo híbrido baseado em colônia de formigas com método Simplex

P: precipitação

E: evapotranspiração

EP: evapotranspiração potencial

ER: evapotranspiração real

R: armazenamento do reservatório de perdas

a: parâmetro do programa IPH II

b: parâmetro do programa IPH II

T: percolação

Ves: escoamento superficial

Imp: percentagem de área impermeável da bacia analisada

I: capacidade de infiltração

Ve: volume de escoamento superficial

Vi: volume infiltrado

Vp: volume percolado

$\Delta t$ : intervalo de tempo

Qsup: vazão superficial

Qsub: vazão subterrânea

Qt: vazão total

CIAC: iteração contínua de colônia de formigas

P: posição da formiga em cada iteração no AS

$\tau$ : intensidade de feromônio

$\eta$ : parâmetro relacionado à visão de cada formiga

$\rho$ : parâmetro de evaporação do feromônio

Q: parâmetro constante para o cálculo da evaporação de feromônio

$L_k$ : comprimento de cada laço que será explorado por cada formiga

s: posição da formiga em cada iteração no ACS

J: conjunto de nós não visitados pela k-ésima formiga

q: valor aleatório com distribuição uniforme entre (0,1)

W: Caminho mais curto escolhido pelas formigas

$\alpha, \beta$ : Parâmetros dos algoritmos AS, ACS, MMAS

$\tau_{max}$ : Quantidade máxima de feromônio admitida no MMAS

$\tau_{min}$ : Quantidade mínima de feromônio admitida no MMAS

$\gamma$ : Parâmetro do MMAS, cuja faixa de variação é de  $0 < \gamma < 0.5$ .

ACO-IM: algoritmo baseado em colônia de formigas para a simulação de de infiltração em solo não saturado.

ACO-IPH: modelo baseado em colônia de formigas desenvolvido neste trabalho e aplicado a calibração automática no modelo hidrológico IPH II.

KGE: coeficiente de eficiência de Kling-Gupta (2009)

ED: distancia euclidiana entre até o ponto ideal na fórmula KGE

NS: coeficiente de eficiência de Nash-Sutcliffe (1970)

IQ: inverso das vazões.

SCR: solução candidata de reflexão do algoritmo SCE-UA

SCC: solução candidata de contração do algoritmo SCE-UA

SCP: solução candidata pior do algoritmo SCE-UA

SCA: solução candidata aleatória do algoritmo SCE-UA

S: score que serve de base para o posicionamento a partir do segundo ciclo no algoritmo ACO-IM e ACO-IPH

FH: função de Hosaki

FS: função de Schaffer

FO: função-objetivo

# 1- INTRODUÇÃO

A modelagem hidrológica visa representar, de forma simplificada, os complexos processos do ciclo hidrológico. Entre os modelos hidrológicos, os mais utilizados são os modelos chuva-vazão. Estes modelos possuem parâmetros que devem ser calibrados com o objetivo de conseguir uma representação do comportamento hidrológico de uma bacia hidrográfica o mais próximo da realidade.

Os modelos chuva-vazão consideram a bacia hidrográfica como um sistema sobre o qual um conjunto de entradas incide produzindo um conjunto de saídas como resposta. Assim, estes modelos tipicamente recebem como entrada informações de precipitação e clima e produzem como resultados as vazões nos locais de interesse.

O ajuste de um modelo chuva-vazão envolve buscar que as vazões simuladas se aproximem dos valores observados, e nesse sentido, as etapas de calibração e verificação são executadas. Durante a calibração, que pode ser manual ou automática, os valores dos parâmetros que governam as equações matemáticas utilizadas pelos modelos são modificados buscando uma boa concordância entre vazões simuladas e observadas ao longo de um período de tempo. Posteriormente, a verificação do modelo utiliza os valores dos parâmetros definidos na etapa anterior para produzir resultados para um período diferente ao utilizado na calibração e verificar se o desempenho do modelo é mantido.

Na calibração manual, que consiste basicamente em aproximar o resultado calculado ao observado alterando manualmente os valores dos parâmetros, o usuário vai ganhando maior familiaridade com os parâmetros. Porém, essa técnica consome mais tempo e quando aplicada por usuários inexperientes ou a modelos com grande número de parâmetros, pode resultar em uma tarefa longa e tediosa. Na calibração automática um procedimento matemático é o responsável por alterar os valores dos parâmetros com o objetivo de aproximar os valores das vazões calculadas ao das vazões observadas. Nesse caso existe a vantagem de o processo demorar muito menos, mas o resultado é dependente do procedimento adotado e do conhecimento dos limites aceitáveis de variação dos valores dos parâmetros.

Existem diferentes metodologias que podem ser utilizadas na etapa de calibração automática, entre as quais destacam-se os algoritmos heurísticos. O termo heurístico foi definido por Newell *et al.*(1963) como um processo que pode encontrar uma solução para um problema dado mas que não garante encontrar a solução ótima e que não possui limite formal de qualidade, sendo avaliado tipicamente por métodos empíricos. Os algoritmos heurísticos são capazes de resolver diversos problemas de otimização, com bons resultados, devido a sua adaptabilidade, estabilidade e capacidade de trabalhar com implementações paralelas (e.g.

Duan *et al.*, 1992; Dorigo *et al.*, 1996; Dorigo *et al.*, 1997, Jalali *et al.*, 2007). Como integrantes desta família, os algoritmos baseados no comportamento de colônia de formigas (ACO, sigla em inglês referida a *Ant Colony Optimization*), utilizados neste trabalho, apresentam as vantagens descritas anteriormente.

Entre os algoritmos heurísticos pode ser citado o conjunto de algoritmos evolucionários, dentre os quais destacam-se o algoritmo genético puro (AGP; Goldberg, 1989), SCE-UA (Duan *et al.* 1992), MOCOM-UA (Yapo *et al.* 1998), MOSCEM-UA (Vrugt *et al.* 2003). Outros algoritmos heurísticos são: o algoritmo de busca aleatória adaptativo (ARS; Masri *et al.*, 1978), o algoritmo de busca aleatória uniforme (URS; Duan *et al.*, 1992), o algoritmo Simplex (Nelder e Mead, 1965). Mais recentemente, novos algoritmos heurísticos têm sido desenvolvidos com base em inteligência coletiva com bons resultados em diferentes áreas como, por exemplo, o ACO, que apresentou bons resultados em diferentes aplicações (e.g. problema do caixeiro viajante (Dorigo *et al.*, 1996), projeto de redes pluviais (Afshar, 2006), traçado de obras lineares (Bravo *et al.*, 2008), operação de reservatório com múltiplos usos (Kumar *et al.*, 2006)). As aplicações do ACO em calibração automática de modelos hidrológicos são reduzidas. Apenas um trabalho foi encontrado na literatura onde foi feita a estimativa dos parâmetros de um modelo de propagação em meio não saturado (Abbaspour *et al.*, 2001).

Em função do previamente apresentado existe uma demanda pelo contínuo aprimoramento do processo de calibração de modelos chuva-vazão com a implementação de novas metodologias.

### **1.1- Justificativa da pesquisa**

O ajuste de um modelo matemático requer uma etapa de calibração onde são estimados os valores dos parâmetros. Os modelos matemáticos utilizados na simulação hidrológica não representam uma exceção e durante a calibração são utilizados diferentes métodos de otimização para ajuste dos parâmetros.

Devido ao constante desenvolvimento de novas ferramentas utilizadas em processos de otimização, é apropriado avaliar o desempenho destas na calibração automática do modelo IPH II, contribuindo para o contínuo aprimoramento do programa WIN\_IPH2. O WIN\_IPH2 é um programa com fins educacionais que acopla o IPH II a algoritmos evolucionários, os quais apesar de apresentarem bom desempenho no processo de calibração automática, foram desenvolvidos há 30 anos.

O algoritmo ACO tem demonstrado bom desempenho na resolução de problemas de diversas áreas e por isto se apresenta como uma alternativa interessante a ser testada, embora especificamente na calibração automática de modelos hidrológicos sejam escassas as aplicações.

Além disso, o formato das superfícies de respostas de diferentes medidas de desempenho utilizadas na calibração do modelo IPH II, onde foi observada a presença de um grande número de boas soluções circundadas por soluções ruins, permite imaginar que um algoritmo baseado na estratificação dos valores dos parâmetros possa apresentar um desempenho favorável.

## **1.2- Objetivo principal**

O objetivo principal dessa pesquisa é investigar a aplicabilidade de um algoritmo baseado no comportamento de colônias de formigas na calibração automática de modelos chuva-vazão concentrados. Como forma de alcançar tal objetivo, propõe-se responder as seguintes perguntas:

- O algoritmo ACO consegue desempenho aceitável na calibração automática do modelo hidrológico com eficácia e eficiência?
- Quais as limitações da sua utilização?
- Existe alguma vantagem na utilização do ACO em relação aos algoritmos que se enquadram no estado da arte da calibração de modelos hidrológicos (e.g. SCE-UA)?

## **1.3- Organização do trabalho**

O trabalho foi dividido em cinco etapas que são descritas brevemente a seguir:

- Uma revisão bibliográfica (capítulo 2) sobre modelos hidrológicos, tipos e usos de modelos, calibração de modelos hidrológicos, calibração manual e automática, calibração automática mono-objetivo e multi-objetivo;
- Uma breve discussão do estado da arte em relação a algoritmos evolucionários, apresentando a descrição de um algoritmo genético puro, o algoritmo SCE-UA e o algoritmo baseado no comportamento de colônias de formigas (ACO) no capítulo 3;
- A metodologia utilizada neste trabalho (capítulo 4), onde é explicado como foi desenvolvido o algoritmo ACO-IPH e os diferentes testes executados com base no uso de funções matemáticas com ótimos conhecidos e, posteriormente, o acoplamento ao modelo chuva-vazão para a calibração automática utilizando séries sintéticas de vazões ou séries reais de vazões;

- Os resultados e as discussões dos diferentes estudos de caso: utilização nas funções matemáticas, na série sintética e nas séries reais de vazões (capítulo 5);

Finalmente, as conclusões e recomendações são apresentadas no capítulo 6.

## **2- MODELOS HIDROLÓGICOS**

Segundo Tucci (2005), os modelos são a representação de algum objeto ou sistema em uma linguagem ou forma de fácil acesso ou uso, com o objetivo de entendê-lo e buscar respostas para diferentes entradas.

Um modelo hidrológico representa, de forma simplificada, os complexos processos do ciclo hidrológico dentro de uma área delimitada, chamada de bacia hidrográfica. Os modelos hidrológicos simulam um sistema através de equações matemáticas, com dados de entrada relativos a variáveis hidrológicas e como elas se comportam dentro da bacia hidrográfica, e devolvendo como saída um resultado. No caso de modelos chuva-vazão, os dados de entrada são os dados climáticos e das características da bacia, e como saída temos, tipicamente, a série de vazões (Ponce, 1989).

### **2.1- Tipos de modelos**

Os modelos hidrológicos podem ser classificados com base em: descrição dos processos, discretização espacial, fundamentação teórica, tratamento estatístico e extensão temporal (Tucci, 2005).

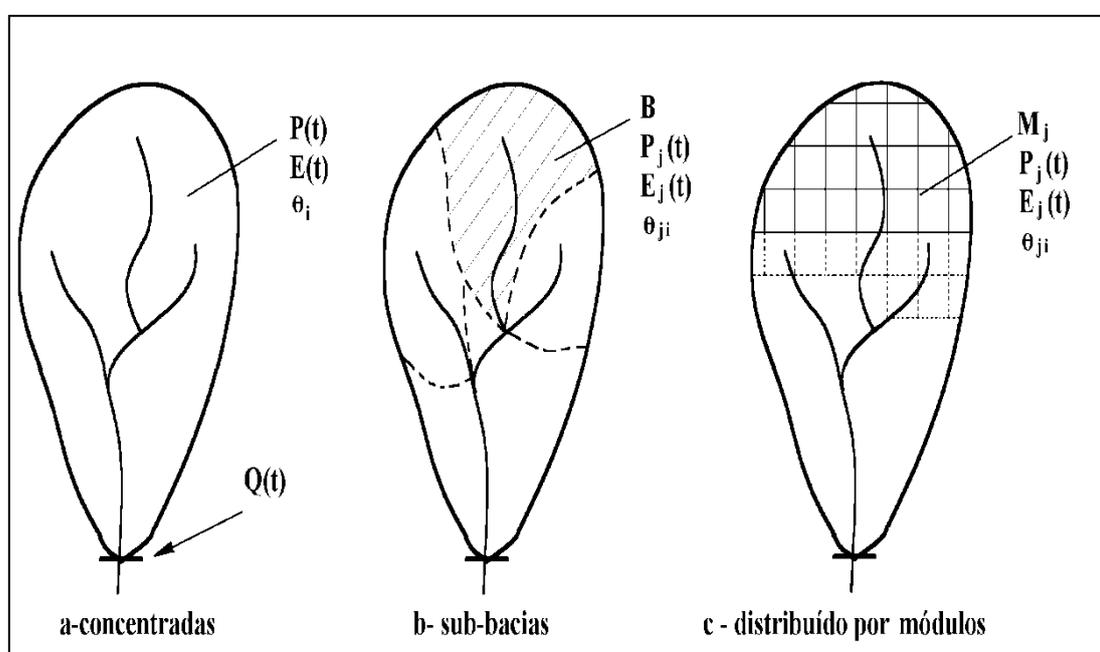
Em relação à descrição dos processos se encontram os seguintes tipos de modelo: (1) Orientados por dados, que são modelos nos quais o mais importante é a entrada e a saída, como por exemplo, um modelo do tipo “caixa preta”; (2) Orientados por processos, onde, além das entradas e as saídas, os processos intermediários pelos quais passam os dados de entrada são descritos com detalhe. Um exemplo de modelo detalhado é o SHE (Sistema Hidrológico Europeu); e (3) Intermediários, nos quais alguns processos são descritos com bom grau de detalhe e outros são mais simplificados. A maioria dos modelos do tipo chuva-vazão pertence a esta categoria, por exemplo, o IPH II, Topmodel, Stanford, etc.

Baseado no critério da fundamentação teórica, os modelos podem ser Conceituais ou Empíricos. Nos modelos conceituais as funções utilizadas na sua elaboração levam em conta os processos físicos, e os modelos empíricos são aqueles que ajustam os valores calculados aos valores observados sem relação nenhuma aos processos físicos envolvidos (Tucci, 2005).

Com relação à inclusão do conceito de probabilidade, os modelos são classificados em Estocásticos ou Determinísticos. Um modelo é dito de estocástico quando o conceito de

probabilidade é introduzido, e a chance de ocorrência das variáveis é levada em conta. Quando um modelo segue uma lei definida, diferente da lei de probabilidades, ignorando a chance de ocorrência dos eventos, ele é dito determinístico (Chow, 1964).

Por fim, com base na discretização espacial da unidade de análise, a bacia hidrográfica, os modelos podem ser divididos em Concentrados e Distribuídos (Figura 1). Um modelo é chamado de concentrado quando não leva em conta a variabilidade espacial (Figura1–a). A precipitação média de uma bacia é um exemplo da integração espacial da variável de entrada. Em geral, os modelos concentrados utilizam somente o tempo como variável independente. Nos modelos distribuídos, as variáveis e parâmetros do modelo dependem do espaço e do tempo. O modelo distribuído pode ser discretizado em: módulos (Figura1–c), quando a bacia é subdividida em células de igual tamanho, sendo a célula a menor unidade a ser analisada, ou sub-bacias (Figura1–b), se a bacia for subdividida em sub-bacias menores, onde cada sub-bacia resulta a menor unidade a ser analisada.

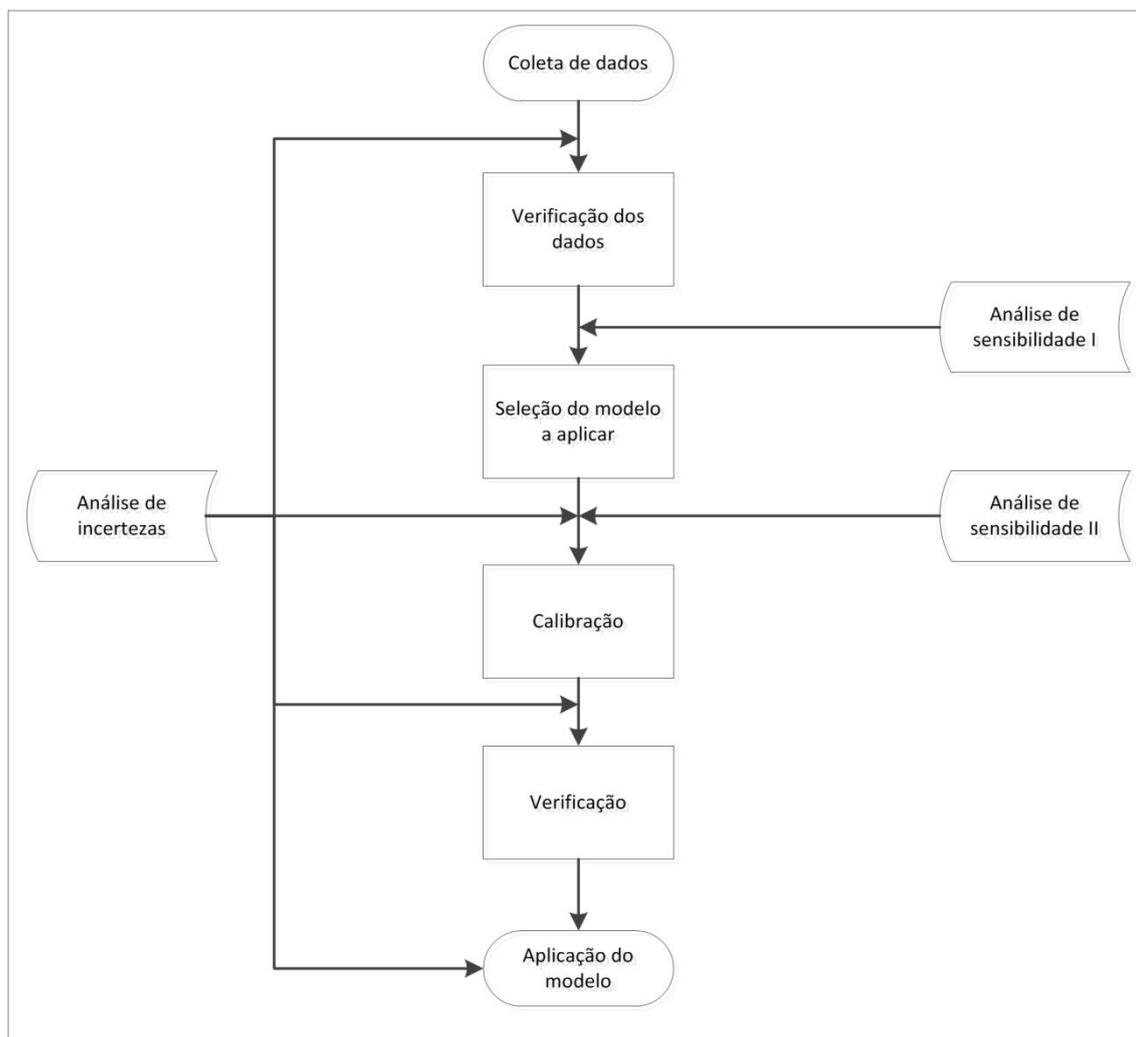


**Figura 1.** Discretização espacial de bacias (Tucci, 2005).

## 2.2- Usos de modelos hidrológicos

Entre os usos mais comuns dos modelos hidrológicos podem ser citados o preenchimento de falhas em séries de vazões, a avaliação do impacto das mudanças climáticas, simulação de qualidade da água, simulação no transporte de sedimentos, geração de eventos de projeto utilizados no dimensionamento de obras hidráulicas, previsão de vazão em tempo real, incorporação a modelos atmosféricos, modelagem ecológica, dimensionamento de redes de abastecimento urbano e redes de esgoto, dimensionamento de reservatórios e barragens (utilizadas para geração de energia elétrica, irrigação, abastecimento de água, controle de cheias, entre outros) e gerenciamento de recursos hídricos.

Para utilizar um modelo hidrológico nos diferentes processos citados é necessária uma etapa fundamental que consiste no ajuste. Em geral, podemos resumir que para realizar o ajuste de um modelo hidrológico, se conta com os seguintes passos (Figura 2): 1) Coleta, análise e formatação dos dados de entrada, onde os dados coletados são preparados e formatados como para que sejam utilizados pelo modelo; 2) Verificação dos dados de entrada no modelo, para que eles sejam introduzidos e processados no modelo escolhido; 3) Seleção do modelo a aplicar, e geração de um primeiro resultado de saída a ser comparado com os dados observados; 4) Calibração, onde por meio de algoritmos específicos se procura aproximar os valores calculados aos valores observados em um período de simulação, ajustando os valores dos parâmetros do modelo; 5) Verificação ou validação, onde se analisam os resultados em um período de tempo diferente ao utilizado na calibração, e se verifica se o modelo mantém o desempenho obtido na calibração; 6) Aplicação do modelo e geração do segundo resultado de saída, onde os dados observados são comparados com os resultados gerados, sendo este um processo iterativo.



**Figura 2.** Fluxograma geral da metodologia de ajuste de um modelo hidrológico. Adaptado de Wagener *et al.* (2004).

### 2.3- Modelo IPH II / WIN\_IPH2

O modelo IPH II é empregado como estudo de caso neste trabalho e por isto é apresentado em detalhe a seguir. O IPH II é um modelo hidrológico chuva-vazão do tipo concentrado, desenvolvido no Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul.

Conforme Tucci (1998), o modelo IPH II é baseado no algoritmo de separação do escoamento desenvolvido por Berthelot (1970), que utilizou a equação da continuidade combinada com a equação de infiltração de Horton e uma função empírica para a percolação. Berthelot *et al.* (1972), Sanchez (1972) e Muñoz e Tucci (1974) utilizaram este algoritmo para compor um modelo chuva-vazão. Posteriormente, Tucci *et al.* (1981) utilizaram o referido algoritmo em conjunto com outros (perdas, escoamento superficial e subterrâneo) e implementaram o modelo IPH II. Finalmente, Tucci e Campana (1993) ampliaram o uso do

modelo IPH II através de modificações na estrutura do algoritmo de escoamento superficial. O modelo IPH II tem sido aplicado, desde então, a diversas bacias brasileiras na simulação de séries contínuas e eventos isolados, apresentando bons resultados.

Na última década, foi desenvolvido o programa WIN\_IPH2 (Bravo *et al.*, 2006a) que acoplou o modelo IPH II para simulação de séries contínuas e eventos isolados a dois algoritmos de otimização. Essa nova versão apresenta uma interface mais amigável, integralmente programada como uma aplicação *QuickWin* de Visual Fortran. Assim, o novo modelo tem características do ambiente Windows e uma saída gráfica de resultados.

O programa WIN\_IPH2 foi concebido para facilitar a calibração do modelo IPH II aplicado a séries contínuas ou eventos isolados. Opções de calibração manual e automática encontram-se disponíveis no programa. Quando o programa é utilizado no modo de calibração manual, o usuário altera os valores dos parâmetros até que o resultado obtido seja considerado satisfatório na comparação visual entre os hidrograma observados e calculados apresentados pela interface do programa. No caso de calibração automática, o algoritmo SCE-UA (Duan *et al.*, 1992) é utilizado na calibração automática mono-objetivo, enquanto o algoritmo MOCOM-UA (Yapo *et al.*, 1998) é utilizado na calibração automática multi-objetivo. Dessa forma, no desenvolvimento do programa, foram incorporadas as versões em Fortran do algoritmo SCE-UA adaptada e testada por Collischonn e Tucci (2001) e do algoritmo MOCOM-UA adaptada e testada por Collischonn e Tucci (2003). Além da possibilidade de calibração de parâmetros, o programa WIN\_IPH2 pode ser utilizado simplesmente para simulação do modelo IPH II, com um conjunto de parâmetros previamente calibrado ou escolhido pelo usuário.

O modelo IPH II é composto dos seguintes algoritmos (Tucci, 1998; Tassi *et al.*, 2006): (1) perdas e interceptação; (2) separação do escoamento e (3) propagação do escoamento, conforme apresentados na Figura 3 e descritos brevemente à continuação.

Perdas por evaporação e interceptação: o algoritmo de perdas utiliza um único parâmetro ( $R_{max}$ ), que reflete a capacidade de armazenamento máximo em um reservatório hipotético de perdas.

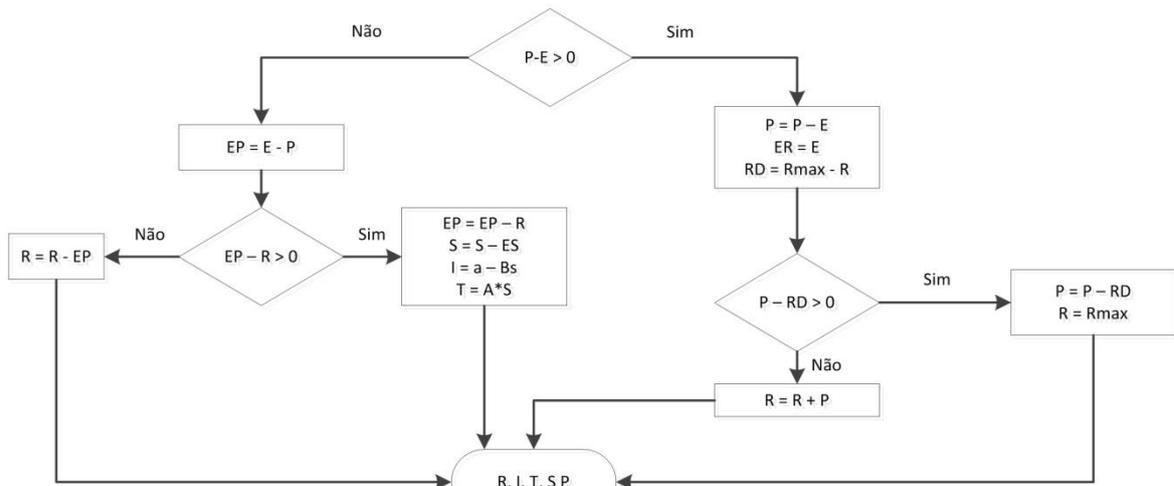
Separação do escoamento: o algoritmo de separação do escoamento utiliza os parâmetros  $I_0$ ,  $I_b$  e  $H$ , característicos da equação de infiltração de Horton. Os parâmetros  $I_0$  e  $I_b$  representam a taxa de infiltração quando o solo se encontra em capacidade de campo e quando o solo se encontra saturado, respectivamente, e  $h$  é igual a  $e^{-k}$ , sendo  $e$  a base dos logaritmos neperianos e  $k$  um parâmetro empírico relacionado ao tipo de solo.

Propagação do escoamento: a propagação do escoamento superficial no modelo é feita através do método de Clark, que representa uma combinação do histograma tempo-área (HTA) com um reservatório linear simples, sendo utilizado o parâmetro tempo de concentração ( $t_c$ ) e

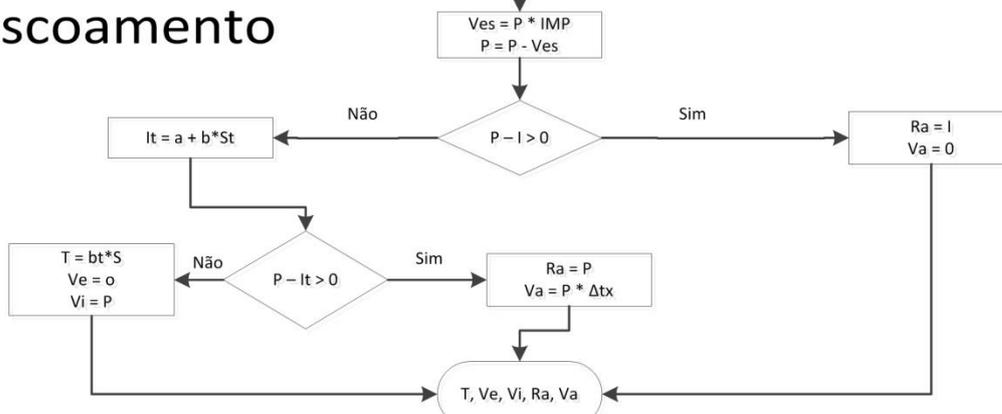
os parâmetros que definem um HTA sintético. Um HTA estimado pode ainda ser introduzido nos dados do modelo. Esses parâmetros podem ser calibrados ou mantidos fixos, de acordo com a disponibilidade de informações sobre as características físicas da bacia. Para a propagação do escoamento superficial é necessário definir também o percentual de área impermeável ( $A_{imp}$ ) na bacia hidrográfica, enquanto a propagação do escoamento subterrâneo é obtida pela aplicação do modelo reservatório linear simples. Dois parâmetros devem ser definidos na propagação do escoamento superficial e subterrâneo,  $K_s$  e  $K_{sub}$ , que representam o tempo médio de esvaziamento do reservatório de escoamento superficial e subterrâneo, respectivamente. O modelo IPH II foi originalmente desenvolvido para simulação de eventos, entretanto, para simulação de séries contínuas de longo período, os autores introduziram um parâmetro adicional denominado  $\alpha$ . Esse parâmetro participa do processo de separação do escoamento nos casos em que a precipitação é menor que a capacidade de infiltração.

Além dos parâmetros acima citados, para a simulação, devem ser informados: a área da bacia hidrográfica; intervalo de tempo dos dados; condição inicial; valores dos parâmetros e as séries temporais das variáveis de entrada, precipitação e evaporação. Maiores informações a respeito do modelo IPH II podem ser encontradas em Tucci (1998), Mine (1998), Villanueva *et al.* (2005) e Bravo *et al.* (2006b).

## Perdas



## Escoamento



## Propagação

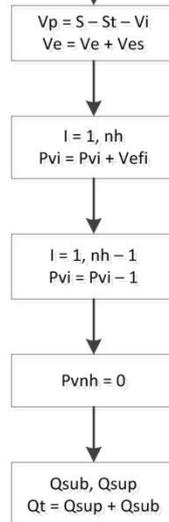


Figura 3. Fluxograma simplificado do programa IPH II.

## **2.4- Calibração de modelos hidrológicos**

A calibração de modelos hidrológicos consiste em encontrar o valor dos parâmetros do modelo que melhor ajuste os valores dos dados observados e calculados. Essa busca dos valores dos parâmetros pode ser feita mediante a calibração manual ou automática, que serão brevemente explicadas na continuação.

### **2.4.1- Calibração manual**

Na calibração manual o usuário altera manualmente os valores dos parâmetros de forma a aproximar os resultados do modelo aos valores observados da variável de saída. Este processo é iterativo até que o usuário do modelo considere que o ajuste obtido é adequado para o objetivo do uso do modelo. Nesse sentido, a calibração manual pode ser um processo muito lento, repetitivo e tedioso, especialmente quando o modelo utilizado tem um grande número de parâmetros e o usuário é inexperiente (Collischonn e Tucci, 2003). Isto acontece porque é difícil deduzir a lógica segundo a qual os parâmetros deveriam ser ajustados para melhorar a representação (Sorooshian e Gupta, 1995).

Uma das principais deficiências da calibração manual é a falta de um critério de comparação mensurável que considere todas as características analisadas visualmente, tornando difícil, dessa forma, saber quando interromper o processo de calibração (Sorooshian e Gupta, 1995). Além disso, o processo de calibração manual utiliza critérios subjetivos, assim, diferentes usuários do modelo podem obter um conjunto de parâmetros completamente diferente para uma mesma bacia.

Entre as vantagens da calibração manual, podemos mencionar que o usuário gera um grau de familiaridade com o programa e os parâmetros, através da experiência, tornando às vezes muito mais eficaz o processo de calibração. Além disso, a calibração manual tende a realizar um ajuste dos parâmetros de forma que estes sejam mais representativos da realidade física do processo simulado.

### **2.4.2- Calibração automática**

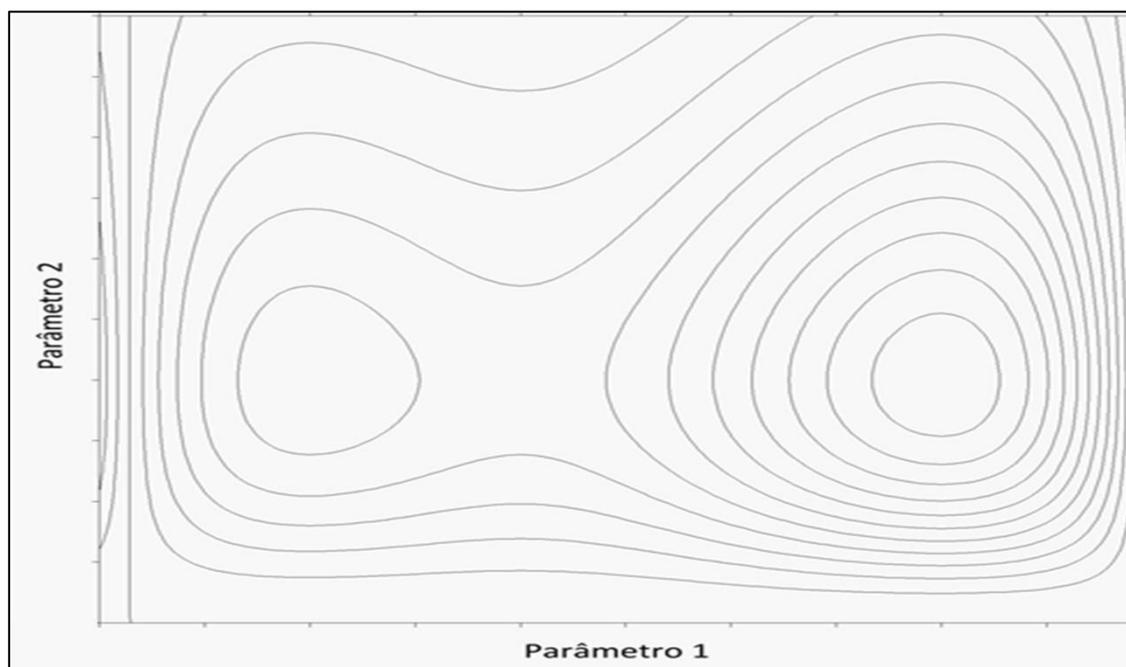
Dado quão ineficiente pode chegar a ser o processo de calibração manual, em muitos casos se recorre a técnicas matemáticas de otimização que ajudam a reduzir o tempo utilizado na busca de um resultado ótimo, através do processo chamado de calibração automática.

Com o objetivo de tornar mais rápido e eficiente o processo de calibração foram desenvolvidos algoritmos de otimização que se baseiam na utilização intensiva de computadores para a calibração automática de modelos hidrológicos. Nesse sentido, desde a década de 1960, diferentes técnicas para a calibração automática de modelos hidrológicos têm sido desenvolvidas. Atualmente, um grande número de técnicas encontra-se disponíveis. Um procedimento típico para estimar os valores de parâmetros de modelos chuva-vazão considera

os seguintes elementos principais: 1) a definição da função-objetivo; 2) escolha do algoritmo de otimização; 3) definição do critério de parada.

O propósito da calibração automática é encontrar aqueles valores dos parâmetros do modelo que otimizam (maximizam ou minimizam) a função-objetivo, que representa a meta a ser atingida no processo de calibração. Quando otimizado o valor de uma única função-objetivo, o processo de calibração automática é denominado mono-objetivo. Entretanto, quando otimizado o valor de duas ou mais funções-objetivo, o processo de calibração automática é dito multi-objetivo.

A superfície descrita pela função-objetivo no espaço dos parâmetros é conhecida como superfície de resposta (Sorooshian e Gupta, 1995). Um algoritmo de otimização é um procedimento lógico que é utilizado para explorar a superfície de resposta e obter os valores dos parâmetros que otimizam (maximizam ou minimizam) a função-objetivo considerando a faixa de valores viáveis de cada parâmetro (Figura 4). Quando se trata de calibração de modelos hidrológicos, as técnicas numéricas (iterativas) de otimização são as mais utilizadas porque, normalmente, a função-objetivo resultante do uso destes modelos é implícita (Tucci, 1998).



**Figura 4.** Superfície de resposta para uma função com dois parâmetros.

A calibração automática utiliza critérios mais objetivos para definir o final do processo de calibração. Sorooshian e Gupta (1995) apresentaram os seguintes critérios de parada: (a) convergência da função-objetivo; (b) convergência dos valores dos parâmetros; (c) número máximos de iterações.

A calibração automática pode ser mono-objetivo ou multi-objetivo em função do número de funções-objetivo sendo otimizadas.

A calibração mono-objetivo consiste em buscar os valores ótimos do conjunto de parâmetros do modelo hidrológico que maximizam (ou minimizam) uma função-objetivo. Nesse sentido, diferentes medidas de desempenho baseadas no erro (diferença entre as vazões observadas e calculadas) são utilizadas como função-objetivo, como por exemplo, as apresentadas a seguir:

$$\text{Minimizar } KGE = 1 - ED \quad (1)$$

$$\text{para: } ED = \sqrt{(r-1)^2 + (a-1)^2 + (b-1)^2}; \quad r = \frac{\text{cov}(Q_c - Q_o)}{\sigma_c \times \sigma_o}; \quad b = \frac{\mu_c}{\mu_o} \quad \text{e} \quad a = \frac{\sigma_c}{\sigma_o}$$

onde KGE representa o coeficiente de eficiência proposto por Gupta et al. (2009) para o intervalo  $-\infty < KGE \leq 1$ ; ED representa a distancia euclidiana até o ponto ideal; r é o coeficiente de correlação entre as vazões calculadas e observadas;  $\text{cov}(Q_c - Q_o)$  representa a covariância entre vazões calculadas ( $Q_c$ ) e observadas ( $Q_o$ ); b representa a relação entre a média das vazões calculadas ( $\mu_c$ ) e a média das vazões observadas ( $\mu_o$ ); e a representa a relação entre o desvio padrão das vazões calculadas ( $\sigma_c$ ) e o desvio padrão das vazões observadas ( $\sigma_o$ ).

$$\text{Minimizar } NS = 1 - \frac{\sum_{t=1}^n (Q_o(t) - Q_c(t))^2}{\sum_{t=1}^n (Q_o(t) - \overline{Q_o})^2} \quad (2)$$

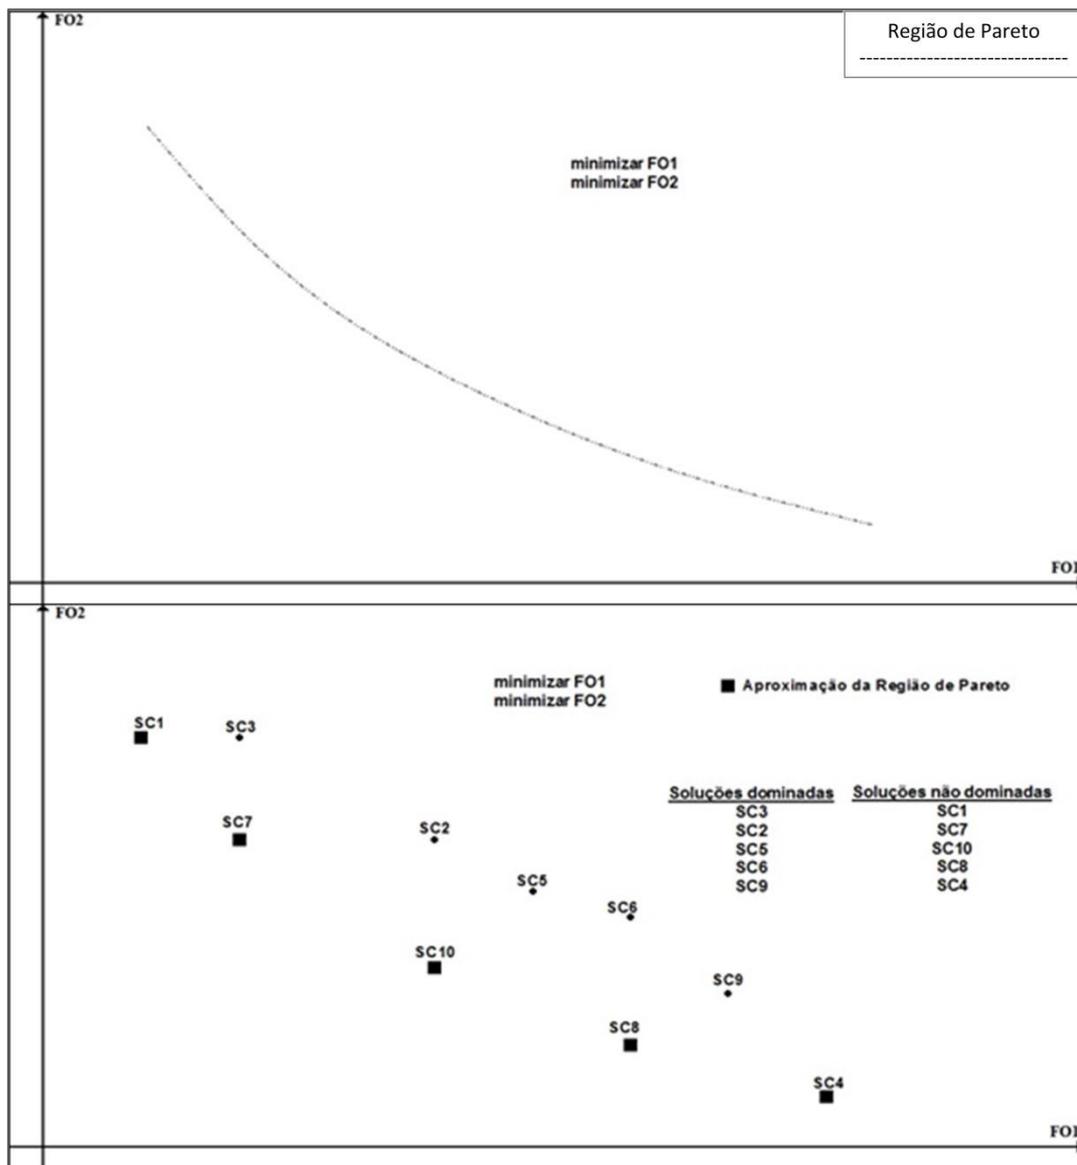
onde NS representa o coeficiente de eficiência proposto por Nash e Sutcliffe (1970) para o intervalo  $-\infty < NS \leq 1$ ;  $Q_o$  é a vazão observada no instante t,  $Q_c$  é a vazão calculada no instante t;  $\overline{Q_o}$  é a média das vazões observadas e n é o número de intervalos de tempo.

$$\text{Minimizar } IQ = \sqrt{\frac{\sum_{t=1}^n \left( \frac{1}{Q_o(t)} - \frac{1}{Q_c(t)} \right)^2}{n}} \quad (3)$$

onde IQ representa a medida de desempenho em relação ao quadrado do inverso das vazões para o intervalo  $-\infty < IQ < +\infty$ ;  $Q_o$  é a vazão observada no instante t,  $Q_c$  é a vazão calculada no instante t e n é o número de intervalos de tempo.

A calibração multi-objetivo consiste em encontrar os valores ótimos do conjunto de parâmetros considerando duas ou mais funções-objetivo. Uma característica importante do resultado de um processo de calibração multi-objetivo é que, geralmente, não existe uma única

solução (único conjunto de parâmetros). Ao considerar várias funções-objetivo, o processo de calibração multi-objetivo apresenta um caráter vetorial, existindo dois grupos de soluções (Figura 5): 1) soluções dominadas, aquelas que, considerando todas as funções-objetivo serão piores que as demais soluções; 2) soluções não dominadas ou de Pareto ótimas, que quando comparadas com todas as outras, serão melhores numa ou mais funções-objetivo e piores em outras. O grupo de soluções não-dominadas é o alvo principal da calibração multi-objetivo. Esse grupo forma uma superfície (no espaço das funções-objetivo) conhecida como região de Pareto. A região de Pareto define o *trade-off* entre as funções-objetivo, e é definida sem estabelecer uma preferência relativa subjetiva para minimizar (ou maximizar) alguma das funções-objetivo a custa de outras (Bravo *et al.*, 2007).



**Figura 5.** Região de Pareto para calibração automática multi-objetivo para duas FO.

Entre as técnicas mais utilizadas na calibração automática de modelos hidrológicos se encontram os algoritmos evolucionários, descritos a seguir, no capítulo 3.

### **3- ALGORITMOS EVOLUCIONARIOS**

São procedimentos computacionais aplicados à solução de problemas ou modelagem de processos evolutivos, baseados no princípio de seleção natural e sobrevivência estabelecido por *Charles Darwin* (pais mais aptos tem maior probabilidade de ter filhos), resultante da aplicação de técnicas heurísticas.

Em geral, pode-se caracterizar a um algoritmo evolucionário (AE) pelas seguintes características (Dorigo *et al.*, 1996): 1) baseia-se num fenômeno natural; 2) estocástico; 3) apresenta adaptabilidade; 4) utiliza um número definido de iterações; 5) possui uma população inicial (cromossomas, insetos, partículas); 6) operação/cooperação/competição; 7) incorpora processos de auto-modificação dos parâmetros do problema.

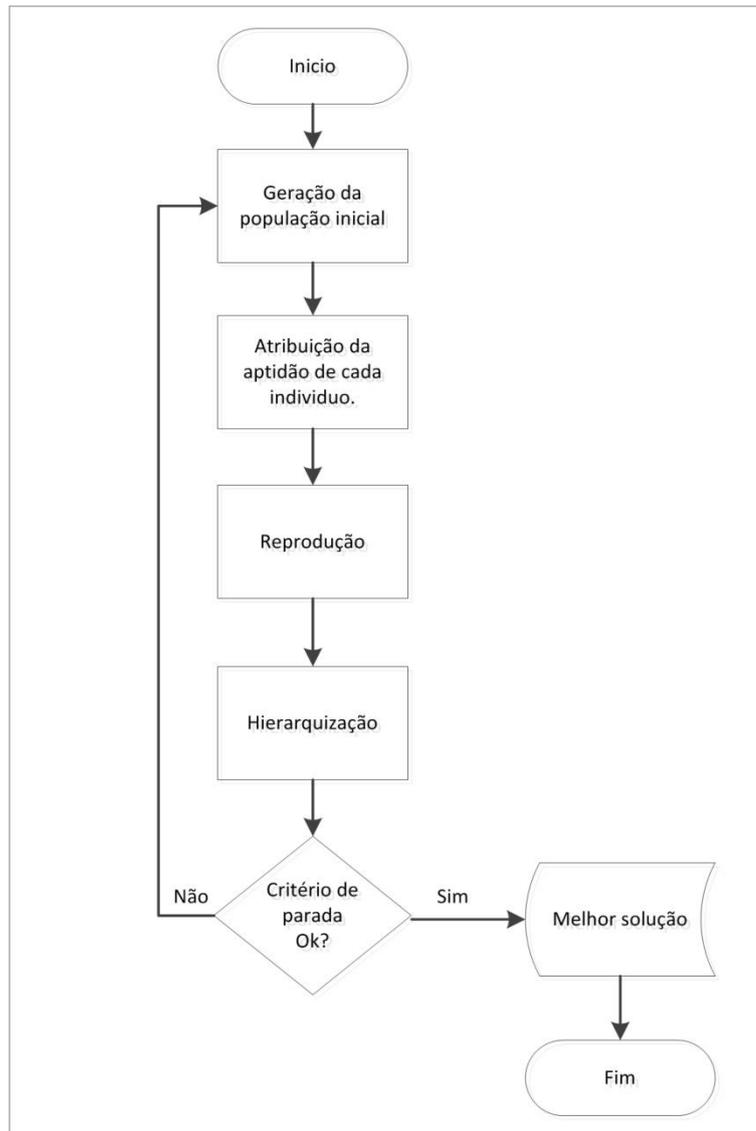
O processo de evolução em um AE é comumente caracterizado por três passos: 1) reprodução com herança genética; 2) variação aleatória em população de indivíduos e 3) aplicação da seleção natural para a geração da próxima população, que basicamente flui da seguinte maneira: a variação cria diversidade na população, a diversidade é transmitida pela herança e na seleção são eliminados os indivíduos menos aptos.

Quatro operações são fundamentais em relação à população de indivíduos: reprodução; variação; atribuição de um valor ou grau de aptidão (*fitness*); e escolha de indivíduos que irão compor a próxima geração.

Em termos computacionais, o objetivo do processo de seleção natural tem como finalidade estabelecer matematicamente condições que aprimorem o processo de otimização (maximização ou minimização). Neste sentido, os AE caracterizam-se como técnicas meta-heurísticas que compreendem metodologias de procura de soluções candidatas em espaços de busca, capazes de dirigir operadores computacionais de busca local e de busca global.

Para conceber um problema de otimização usando AE (Figura 6), são estabelecidos os seguintes passos: 1) Inicialização do algoritmo, onde são definidas as condições iniciais do problema, sendo elas a população inicial, o número de parâmetros, as características de cada indivíduo, operações que serão feitas, entre outras; 2) geração da população inicial, onde se estabelece o número de indivíduos que são candidatos à solução do problema, que são gerados aleatoriamente dentro do espaço de busca; 3) avaliação de cada indivíduo, onde a cada um é atribuído um valor de aptidão ou *fitness*, que influencia o valor da probabilidade dele ser escolhido para a seguinte etapa; 4) hierarquização dos indivíduos, onde a população é arranjada em ordem relativa à aptidão de cada um dos indivíduos, onde aqueles com maior

aptidão possuem maior probabilidade de serem escolhidos; 5) avaliação do critério de parada, onde sendo ele atendido, identifica-se e apresenta-se o resultado com a solução candidata com maior aptidão, caso contrário o processo se repete a partir da etapa 2).



**Figura 6.** Fluxograma de um AE genérico.

A seguir são apresentados dois algoritmos evolucionários mono-objetivos: o algoritmo genético puro (Holland, 1975) e o algoritmo SCE-UA (*Shuffled Complex Evolution – University of Arizona*), descrito inicialmente por Duan *et al.* (1992). O algoritmo genético puro foi o primeiro a ser desenvolvido e apresentou bons resultados na resolução de problemas de otimização. Utiliza os conceitos de seleção natural e mutação, bem como toma emprestados muitos outros termos biológicos, tais como filhos, pais, reprodução, casais. O algoritmo SCE-UA é um algoritmo de busca global, testado amplamente na calibração de modelos hidrológicos e outras aplicações na área, com bons resultados. Posteriormente é apresentada uma descrição em maior detalhe dos algoritmos baseados no comportamento de colônia de formigas, desenvolvidos inicialmente por Dorigo *et al.* (1996) para a solução do problema do

caixeiro viajante, apresentando resultados alentadores. Os mesmos serão utilizados nessa pesquisa.

### 3.1- Algoritmo genético puro

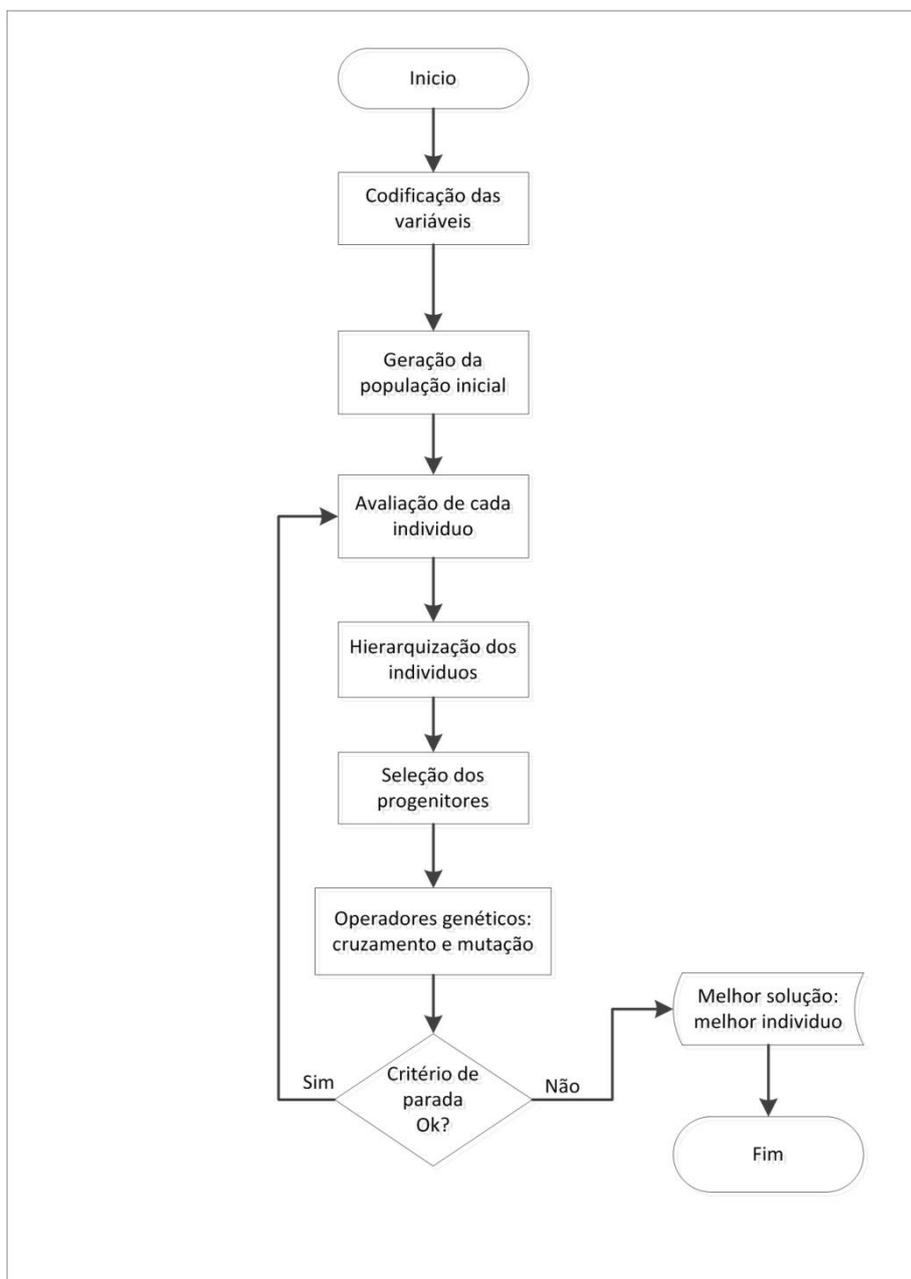
Desenvolvido por Holland (1975) e utilizado por Goldberg (1989), o algoritmo genético puro (AGP) é considerado como um algoritmo robusto e de boa aplicabilidade em problemas de otimização. A ideia inicial de Holland não era desenvolver nem aprimorar algoritmos de soluções para problemas específicos, mas sim propiciar, por meio de estudos dos fenômenos de adaptação, a utilização destes mecanismos na computação.

Para resolver um problema de otimização com um algoritmo genético é feita uma analogia com um verdadeiro problema genético, onde se procura o indivíduo mais apto dentro de uma população, mediante funções que ligam os indivíduos e a sua aptidão com a função-objetivo.

Um processo de otimização com um algoritmo genético puro é executado mediante a aplicação dos seguintes passos (Figura 7): 1) inicialização do algoritmo, onde são definidas: a população inicial, o número de variáveis de decisão, as características de cada indivíduo, operações que serão feitas, função-objetivo, entre outras; 2) codificação das variáveis de decisão, onde cada indivíduo é codificado na forma de um cromossoma, por meio de uma cadeia binária de bits (0 e 1), e representa uma solução candidata do problema de otimização; 3) geração da população inicial, onde se estabelece o número de indivíduos ou cromossomos que são candidatos à solução do problema, sendo eles então gerados aleatoriamente dentro do espaço de busca; 4) avaliação de cada indivíduo, onde a cada um é atribuído um valor de aptidão ou *fitness*, que depende da função-objetivo ou de uma função transformada desta, e que influencia o valor da probabilidade dele ser escolhido para a seguinte etapa; 5) hierarquização dos indivíduos, onde a população é arranjada em ordem relativa à aptidão que possui cada um dos indivíduos, onde aqueles com maior aptidão possuem maior probabilidade de serem escolhidos no processo de seleção; 6) seleção dos progenitores, etapa na qual os indivíduos que participam do processo de reprodução são escolhidos, salvando tipicamente o melhor indivíduo, em relação à aptidão, para ser parte ainda da próxima geração através do operador denominado elitismo; 7) reprodução, através da aplicação de operadores tais como cruzamento (ou recombinação) ou mutação (troca do valor de algum ou alguns bits que compõem a cadeia); 8) avaliação do critério de parada e, sendo este atendido, é identificado e apresentado o resultado com a solução candidata com a maior aptidão, caso contrário o processo se repete o processo a partir da etapa 4).

A partir do algoritmo genético puro surgiu um grande número de diferentes versões de algoritmos genéticos os quais aprimoraram o algoritmo original incluindo novos operadores de reprodução, diferentes critérios para seleção das soluções que participarão do processo de

reprodução ou combinados com algoritmos de busca local (Nicklow *et al.*, 2010). Diferentes aplicações de algoritmos genéticos existem na área de modelagem hidrológica, por exemplo, na calibração multi-objetivo de um modelo hidrológico distribuído (WetSpa) aplicado à previsão de vazões em um rio eslovaco (Shafii e De Smedt, 2008) , na calibração multi-objetivo do modelo IPH II (Araújo *et al.*, 2013), na calibração de um modelo hidrológico chuva-vazão em combinação com um algoritmo de busca local (Award e Von Poser, 2010).



**Figura 7.** Fluxograma de um algoritmo genético puro.

### 3.2- SCE – UA

O algoritmo SCE-UA (*Shuffled Complex Evolution – University of Arizona*) combina os pontos fortes do método Simplex (Nelder e Mead, 1965) com os conceitos de busca aleatória

controlada (Price, 1987), princípios de evolução competitiva (Holland, 1975), mais o conceito de mistura de complexos.

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, por apresentar um grande número de ótimos locais, os métodos de calibração automática de busca local, como o método Rosenbrock e o método Simplex não conseguiam encontrar o ótimo global. 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 pelo conjunto de variáveis de decisão e representa uma solução candidata. Conforme Duan *et al.* (1992), o algoritmo SCE-UA imita o processo de evolução natural. Os pontos da amostra constituem a 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, as comunidades 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).

Continuando com a analogia biológica, cada um dos membros de uma comunidade é candidato a ser 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 dois membros.

Para garantir que o processo seja competitivo, é necessário que os pais com maior aptidão tenham maior probabilidade de serem escolhidos para o processo de reprodução. Para isso, a aptidão dos pais é avaliada pelo valor da função-objetivo ou uma função transformada desta. Quanto menor o valor da função-objetivo, maior será considerada a aptidão do pai, visto que este algoritmo foi desenvolvido para problemas de minimização. 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 Simplex de Nelder e Mead.

Os passos do algoritmo são apresentados a seguir, conforme Duan *et al.* (1992):

(1) Início do processo: são selecionados os valores dos parâmetros do algoritmo;  $p \geq 1$  e  $m \geq 2n+1$ ; onde  $p$  representa o número de complexos,  $m$  o número de indivíduos em cada complexo e  $n$  o número de parâmetros do problema de otimização. O tamanho da população ( $s$ ) é igual ao produto de  $p$  e  $m$ .

(2) Geração da população: são gerados  $s$  conjuntos de parâmetros do modelo de simulação, entre os limites máximo e mínimo definidos para cada parâmetro. Estes conjuntos são escolhidos de forma aleatória, utilizando uma distribuição de probabilidades uniforme.

(3) Hierarquização dos indivíduos: os indivíduos da população são avaliados com a função-objetivo e reorganizados, em ordem crescente de função-objetivo, formando o conjunto  $D$ . O primeiro indivíduo de  $D$  apresenta o melhor (menor) valor da função-objetivo.

(4) Divisão das amostras em complexos: a população  $D$  de  $s$  indivíduos é dividida em  $p$  complexos, cada um com  $m$  indivíduos. A divisão é feita de tal forma a garantir que cada complexo esteja integrado por certo número de indivíduos com boa aptidão e outros com aptidão ruim.

(5) Evolução dos complexos: a cada complexo é dada a oportunidade de evoluir com base no método de Evolução Competitiva Complexa, descrito por Duan *et al.*(1992) como segue:

(a) Início: são selecionados os valores de  $q$ ,  $\alpha'$  e  $\beta$ , que são parâmetros do SCE-UA. Os valores são escolhidos de forma que  $2 \leq q \leq m$ ,  $\alpha' \geq 1$ , e  $\beta \geq 1$ , e é delimitado o hipercubo que irá conter os filhotes.

(b) Atribuição de pesos: cada um dos indivíduos do complexo recebe um peso, proporcional a sua posição na hierarquia do complexo.

(c) Seleção dos pais: um sub-complexo de  $q$  indivíduos é escolhido de forma aleatória de cada complexo. A probabilidade de cada indivíduo do complexo ser parte do sub-complexo é dada pelo peso definido em (b).

(d) Geração dos filhotes: os indivíduos do sub-complexo ( $u_j$  para  $j=1, q$ ) são organizados de forma crescente de função-objetivo e é calculado o centróide dos  $q-1$  melhores indivíduos do sub-complexo.

Na continuação, as coordenadas de um novo indivíduo são calculadas como segue, considerando o valor da FO associado ao pior indivíduo do sub-complexo igual a FO (SCP) (Figura 6):

- i. Reflexão: um novo indivíduo é criado por reflexão com base no centróide definido em (d) e a posição do pior indivíduo do sub-complexo (Figura 8a) e chamado de Solução Candidata de Reflexão (SCR).
- ii. Se SCR estiver contido no espaço factível dos parâmetros é calculado o valor da função-objetivo FO (SCR) e o procedimento continua no passo iii. Caso contrário, é definido o menor hipercubo que contém todos os indivíduos do complexo e gerado um indivíduo, de forma aleatória, denominado Solução Candidata Aleatória (SCA), no interior deste hipercubo.

Posteriormente, é calculada a FO (SCA) e feito  $SCR=SCA$  e  $FO(SCR)=FO(SCA)$ , conhecido como passo de mutação.

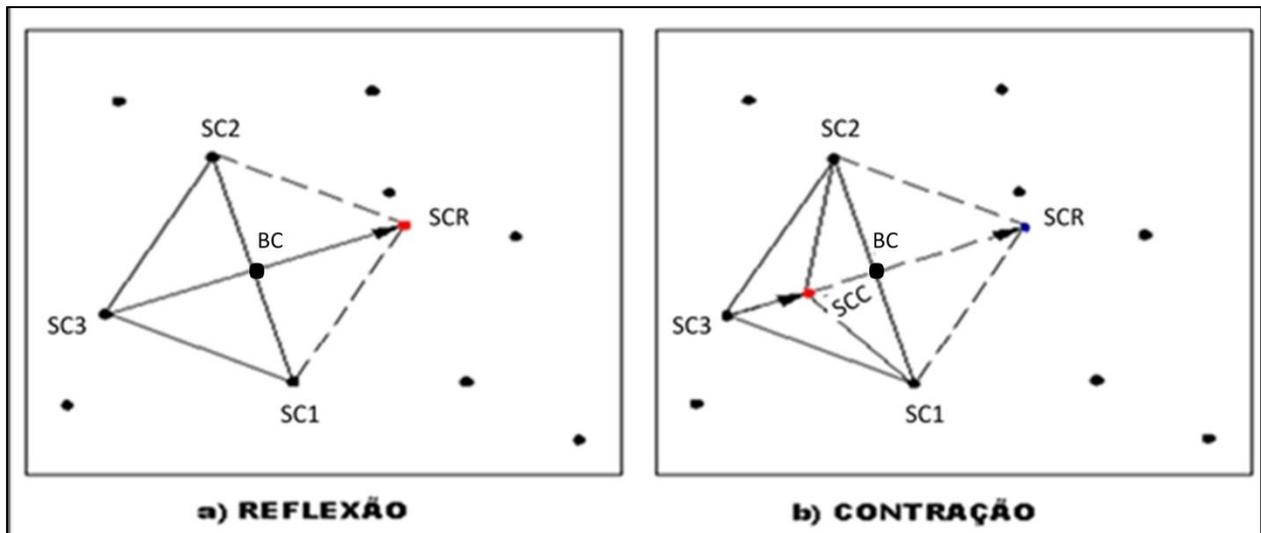
iii. Se  $FO(SCR) < FO(SCP)$ , SCP é substituído por SCR e o procedimento continua no passo v. Caso contrário, é feito o procedimento de contração com base no centróide definido em (d) e a posição do pior indivíduo do sub-complexo (Figura 8b), e esse novo indivíduo é chamado de Solução Candidata por Contração (SCC).

iv. Se  $FO(SCC) < FO(SCP)$ , SCP é substituído por SCC e o procedimento continua no passo v. Caso contrário é definido o menor hipercubo que contém todos os indivíduos do complexo e gerado um indivíduo, de forma aleatória, denominado Solução Candidata Aleatória (SCA), no interior deste hipercubo. Posteriormente é calculada FO (SCA) e substituído SCP por SCA.

v. Repetir os passos i-iv um número  $\alpha'$  de vezes.

Os indivíduos de cada um dos sub-complexos são devolvidos, modificados, a cada complexo.

Os passos 1 a 5 são repetidos um número  $\beta$  de vezes.



**Figura 8.** Métodos de geração de novos indivíduos por reflexão (a) e contração (b).

(6) Mistura dos complexos: os complexos são novamente agrupados na população D, e os indivíduos reorganizados, em ordem crescente de função-objetivo.

(7) Teste de convergência: Se o critério de convergência é satisfeito, o algoritmo se encerra. Caso contrário, o procedimento retorna ao passo (3) (Figura 9).

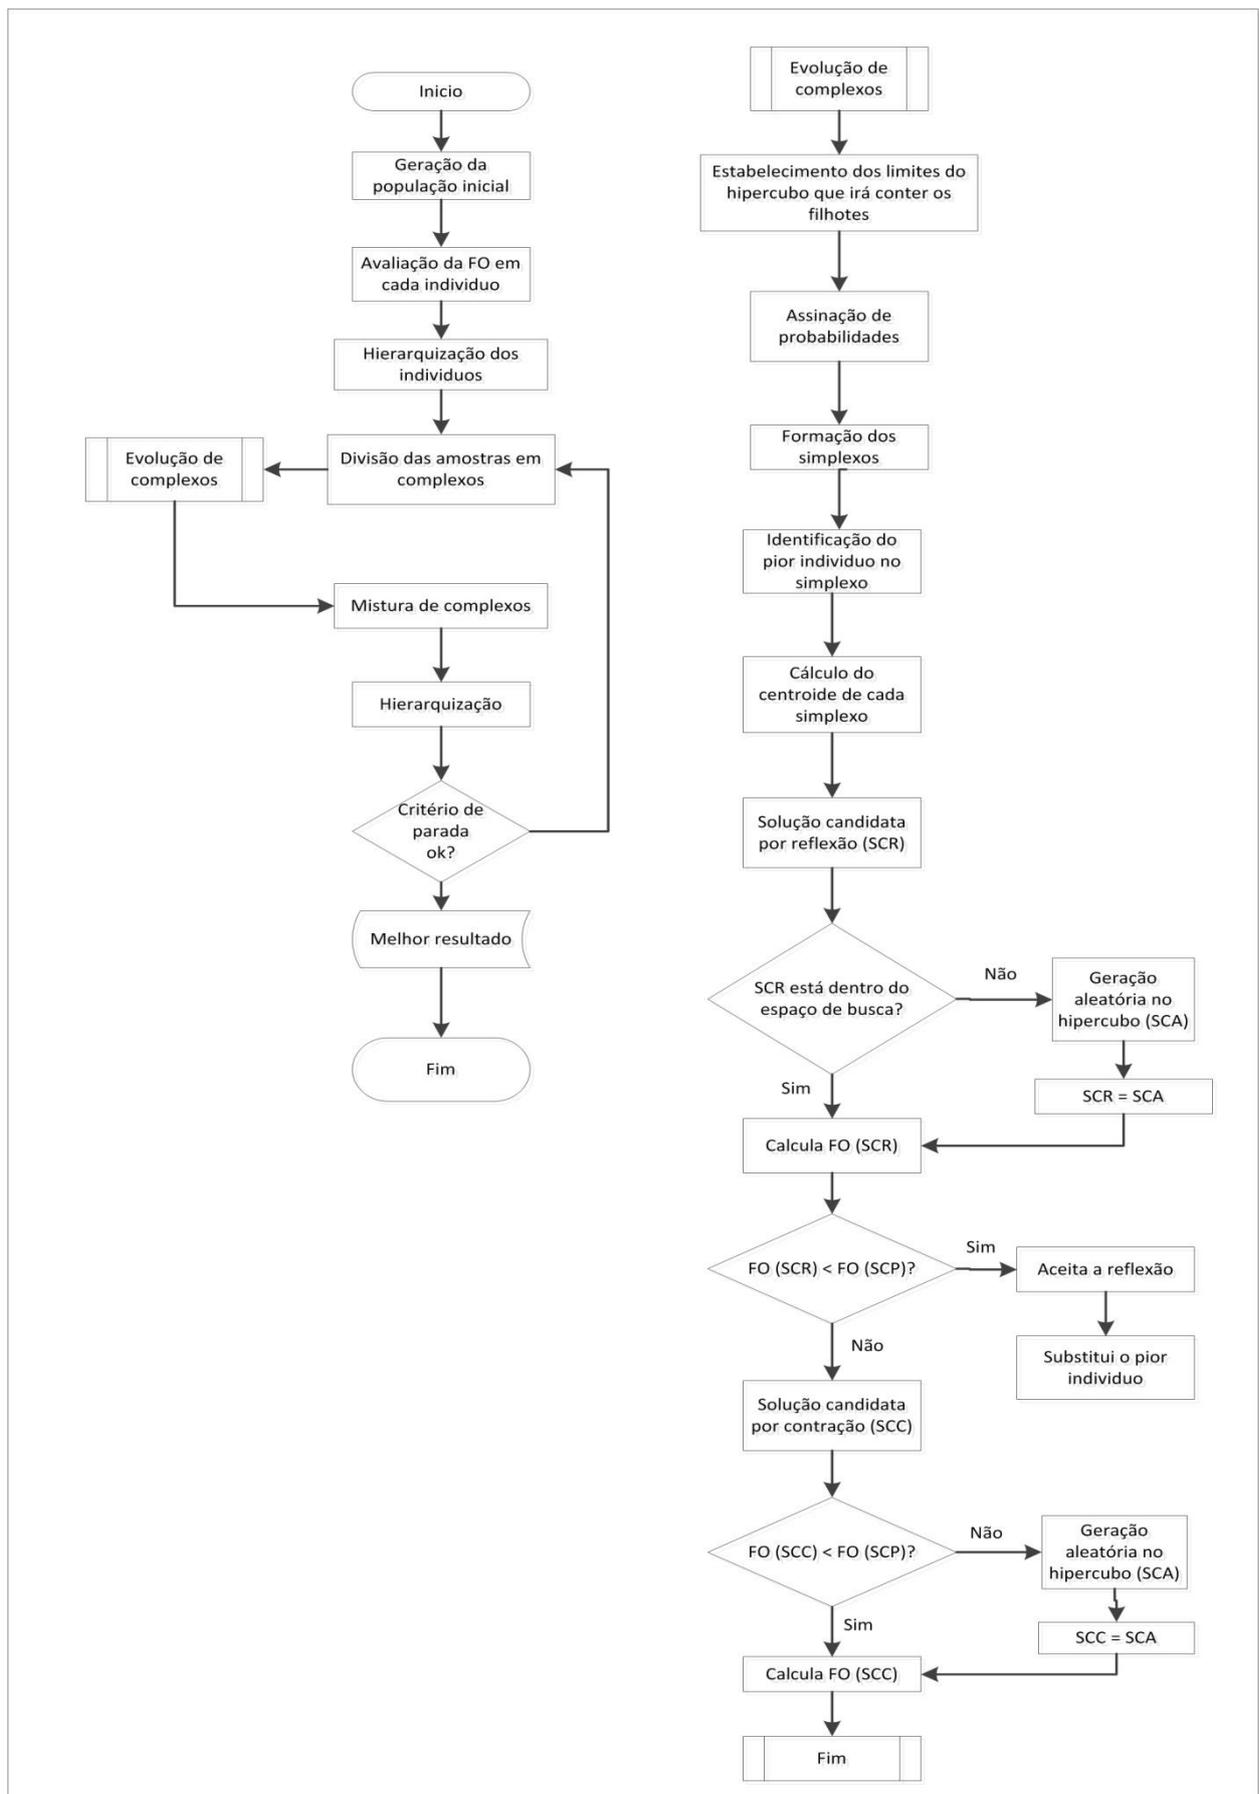
### 3.3- Algoritmos baseados no comportamento de colônia de formigas

Atualmente, para se falar a respeito de ferramentas computacionais dotadas de algum tipo de inteligência, existe uma gama de termos a ser conhecida, tais como: Inteligência Artificial, Inteligência Computacional, Computação Natural, entre outras (Freitas, 2009).

Devido às pesquisas desenvolvidas nos últimos anos com o objetivo de desenvolver métodos heurísticos de otimização baseados no comportamento de colônia de insetos, surgiu uma nova linha de pesquisa denominada Inteligência Coletiva ou *Swarm Intelligence* (BONABEAU *et al.*, 1999). Nesse sentido, o interesse no comportamento de colônias de formigas, colônias de bactérias, ou de bandos de pássaros, por exemplo, revela uma característica importante da inteligência coletiva, que é o estudo de grupos de animais que, individualmente, não agem inteligentemente, mas que, coletivamente, desenvolvem atividades relativamente complexas, tais como identificar a menor trajetória entre suas localizações, as fontes de alimento de melhor qualidade e mais próximas, a região com as melhores condições climáticas para a reprodução da espécie, entre outras.

As formigas têm recebido uma especial atenção nesse sentido, pois elas depositam uma substância química, chamada feromônio, ao se movimentar na procura de alimentos, tanto no trajeto ninho-alimento, como na volta, no trajeto alimento-ninho, marcando o caminho mediante a mudança no ambiente que as outras formigas percebem como um sinal para a escolha do caminho, sendo o caminho com maior quantidade de feromônio o que tem mais chance de ser escolhido. Esse comportamento dos insetos, entre eles, as formigas, que encontra-se baseado em modificações ambientais não visuais que os integrantes da colônia podem realizar e perceber é chamado de *stigmergy*.

Computacionalmente, trata-se do desenvolvimento de uma colônia artificial de formigas que, cooperando entre si, exploram o espaço de busca pelas melhores soluções factíveis para um dado problema. O conjunto de métodos computacionais baseados em analogias com o comportamento de colônias de formigas e utilizado em processos de otimização foi denominado ACO (*Ant Colony Optimization*).



**Figura 9.** Fluxograma do algoritmo SCE – UA.

### 3.3.1- Sustento biológico do método

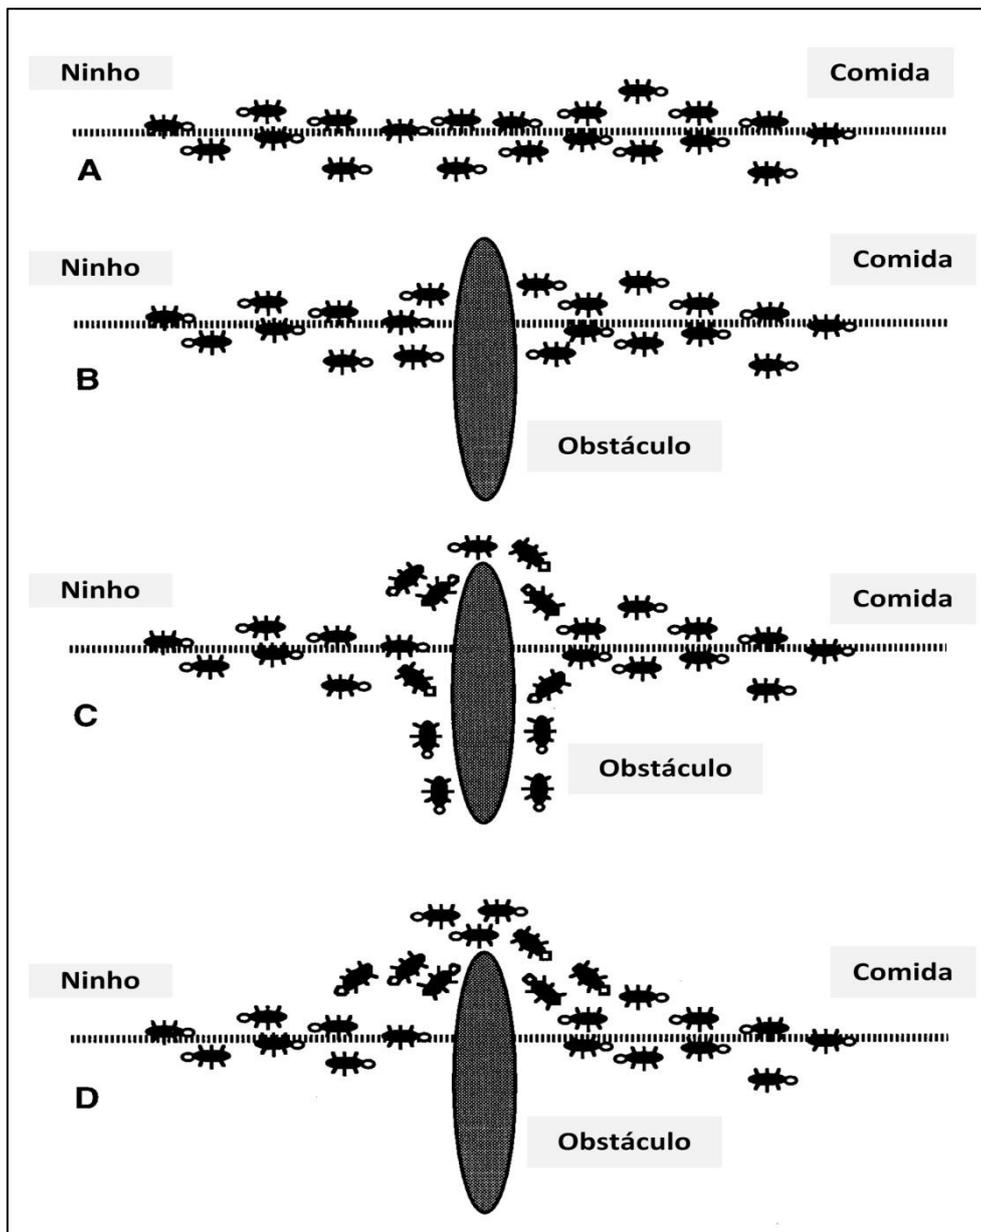
As formigas constituem sociedades com dinâmicas comportamentais avançadas, conhecidas como eusocialidades, integrando a ordem das Hymenoptera, classificadas sob a família Formicida, e são tão relevantes à biodiversidade que chegam a compor aproximadamente 15% a 20% da biomassa animal terrestre, podendo alcançar até 25% em regiões tropicais (Schultz, 2000).

Em relação ao comportamento coletivo desta classificação de animais, McGlynn *et al.* (2003) esclarece que as espécies respondem às transformações do meio ambiente por meio de sinais endógenos ou exógenos. As formigas, porém, lidam frequentemente com cenários hostis e de constantes mudanças. Nesse sentido, Johnson e Rossi (2006) explicam que o comportamento social das formigas desperta a curiosidade científica, especialmente, porque não há um controle central para tal processo, ou seja, trata-se de simples organismos vivos que, coletivamente, são capazes de manter a autopreservação de suas colônias.

Segundo Vittori *et al.* (2006), a movimentação das formigas é governada por dois tipos de *feedback*, ambos relacionados à concentração de feromônio secretado pelos agentes: um positivo, que ocorre com a intensificação da quantidade de feromônio depositada em um determinado caminho; e um negativo, ocorrente com a evaporação gradativa da concentração de feromônio em certas trajetórias, sendo a combinação destas informações que faz a colônia escolher o melhor caminho entre o ninho e a comida.

Uma colônia de formigas é capaz de identificar o caminho mais curto entre seu ninho e a fonte de comida sem indícios visuais (Goss *et al.*, 1989; Beckers *et al.*, 1992), e de adaptar seu comportamento conforme mudanças no ambiente ou espaço de locomoção, também sem utilizar o sentido da visão (Holdöbler e Wilson, 1990).

Na Figura 10, observam-se quatro cenários de um comportamento exploratório de uma colônia de formigas na procura pelo caminho mais curto entre o ninho e uma fonte de comida. Em (A), as formigas fazem o percurso entre o ninho e uma fonte de comida, de ida e de volta, sem o obstáculo e sem problema nenhum. Em (B), colocou-se um obstáculo no percurso que faz com que as formigas devam tomar uma decisão para contorná-lo. Inicialmente esta decisão é aleatória, pois nenhum caminho alternativo apresenta conteúdo de feromônio e, em consequência, uma parte da população escolhe o caminho mais curto e outra vai pelo caminho mais longo. Em (C), observa-se que a tendência é que a maior parte da população comece a escolher o caminho mais curto em função do maior aumento do conteúdo de feromônio, e finalmente, em (D), após um determinado período de tempo, toda a colônia de formigas percorre o caminho mais curto.



**Figura 10.** Comportamento biológico exploratório de uma colônia de formigas. Adaptado de Dorigo *et al.* (1996).

### 3.3.2- ACO desde uma perspectiva computacional

No ambiente computacional, os algoritmos matemáticos desenvolvidos com base no comportamento coletivo das formigas, procuram abranger ajustes e adaptações que aprimoram os procedimentos de busca pelos valores otimizados de funções-objetivo fazendo uma analogia com a busca pelo caminho mais curto entre o ninho e a fonte de alimentos, quando comparados com aqueles praticados pelas formigas da natureza. Segundo Heininen e Petterson (2007), as formigas artificiais movimentam-se, desde que assim predeterminado, somente por caminhos que atendam determinadas restrições, ou lhes é atribuída memória adaptativa, capaz de armazenar as trajetórias já percorridas.

Blum (2005) menciona, que em termos de modelagem do comportamento das formigas para fins de otimização, são introduzidas, basicamente, três características diferenciais, quais seriam:

- Na vida real, as formigas movimentam-se de modo aleatório; no modelo artificial, elas deslocam-se do ninho até a fonte de comida e percorrem o caminho de volta de maneira sincronizada, adotando o mesmo caminho em ambos os sentidos;

- Se, por um lado, as formigas reais depositam feromônio a todo o momento durante suas caminhadas, as formigas artificiais depositam feromônio somente no retorno ao ninho, uma vez já avaliada a qualidade das soluções identificadas;

- Enquanto as formigas reais avaliam implicitamente a qualidade de um determinado caminho percorrido (quanto mais curto, melhor), os agentes artificiais adotam uma avaliação explícita de acordo com alguma medida qualitativa de desempenho.

Compreendida adequadamente a natureza comportamental de colônias de formigas em um ambiente real e em um ambiente computacional, pode-se analisar melhor o funcionamento do método ACO, desde sua formulação biológica até a sua formulação matemática.

### **3.3.3- Tipos principais de ACO e algumas aplicações**

A seguir são descritos quatro tipos de ACO, aquele desenvolvido desde os primórdios e denominado *Ant System* (AS), uma variação deste com algumas melhorias apresentado alguns anos depois, *Ant Colony System* (ACS), uma das mais recentes versões, o *Max-Min Ant System* (MMAS), todas elas utilizadas para resolver problemas de otimização associados a caminhos de mínimo custo, baseadas em análises combinatórias em que as variáveis de decisão são discretas. Por fim, é apresentada uma quarta versão de algoritmos baseados no comportamento de colônias de formigas, desenvolvida por Abbaspour *et al.* (2001) e utilizada na calibração de um modelo hidráulico que simula a infiltração em solo não saturado, neste caso tratando-se de problemas de otimização com variáveis de decisão contínuas. Também serão mencionadas algumas outras versões com a sua utilização.

Nesse contexto, pode-se dizer que, segundo Huang e Liao (2008) e Yagmahan e Yenisey (2008), o ACO é um método de otimização global inspirado no comportamento natural de colônias de formigas, quando empenhadas em encontrar novas fontes de alimentos partindo de seus ninhos. O método de Otimização por Colônia de Formigas (ACO) foi desenvolvido em 1991 por Dorigo *et al.* (1991), e apresentado por meio de um relatório técnico intitulado *Ant System: an autocatalytic optimizing process*. Em sua versão original, denominada *Ant System* (AS), o algoritmo matemático baseado no comportamento de formigas tinha como intuito resolver o problema de otimização conhecido como o problema do caixeiro viajante (TSP), onde um indivíduo precisa visitar X cidades uma única vez, percorrendo Y distâncias diferentes

entre as mesmas. O objetivo do processo de otimização no problema do caixeiro viajante é encontrar a rota que apresente a menor distância.

Alguns aspectos gerais e importantes do ACO são mencionados a seguir:

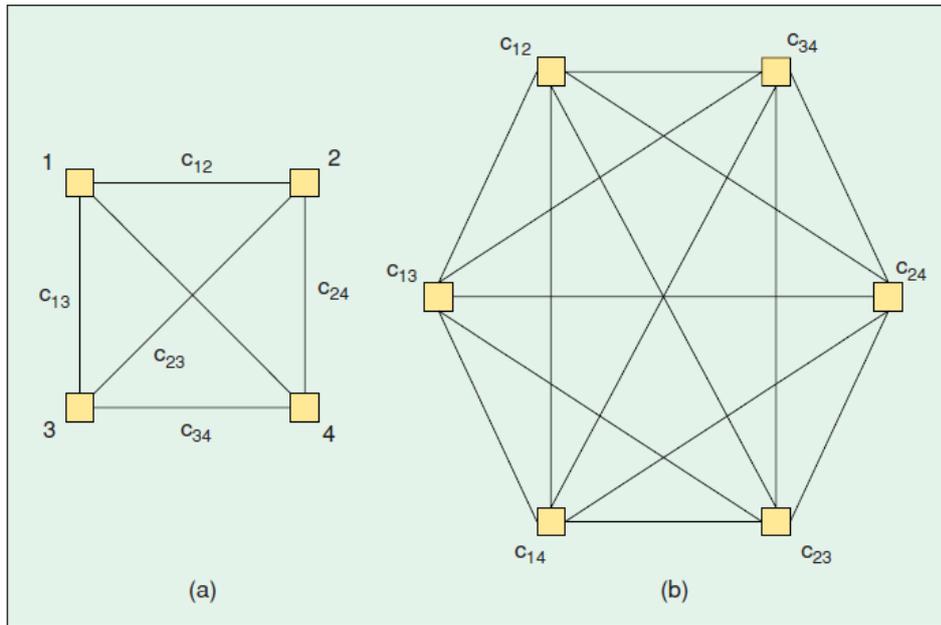
(1) O tamanho da população de formigas que irá em busca da solução ótima (o caminho da formiga entre o ponto inicial e final, representa uma solução candidata do problema de otimização) é muito importante porque um número ótimo delas, até certo limite, garante achar o ótimo procurado sem dispendir tempo de processamento em excesso. A estimativa do número ideal de formigas será testada e o procedimento explicado mais adiante no texto.

(2) O número de ciclos do algoritmo refere-se à quantidade de vezes que as formigas vão partir do ponto inicial em procura do ótimo; em cada ciclo cada formiga sai desde o ponto inicial e vai até o ponto final, deixando aí a informação do caminho percorrido.

(3) O feromônio inicial refere-se ao valor inicial que terá cada caminho em todo o campo do espaço de busca no primeiro ciclo e o feromônio crítico é o valor mínimo que existirá em cada trecho de caminho, mesmo que ele não tenha sido visitado, com o objetivo de não deixar sem chances esse caminho e de não zerar a quantidade de feromônio em trajetos menos visitados ou mesmo não visitados.

Em geral, uma solução para um problema, implementando o algoritmo AS, pode ser resumida nos seguintes passos (Figura 12), considerando o espaço de busca definido por um conjunto de nós vinculados por links:

(1) Inicialização do problema, onde cada formiga é localizada aleatoriamente no nó de início (Figura 11), que representa o local do ninho, e é adotado o valor inicial do conteúdo de feromônio, uniforme em todo o espaço de busca.



**Figura 11.** Exemplo de inicialização com quatro nós e os possíveis links. Dorigo *et al.* (2006)

(2) Movimentação das formigas para os outros nós seguindo links através da regra de transição definida pela equação (4), até encontrar o nó de destino que representa o local da fonte de comida.

$$P_{i,j}^k(t) = \begin{cases} \frac{\tau_{i,j}^\alpha(t) \times \eta_{i,j}^\beta}{\sum_{v \in J_i^k} \tau_{i,v}^\alpha(t) \times \eta_{i,v}^\beta} \dots j \in J_i^k \\ 0 \dots j \notin J_i^k \end{cases} \quad (4)$$

onde  $P$  é a probabilidade de escolha da direção e sentido;  $\eta_{ij} = 1/d_{i,j}$  é a visão da formiga e  $d_{i,j}$  representa a distância entre o nó  $i$  e o nó  $j$ ;  $\tau_{i,j}(t)$  é o conteúdo atual de feromônio no link  $i,j$ ;  $J_i^k$  é o conjunto de nós ainda não visitados pela  $k$ -ésima formiga a partir do nó  $i$ ;  $\alpha$  e  $\beta$  são parâmetros do algoritmo que definem os pesos relativos entre a informação definida com base no conteúdo de feromônio e de visão das formigas.

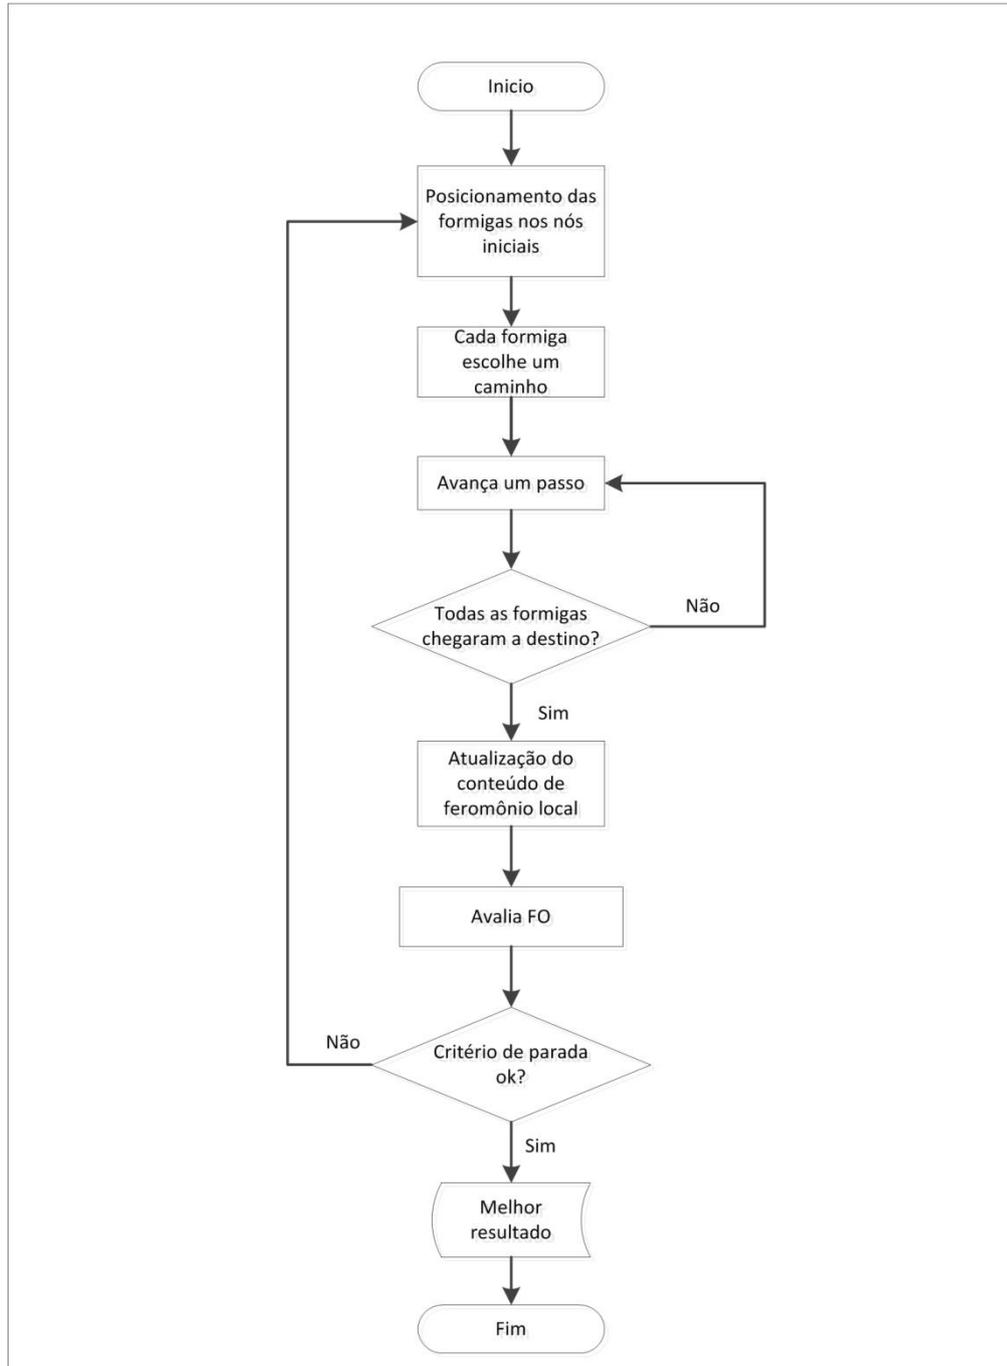
(3) Atualização do conteúdo de feromônio, após a construção da solução candidata (percurso da formiga), cada formiga atualiza o conteúdo de feromônio no seu caminho de volta ao ninho segundo a seguinte equação:

$$\tau_{i,j}(t+1) = (1-\rho) \times \tau_{i,j}(t) + \sum_{k=1}^m \Delta\tau_{i,j}^k \quad (5)$$

onde  $\rho$  é o parâmetro de evaporação do feromônio, e  $\Delta\tau$  é calculada pela equação a seguir:

$$\Delta\tau_{i,j}^k = \begin{cases} Q & \dots \text{se } k \in (i, j) \text{ na itera\c{c}\~{a}o} \\ L_k & \\ 0 & \dots \text{se } k \notin (i, j) \text{ na itera\c{c}\~{a}o} \end{cases} \quad (6)$$

onde  $Q$  é um parâmetro constante,  $\Delta\tau_{i,j}^k$  é a quantidade de feromônio depositada pela formiga  $k$  no link  $i, j$  e  $L_k$  está relacionado com a distância total da rota percorrida pela formiga  $k$ .



**Figura 12.** Fluxograma do algoritmo AS.

O AS, foi concebido com o objetivo de resolver problemas de análise combinatória, especificamente testado e comparado com outros algoritmos na resolução do problema do TSP, apresentando resultados alentadores, mas com desempenho não muito competitivo em relação aos outros algoritmos do estado da arte na resolução do problema do TSP. Por tanto, um importante foco de pesquisa foi a introdução de melhorias no AS, com o objetivo de melhorar seu desempenho.

Assim, foi apresentada por Dorigo e Gambardella (1997) uma versão melhorada do AS, denominada *Ant Colony System* (ACS) e também utilizada na solução do problema do caixeiro viajante. Os resultados obtidos foram considerados satisfatórios quando comparados com resultados obtidos por outros algoritmos evolucionários.

Uma das melhorias deste algoritmo é a de ter duas formas de atualização do conteúdo de feromônio, a denominada atualização local e a atualização global. Além disso, o ACS considera uma regra de transição diferente do AS para a escolha de cada passo dado pela formiga, conforme explicado adiante no texto.

Um problema de otimização, utilizando o método do algoritmo ACS, deve também ser configurado por um conjunto de nós vinculados por links e é resolvido seguindo os passos apresentados a seguir (Figura 13):

(1) Inicialização do problema, onde cada formiga é localizada aleatoriamente no nó de início, que representa o local do ninho, e é adotado o valor inicial do conteúdo de feromônio, uniforme em todo o espaço de busca.

(2) Movimentação das formigas, para os outros nós seguindo links, até encontrar o nó de destino que representa o local da fonte de comida. Nessa etapa do ACS é utilizada a comparação direta entre os novos caminhos a serem explorados e o estabelecimento de prioridades com base na informação acumulada. Assume-se que a  $k$ -ésima formiga localizada no nó  $i$ , escolherá o próximo nó  $i+1$ , a partir da regra de transição apresentada pela equação a seguir:

$$s = \begin{cases} \operatorname{argmax}_{j \in J_i^k} [\tau_{i,j}(t) \times \eta_{i,j}^\beta] & \text{se } q \leq q_0 \\ j & q > q_0 \end{cases} \quad (7)$$

onde  $s$  é a regra de transição;  $q$  é um número aleatório com distribuição uniforme entre  $(0,1)$ ;  $j$  é o nó que seria escolhido utilizando a equação (1) do AS com o valor do parâmetro  $\alpha = 1$ ;  $q_0$  é um parâmetro que dará maior prioridade à primeira alternativa de escolha do link (link com maior conteúdo de feromônio e visão) ou a escolha seguindo a equação do AS, onde  $0 \leq q_0 \leq 1$ ,  $\tau_{i,j}(t)$  é o conteúdo atual de feromônio no link  $i,j$  no instante  $t$ ,  $\beta$  é o parâmetro que define o valor do peso relativo da visão e  $\eta_{i,j}$  é a visão da formiga no link  $i,j$ .

(3) Atualização do conteúdo de feromônio: duas formas de atualização do conteúdo de feromônio existem neste algoritmo: local e global. A regra de atualização local do feromônio (equação 8), é aplicada a todas as formigas, e cada formiga atualiza a quantidade do feromônio no seu caminho de volta ao ninho em função da qualidade da solução obtida. A regra de atualização global de feromônio (equação 9) é apenas aplicada à formiga que percorreu o caminho que apresenta o melhor resultado, nos problemas analisados, o caminho mais curto ( $W_t$ ).

$$\tau_{i,j}(t+1) = (1-\rho) \times \tau_{i,j}(t) + \rho \times \tau_0 \quad (8)$$

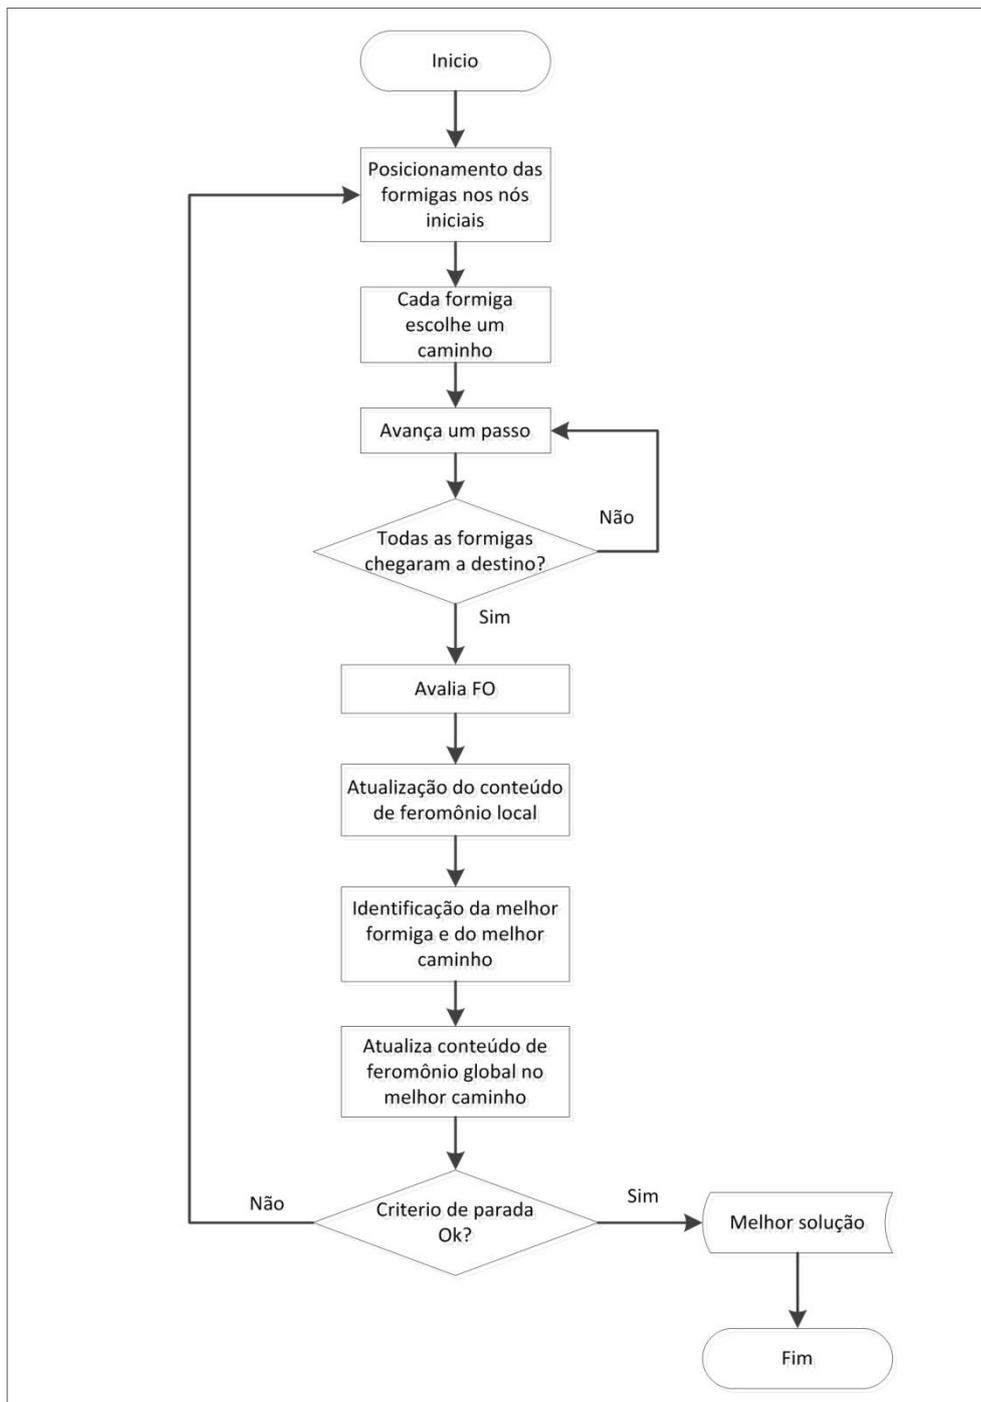
$$\tau_{i,j}(t+1) = (1-\rho) \times \tau_{i,j}(t) + L_{gl}^{-1}(t) \quad (9)$$

onde  $\tau_{i,j}(t+1)$  é o conteúdo atual de feromônio no link  $i,j$  no instante  $t+1$ ;  $\rho$  é o parâmetro de evaporação do feromônio;  $L_{gl}$  é o comprimento do caminho mais curto  $W_t$ ,  $\tau_{i,j}(t)$  é o conteúdo atual de feromônio no link  $i,j$  no instante  $t$ , e  $\tau_0$  é o conteúdo inicial de feromônio.

Entre algumas aplicações do ACS na área de recursos hídricos se encontram os processos de otimização de: operação de reservatórios com múltiplos usos (Kumar e Reddy, 2006), agrupamento de informação mútua de dados ecológicos (Maier *et al.*, 2005), sistema de distribuição de água (Zecchin *et al.*, 2005), projeto de rede de drenagem pluvial (Afshar, 2006) e implementação em problema de paralelização (Randall, 2002).

O terceiro algoritmo da família ACO aqui apresentado é denominado MMAS, algoritmo sistema máximo-mínimo de formigas. Este algoritmo é definido por Stutzle e Hoos (1997) como uma versão melhorada do ACS, pois gera melhores caminhos iniciais porque só permite à melhor formiga atualizar o conteúdo de feromônio em cada ciclo, e assim diminui a chance de ocorrer o engarrafamento de formigas, fenômeno conhecido como estagnação, segundo o qual as formigas convergem rapidamente para uma solução determinada.

As principais alterações introduzidas por este algoritmo ao AS estão centradas na atualização do conteúdo de feromônio e na adoção de patamares inferiores e superiores do conteúdo de feromônio.



**Figura 13.** Fluxograma do algoritmo ACS.

Os mesmos passos utilizados pelo AS para resolver um problema de otimização são seguidos pelo MMAS; no entanto, o processo de atualização do feromônio resulta diferente:

(1) Inicialização do problema, etapa na qual cada formiga é localizada aleatoriamente no nó de início, que representa o local do ninho, e é adotado o valor inicial do conteúdo de feromônio, uniforme em todo o espaço de busca.

(2) Movimentação das formigas para os outros nós seguindo links através da regra de transição definida pela equação (4), até encontrar o nó de destino que representa o local da fonte de comida.

(3) Atualização do conteúdo de feromônio, existindo apenas a atualização global do feromônio, onde apenas é aplicada à formiga que percorreu o caminho que apresenta o melhor resultado na iteração, conforme a equação (10), ou à formiga que encontrou a melhor solução até o final dos n ciclos, conforme a equação (11):

$$\tau_{i,j}(t+1) = (1-\rho) \times \tau_{i,j}(t) + \Delta\tau_{i,j}^* \quad (10)$$

$$\tau_{i,j}(t+1) = (1-\rho) \times \tau_{i,j}(t) + \Delta\tau_{i,j}^+ \quad (11)$$

onde  $\rho$  é o parâmetro de evaporação do feromônio;  $\Delta\tau^*$  indica o incremento de feromônio a ser depositado no caminho percorrido pela melhor formiga da iteração e  $\Delta\tau^+$  indica o incremento de feromônio a ser depositado no caminho percorrido pela melhor formiga até o final dos n ciclos.

Também são considerados os patamares  $\tau_{\max}$  e  $\tau_{\min}$  com a finalidade de evitar rápida convergência a uma solução, eliminando a chance de explorar outros caminhos que poderiam ser ótimos. Os valores de  $\tau_{\max}$  e  $\tau_{\min}$  são definidos de forma diferente por diversos autores (e.g. Stutzle e Hoos, 1997; Dorigo e Stutzle, 2004). A seguir são apresentadas as equações utilizadas por Bravo *et al.* (2008):

$$\tau_{\max}(t) = \frac{1}{d^*} \quad (12)$$

$$\tau_{\min}(t) = \gamma \times \sum_{k=1}^m \tau_{i,j}^k \quad (13)$$

onde  $d^*$  representa o valor da melhor solução encontrada até o ciclo atual e  $\gamma$  é um parâmetro de valor constante ( $0 < \gamma < 0,05$ ).

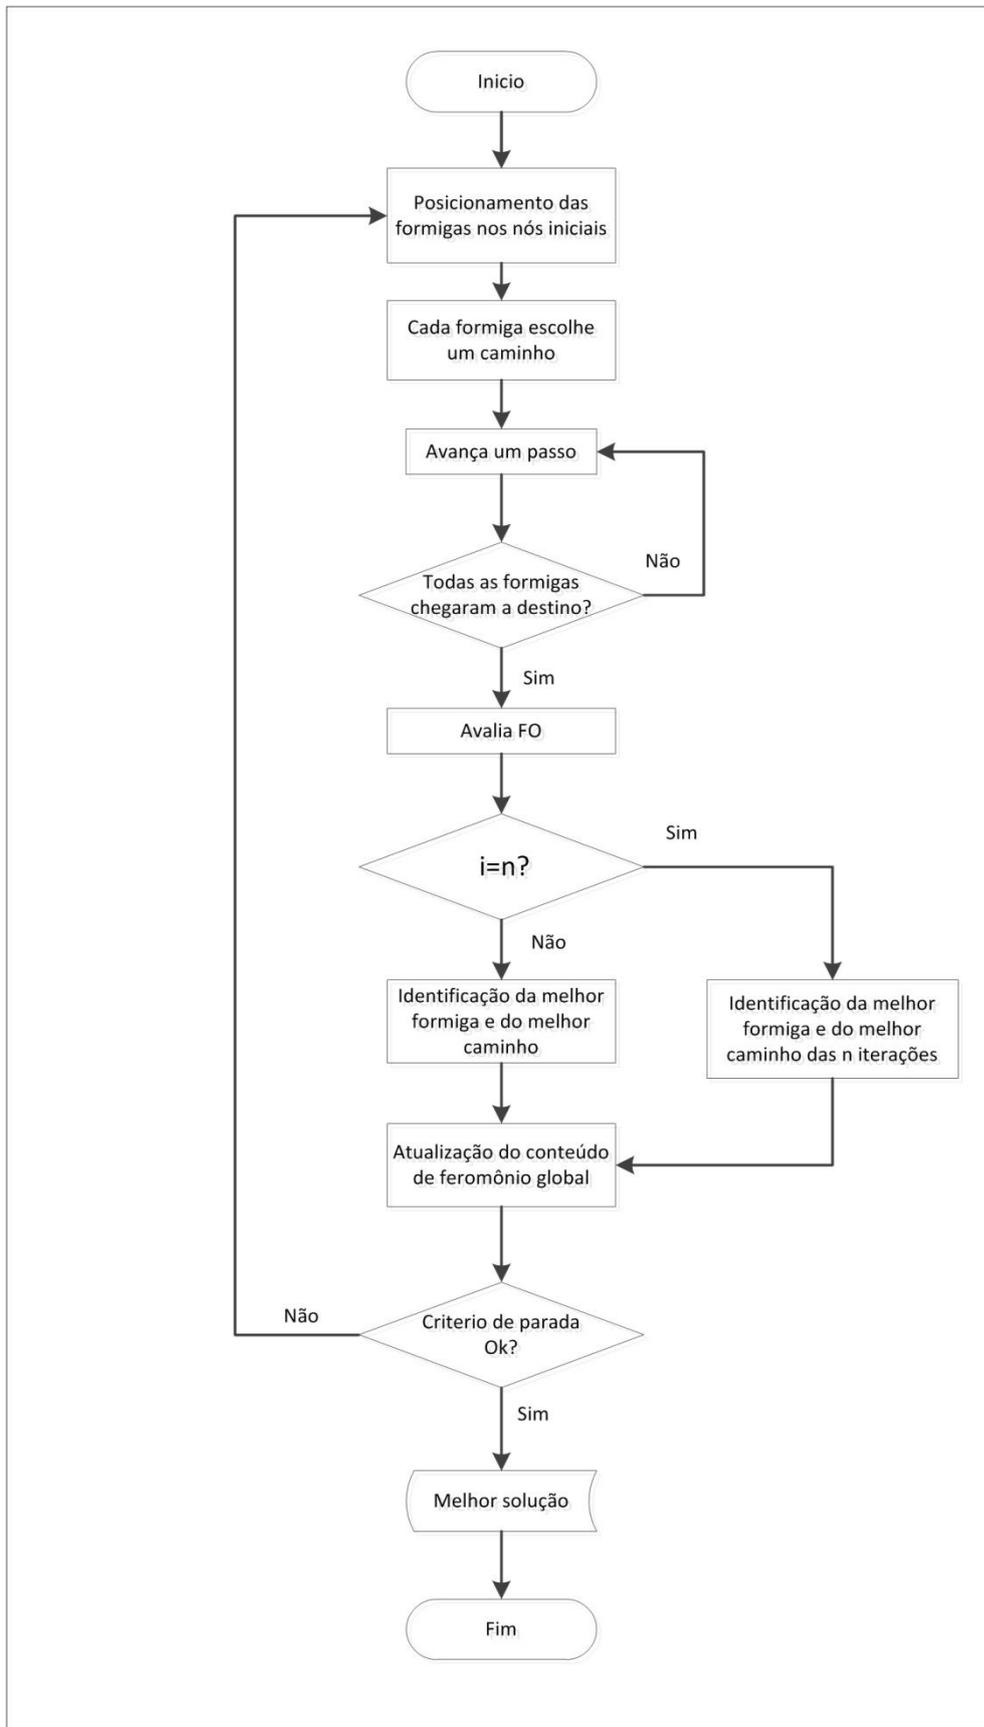
O algoritmo MMAS foi aplicado com resultados satisfatórios no problema do TSP (Stutzle e Hoos, 1997; Dorigo e Stutzle, 2004) e também com bons resultados em problemas de caminho de mínimo custo em ambientes raster referentes ao traçado de obras (Bravo *et al.*, 2008), na otimização do projeto de rede de drenagem pluvial (Afshar, 2006), e na otimização de trânsito em horas pico em ruas principais em Pequim (Hao *et al.*, 2012).

Por fim, o quarto algoritmo da família ACO apresentado neste trabalho foi desenvolvido por Abbaspour *et al.*(2001), denominado ACO-IM e utilizado na calibração de um modelo hidráulico HYDRUS que simula a infiltração em solo não saturado.

Uma medida de desempenho baseada no erro entre os valores calculados e observados de uma variável é utilizada como função-objetivo (equação 14):

$$FO(\beta) = \sum_{i=1}^N f(Q_o(t) - Q_c(t)) \quad (14)$$

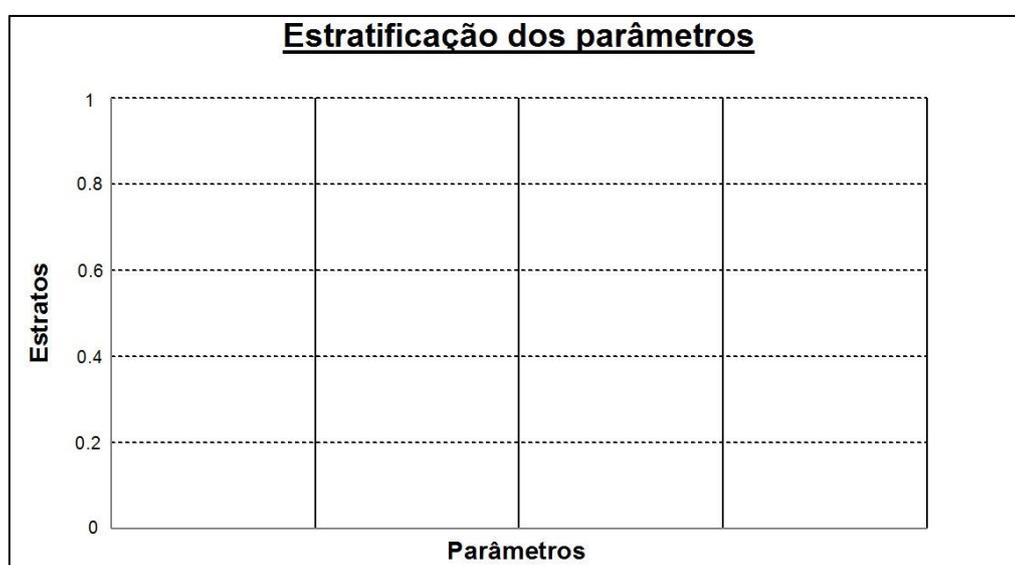
onde FO é a função-objetivo;  $\beta$  é o conjunto de parâmetros do modelo;  $Q_o(t)$  é o valor observado da variável no intervalo de tempo t;  $Q_c(t)$  é o valor calculado da variável no intervalo de tempo t; N é o número total de intervalos de tempo do período analisado e f representa a forma em que os erros são ponderados pela medida de desempenho.



**Figura 14.** Fluxograma do algoritmo MMAS.

Um problema de otimização, utilizando a método do algoritmo ACO-IM, pode ser resolvido seguindo os passos apresentados a seguir, considerando as variáveis de decisão contínuas discretizadas em estratos, representando um espaço de busca semelhante ao utilizado pelos algoritmos previamente apresentados, onde os nós correspondem ao valor da variável no centro do estrato e os links vinculam nós da primeira variável com nós da segunda variável, da segunda variável com a terceira, e assim sucessivamente até chegar à última variável:

(1) Inicialização do problema, etapa na qual cada formiga é localizada aleatoriamente seguindo uma distribuição uniforme nos nós de início, localizados nos centros dos estratos da primeira variável (Figura 15), e é estabelecido o valor inicial do conteúdo de feromônio, uniforme em todo o espaço de busca.

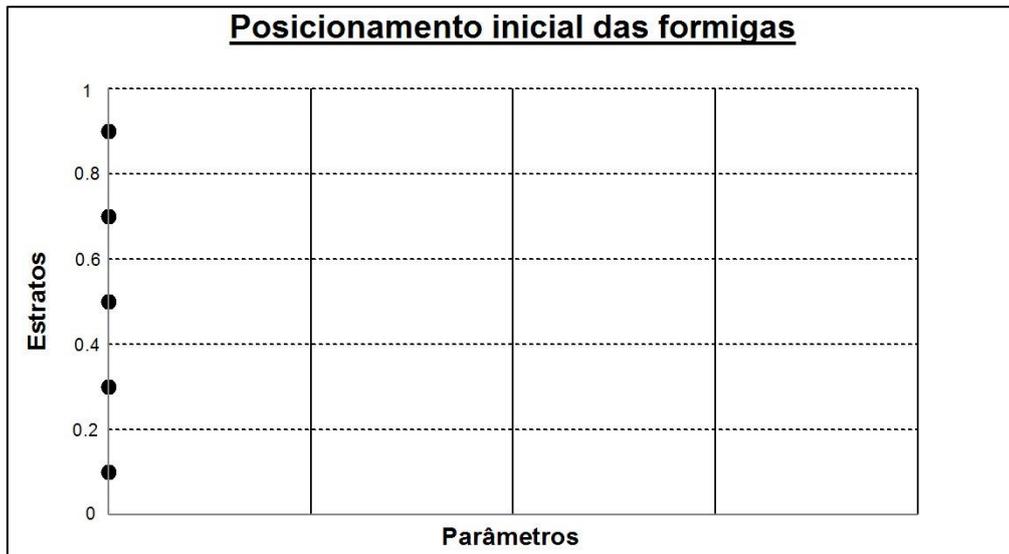


**Figura 15.** Estratificação do espaço de busca no algoritmo ACO-IM.

Na primeira iteração, as formigas são distribuídas de forma aleatória, seguindo uma distribuição uniforme, nos centros dos estratos (denominados pontos de partida), e elas podem ir desse ponto a qualquer outro ponto na variável seguinte, até chegar à última variável (Figura 16).

(2) Movimentação das formigas para os outros nós (centros dos estratos), onde após percorrer todo seu caminho, cada formiga salva o valor da FO associada ao seu trajeto.

Uma vez que as formigas estão todas posicionadas, elas percorrem caminhos de centro de estrato a centro de estrato até chegar à última variável de decisão. Com o conhecimento do caminho percorrido por uma formiga, é obtido o valor da função-objetivo, e a partir dessa informação é calculada a quantidade de feromônio a depositar nesse estrato e o score.



**Figura 16.** Posicionamento inicial aleatório das formigas nos centros dos estratos da primeira variável.

Uma vez que as formigas estão todas posicionadas, elas percorrem caminhos de centro de estrato a centro de estrato até chegar à última variável de decisão. Com o conhecimento do caminho percorrido por uma formiga, é obtido o valor da função-objetivo, e a partir dessa informação é calculada a quantidade de feromônio a depositar nesse estrato e o score.

(3) Atualização do conteúdo de feromônio seguindo a equação 15, e cálculo do score, denotado pela letra  $S$  e calculado através da equação 16, ambos os valores diretamente ligados à FO.

$$\tau_i = \begin{cases} \exp\left(4.6\left(\frac{FO_i - FO_{crit}}{FO_{min} - FO_{crit}}\right)\right) & \dots\dots\dots FO_i \leq FO_{crit} \\ 0 & \dots\dots\dots FO_i > FO_{crit} \end{cases} \quad (15)$$

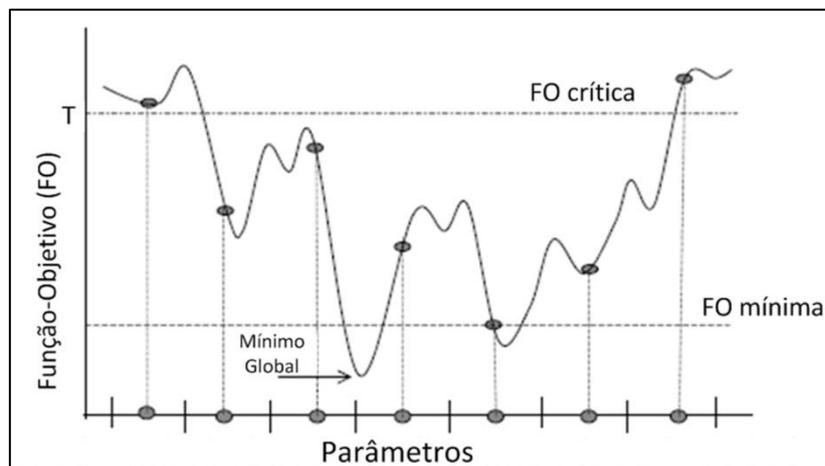
onde  $\tau_i$  é o valor do feromônio no estrato na variável analisada,  $FO_i$  é o valor da FO com base no caminho percorrido pela formiga  $i$ ,  $FO_{min}$  é o valor mínimo da FO da iteração, e  $FO_{crit}$  é o valor estabelecido para a FO crítica, conforme apresentado a seguir.

$$S_{(FO_{crit}=T)} = \frac{(\tau_{ac_{ij}})^{\alpha} \times (\sigma_{ij})^{\beta}}{\sum_i \left[ \sum_j (\tau_{ac_{ij}})^{\alpha} \times (\sigma_{ij})^{\beta} \right]} \quad (16)$$

$$\beta = C_{\beta} \times \frac{\sigma_{ij}}{\mu_{ij}} \quad (17)$$

$$T = FO_{\min} + CT \times \frac{\sigma_{FO}}{\mu_{FO}} \quad (18)$$

onde S é o score que serve de base para o posicionamento inicial das formigas no próximo ciclo;  $\tau_{ac_{ij}}$  representa o total de feromônio acumulado no estrato j do parâmetro i;  $\sigma_{ij}$  é o valor do desvio padrão da função-objetivo no estrato j do parâmetro i; os parâmetros  $\alpha=1, \beta, T$  são para controlar a influência ou peso relativo dentro do score dos valores de  $\tau_{ac_{ij}}$ ,  $\sigma_{ij}$  e a  $FO_{crit}$ , respectivamente, onde  $FO_{crit}$  (Figura 17) é o valor crítico da FO, que é estabelecido pelo usuário para cada caso.



**Figura 17.** Ilustração do comportamento da FO crítica. Adaptado de Abbaspour *et al.* (2001).

Os fatores de ponderação são parâmetros próprios do método, e eles são o peso dado ao feromônio e o peso dado à visão, que serão utilizados tanto na transição das formigas de um estrato para outro como no score, que define as probabilidades de cada estrato ser o escolhido pelas formigas durante sua movimentação.

Os valores de  $C_{\beta}$  e  $CT$  são constantes do método associadas a  $N$  e  $T$ , respectivamente. Os valores sugeridos para estes parâmetros foram  $C_{\beta} = 0,3$  e  $CT = 0,5$ ; os quais foram definidos pelos autores após diversos testes. Os valores de  $\sigma_{FO}$  e  $\mu_{FO}$  representam o desvio padrão e a média aritmética da FO para cada ciclo. O valor do score no estrato determina como será feita a distribuição das formigas nos estratos da primeira variável de decisão, antes de iniciar o segundo ciclo. A partir do segundo ciclo, a probabilidade de um estrato de qualquer variável ser escolhido dependerá do valor dado pelo score obtido no ciclo anterior.

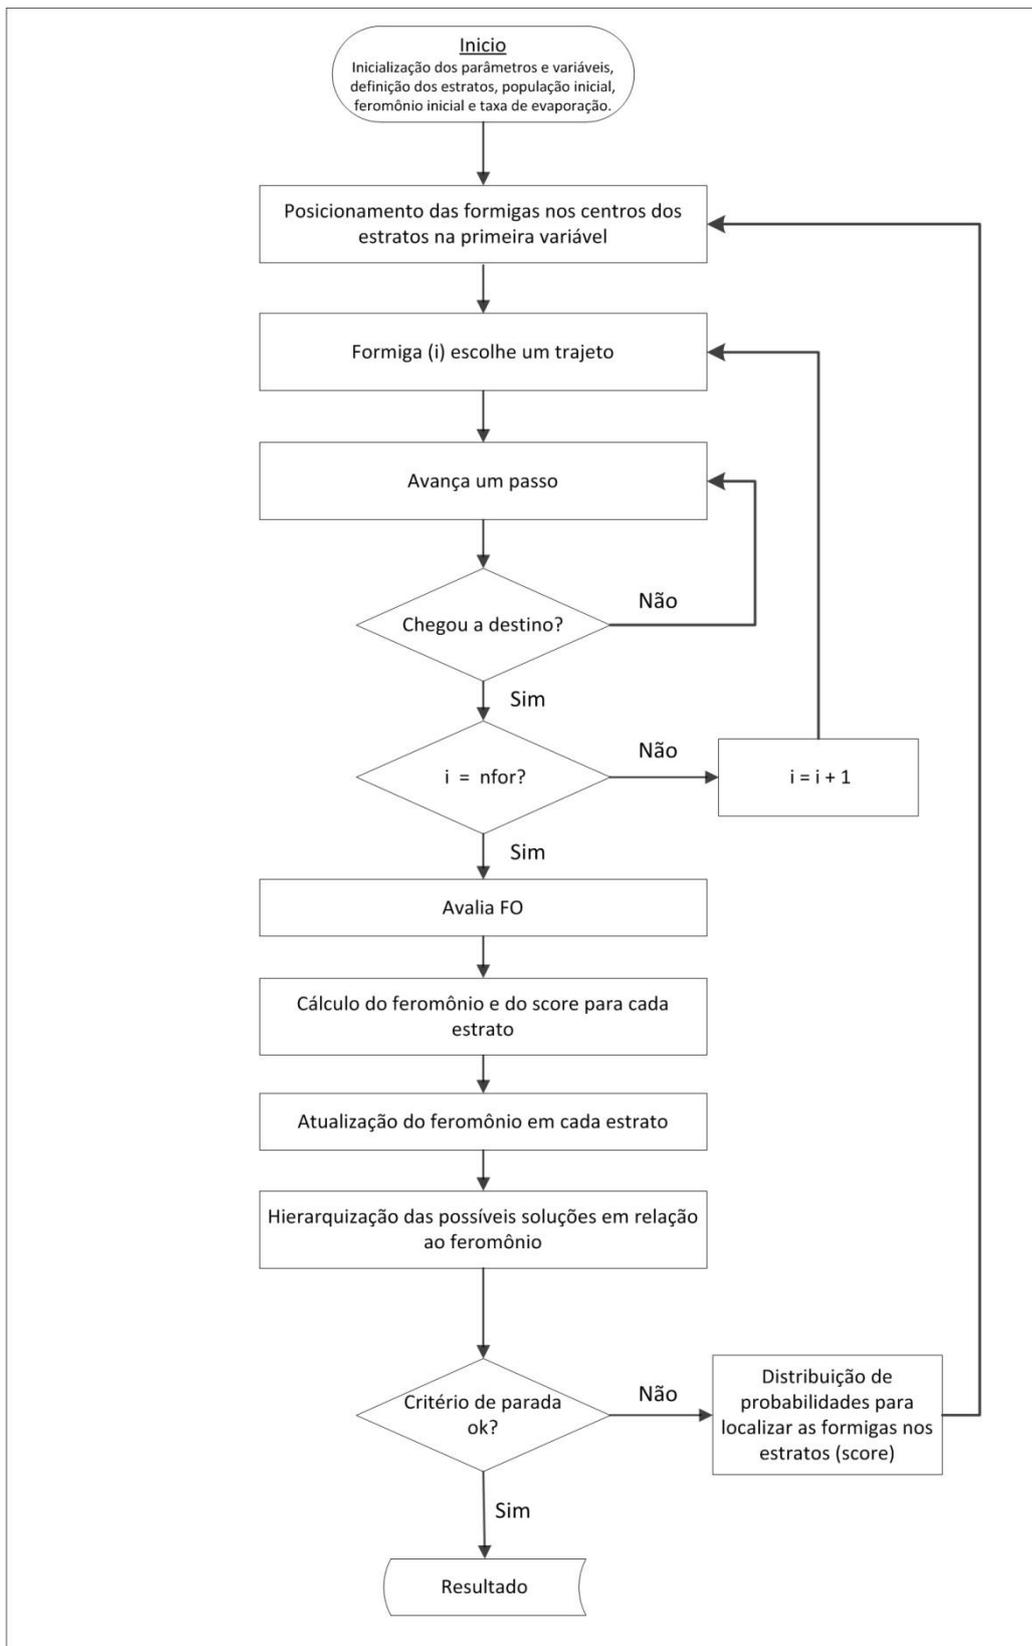
Especificamente em relação à FO crítica, ela é atualizada automaticamente em cada iteração, mas o usuário insere o seu valor inicial. A medida em que o algoritmo vai convergindo, a diminuição do valor da FO crítica faz com que apenas as melhores soluções recebam incremento de feromônio. A Tabela 1 mostra um exemplo do resultado obtido na estimativa do feromônio com a equação 15 com base em diferentes valores de FO crítica e para valores diferentes da FO obtida pelas formigas.

**Tabela 1.** Atualização automática e efeito da FO crítica

		FO crítica											
		200	150	100	50	25	10	5	1,5	1,2	1,1	1,05	
FO ótima	20	64,12	55,34	41,15	16,72	2,61	0,01	0,00	0,00	0,00	0,00	0,00	0,00
	15	71,98	64,57	51,91	26,73	6,80	0,08	0,00	0,00	0,00	0,00	0,00	0,00
	10	80,80	75,35	65,48	42,74	17,73	1,00	0,00	0,00	0,00	0,00	0,00	0,00
	5	90,70	87,93	82,61	68,34	46,22	12,88	1,00	0,00	0,00	0,00	0,00	0,00
	4	92,82	90,68	86,54	75,07	55,98	21,47	3,16	0,00	0,00	0,00	0,00	0,00
	3	94,99	93,53	90,66	82,45	67,81	35,79	9,97	0,00	0,00	0,00	0,00	0,00
	2	97,21	96,46	94,97	90,57	82,13	59,67	31,50	0,01	0,00	0,00	0,00	0,00
	1,8	97,66	97,06	95,85	92,29	85,34	66,10	39,65	0,06	0,00	0,00	0,00	0,00
	1,5	98,34	97,96	97,20	94,92	90,39	77,05	55,98	1,00	0,00	0,00	0,00	0,00
	1,3	98,80	98,57	98,11	96,72	93,93	85,34	70,46	6,30	0,10	0,00	0,00	0,00
	1,1	99,25	99,18	99,02	98,55	97,60	94,53	88,68	39,65	9,97	1,00	0,01	0,01
	1,05	99,37	99,33	99,25	99,02	98,54	96,97	93,93	62,80	31,50	9,97	1,00	1,00
	1	99,48	99,48	99,48	99,48	99,48	99,48	99,48	99,48	99,48	99,48	99,48	99,48

Uma vez obtidos os valores da FO de cada formiga e calculados a quantidade de feromônio e o score, as formigas iniciam um novo ciclo, mas desta vez com uma distribuição calculada a partir do score, sendo que os estratos com maior valor do score tem maior probabilidade de serem escolhidos. A partir daqui, esse processo, mostrado na Figura 18 é repetido até atingir algum critério de parada estabelecido como uma das condições iniciais na inicialização do problema.

O número de estratos ou subdivisões das variáveis de decisão é tão importante quanto o número de formigas, pois como elas vão do centro do estrato de uma variável ao centro do estrato da seguinte, quanto menor o valor, mais próximo estaremos do valor ótimo do estrato. Esta discretização também deve ser feita com parcimônia, pois uma estratificação exagerada só aumenta o tempo de processamento sem trazer melhores resultados.



**Figura 18.** Fluxograma do algoritmo ACO-IM.

Têm-se outras variações de ACO, como por exemplo:

- Múltiplas Colônias de Formigas (MACO), utilizado para equilíbrio de carga em roteamento (Sim e Sun, 2003).
- ACS/GA, utilizado para equilíbrio de carga em roteamento (Sim e Sun, 2003).
- A rede de formigas (AntNet) utilizado para equilíbrio de carga em roteamento (Sim e Sun, 2003)
- Algoritmo de otimização contínua com colônia de formigas (CACO), utilizado em problema de otimização de operação de múltiplos reservatórios em simultâneo (Jalali *et al.*, 2007).
- Algoritmo híbrido baseado na busca da abelha e a colônia de formigas (Beam-ACO), utilizado para achar o mínimo global em quadros de vários níveis (Blum, 2005)
- Algoritmo híbrido ACO/Simplex, também chamado de algoritmo de interação contínua de colônia de formigas (CIAC), aplicado em problemas de otimização contínua (Dreo e Siarry, 2006).
- Busca de mínimo global em funções contínuas (Toksari 2006).

## 4 - METODOLOGIA

A metodologia desse trabalho é baseada no desenvolvimento de um algoritmo matemático para a calibração automática de modelos hidrológicos. No entanto, em uma etapa inicial este foi testado em funções matemáticas com ótimos conhecidos para posteriormente passar à calibração automática. Nesse sentido, o procedimento metodológico foi dividido em cinco etapas apresentadas a seguir:

- 1) Desenvolvimento do algoritmo ACO-IPH.
- 2) Testes em funções matemáticas com ótimos conhecidos.
- 3) Calibração de modelo hidrológico concentrado utilizando série sintética de vazões.
- 4) Calibração de modelo hidrológico concentrado utilizando séries reais de vazões.
- 5) Medidas de eficácia e eficiência.

### 4.1- Algoritmo ACO-IPH

O algoritmo desenvolvido nesse trabalho é baseado no ACO-IM apresentado por Abbaspour *et al.* (2001), que foi o primeiro a aplicar estas metodologias na calibração automática de modelos na área de recursos hídricos.

O algoritmo aqui apresentado foi denominado ACO-IPH e utiliza as mesmas equações e estrutura geral do ACO-IM, conforme apresentado a seguir, mas agregando uma rotina com operador de elitismo e uma rotina de refinamento da estratificação. Ambos os algoritmos utilizados neste trabalho foram escritos na linguagem Fortran.

As etapas do ACO-IPH são:

(1) Inicialização do problema, onde cada formiga é localizada aleatoriamente seguindo uma distribuição uniforme nos nós de início, localizados nos centros dos estratos da primeira variável e é estabelecido o valor inicial do conteúdo de feromônio, uniforme em todo o espaço de busca.

Na primeira iteração, as formigas são distribuídas de forma aleatória, seguindo uma distribuição uniforme, nos centros dos estratos (denominados pontos de partida), e elas podem ir desse ponto a qualquer outro ponto na variável seguinte, até chegar à última variável.

(2) Movimentação das formigas para os outros nós (centros dos estratos), onde após percorrer todo seu caminho, cada formiga salva o valor da FO associada ao seu trajeto.

Uma vez que as formigas estejam todas posicionadas, elas percorrem caminhos de centro de estrato a centro de estrato, até chegar à última variável de decisão. Com o

conhecimento do caminho percorrido por uma formiga, é obtido o valor da função-objetivo, e a partir dessa informação é calculada a quantidade de feromônio a depositar nesse estrato e o score.

(3) Atualização do conteúdo de feromônio seguindo a equação 19, e cálculo do score, denotado pela letra S e calculado por meio da equação 20, ambos os valores diretamente ligados à FO.

$$\tau_i = \begin{cases} \exp\left(4.6\left(\frac{FO_i - FO_{crit}}{FO_{min} - FO_{crit}}\right)\right) & \dots\dots\dots FO_i \leq FO_{crit} \\ 0 & \dots\dots\dots FO_i > FO_{crit} \end{cases} \quad (19)$$

onde  $\tau_i$  é o valor do feromônio no estrato na variável analisada,  $FO_i$  é o valor da FO com base no caminho percorrido pela formiga i,  $FO_{min}$  é o valor mínimo da FO da iteração, e  $FO_{crit}$  é o valor estabelecido para a FO crítica, conforme apresentado a seguir.

$$S_{(FO_{crit}=T)} = \frac{(\tau_{ac,ij})^\alpha \times (\sigma_{ij})^\beta}{\sum_i \left[ \sum_j (\tau_{ac,ij})^\alpha \times (\sigma_{ij})^\beta \right]} \quad (20)$$

$$\beta = C_\beta \times \frac{\sigma_{ij}}{\mu_{ij}} \quad (21)$$

$$T = FO_{min} + CT \times \frac{\sigma_{FO}}{\mu_{FO}} \quad (22)$$

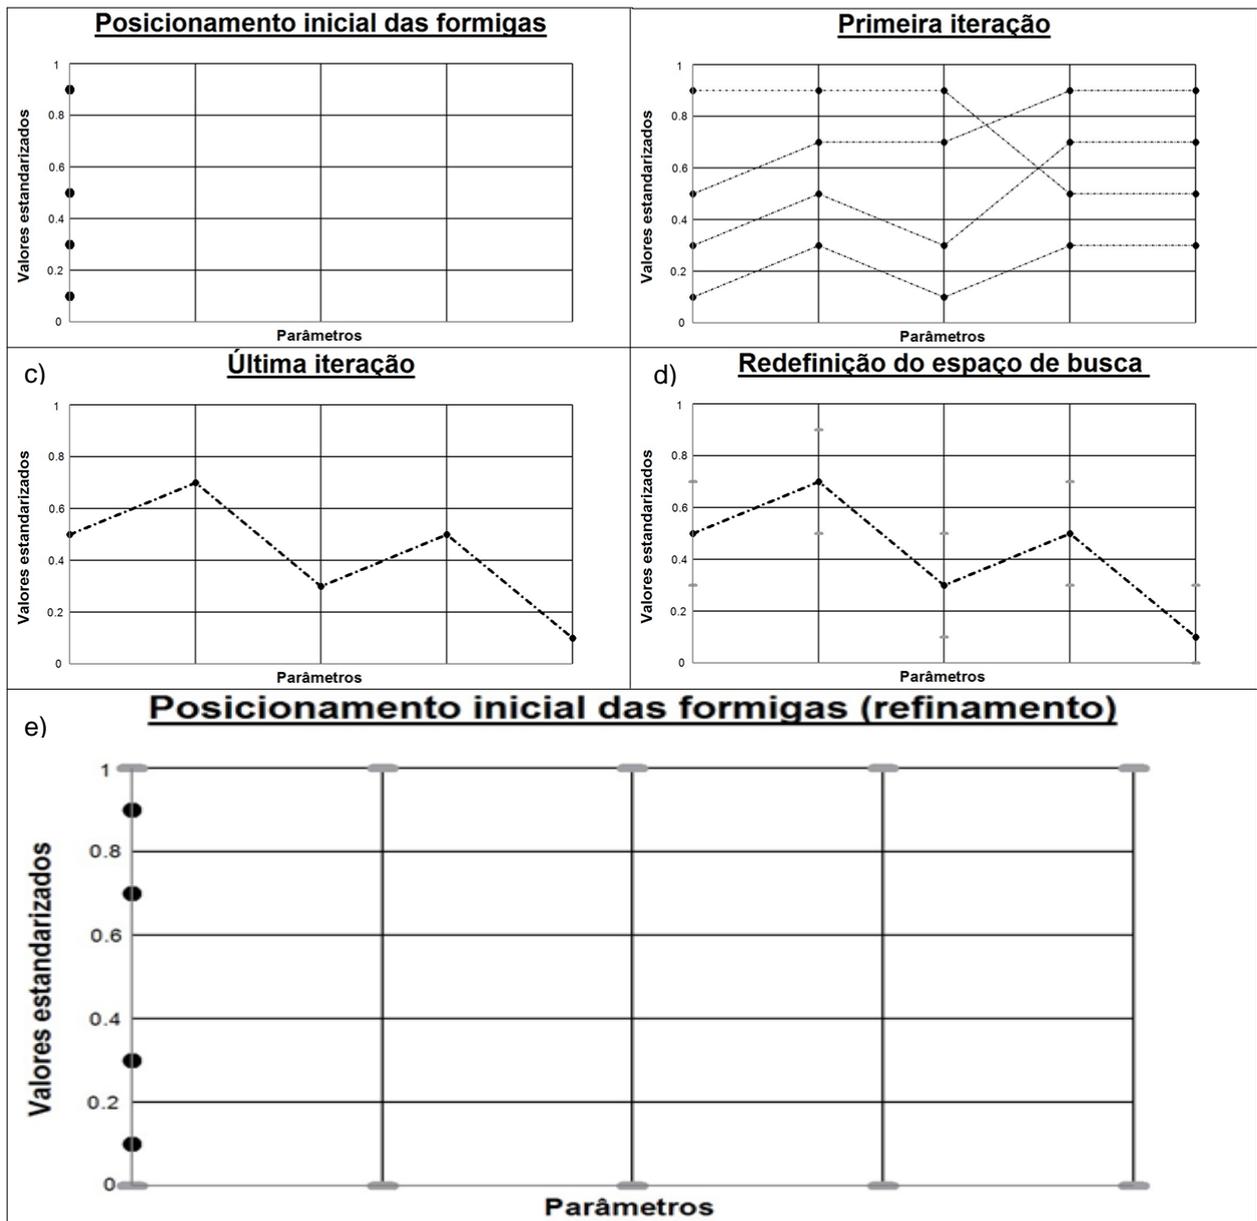
onde S é o score que serve de base para o posicionamento inicial das formigas no próximo ciclo;  $\tau_{ac,ij}$  representa o total de feromônio acumulado no estrato j do parâmetro i;  $\sigma_{ij}$  é o valor do desvio padrão da função-objetivo no estrato j do parâmetro i; os parâmetros  $\alpha=1, \beta, T$  controlam a influência ou peso relativo dentro do score dos valores de  $\tau_{ac,ij}$ ,  $\sigma_{ij}$  e a  $FO_{crit}$ , respectivamente, onde  $FO_{crit}$  é o valor crítico da FO, que é estabelecido pelo usuário para cada caso.

(4) Elitismo: no algoritmo ACO-IPH foi implementado um operador de elitismo que salva o melhor resultado obtido em cada ciclo. Com o a rotina do elitismo se tem certeza que não é perdida a melhor solução de cada ciclo.

(5) Refinamento da estratificação inicial, que faz rodar o programa em um espaço de busca reduzido, onde uma vez obtida a convergência do algoritmo, é criado um novo espaço de busca, no interior do espaço de busca inicial, tendo como ponto central, o centro do estrato associado aos valores otimizados das variáveis de decisão encontrados no processo anterior e os limites, um estrato para cima e um para baixo (Figura 19). Um novo processo de otimização é iniciado neste novo espaço de busca. Com a rotina de refinamento damos uma rodada mais refinada para melhorar a solução, pois como se trabalha com números reais discretizados, estaríamos fazendo uma melhor discretização, melhorando assim o resultado.

a)

b)



**Figura 19.** Funcionamento da rotina de refinamento do ACO-IPH. a) Posicionamento inicial das formigas; b) Primeira iteração; c) Última iteração sem refinamento; d) Redefinição do espaço de busca; e) Início do refinamento com a primeira iteração no novo espaço de busca.

As duas etapas adicionais que o modelo ACO-IPH considera foram motivadas por ter-se observado, em testes preliminares com o ACO-IM: (1) a perda de boas soluções encontradas em ciclos intermediários, convergindo a soluções com desempenho inferior; e (2) a perda das soluções associadas ao ótimo global provocada pela estratificação do espaço de busca.

Em funções com ótimo global bem diferenciado dos ótimos locais, ou em funções cuja superfície de resposta apresenta mudanças suaves, a utilização do refinamento pode não melhorar o resultado obtido, mas em funções com ótimo global com valores muito próximos aos

ótimos locais, ou em funções cuja superfície de resposta varie bruscamente, este processo melhora os resultados. O fluxograma do ACO-IPH é apresentado na Figura 20.

O algoritmo desenvolvido pode ser considerado genérico em relação ao número de variáveis de decisão, pois pode ser utilizado em processos de otimização mono-objetivo com qualquer número de variáveis de decisão. Neste trabalho, ele será testado em duas funções matemáticas com duas variáveis de decisão e, posteriormente, acoplado ao modelo IPH II, que possui sete parâmetros, para executar um processo de calibração automática.

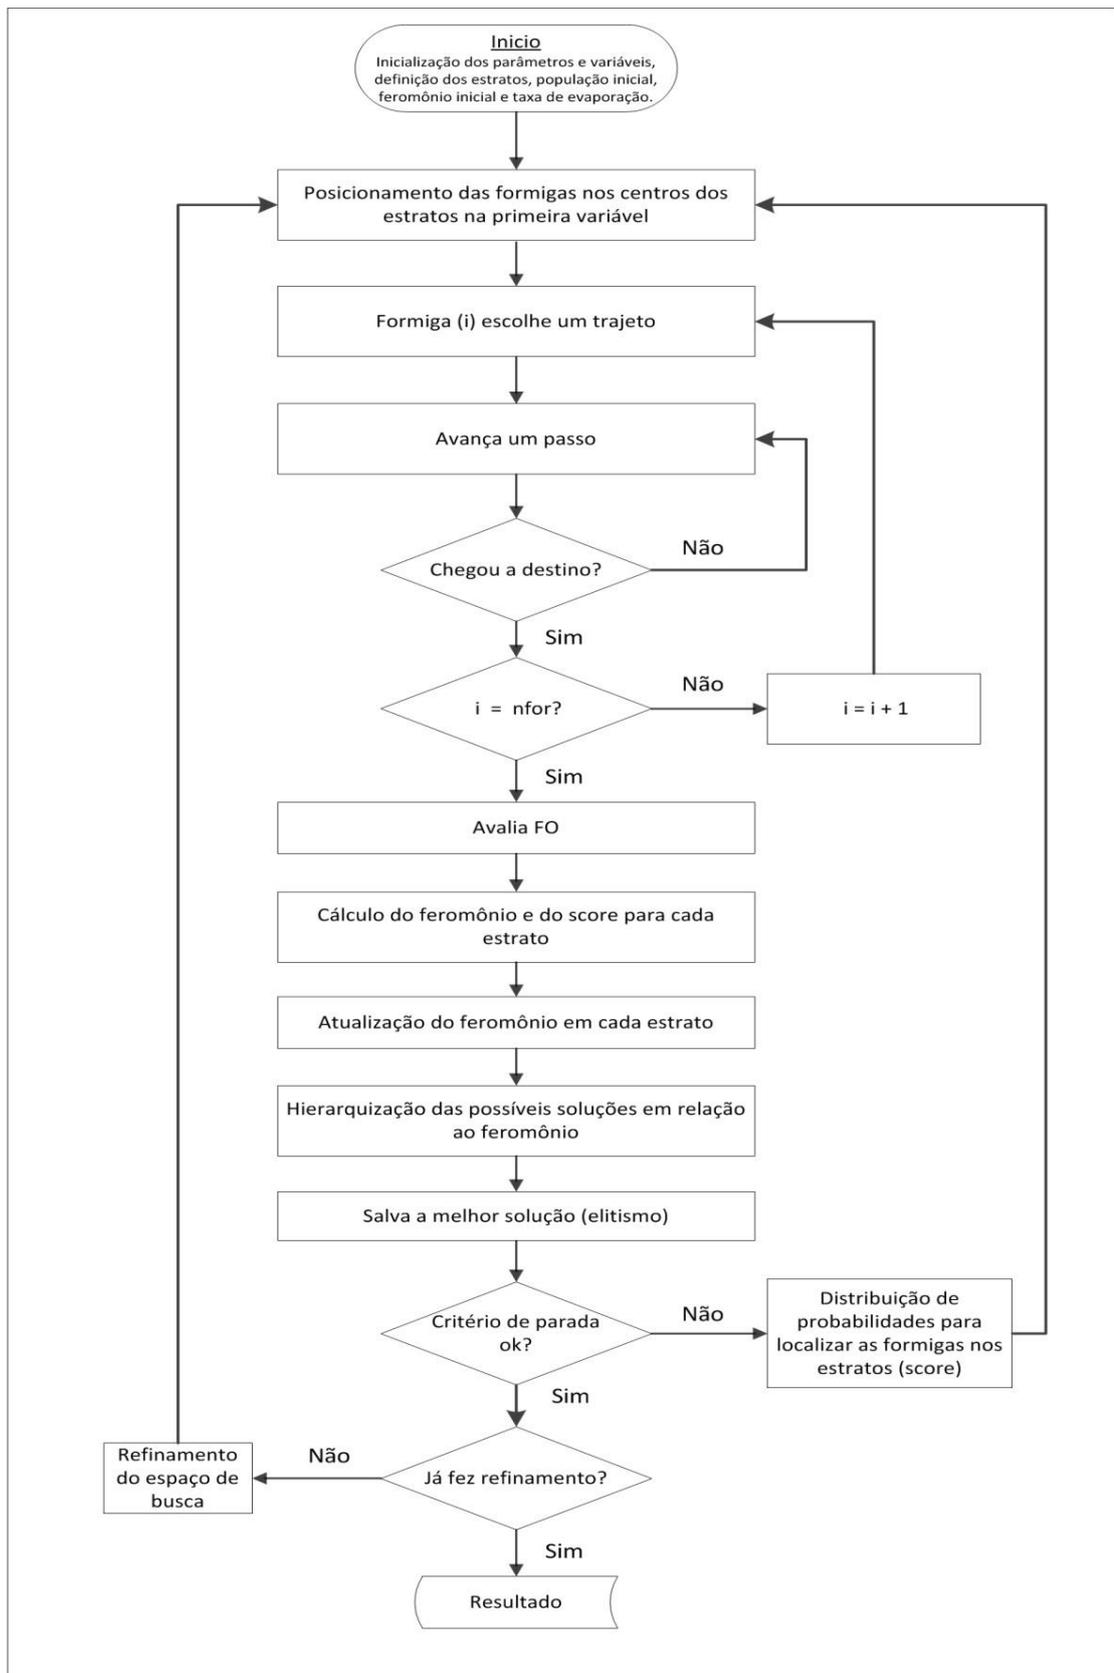


Figura 20. Fluxograma do algoritmo ACO-IPH.

#### 4.2- Testes em funções matemáticas com ótimos conhecidos

Uma vez desenvolvido o ACO-IPH, este foi testado inicialmente para duas funções matemáticas com duas variáveis de decisão e cujos valores ótimos são conhecidos, como a função de Hosaki e a função de Schaffer, respectivamente.

A função de Hosaki é uma função bidimensional ( $X_1$  e  $X_2$ ) não convexa que tem dois ótimos: um ótimo local (para  $X_1=1$  e  $X_2=2$ ) e um ótimo global ( $X_1=4$  e  $X_2=2$ ). Na continuação é apresentada a equação que descreve a função (equação 20) e uma figura em vista tridimensional (Figura 21) onde pode ser visualizada a forma da função e seus ótimos.

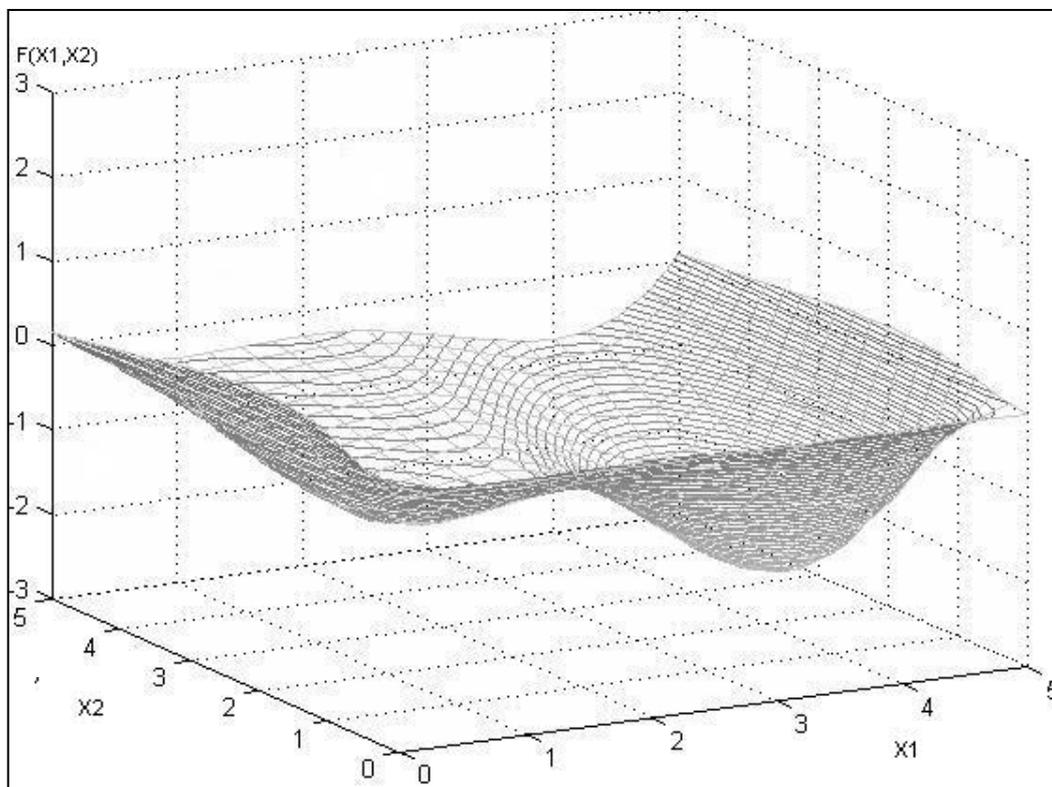
Acompanhando a equação que define a função, se encontram os limites do espaço de busca, que seriam todas possíveis combinações de valores que podem obter o par ordenado  $(X_1, X_2)$  dentro dos valores estipulados como restrições, e que determinam o valor da função de Hosaki, denotada como  $F(X_1, X_2)$

$$\text{minimizar } F(X_1, X_2) = \left(1 - 8X_1 + 7X_1^2 - \frac{7}{3}X_1^3 + \frac{1}{4}X_1^4\right) X_2^2 \cdot e^{-X_2} \quad (23)$$

sujeito a:

$$0 \leq X_1 \leq 5$$

$$0 \leq X_2 \leq 5$$



**Figura 21.** Gráfico tridimensional da função de Hosaki.

Supõe-se que a função de Hosaki teria um grau de dificuldade menor que a função de Schaffer, por possuir um ótimo local e o ótimo global bem diferenciados um do outro, bem diferente da função de Schaffer, apresentada na sequência, que possui muitos ótimos locais, bem próximos do ótimo global.

A função de Schaffer é uma função bidimensional ( $X_1$  e  $X_2$ ) multivariada que tem vários ótimos locais muito próximos entre si, e um ótimo global ( $X_1=0$  e  $X_2=0$ ). Na continuação é apresentada a equação que descreve a função (equação 21) e uma figura em vista tridimensional (Figura 22) onde pode ser visualizada a forma da função e seus ótimos.

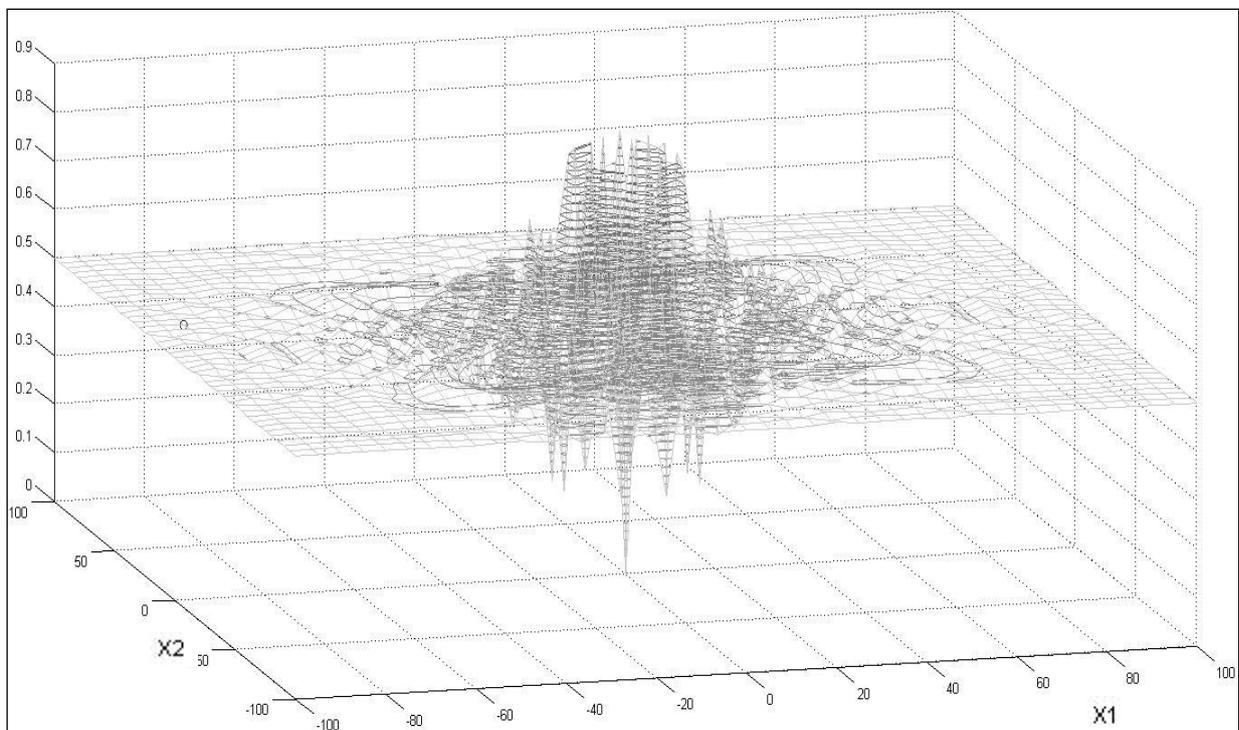
Acompanhando a equação que define a função, se encontram os limites do espaço de busca, que seriam todas as possíveis combinações de valores que podem obter o par ordenado ( $X_1, X_2$ ) dentro dos valores estipulados como restrições, e que determinam o valor da função de Hosaki, denotada como  $F(X_1, X_2)$

$$\text{mimizar} \quad F(X_1, X_2) = 0,5 + \frac{\left( \sin\left(\sqrt{X_1^2 + X_2^2}\right) - 0,5 \right)}{\left( 1 + 0,001 \times (X_1^2 + X_2^2) \right)^2} \quad (24)$$

sujeito a

$$-100 \leq X_1 \leq 100$$

$$-100 \leq X_2 \leq 100$$



**Figura 22.** Gráfico tridimensional da função de Schaffer.

Na função de Schaffer aumenta consideravelmente o grau de dificuldade na busca do ótimo global, pois existem vários ótimos locais muito próximos à ele, o que se espera que aconteça na busca de ótimo nas funções que serão analisadas na calibração automática do modelo hidrológico IPH II, pois tipicamente estas apresentam um comportamento semelhante.

Foram avaliadas 42 configurações possíveis entre diferentes combinações de números de formigas e número de estratos na resolução dos problemas de otimização. Os valores testados de número de formigas foram 10, 50, 100, 500, 1000 e 5000, enquanto que o número de estratos considerado foi: 10, 50, 100, 500, 1000, 5000 e 10000.

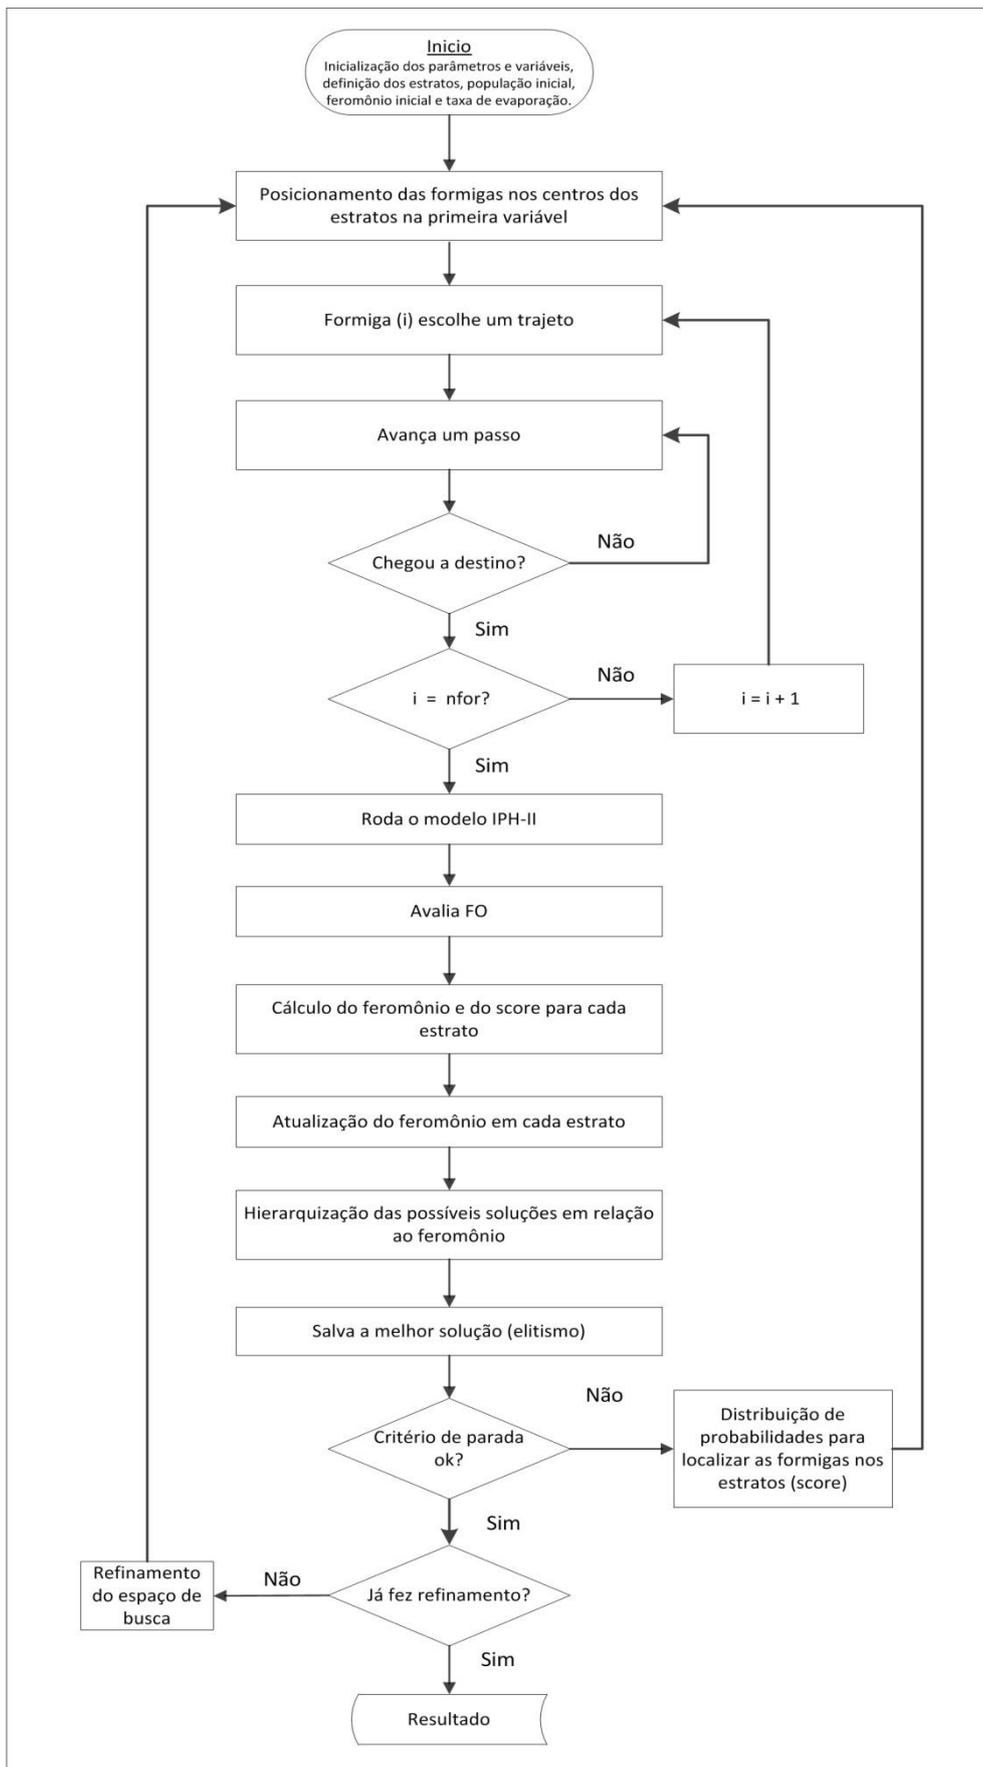
Para cada configuração foi estabelecido um número total de ciclos igual a 200. O processo de otimização com cada configuração foi repetido 100 vezes, e a partir desses resultados foram estimadas as medidas de eficácia e eficiência, apresentadas no item 4.5.

Para ambas as funções foram testados os algoritmos ACO-IM e ACO-IPH, e os resultados obtidos serão apresentados no capítulo 5.

#### **4.3- Acoplamento do ACO-IPH ao modelo hidrológico IPH-II**

Após ser testado nas funções matemáticas, o ACO-IPH foi acoplado ao modelo IPH II, que possui sete parâmetros, conforme apresentado no fluxograma da Figura 23.

Em relação à maneira com que o caminho das formigas é definido, o conceito é igual ao mencionado anteriormente. Nesse sentido, as formigas definem o seu caminho partindo dos valores estratificados do parâmetro  $I_0$  do modelo IPH II, seguindo para os parâmetros  $I_b - H - K_s - K_{sub} - R_{max}$  e finalmente encontram a fonte de comida nos estratos do parâmetro  $\alpha$ . Foram feitos testes preliminares quanto à alteração da sequência dos diferentes parâmetros do modelo IPH II, não produzindo alterações nos resultados, por isso decidiu-se utilizar a sequência  $I_0 - I_b - H - K_s - K_{sub} - R_{max} - \alpha$ . Esta é a sequência em que é feita a calibração automática no modelo IPH-II com interface gráfica: WIN\_IPH2.



**Figura 23.** Fluxograma do acoplamento do algoritmo ACO-IPH ao modelo IPH-II.

#### 4.4- Calibração automática de modelo hidrológico

O algoritmo ACO-IPH acoplado ao modelo IPH II foi posteriormente testado em diferentes processos de calibração automática. O primeiro conjunto de testes efetuados é baseado no uso de séries de vazões sintéticas. A série sintética é obtida executando o modelo, com os parâmetros fixos em valores escolhidos, e com uma série de dados pluviométricos e outra de dados de evaporação. Esta série gerada pelo modelo é, posteriormente, utilizada como série de vazões observadas para o procedimento de calibração. Ao considerar uma série sintética na calibração são eliminadas as incertezas nos dados e na capacidade de representação do modelo, restando somente a incerteza na calibração dos parâmetros. O segundo conjunto de testes utiliza as séries reais de vazões nos diferentes estudos de caso.

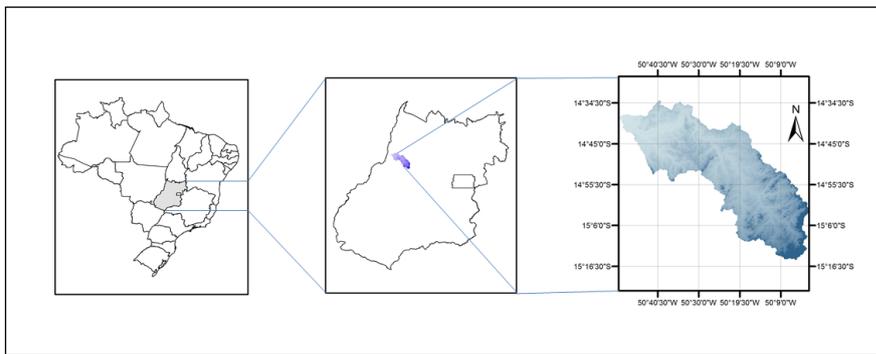
Em todas as análises foi ainda utilizado o algoritmo SCE-UA para comparação do desempenho do ACO-IPH na calibração automática do modelo IPH II. Por fim, os estudos de caso são baseados nos dados de quatro bacias hidrográficas, descritas a seguir.

##### 4.4.1- Estudos de casos

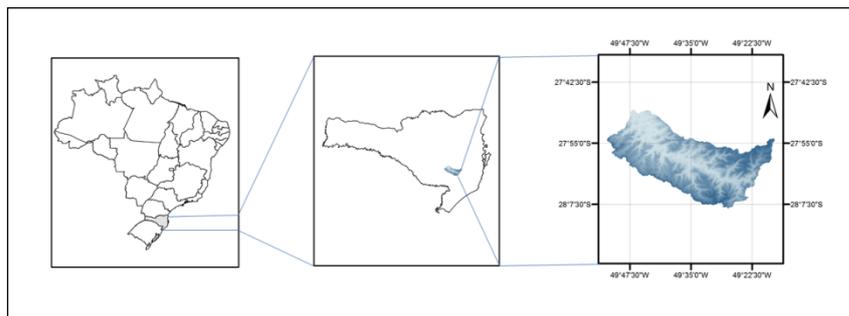
Foram escolhidos quatro estudos de caso para testar o desempenho do ACO-IPH acoplado ao modelo hidrológico IPH II (Tabela 2): a bacia do Rio Tesouras, localizada no estado de Goiás, mas desta vez com serie real e não serie sintética (ver Figura 24), a bacia do Rio Canoas, localizada no estado de Santa Catarina (ver Figura 25), a bacia do Rio Itu, localizada no estado do Rio Grande do Sul (ver Figura 26), e, a bacia do Rio Preto, localizada no estado de Bahia (ver Figura 27).

**Tabela 2.** Bacias utilizadas na calibração automática com o algoritmo ACO-IPH. Fonte: Hidroweb.

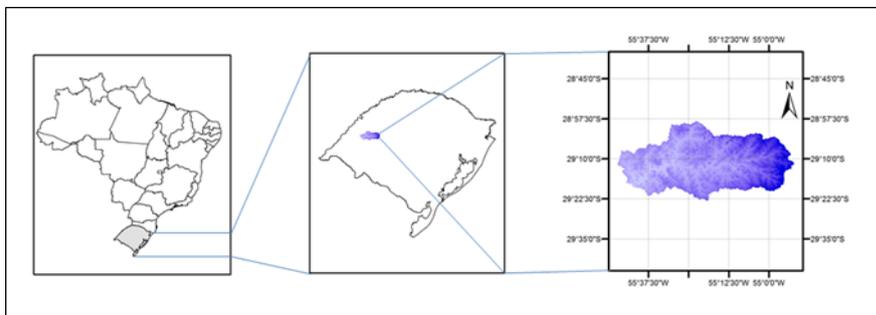
Bacia Hidrográfica	Estado	Área (km <sup>2</sup> )	Registros	Período analisado	Posto Fluviométrico	Postos Pluviométricos	Cidades que abrange
Bacia do Rio Tesouras	GO	1817	1826	1982-1986	25500000	1549004, 1450001, 1450001, 1451000, 1450000	Crixás, Nova Crixás, Cocalinho, Mozarlândia, Rubiataba, Nova América, Fainá e Aruana
Bacia do Rio Itu	RS	2564	2319	1978-1984	76650000	2955002, 2955007, 2955014, 2954020	Itaqui, Manoel Viana, São Francisco de Assis, Macambara, Unistalda e Santiago
Bacia do Rio Canoas	SC	1011	2191	1978-1983	71200000	2849021, 2849023, 2749031	Urubici, Rio Rufino e Bom Retiro
Bacia do Rio Preto	BA	346	2557	1973-1980	51840000	1339014, 1339018, 1339028	Jaguaquara, Itaquara, Cravolândia e Ubaíra



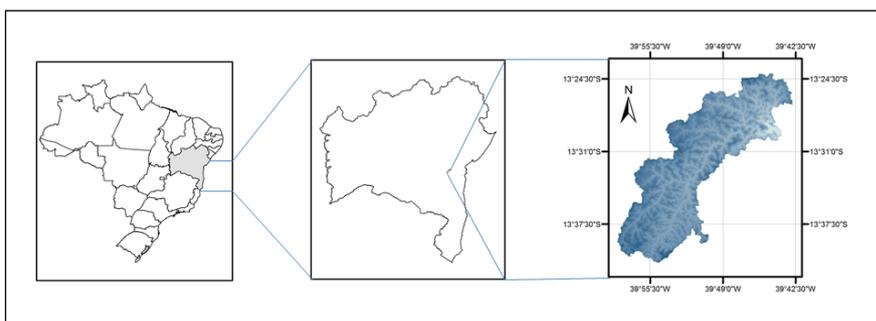
**Figura 24.** Bacia do Rio Tesouras – GO



**Figura 25.** Bacia do Rio Canoas – SC



**Figura 26.** Bacia do Rio Itu – RS



**Figura 27.** Bacia do Rio Preto – BA

#### 4.4.2- Funções-objetivo

Três medidas de desempenho foram disponibilizadas para serem escolhidas durante o processo de calibração, o coeficiente de eficiência de Klinge-Gupta (KGE), o coeficiente de Nash-Sutcliffe (NS) e o Inverso das Vazões (IQ), conforme apresentadas pelas equações 25 a 27, a seguir:

$$\text{minimizar } KGE = 1 - ED \quad (25)$$

$$\text{para: } ED = \sqrt{(r-1)^2 + (a-1)^2 + (b-1)^2}; \quad r = \frac{\text{cov}(Q_c - Q_o)}{\sigma_c \times \sigma_o}; \quad b = \frac{\mu_c}{\mu_o}; \quad a = \frac{\sigma_c}{\sigma_o}$$

onde  $-\infty < KGE \leq 1$ ; ED representa a distância euclidiana até o ponto ideal; r é o coeficiente de correlação entre as vazões calculadas e observadas;  $\text{cov}(Q_c - Q_o)$  representa a covariância entre vazões calculadas ( $Q_c$ ) e observadas ( $Q_o$ ); b representa a relação entre a média das vazões calculadas ( $\mu_c$ ) e a média das vazões observadas ( $\mu_o$ ); e a representa a relação entre o desvio padrão das vazões calculadas ( $\sigma_c$ ) e o desvio padrão das vazões observadas ( $\sigma_o$ ).

$$\text{minimizar } NS = 1 - \frac{\sum_{t=1}^n (Q_o(t) - Q_c(t))^2}{\sum_{t=1}^n (Q_o(t) - \bar{Q}_o)^2} \quad (26)$$

onde  $-\infty < NS \leq 1$ ;  $Q_o$  é a vazão observada no instante t,  $Q_c$  é a vazão calculada no instante t;  $\bar{Q}_o$  é a média das vazões observadas, n representa os intervalos de tempo; e n é o número de intervalos de tempo.

$$\text{minimizar } IQ = \sqrt{\frac{\sum_{t=1}^n \left( \frac{1}{Q_o(t)} - \frac{1}{Q_c(t)} \right)^2}{n}} \quad (27)$$

onde  $-\infty < IQ < +\infty$ ;  $Q_o$  é a vazão observada no instante t;  $Q_c$  é a vazão calculada no instante t; n representa os intervalos de tempo; e n é o número de intervalos de tempo.

#### 4.4.3- Calibração automática com série sintética de vazões

Durante a calibração automática com série sintética de vazões foram avaliadas, no ACO-IPH, 25 combinações possíveis de números de formigas e número de estratos, sendo organizados assim: número de formigas: 500-1500-3000-4000-5000; e número de estratos: 100-500-1000-1500-2000. No caso do SCE-UA foram avaliadas as combinações seguintes: se mantiveram constantes o número de complexos em 20 e o número de gerações em 200; b)

para a população de indivíduos por complexo foram atribuídos os seguintes valores: 25-75-150-200-250.

Para cada combinação foi estabelecido que todas as formigas realizariam 200 ciclos, e foi escolhido que se repetiria esse processo 100 vezes, e a partir desses resultados foram feitas as avaliações das medidas de eficácia e eficiência, explicadas na sequência.

Para ambos os algoritmos foram comparados os valores das FO e dos parâmetros obtidos durante a calibração automática. É esperado que em processos que utilizam séries sintéticas, os valores otimizados dos parâmetros correspondam àqueles que geraram a série inicialmente, e que qualquer função-objetivo baseada na minimização do erro apresente como resultado o valor igual à zero.

#### **4.4.4- Calibração automática com série real de vazões**

Como teste final do algoritmo ACO-IPH, foram escolhidas quatro bacias hidrográficas brasileiras, para a calibração automática do modelo hidrológico IPH II utilizando os dados reais. O modelo hidrológico IPH II também foi calibrado com o algoritmo SCE-UA para comparação dos resultados.

Em relação às medidas de eficácia e eficiência, e a avaliação da FO e os parâmetros do modelo hidrológico, foram utilizados os mesmos critérios e combinações que os mencionados no item anterior para a série sintética de vazões.

#### **4.5- Medidas de eficiência e eficácia do algoritmo**

Durante a aplicação dos diferentes algoritmos evolucionários utilizados neste trabalho, um conjunto de medidas de desempenho em termos de eficiência e eficácia foi estimado com o objetivo de identificar a melhor combinação dos valores dos parâmetros destes algoritmos para poder comparar os resultados. Quanto aos algoritmos baseados no comportamento de colônias de formigas, os parâmetros número de formigas na colônia e número de estratos foram avaliados.

Nas funções matemáticas foram avaliados, para o ACO-IM e para o ACO-IPH, os seguintes indicadores de desempenho: (1) tempo de convergência, que indica o tempo que a colônia de formigas demora em convergir para uma solução, deixando claro que nem sempre se trata do ótimo procurado; (2) convergência, que expõe quantas vezes, dos 100 testes, todas as formigas convergiram à mesma solução; (3) número de formigas com valor de FO de convergência, que indica de todas as formigas que chegaram a destino, quantas delas possuem o valor de FO tolerado; (4) percentagem de falhas, valor que dá, dos 100 processos de otimização executados, quantas vezes o algoritmo não convergiu para o verdadeiro ótimo

global; e (5) número de ciclos necessários até a convergência, que indica quantos ciclos são necessários até conseguir a convergência do algoritmo.

Nos casos das séries de vazões sintética e reais, foram avaliadas para o ACO-IPH e o SCE-UA as seguintes medidas de desempenho: (1) convergência, que expõe quantas vezes, dos 100 testes, todas as formigas (indivíduos para o caso do SCE-UA) chegaram a destino; (2) número de formigas (indivíduos) com valor de FO de convergência, que indica de todas as formigas (indivíduos) que chegaram a destino, a quantidade que possui o valor de FO tolerado; (3) tempo de convergência, valor que indica em que quantidade de tempo todas as formigas (indivíduos) fazem um trajeto de 200 ciclos; (4) número de ciclos necessários até a convergência, que indica quantos ciclos são necessários até conseguir a convergência do algoritmo.

## 5- RESULTADOS E DISCUSSÃO

O desempenho do algoritmo ACO-IPH foi inicialmente avaliado na minimização de duas funções matemáticas com ótimos conhecidos, sendo elas a função de Hosaki e a função de Schaffer. Posteriormente, o algoritmo ACO-IPH foi acoplado ao modelo hidrológico IPH II e teve seu desempenho avaliado no processo de calibração automática com base nos dados de quatro bacias brasileiras.

### 5.1- Avaliação de desempenho em funções matemáticas

A função de Hosaki é uma função bidimensional ( $X_1$  e  $X_2$ ) não convexa que tem dois mínimos: um mínimo local em  $X_1=1$  e  $X_2=2$ , com valor da função igual a  $-1,1278$ ; e um mínimo global em  $X_1=4$  e  $X_2=2$ , com valor da função igual a  $-2,3458$ ; no espaço de busca definido por  $0 \leq X_1 \leq 5$  e  $0 \leq X_2 \leq 5$ .

Para aplicar o algoritmo ACO-IPH na busca do ótimo global na função de Hosaki, ele foi inicializado com os seguintes valores apresentados na Tabela 3:

**Tabela 3.** Valores iniciais dos parâmetros do algoritmo ACO-IPH na função de Hosaki.

FO = Função de Hosaki	
Parâmetro	Valor
Número de testes	100
Número de ciclos	200
Feromônio crítico	1
FO crítica	3
A	1
CN	0,3
CT	0,5
Tolerância FO	5%
Tolerância da população com FO de convergência	5%

Depois de executados 100 processos de otimização com cada uma das configurações, foram avaliadas medidas de eficácia e eficiência na aplicação do algoritmo ACO-IM e ACO-IPH.

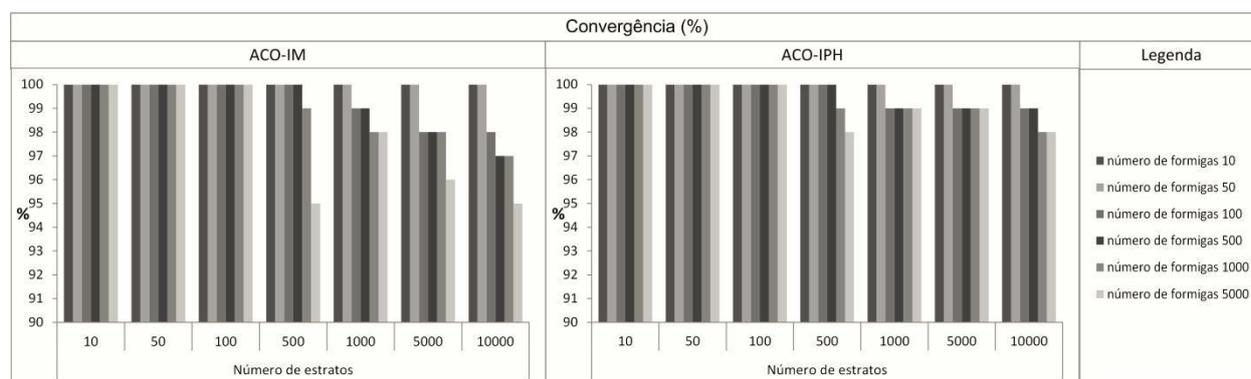
Em termos de convergência (Figura 28), que indica quantas vezes dos 100 testes a colônia de formigas converge para o mesmo valor de FO, não sendo necessariamente a FO ótima, o algoritmo ACO-IPH melhorou o desempenho em relação ao ACO-IM, a diferença é principalmente observada a partir dos 500 estratos, onde com o ACO-IM se apresenta uma diminuição de desempenho. Essa melhoria estaria sustentada na busca do ótimo num espaço de busca reduzido, aumentando a precisão, efeito causado pelo refinamento.

Este refinamento que aumenta o desempenho em relação à convergência também aumenta, como esperado, o tempo computacional do processo de otimização (Figura 29), pois o algoritmo roda uma vez no espaço de busca original e outra vez no espaço de busca refinado. Em ambos os algoritmos, a partir do uso de 1000 estratos se observa um aumento significativo do tempo computacional.

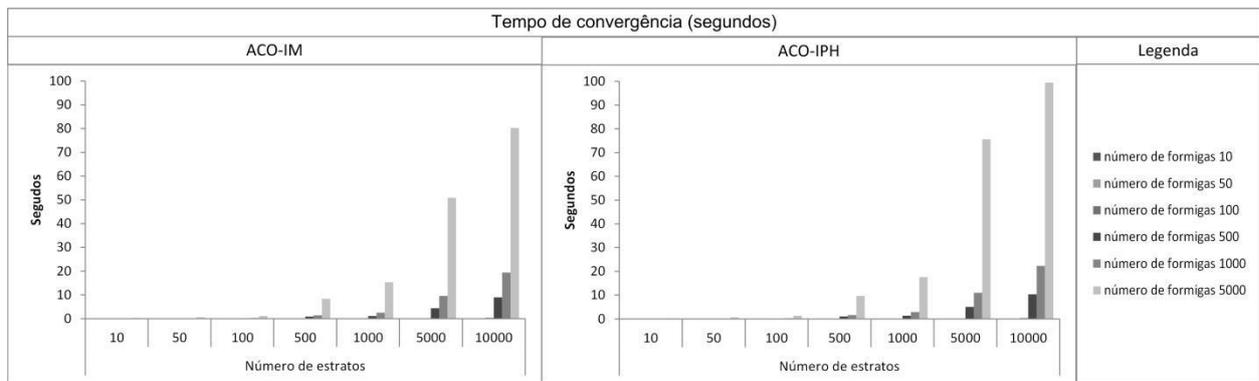
Em relação às falhas do algoritmo em encontrar o ótimo global (Figura 30), a implementação do ACO-IPH mostra uma melhoria importante na redução da porcentagem de falhas, principalmente nas altas estratificações, por exemplo, com 1000 estratos e 5000 formigas as falhas diminuíram de 50% para 17% em 100 processos avaliados. Considera-se apropriado esclarecer que para cada estratificação adotada, se tem o mínimo que pode ser achado com essa estratificação, sabendo que quanto mais estratificado o espaço de busca, maior a exigência solicitada.

Acompanhando a diminuição de falhas, encontra-se o número de ciclos necessários para atingir a convergência do algoritmo ACO-IPH (Figura 31), uma vez que, somando os ciclos da primeira rodada aos ciclos do refinamento, em todos os casos resultou em média dez vezes inferior à quantidade dos ciclos necessários com a ACO-IM. Atribui-se a rapidez da convergência na primeira rodada ao elitismo, e a segunda pela boa qualidade da primeira solução ótima obtida na primeira rodada. Esta diminuição na quantidade de iterações necessárias para lograr a convergência tem a sua contraparte no tempo de processamento, pois ele é ligeiramente maior.

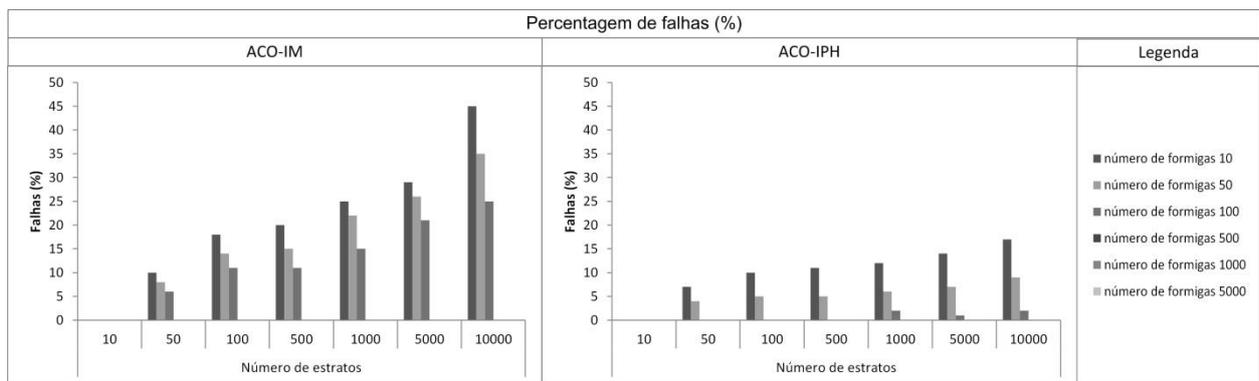
Em relação ao número de formigas com o valor de FO de convergência (Figura 32), que indica a FO tolerada, se observa um aumento não muito considerável, em relação à aplicação do ACO-IPH, deixando 100% em todas as configurações, sendo que a menor era de 98% no ACO-IM.



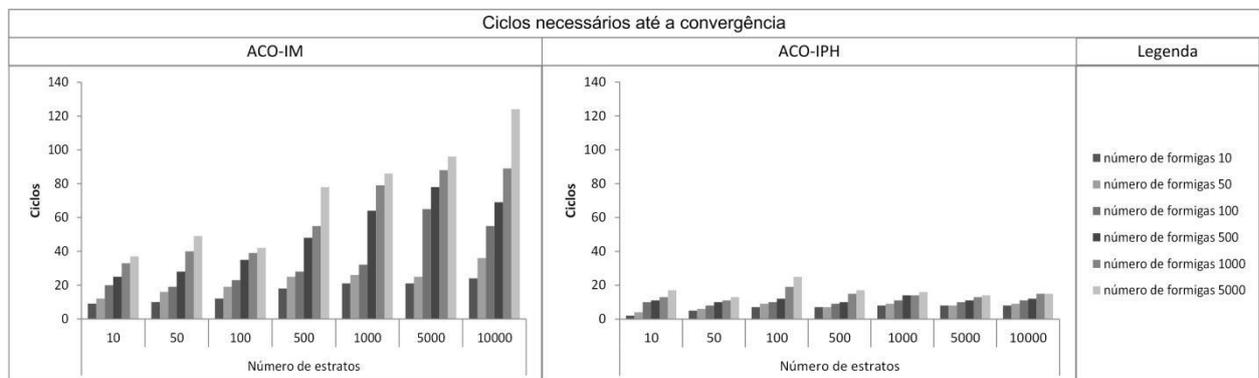
**Figura 28.** Porcentagem de convergência do algoritmo ACO-IM e ACO-IPH na função de Hosaki.



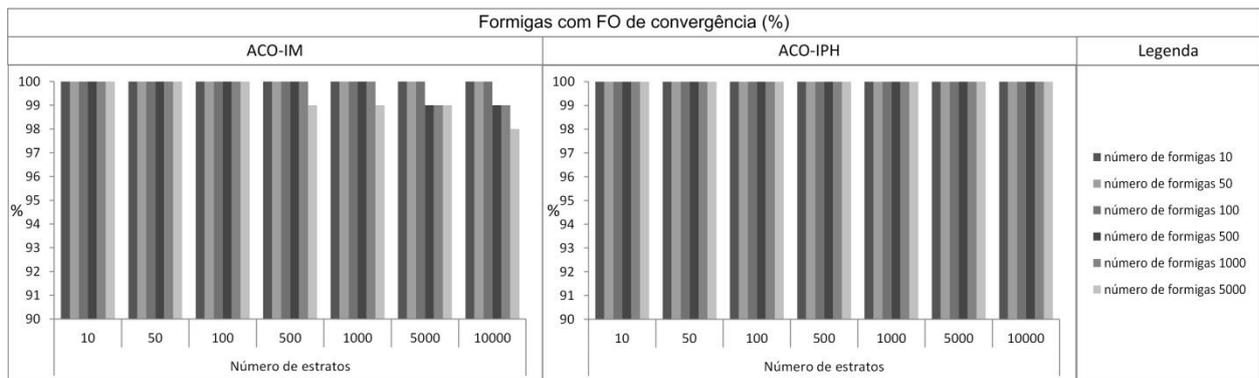
**Figura 29.** Tempo de convergência do algoritmo ACO-IM e ACO-IPH na função de Hosaki.



**Figura 30.** Percentagem de falhas dos algoritmos ACO-IM e ACO-IPH na função de Hosaki.



**Figura 31.** Ciclo de convergência do algoritmo ACO-IM e ACO-IPH na função de Hosaki.



**Figura 32.** Formigas com valor de FO de convergência para a função de Hosaki

O aumento da relação número de estratos – número de formigas (NE-NF), para ambos os algoritmos, aumenta a probabilidade de ser achado o verdadeiro mínimo global da função de Hosaki até o valor de 500 estratos e 100 formigas, mas depois dessa combinação se observa um aumento do tempo computacional até convergência com pequenas reduções nas percentagens de falhas.

Comparando o desempenho de ambos os algoritmos e com base nos resultados apresentados anteriormente para a função de Hosaki, a aplicação do ACO-IPH como alternativa do ACO-IM mostrou uma melhoria em termos de eficácia na aplicação da função de Hosaki, mas em detrimento aumentou, como esperado, o tempo de processamento.

Na sequência, foi analisado o desempenho de ambos os algoritmos na função de Schaffer, que apresenta um nível de dificuldade superior ao da função de Hosaki.

A função de Schaffer é uma função bidimensional ( $X_1$  e  $X_2$ ) que tem um grande número de mínimos locais próximos do mínimo global em  $X_1=0$  e  $X_2=0$ , com valor da função igual a zero, no espaço de busca definido por  $-100 \leq X_1 \leq 100$  e  $-100 \leq X_2 \leq 100$ .

Depois de executados 100 processos de otimização com cada uma das configurações, foram avaliadas medidas de eficácia e eficiência na aplicação do algoritmo ACO-IM e ACO-IPH à função de Schaffer.

Para aplicar o algoritmo ACO-IPH na busca do ótimo global na função de Schaffer, ele foi inicializado com os valores apresentados na Tabela 4:

**Tabela 4.** Valores iniciais dos parâmetros do algoritmo ACO-IPH na função de Schaffer.

<b>FO = Função de Schaffer</b>	
<b>Parâmetro</b>	<b>Valor</b>
Número de testes	100
Número de ciclos	200
Feromônio crítico	1
FO crítica	1
A	1
CN	0,3
CT	0,5
Tolerância FO	5%
Tolerância da população com FO de convergência	5%

Em termos de convergência (Figura 33), que indica quantas vezes dos 100 testes a colônia de formigas converge para o mesmo valor de FO, não sendo necessariamente a FO ótima, o algoritmo ACO-IPH melhorou significativamente o desempenho em relação ao ACO-IM, a diferença é observada principalmente a partir dos 100 estratos, onde com o ACO-IM se apresenta uma diminuição de desempenho, e nos 1000 estratos e 5000 formigas, onde se obteve só uma convergência com o ACO-IM, aumentando a 25 com o ACO-IPH. Esta melhoria está justificada na busca do ótimo em um espaço de busca reduzido, aumentando a precisão, efeito causado pelo refinamento.

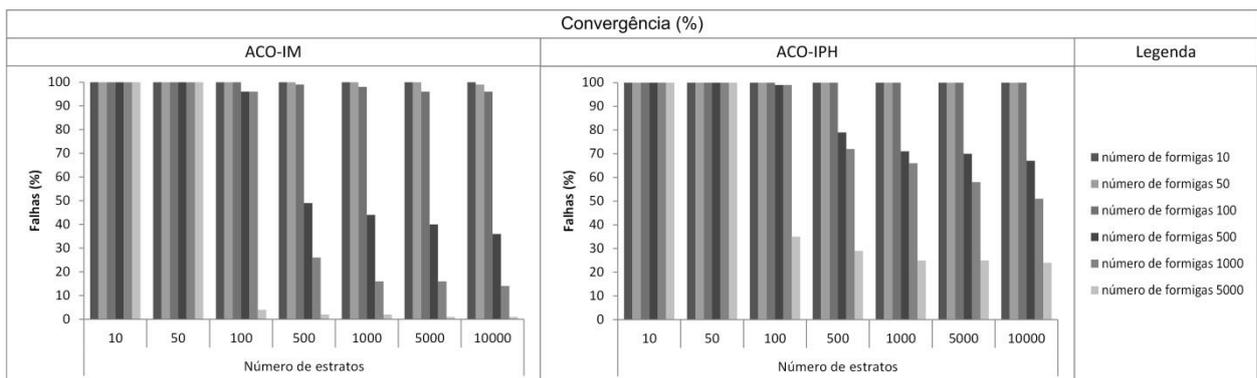
Este refinamento que aumenta o desempenho em relação à convergência também aumenta, como esperado, o tempo computacional do processo de otimização (Figura 34), pois o algoritmo roda uma vez no espaço de busca original e outra vez no espaço de busca refinado. Até os 500 estratos o tempo computacional é quase desprezível, mas a partir de 1000 estratos ele mostra um aumento considerável, chegando inclusive, na última configuração, a ser próximo de 200 segundos no caso ACO-IM e maior que 200 segundos no caso do ACO-IPH. Para cada configuração, em menor ou maior proporção, o ACO-IPH apresenta maior tempo de processamento.

Em relação às falhas do algoritmo em encontrar o ótimo global (Figura 35), a implementação do ACO-IPH mostra uma melhoria bem importante na redução das falhas, desde o primeiro até o último valor de estratificação avaliado. No caso do ACO-IM, este apresenta 100% de falhas em todas as estratificações, mas no caso do ACO-IPH se produz uma diminuição até perto de zerar, sendo que a maior percentagem de falhas é de 55% na configuração com 10 formigas.

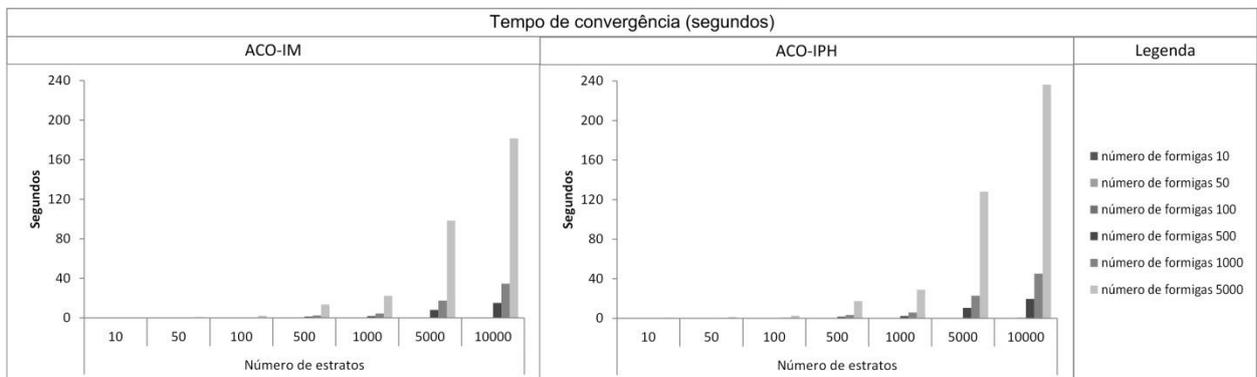
Assim como diminui o número de falhas, cai a quantidade de ciclos necessários para atingir a convergência do algoritmo ACO-IPH (Figura 36). Somando-se o número de ciclos da primeira rodada aos ciclos de refinamento, em todos os casos houve uma redução de até 50%

nas estratificações menores e de até 30% nas altas estratificações, em relação à quantidade dos ciclos necessários com o ACO-IM. Atribui-se a rapidez da convergência na primeira rodada ao elitismo, e a segunda à boa qualidade da primeira solução ótima obtida na primeira rodada. Pelo estilo da função, considera-se esta diminuição como um grande lucro em relação à diminuição, no entanto o tempo computacional demandado foi levemente maior.

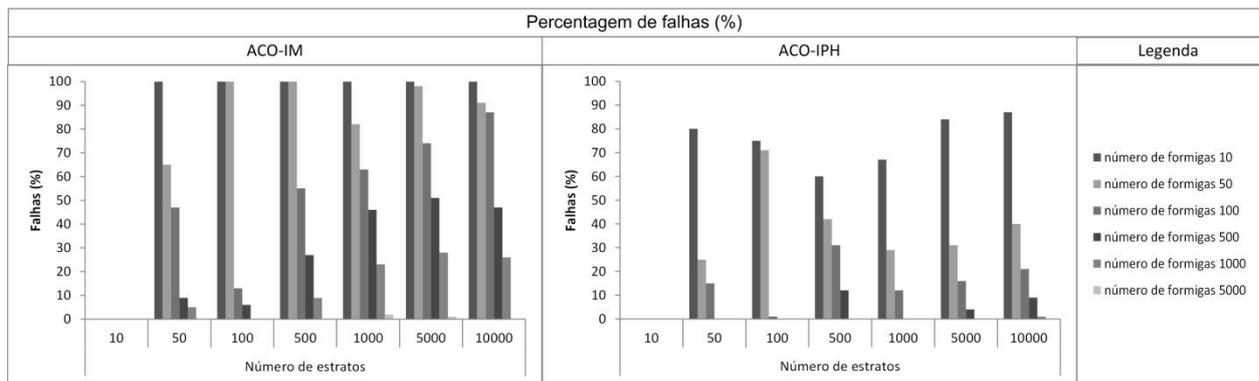
Em relação ao número de formigas com o valor de FO de convergência (Figura 37), que indica a FO tolerada, se observa um aumento considerável, com a aplicação do ACO-IPH, se mantendo acima de 80% da colônia em todas configurações, enquanto que no ACO-IM e considerando altas estratificações, este valor resultou inferior a 40%.



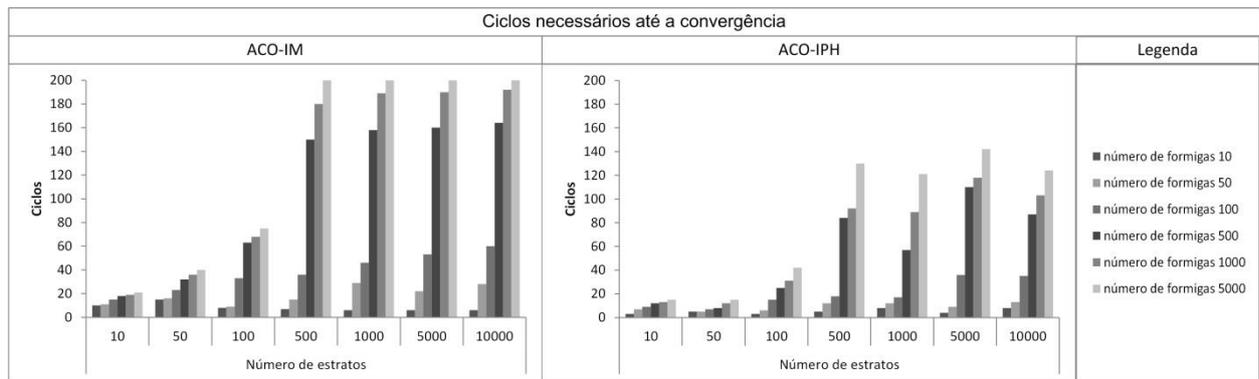
**Figura 33.** Percentagem de convergência dos algoritmos ACO-IM e ACO-IPH na função de Schaffer.



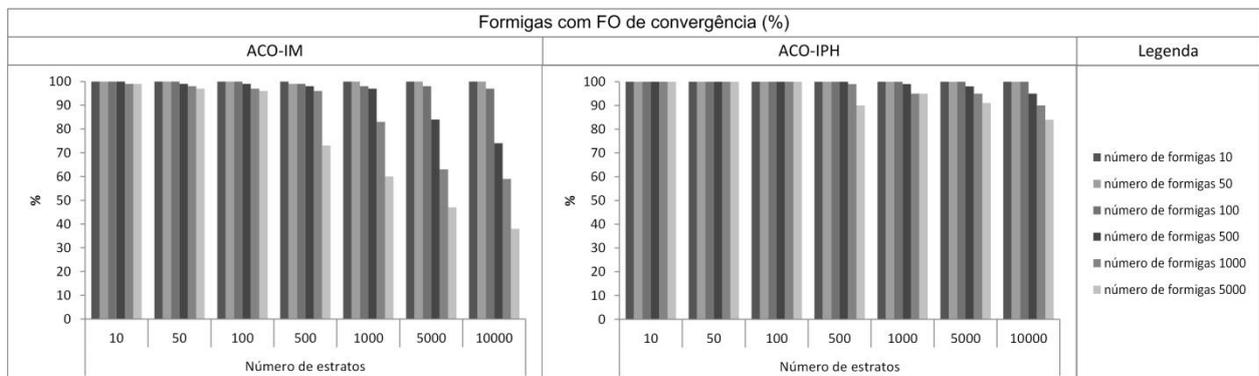
**Figura 34.** Tempo de convergência dos algoritmos ACO-IM e ACO-IPH na função de Schaffer.



**Figura 35.** Percentagem de falhas dos algoritmos ACO-IM e ACO-IPH na função de Schaffer.



**Figura 36.** Ciclo de convergência dos algoritmos ACO-IM e ACO-IPH na função de Schaffer.



**Figura 37.** Formigas com valor de FO de convergência nos algoritmos ACO-IM e ACO-IPH para a função de Schaffer.

Em função dos resultados apresentados previamente, as melhorias introduzidas no ACO-IM, dando origem ao ACO-IPH, produziram um leve aumento de desempenho, quando utilizado na resolução de problemas de otimização simples, como o caso da função de Hosaki. No entanto, o aumento de desempenho foi mais notório quando utilizado na resolução de

problemas mais complexos, como no caso da função de Schaffer, problemas que apresentam um superfície de resposta com características semelhantes às encontradas nas funções-objetivo utilizadas na calibração de modelos hidrológicos, com a existência de grande número de ótimos locais próximos ao ótimo global. Assim, o ACO-IPH foi o algoritmo escolhido para ser acoplado ao modelo hidrológico IPH II e testado na calibração automática mono-objetivo como uma alternativa de calibração ao algoritmo SCE-UA.

## 5.2- Avaliação de desempenho na calibração automática de modelo hidrológico

As funções-objetivo escolhidas para fazer os testes foram: 1) O coeficiente de eficiência de Kling-Gupta (KGE); 2) coeficiente de Nash-Sutcliffe (NS); e 3) Inverso das Vazões (IQ).

Como critério de comparação foi utilizado o algoritmo SCE-UA, já conhecido e testado, e sendo utilizado atualmente como única alternativa de calibração automática mono-objetivo no modelo WIN\_IPH2.

### 5.2.1- Considerando série sintética de vazões

A análise de série sintética foi produzida com base nos dados da bacia do rio Tesouras, localizado no estado de Goiás. Os parâmetros escolhidos para calibrar o modelo foram todos os possíveis, aos quais foram estabelecidos limites mínimos e máximos de variação, conforme a Tabela 5. A série sintética de vazões foi gerada a partir de um conjunto de dados de precipitação e evaporação, disponíveis em uma série real da bacia analisada. O intervalo de tempo foi o diário e o período considerado abrange cinco anos. Os valores dados aos sete parâmetros para gerar a série foram:  $I_0=50$ ;  $I_b=5$ ;  $H=0,5$ ;  $K_s=5$ ;  $K_{sub}=100$ ;  $R_{máx}=6$ ;  $\alpha=15$ .

**Tabela 5.** Limites mínimo e máximo dos parâmetros do modelo IPH II para calibração automática.

Parâmetro	Unidade de medida	Valor mínimo	Valor máximo
$I_0$	mm/ $\Delta t$	10	300
$I_b$	mm/ $\Delta t$	0,1	10
$H$	adimensional	0,01	0,999
$K_s$	$\Delta t$	10	10
$K_{sub}$	$\Delta t$	10	500
$R_{máx}$	mm	0	9
$\alpha$	adimensional	0,01	20

A série sintética foi utilizada posteriormente como a série de vazões observadas na calibração automática do modelo IPH II utilizando os algoritmos ACO-IPH e SCE-UA. O algoritmo ACO-IPH foi testado em 100 processos de otimização com 200 ciclos por iteração considerando os valores iniciais atribuídos a cada parâmetro do método, conforme apresentado na Tabela 6. Um total de 25 configurações de número de formigas e número de estratos foi

avaliado, para cada FO, sendo organizado assim: número de formigas: 500, 1500, 3000, 4000 e 5000; número de estratos: 100, 500, 1000, 1500 e 2000. No caso do SCE-UA foram avaliadas as combinações seguintes: se mantiveram constantes o número de complexos em 20 e o número de gerações em 200; para o número de indivíduos por complexo foram atribuídos os seguintes valores: 25, 75, 150, 200, 250.

**Tabela 6.** Valores iniciais dos parâmetros do algoritmo ACO-IPH para a série sintética.

	<b>FO = KGE</b>	<b>FO = NS</b>	<b>FO = IQ</b>
<b>Parâmetro</b>	<b>Valor</b>	<b>Valor</b>	<b>Valor</b>
Número de testes	100	100	100
Número de ciclos	200	200	200
Feromônio crítico	1	1	1
FO crítica	1	1	50
A	1	1	1
CN	0,3	0,3	0,3
CT	0,5	0,5	0,5
Tolerância FO	5%	5%	5%
Tolerância da população com FO de convergência	5%	5%	5%

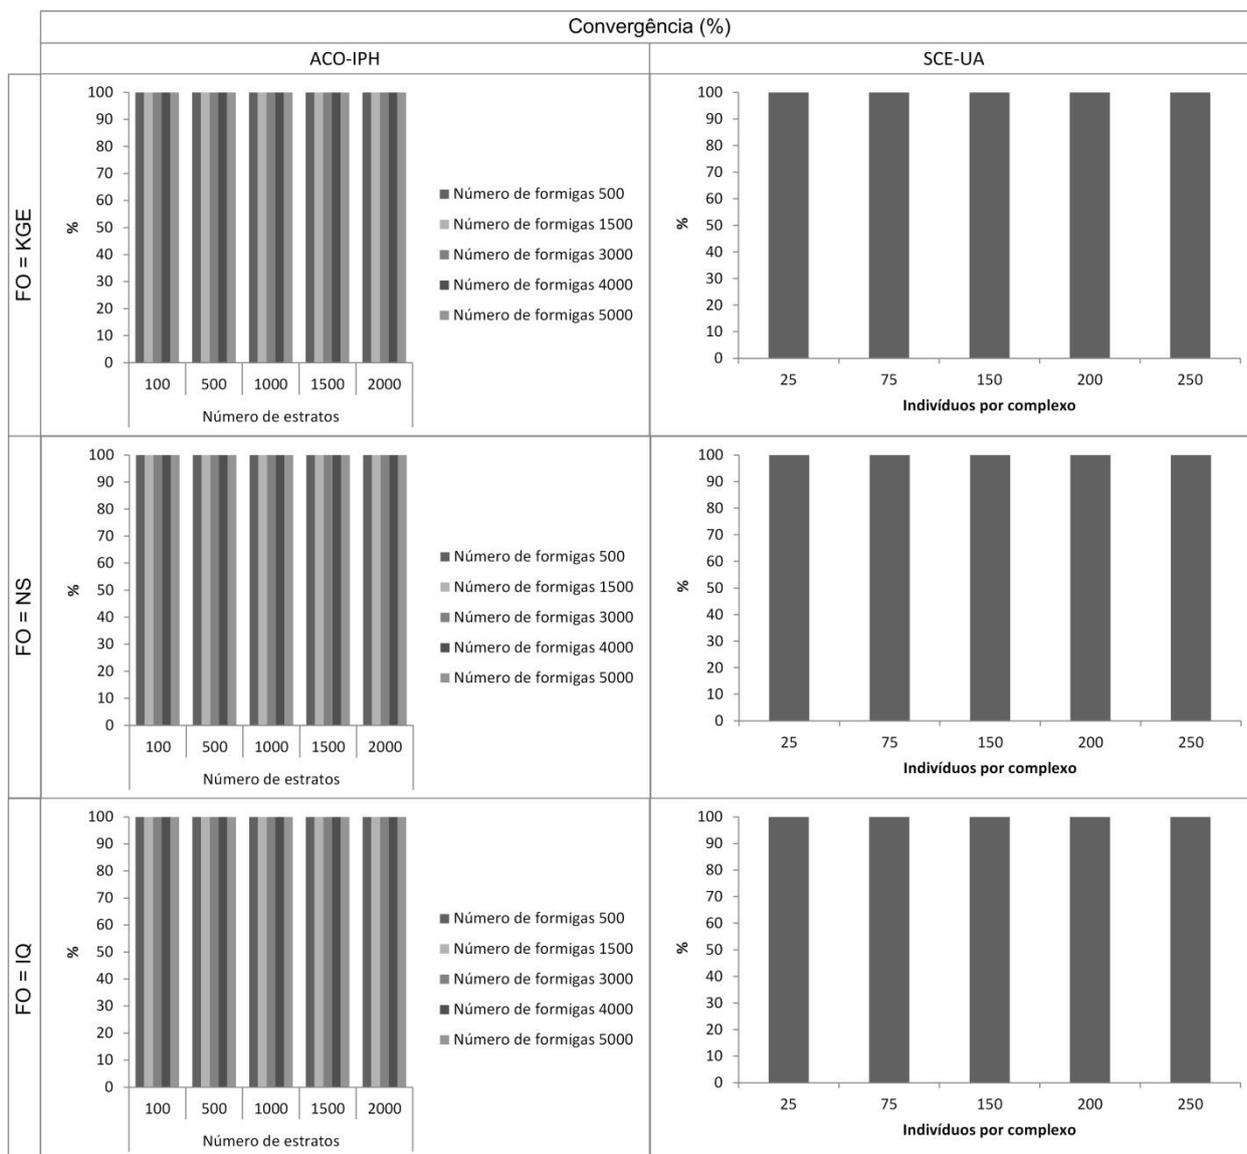
Com relação à convergência (Figura 38), que indica quantas vezes dos 100 testes a colônia de formigas converge para o mesmo valor de FO, o algoritmo ACO-IPH apresentou um bom desempenho, convergindo em todos os casos, da mesma forma que o algoritmo SCE-UA, que também convergiu 100% das ocasiões testadas, para as três FO.

Em relação ao tempo de convergência (Figura 39), no ACO-IPH, a função KGE foi a menos demandante, e a função IQ a mais demandante. Comparando os resultados do ACO-IPH e o SCE-UA, o segundo obteve uma marcante vantagem no tempo de processamento, pois precisou de muito menos tempo para convergir, em todas as configurações e para todas as FO. Essa diferença de tempo de convergência aumenta de forma considerável com o aumento da estratificação do espaço de busca no ACO-IPH.

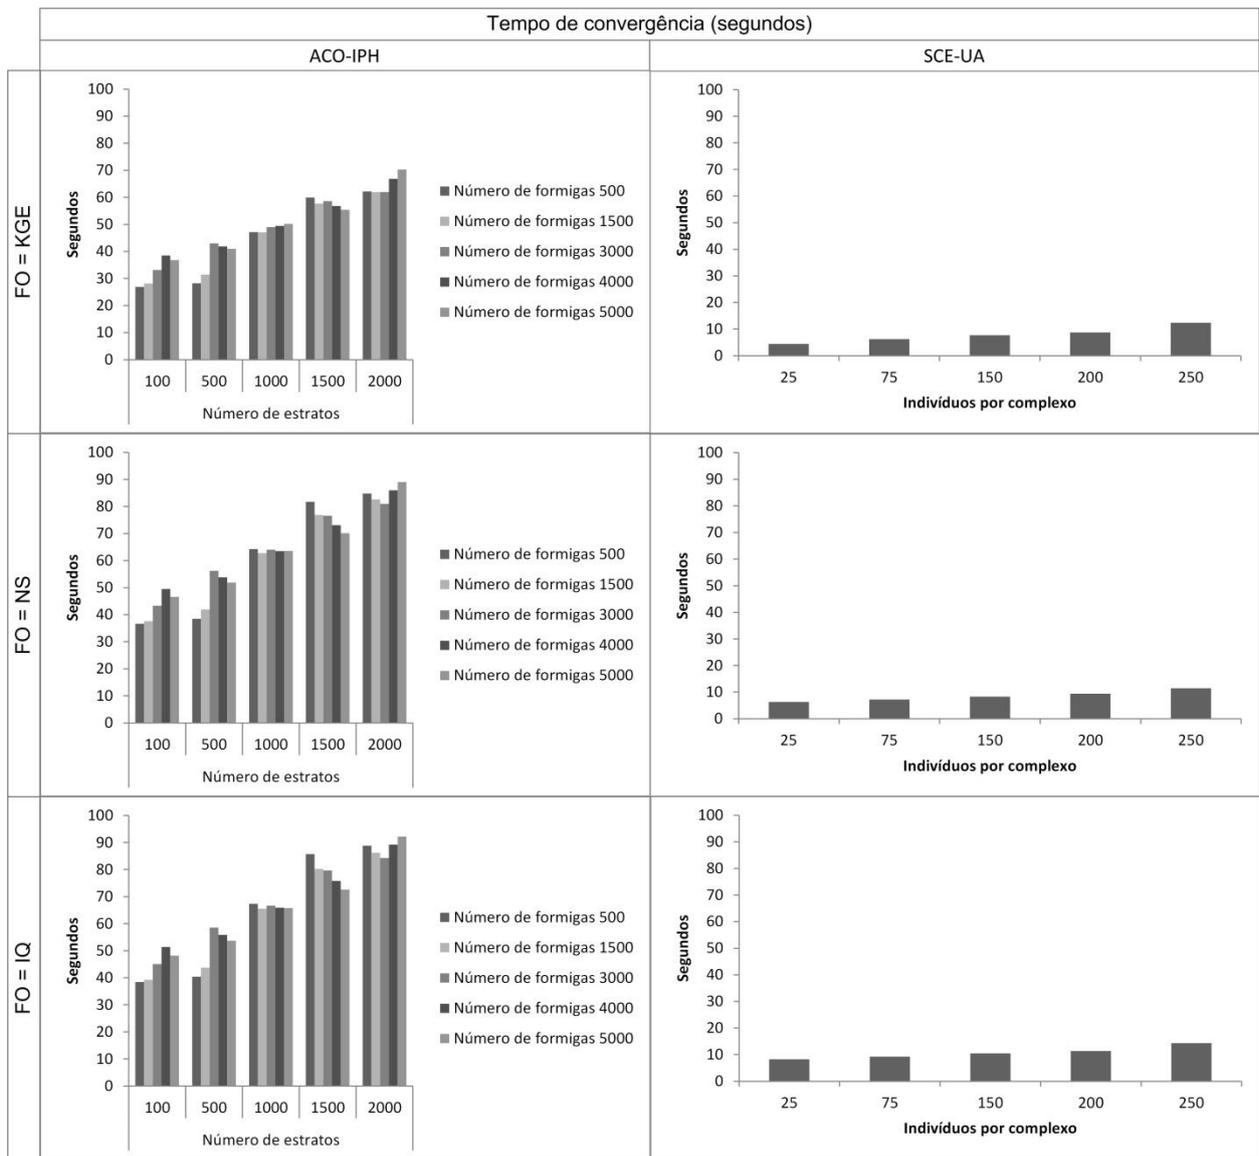
Analisando os ciclos necessários para lograr a convergência (Figura 40), o algoritmo SCE-UA apresentou uma forte vantagem sobre o algoritmo ACO-IPH, pois este último precisou para todas as configurações e em todas as FOs, mais que 150 ciclos para convergir, enquanto que o algoritmo SCE-UA convergiu sempre em menos de 100 ciclos.

O último indicador em questão é o relacionado com a população que possui o valor de FO de convergência (Figura 41), que neste caso foi de 100% dos indivíduos em todos os casos para todas as configurações usando ambos os algoritmos, mostrando que a convergência no

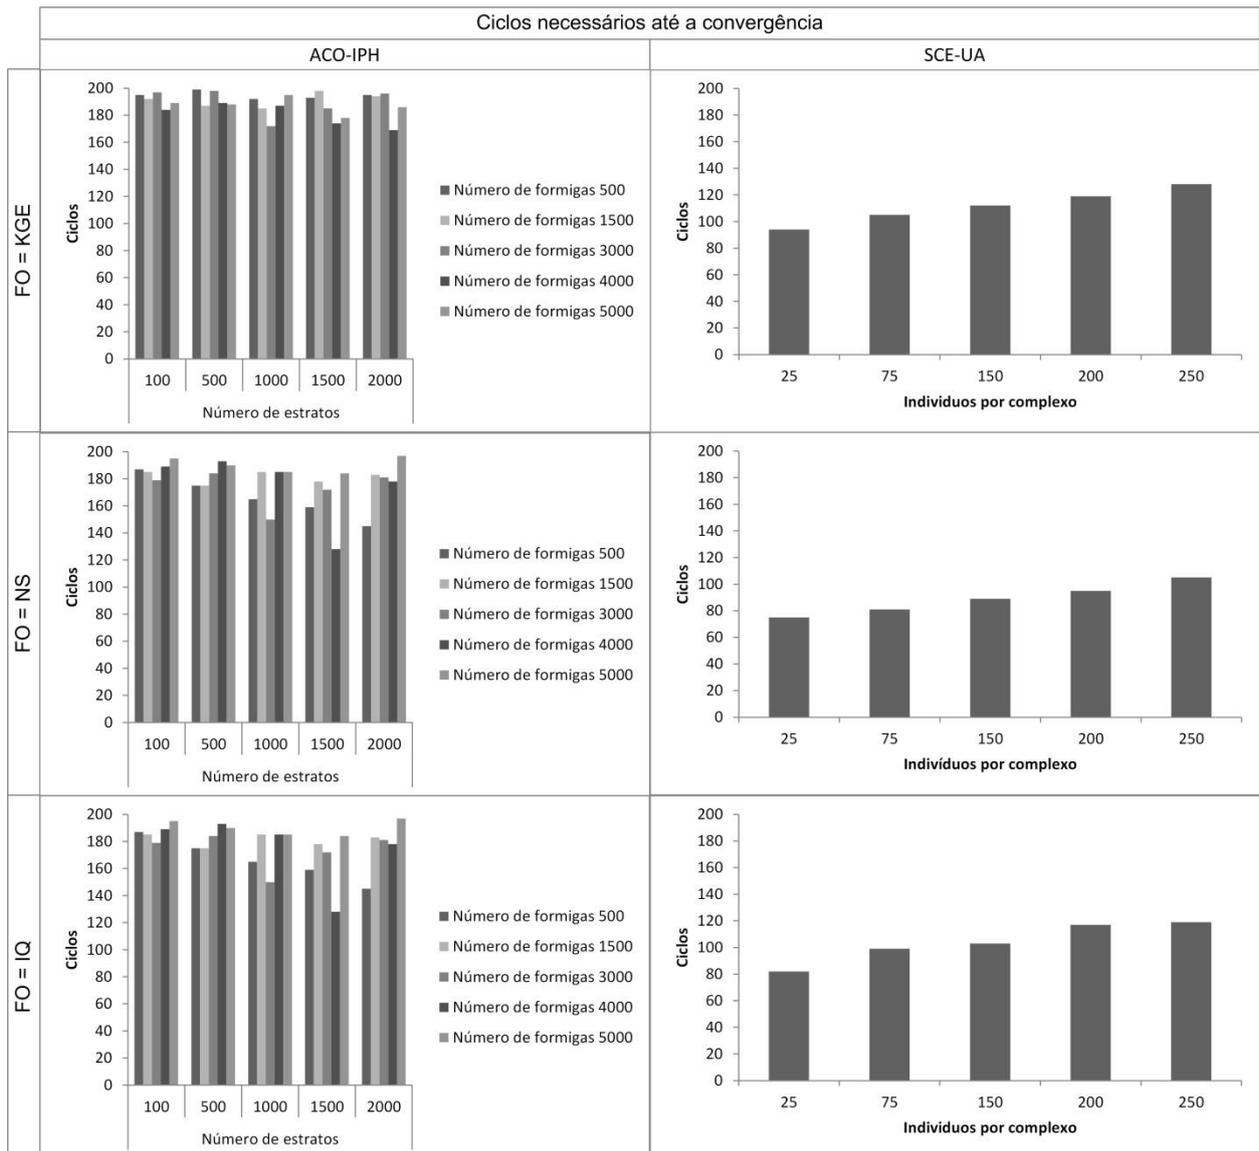
ACO-IPH pode ser mais demorada em questão de ciclos necessários e de tempo computacional, mas garantindo que toda a população converge a um valor da FO.



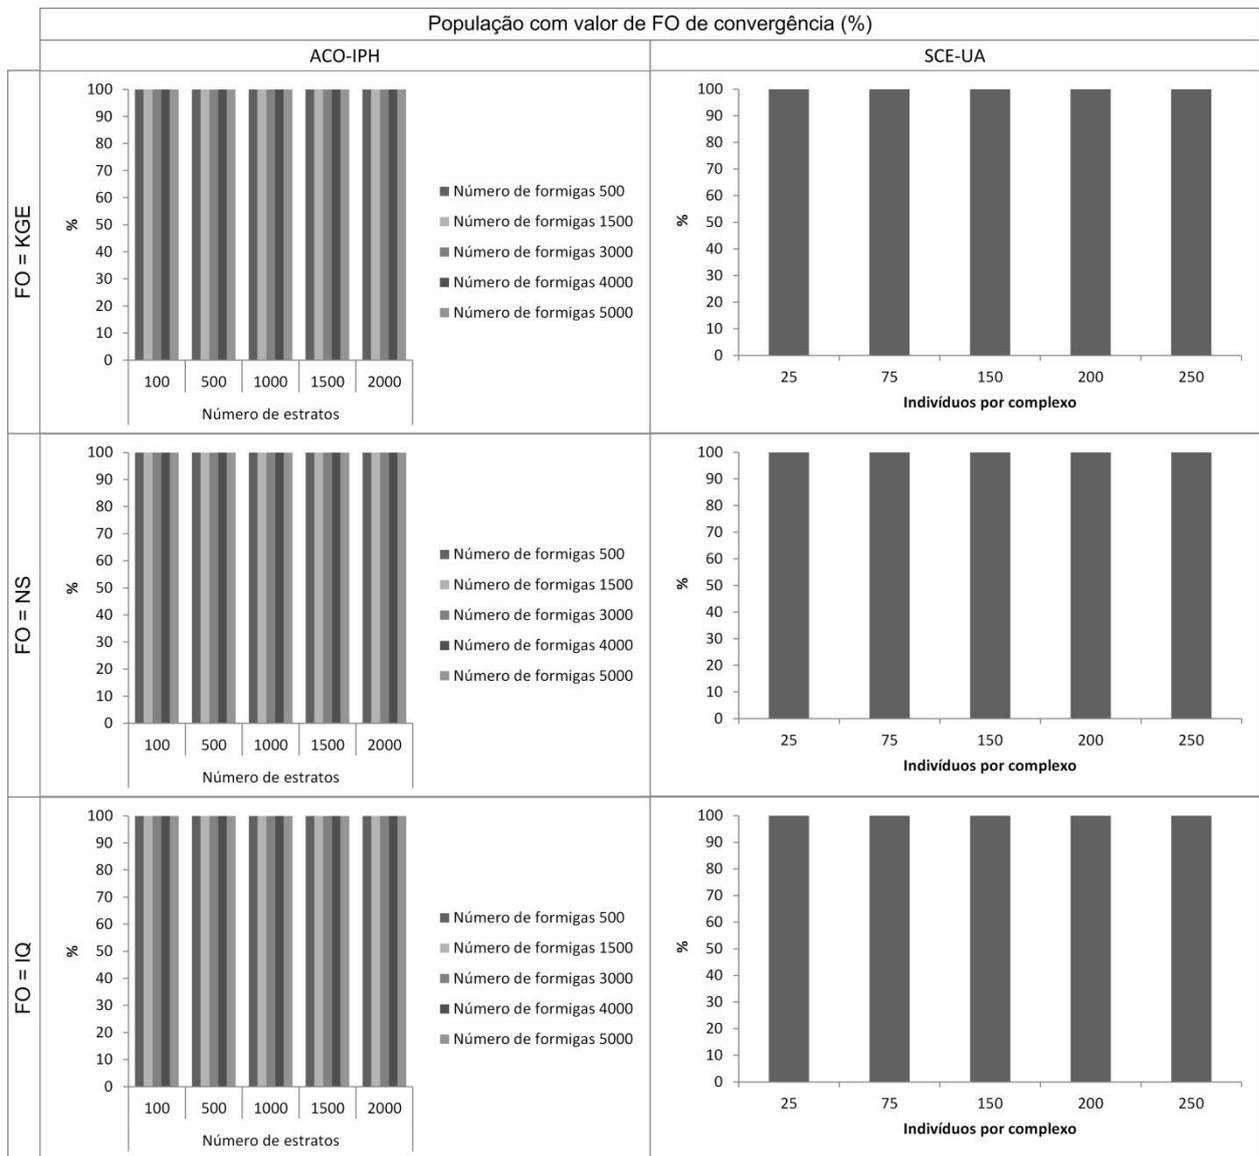
**Figura 38.** Convergência na série sintética de vazões com os algoritmos ACO-IPH e SCE-UA.



**Figura 39.** Tempo de convergência na série sintética de vazões com os algoritmos ACO-IPH e SCE-UA.



**Figura 40.** Ciclos de convergência na série sintética de vazões com os algoritmos ACO-IPH e SCE-UA.



**Figura 41.** População com valor de FO de convergência na série sintética de vazões com os algoritmos ACO-IPH e SCE-UA.

Com base nos resultados apresentados e discutidos nos parágrafos anteriores, o número de formigas escolhido foi de 3000, e o número de estratos, 1000, para avaliar o comportamento do algoritmo ACO-IPH na calibração automática em comparação com o SCE-UA, que foi inicializado com 30 complexos, 100 indivíduos por complexo e 200 gerações.

Em relação aos resultados obtidos usando a função KGE (Tabela 7), o ACO-IPH ficou igual ao SCE-UA até a terceira casa decimal, mas no caso dos valores dos parâmetros, nenhum dos algoritmos avaliados conseguiu obter o conjunto de valores ótimos. Em ambos os casos, os algoritmos convergiram para um conjunto de parâmetros alternativo próximo do conjunto ótimo, mas com diferenças nos valores de alguns parâmetros.

Para o caso do NS (Tabela 7), o algoritmo SCE-UA conseguiu o valor ótimo para a FO e do conjunto de parâmetros. Por sua vez, o algoritmo ACO-IPH produziu um valor da FO muito próximo do valor ótimo, com um conjunto alternativo de valores de parâmetros muito próximo também dos valores ótimos.

Por fim, para a terceira FO analisada, o IQ, o valor da FO obtida com o ACO-IPH ficou diferente apenas a partir da terceira casa decimal, em comparação ao resultado ótimo encontrado pelo SCE-UA. O algoritmo SCE-UA também encontrou os valores ótimos do conjunto de parâmetros, enquanto que o algoritmo ACO-IPH convergiu para um conjunto alternativo de valores de parâmetros próximo do conjunto ótimo, mas com diferenças em alguns dos parâmetros.

**Tabela 7.** Resultados da calibração da série sintética para KGE em MH concentrado

		<b>Valor ótimo</b>	<b>SCE-UA</b>	<b>ACO-IPH</b>
<b>FO</b>	<b>KGE</b>	<b>1</b>	0,9997	0,9990
<b>Parâmetros</b>	<b>lo</b>	<b>50</b>	66,9789	46,6887
	<b>lb</b>	<b>5</b>	5,1355	4,5685
	<b>H</b>	<b>0,5</b>	0,3507	0,5226
	<b>Ks</b>	<b>5</b>	5,0430	5,5308
	<b>Ksub</b>	<b>100</b>	99,6510	113,6021
	<b>Rmáx</b>	<b>6</b>	6,1707	4,3795
	<b>Alfa</b>	<b>15</b>	19,5986	11,3748

**Tabela 8.** Resultados da calibração da série sintética para NS em MH concentrado.

		<b>Valor ótimo</b>	<b>SCE-UA</b>	<b>ACO-IPH</b>
<b>FO</b>	<b>NS</b>	<b>1</b>	1,0000	0,9999
<b>Parâmetros</b>	<b>lo</b>	<b>50</b>	50,0000	48,7039
	<b>lb</b>	<b>5</b>	5,0000	4,7775
	<b>H</b>	<b>0,5</b>	0,5000	0,5229
	<b>Ks</b>	<b>5</b>	5,0000	5,2508
	<b>Ksub</b>	<b>100</b>	100,0000	107,2635
	<b>Rmáx</b>	<b>6</b>	5,0000	3,8844
	<b>Alfa</b>	<b>15</b>	15,0000	11,4700

**Tabela 9.** Resultados da calibração da série sintética para IQ em MH concentrado.

		<b>Valor ótimo</b>	<b>SCE-UA</b>	<b>ACO-IPH</b>
<b>FO</b>	<b>IQ</b>	<b>0</b>	0,0000	0,0015
<b>Parâmetros</b>	<b>Io</b>	<b>50</b>	50,0000	113,6561
	<b>Ib</b>	<b>5</b>	5,0000	4,8702
	<b>H</b>	<b>0,5</b>	0,5000	0,1697
	<b>Ks</b>	<b>5</b>	5,0000	5,5337
	<b>Ksub</b>	<b>100</b>	100,0000	97,4969
	<b>Rmáx</b>	<b>6</b>	5,0000	4,4229
	<b>Alfa</b>	<b>15</b>	15,0000	14,0047

Os resultados obtidos anteriormente foram considerados satisfatórios, embora o algoritmo ACO-IPH não tenha conseguido os valores otimizados das FOs no teste com série sintética. O algoritmo convergiu para valores da FO muito próximos do valor ótimo e, em quase todos os casos, os valores do conjunto de parâmetros também ficaram muito próximos dos valores ótimos.

### **5.2.2- Considerando séries reais de vazões**

Os dados de quatro bacias hidrográficas foram utilizados na calibração automática do modelo IPH II. Os parâmetros escolhidos para calibrar o modelo foram todos os possíveis, aos quais foram estabelecidos os mesmos limites mínimos e máximos de variação utilizados na análise com série sintética. O intervalo de tempo foi o diário. O algoritmo ACO-IPH foi testado em 100 processos de otimização com 200 ciclos considerando os valores iniciais atribuídos a cada parâmetro do método, conforme apresentado na Tabela 10. Um total de 25 configurações de número de formigas e número de estratos foi avaliado, para cada FO em cada bacia, sendo assim organizado: número de formigas: 500, 1500, 3000, 4000 e 5000; número de estratos: 100, 500, 1000, 1500 e 2000. No caso do SCE-UA foram avaliadas as combinações seguintes: se mantiveram constantes o número de complexos em 20 e o número de gerações em 200; para o número de indivíduos por complexo foram atribuídos os seguintes valores: 25, 75, 150, 200 e 250.

**Tabela 10.** Valores iniciais dos parâmetros do algoritmo ACO-IPH para a série real.

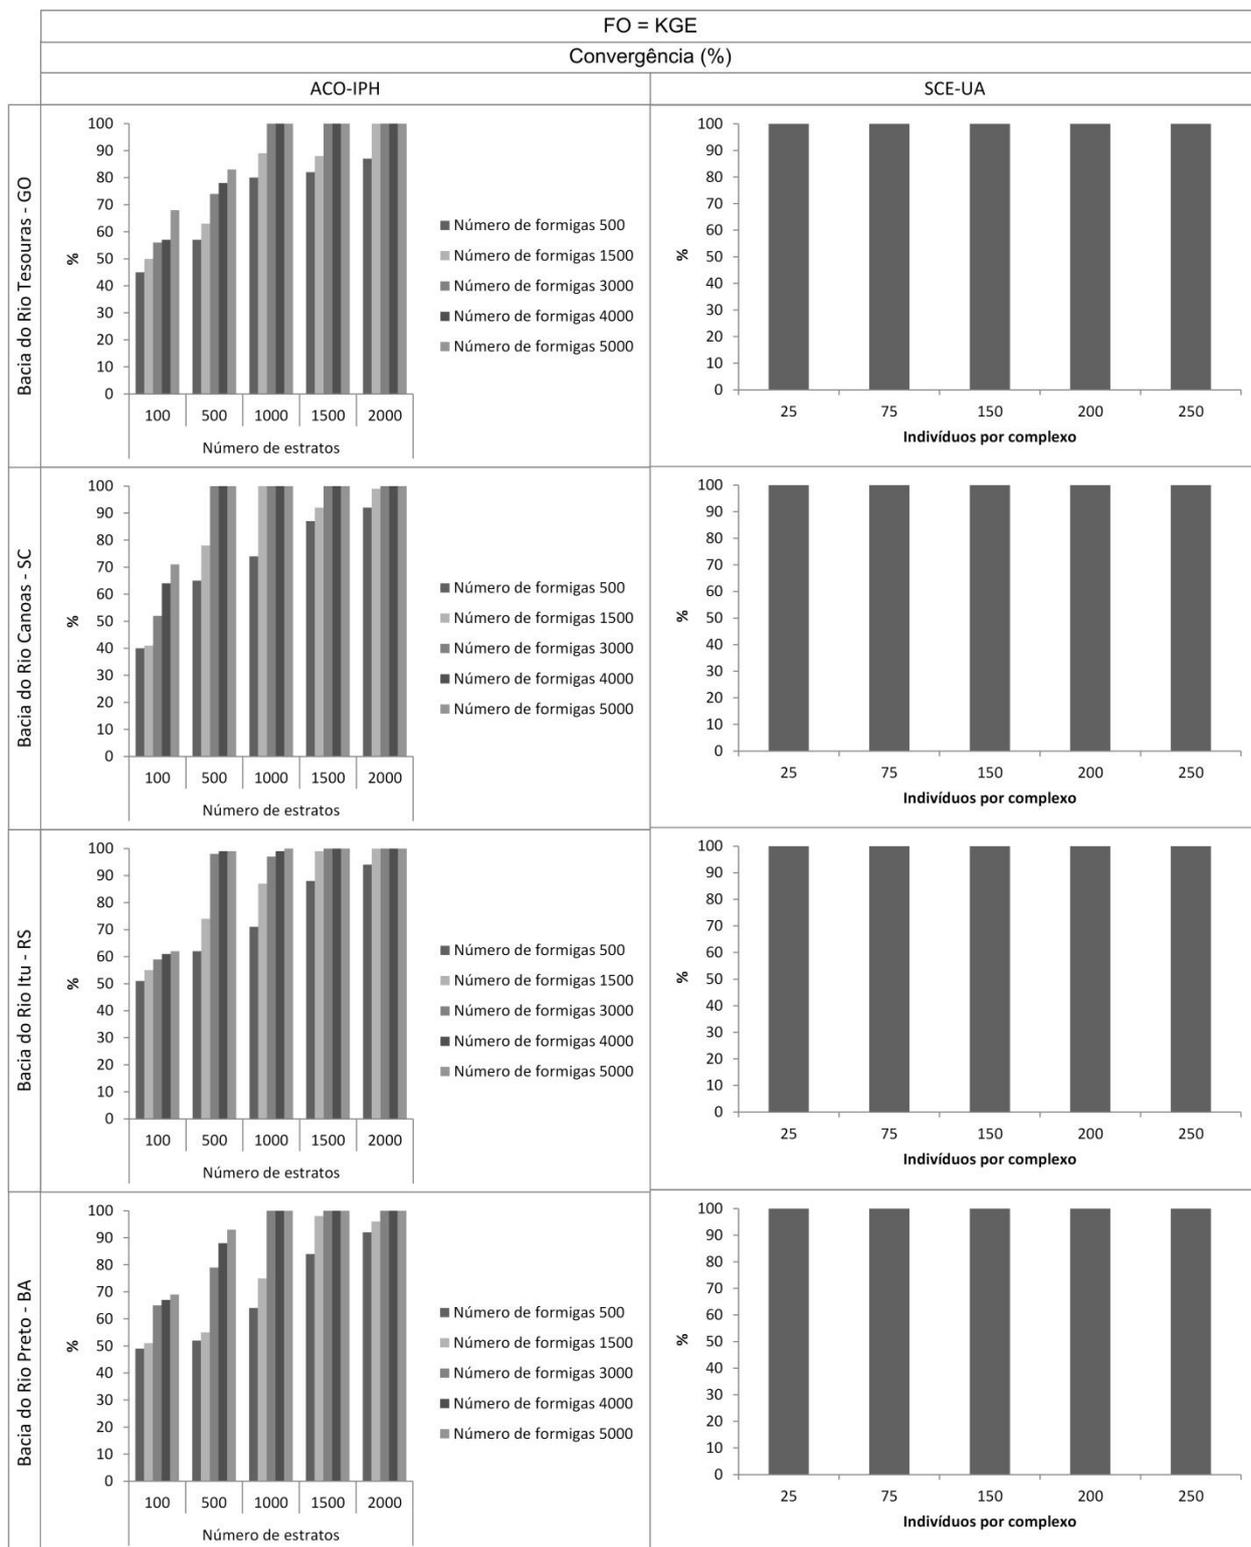
	<b>FO = KGE</b>	<b>FO = NS</b>	<b>FO = IQ</b>
<b>Parâmetro</b>	<b>Valor</b>	<b>Valor</b>	<b>Valor</b>
Número de testes	100	100	100
Número de ciclos	200	200	200
Feromônio crítico	1	1	1
FO crítica	1	1	50
A	1	1	1
CN	0,3	0,3	0,3
CT	0,5	0,5	0,5
Tolerância FO	5%	5%	5%
Tolerância da população com FO de convergência	5%	5%	5%

A convergência do algoritmo ACO-IPH foi avaliada em cada uma das três FO nas quatro bacias hidrográficas analisadas (Figura 42 à Figura 44), sendo que o algoritmo ACO-IPH consegue apenas convergir a partir de uma população igual a 500 formigas e, no caso do SCE-UA, este logra a convergência desde a primeira configuração testada. A partir de uma população de 1000 formigas garante-se uma convergência segura.

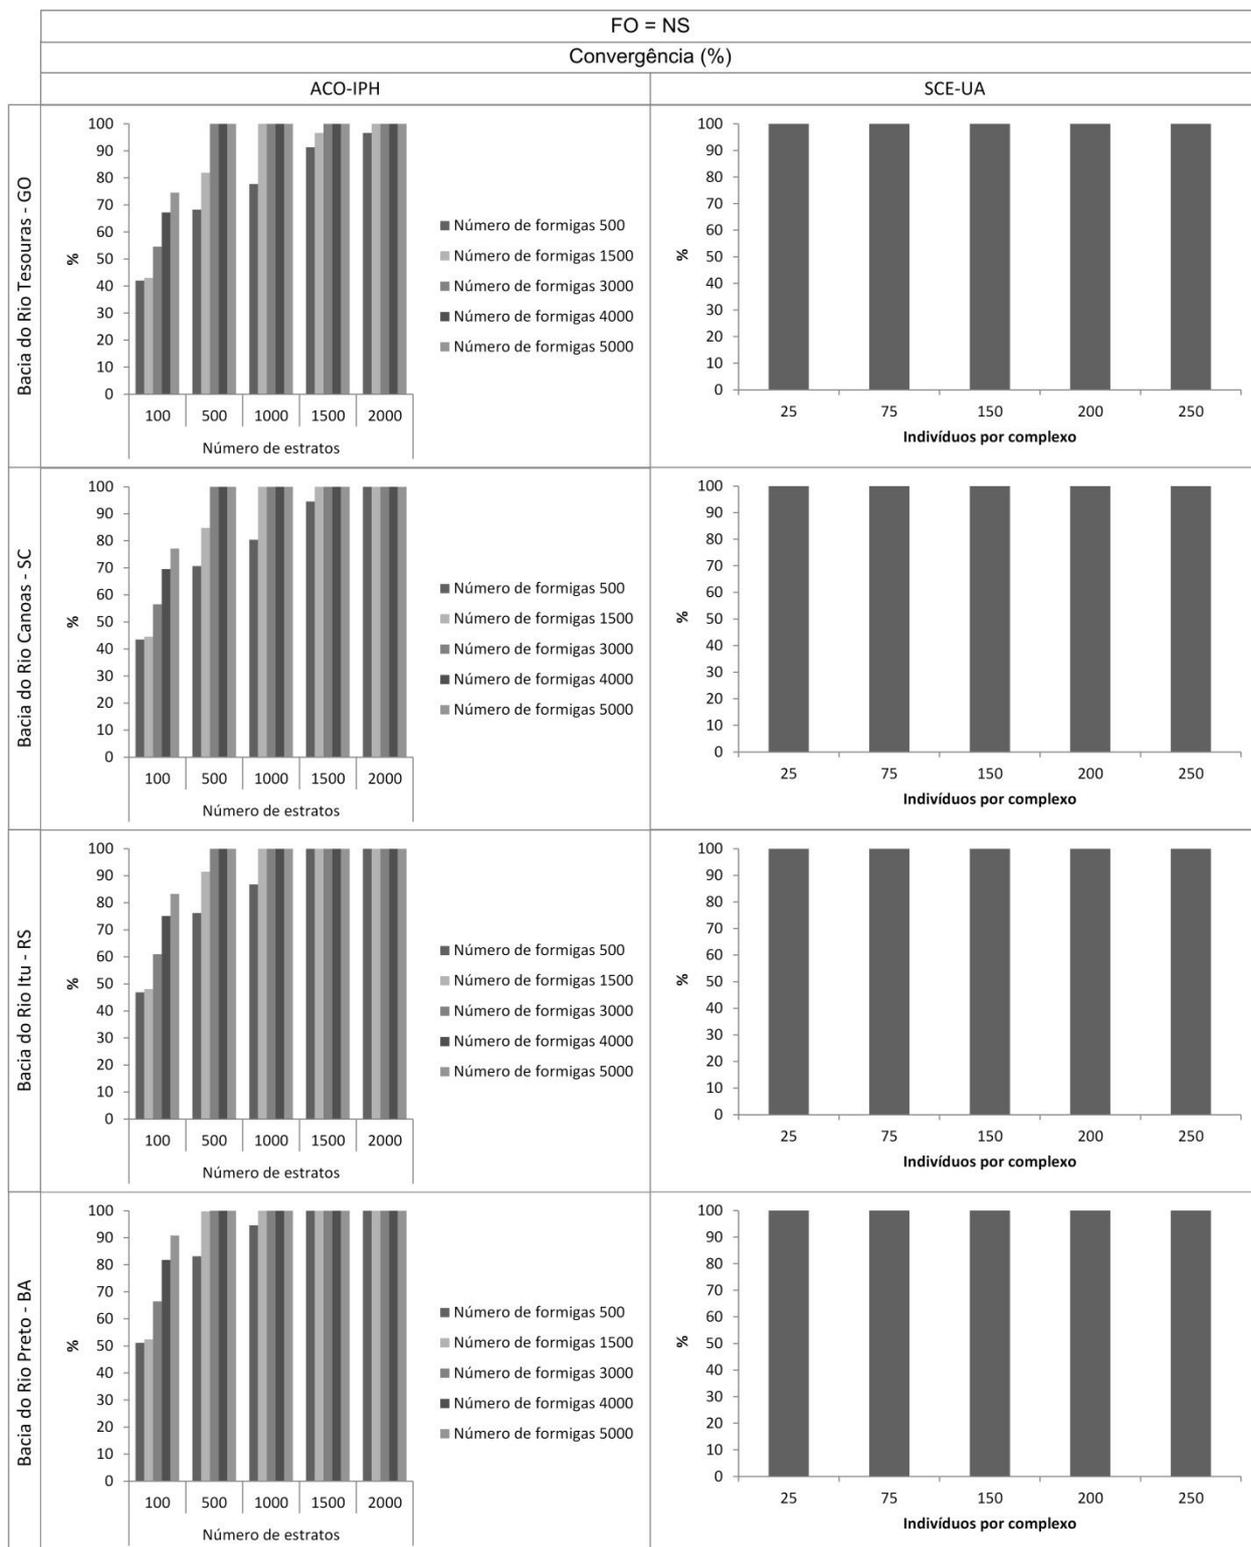
Em termos de tempo de convergência (Figura 45 à Figura 47), o algoritmo ACO-IPH é mais demorado do que o SCE-UA em condições similares de tamanho de população, chegando a ser em alguns casos até mais de dez vezes mais demorado. Esse excesso de tempo se explica pelas estratificações, pois quanto maior a estratificação utilizada, mais demorado o processamento.

A questão dos ciclos necessários para lograr a convergência (Figura 48 à Figura 50) é um indicador no qual o SCE-UA apresenta uma grande vantagem sobre o ACO-IPH, pois em nenhum caso deixou de chegar à convergência, fato acontecido frequentemente no ACO-IPH até 500 estratos. Observa-se como consequência que, para garantir de um bom desempenho e lograr uma convergência sem precisar de tantos ciclos, é necessário aumentar o número de estratos, deixando claro que o mencionado aumento vai ocasionar um incremento de tempo de processamento.

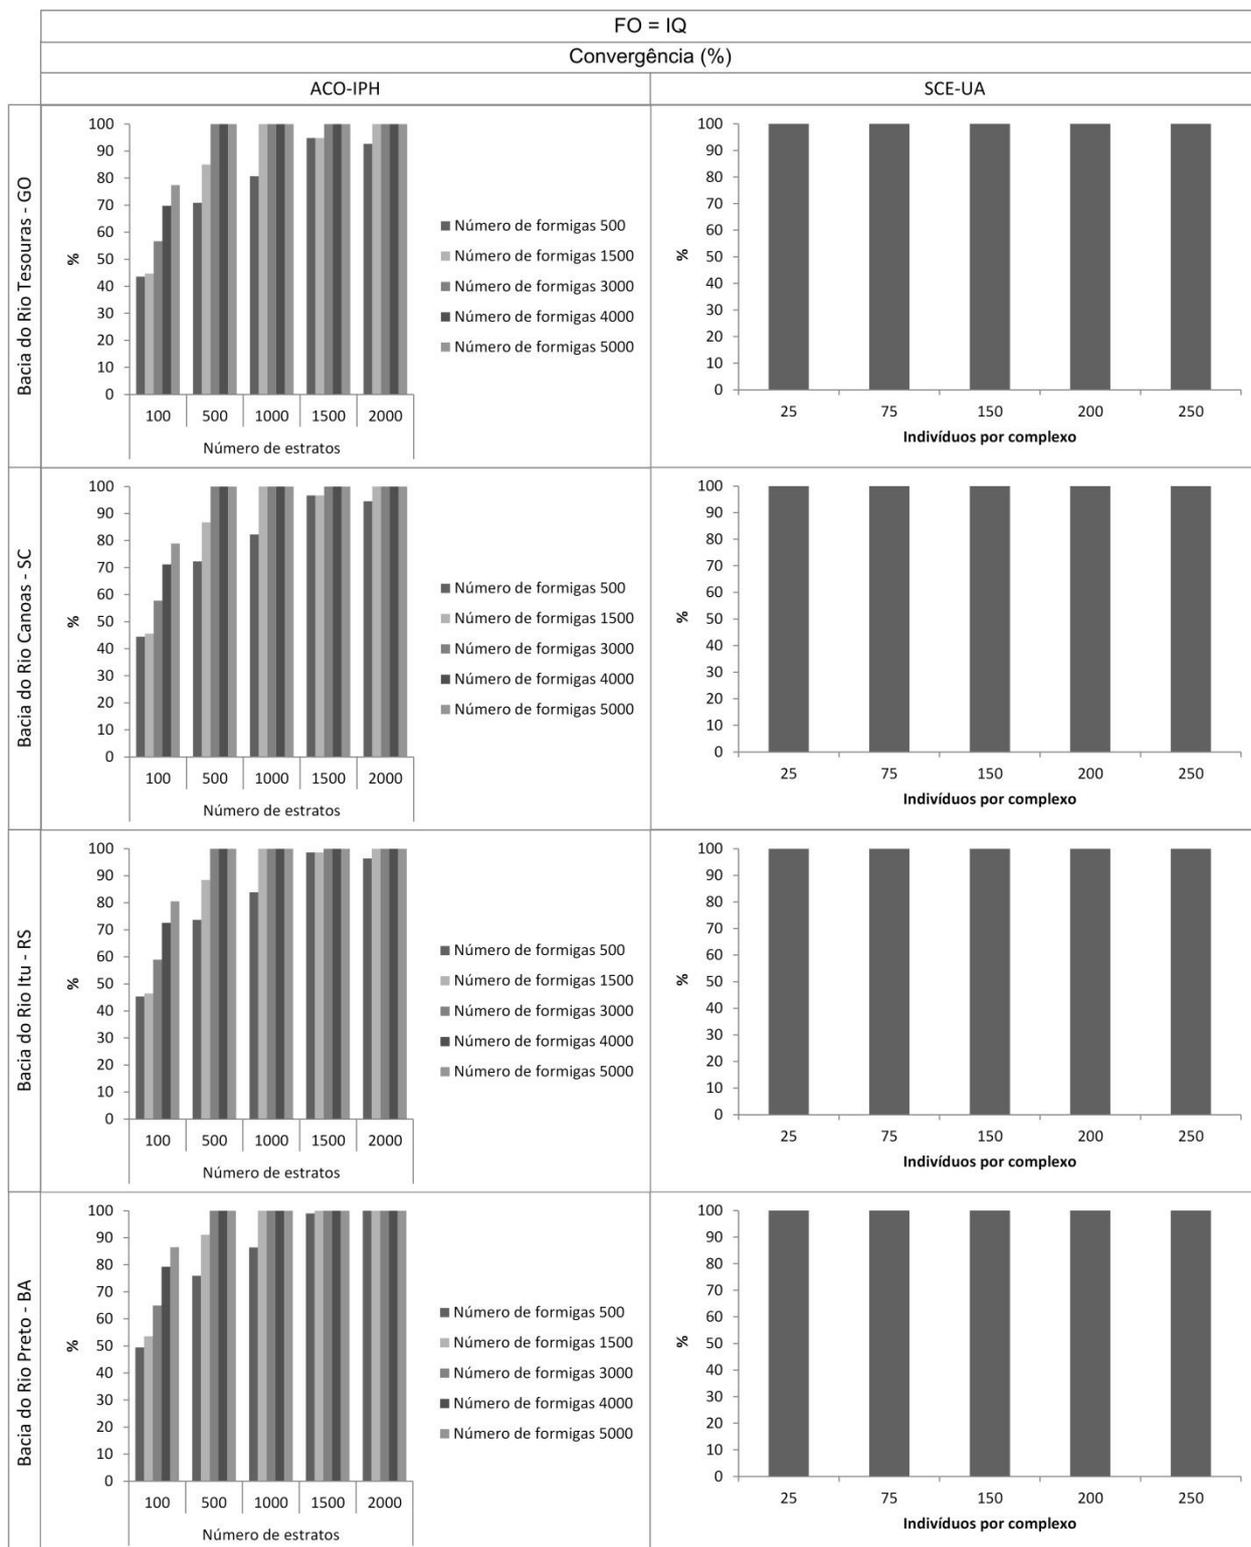
E finalmente, no indicador relacionando a população com o valor de FO de convergência (Figura 51 à Figura 53), o ACO-IPH obteve um bom desempenho pois não baixou de 95% em nenhuma das configurações, inclusive conseguindo nas baixas estratificações bons desempenhos, chegando até a 100%, mas no caso do SCE-UA é bom mencionar que este atingiu o valor ideal de 100% em todas as configurações testadas. Para este indicador, uma melhor estratificação ajuda na busca de garantir que a maioria da população esteja com o valor de FO tolerada.



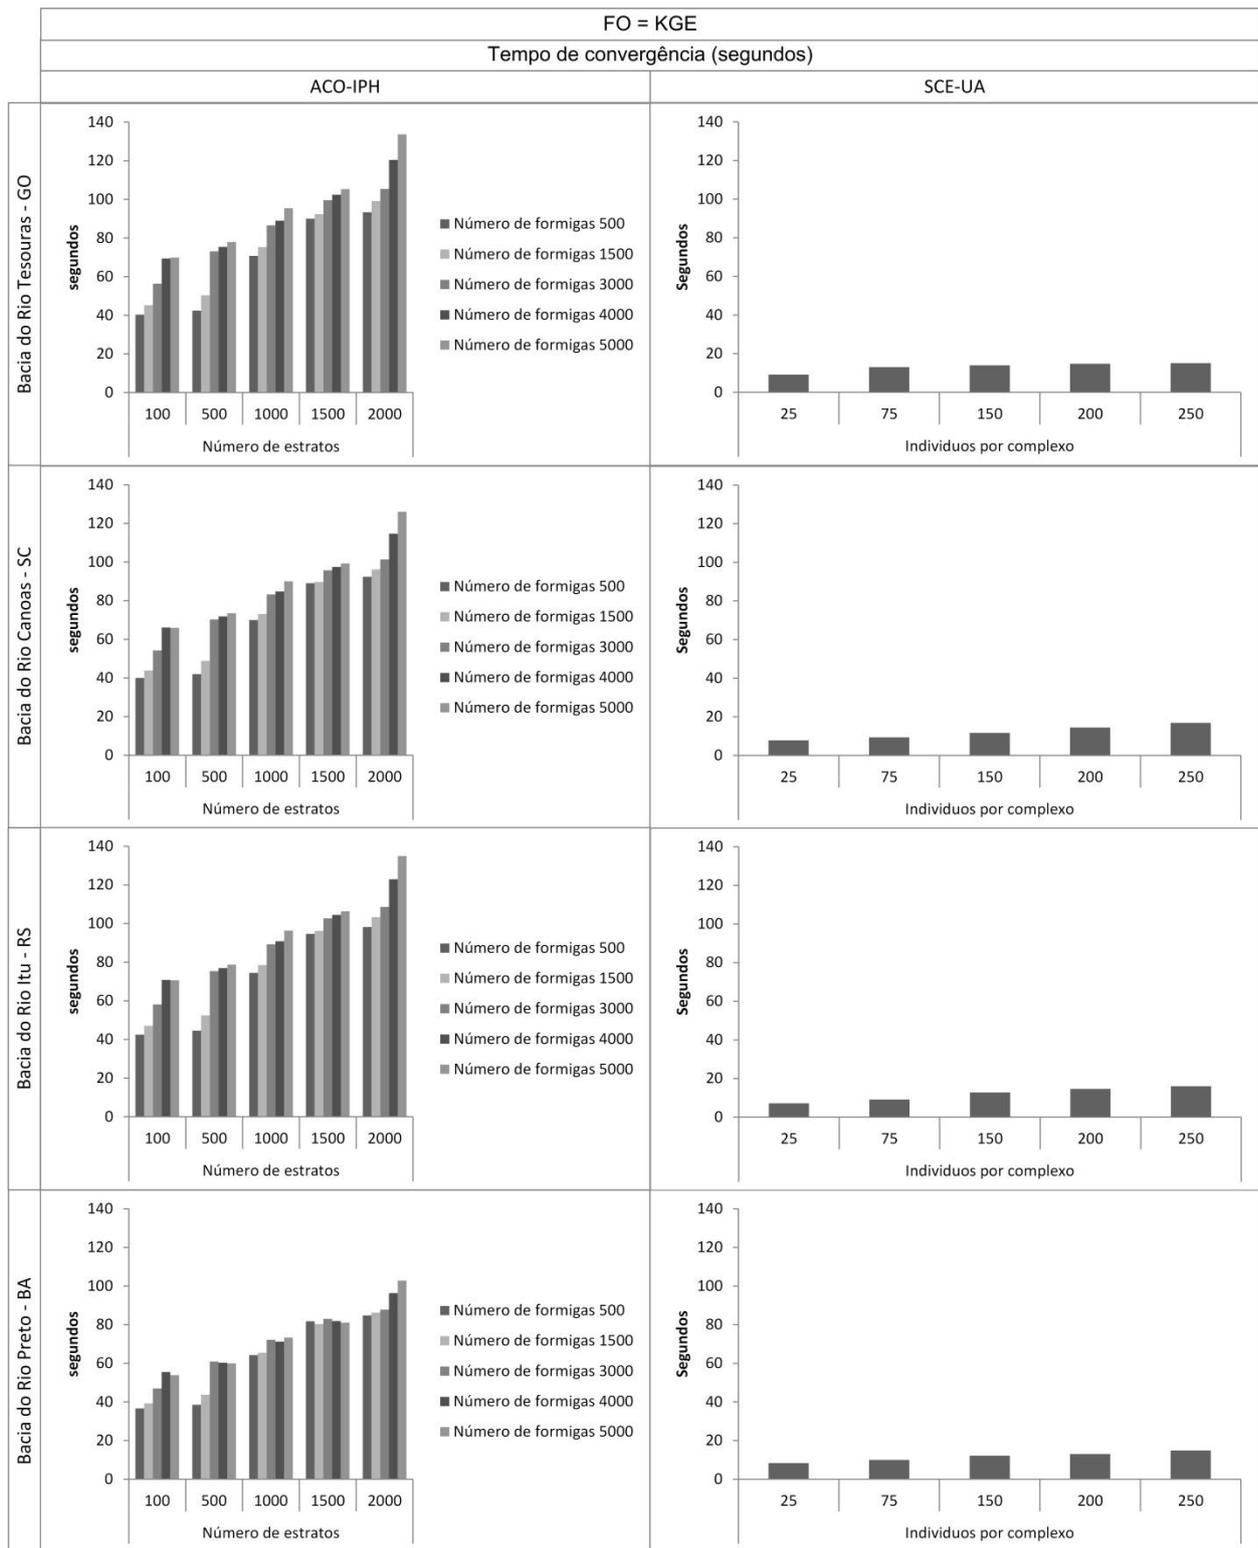
**Figura 42.** Convergência da função KGE nas quatro bacias analisadas.



**Figura 43.** Convergência da função NS nas quatro bacias analisadas.



**Figura 44.** Convergência para a função IQ nas quatro bacias analisadas.



**Figura 45.** Tempo de convergência para a função KGE nas quatro bacias analisadas.

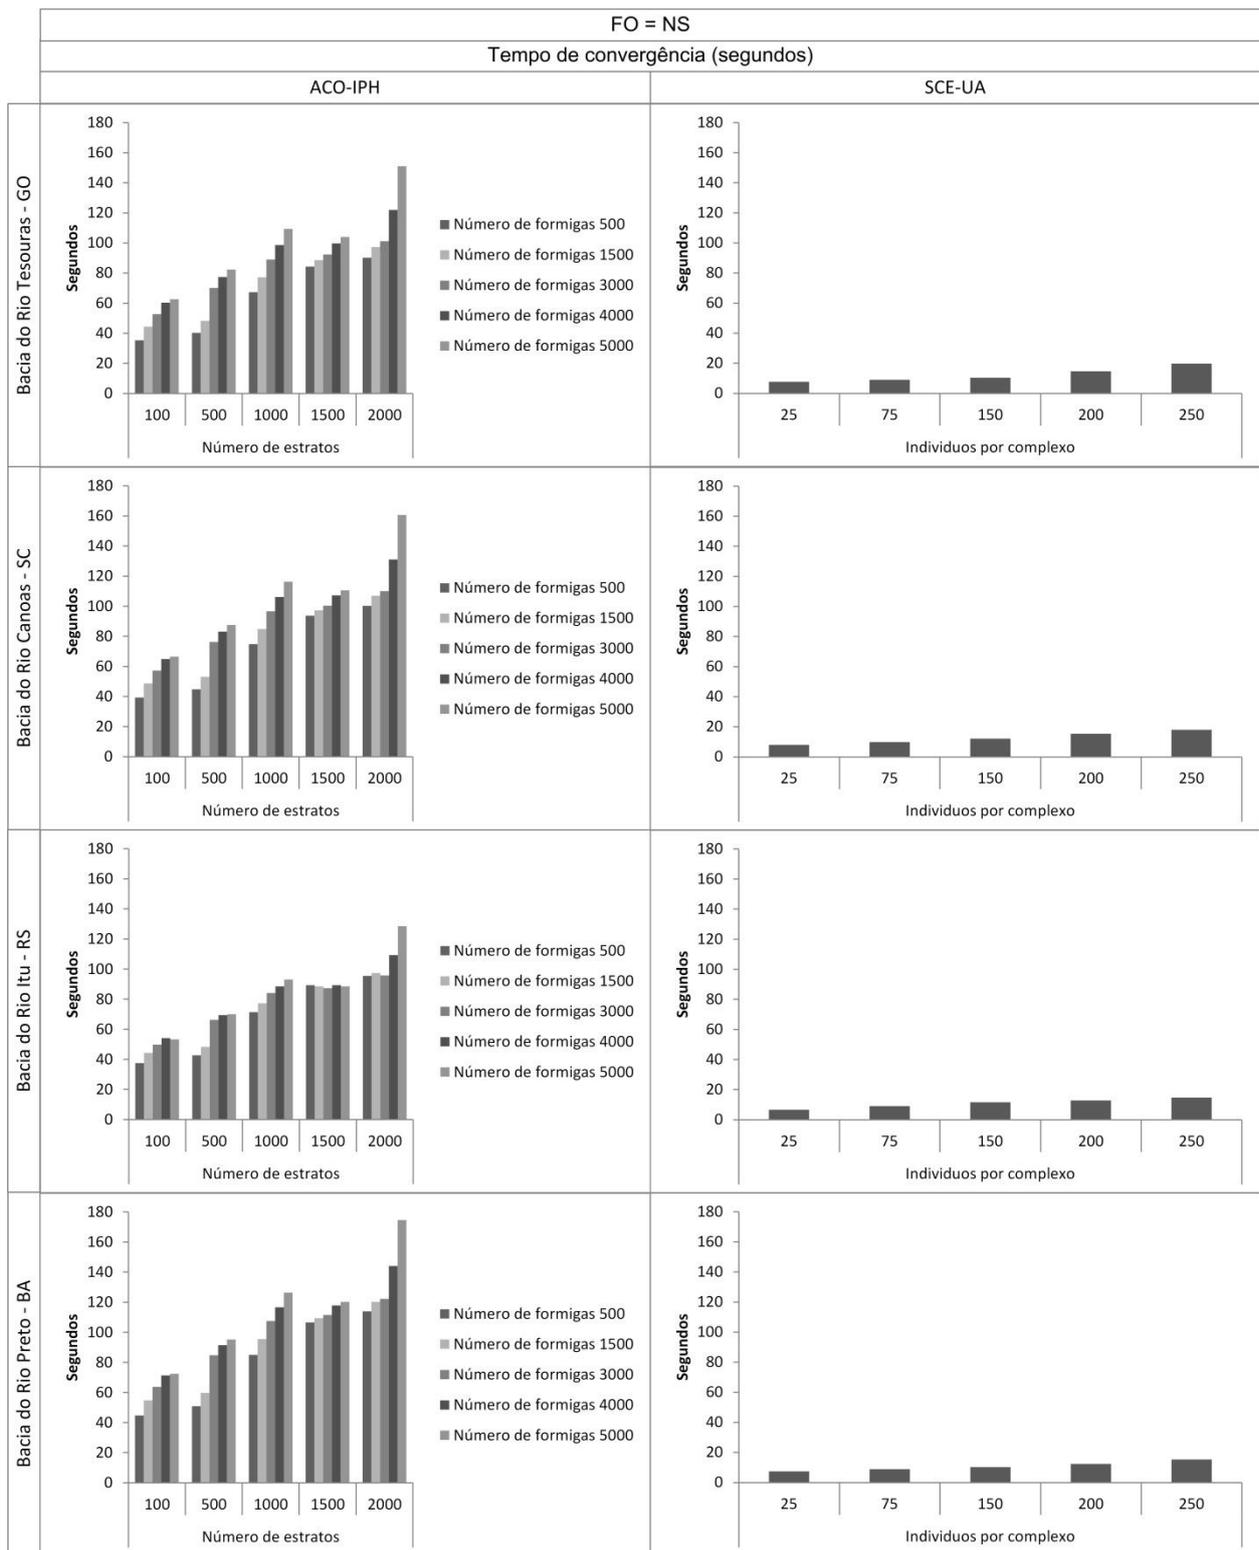
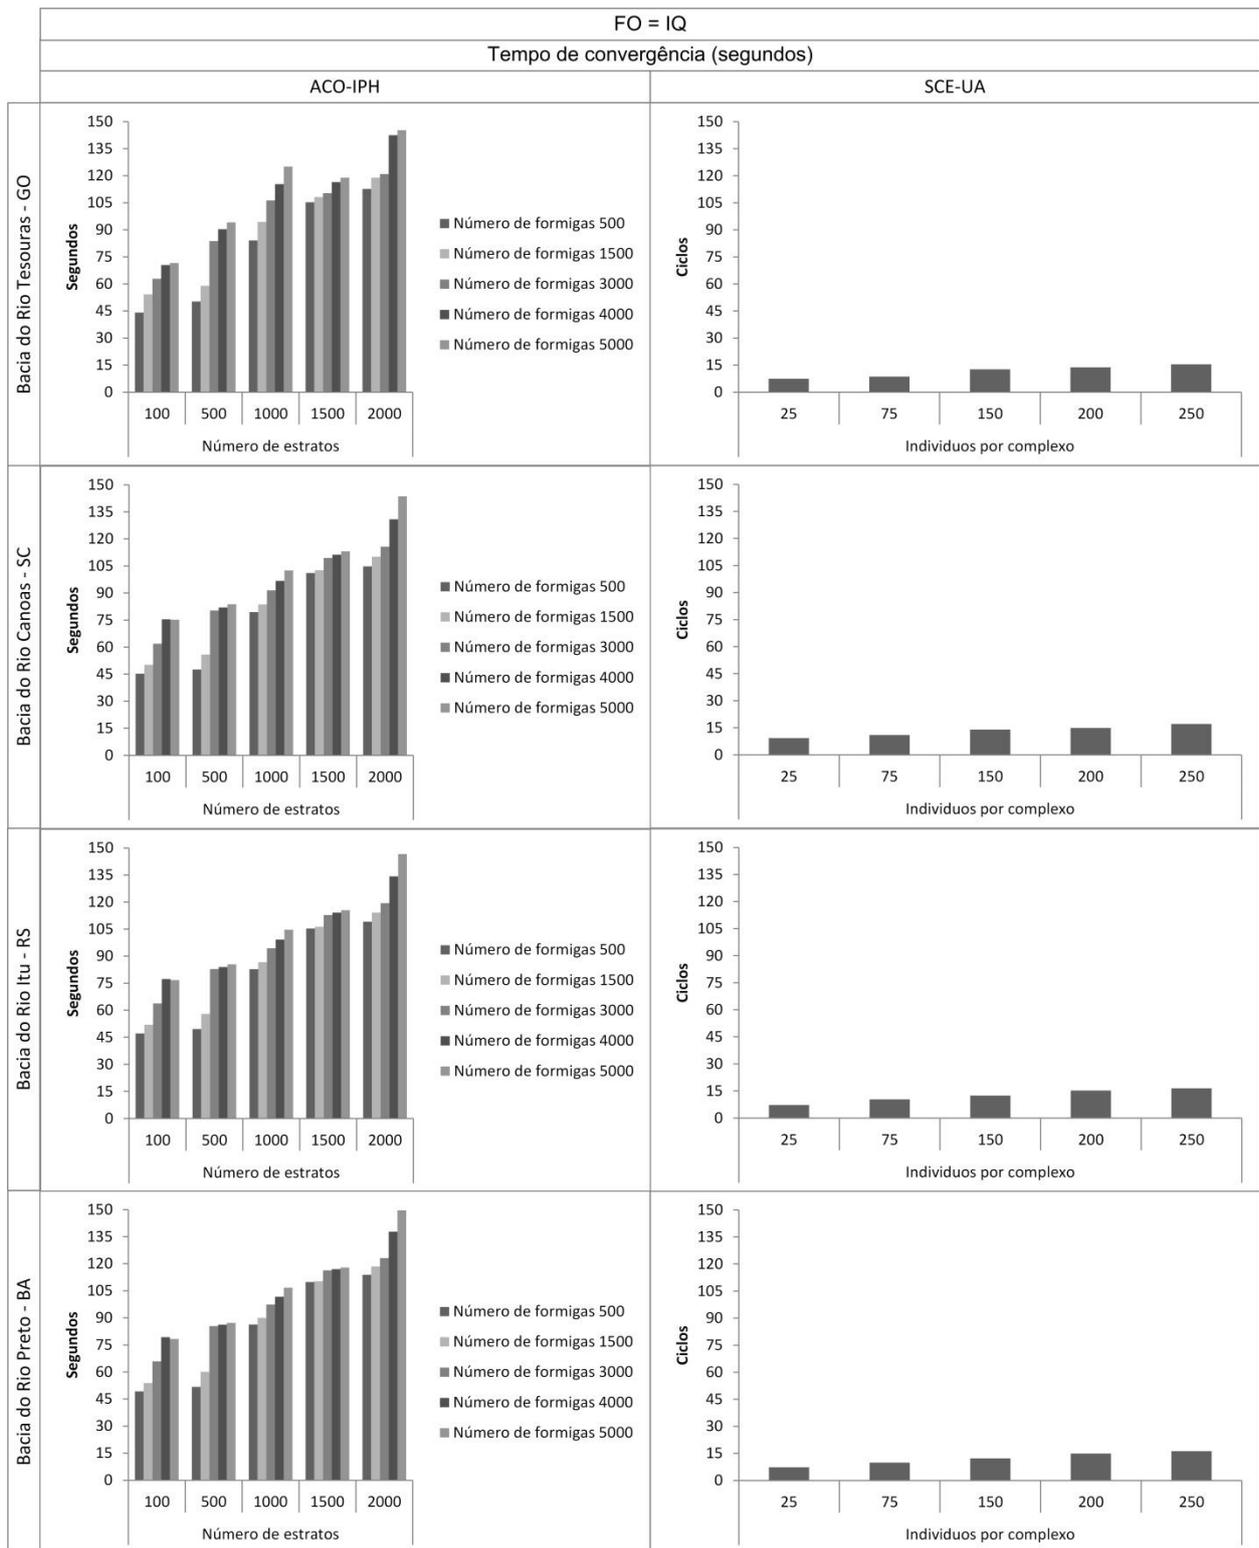
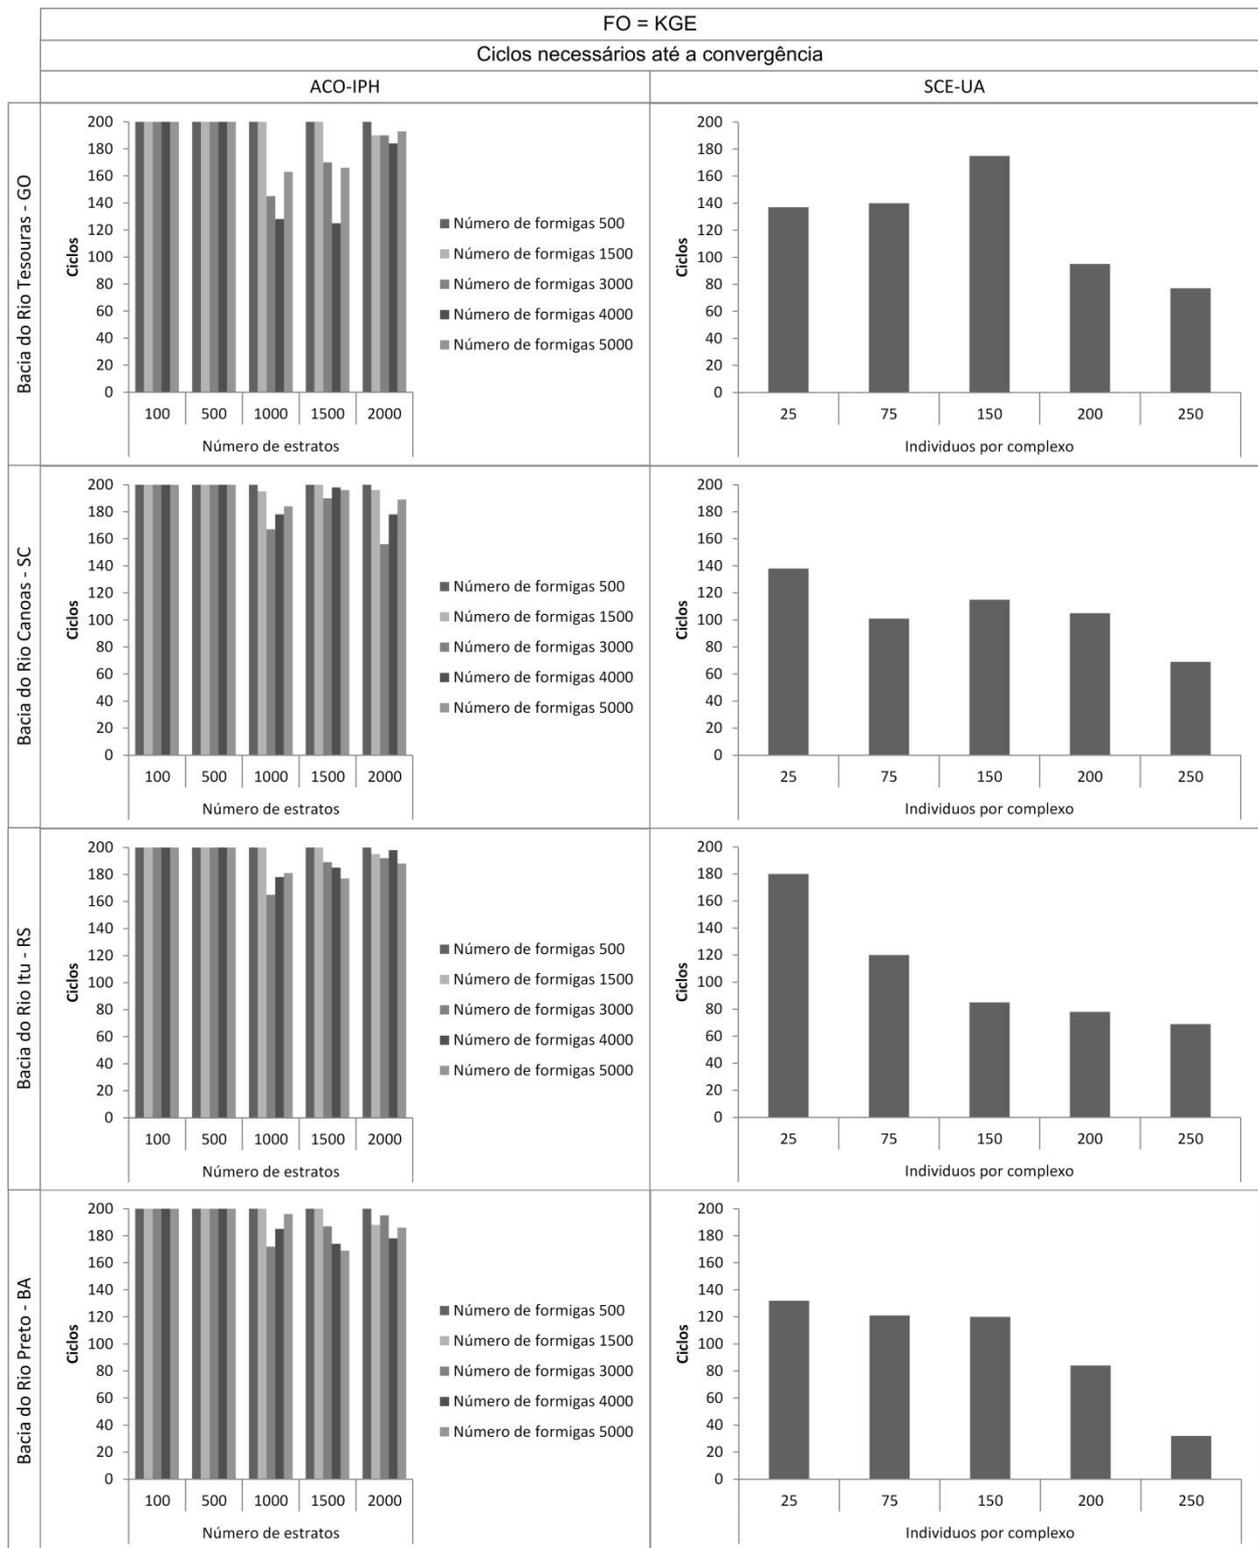


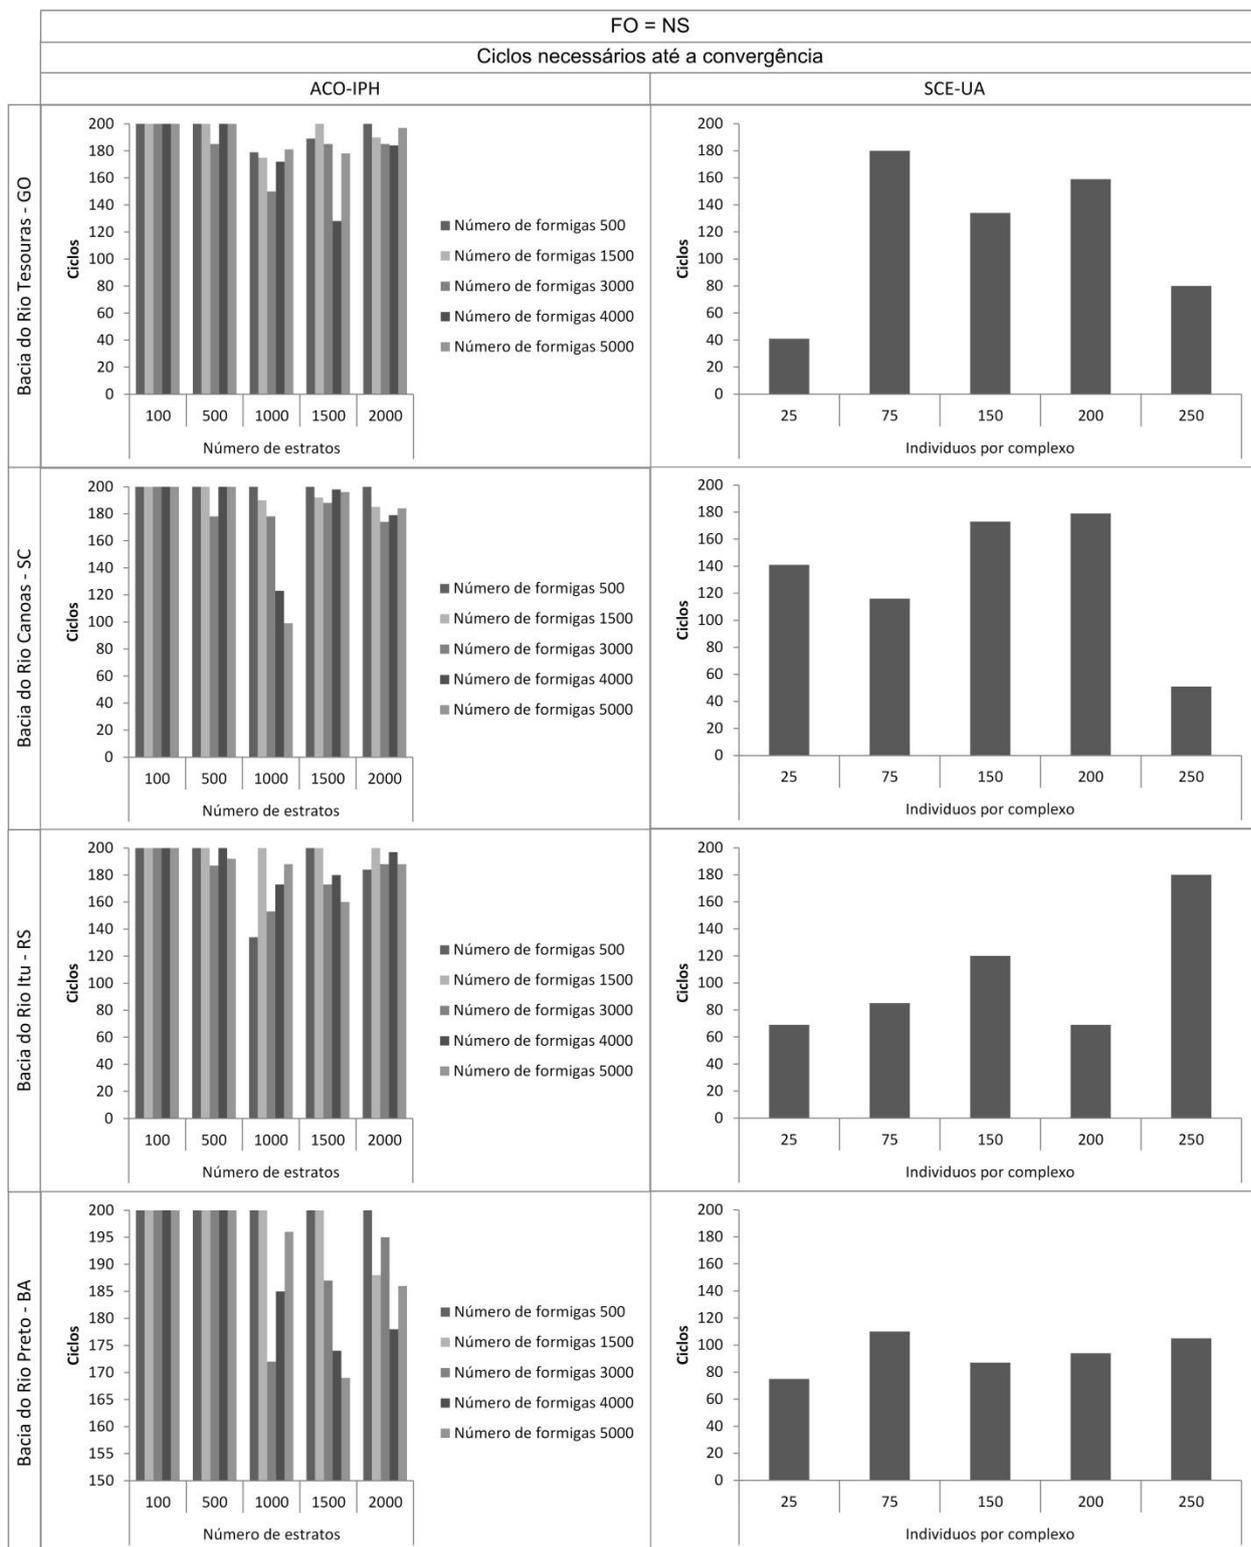
Figura 46. Tempo de convergência da função NS nas quatro bacias analisadas.



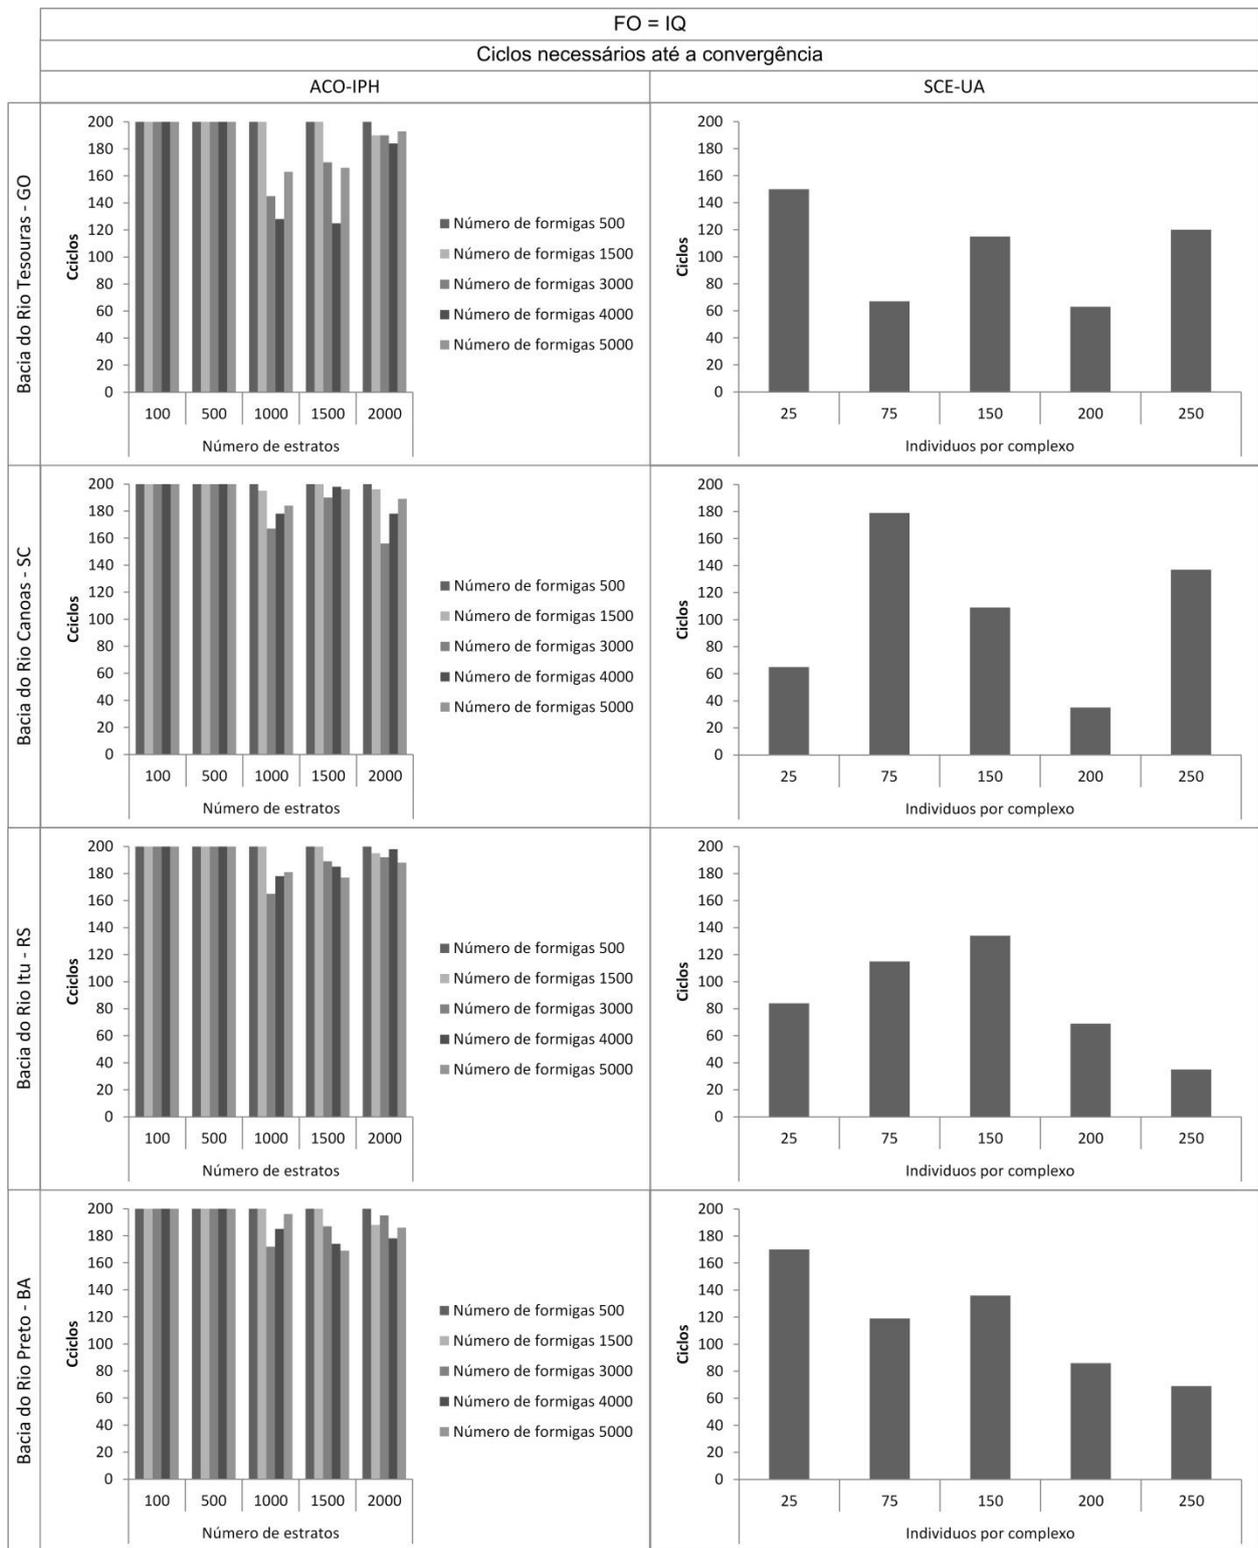
**Figura 47.** Tempo de convergência para a função IQ nas quatro bacias analisadas.



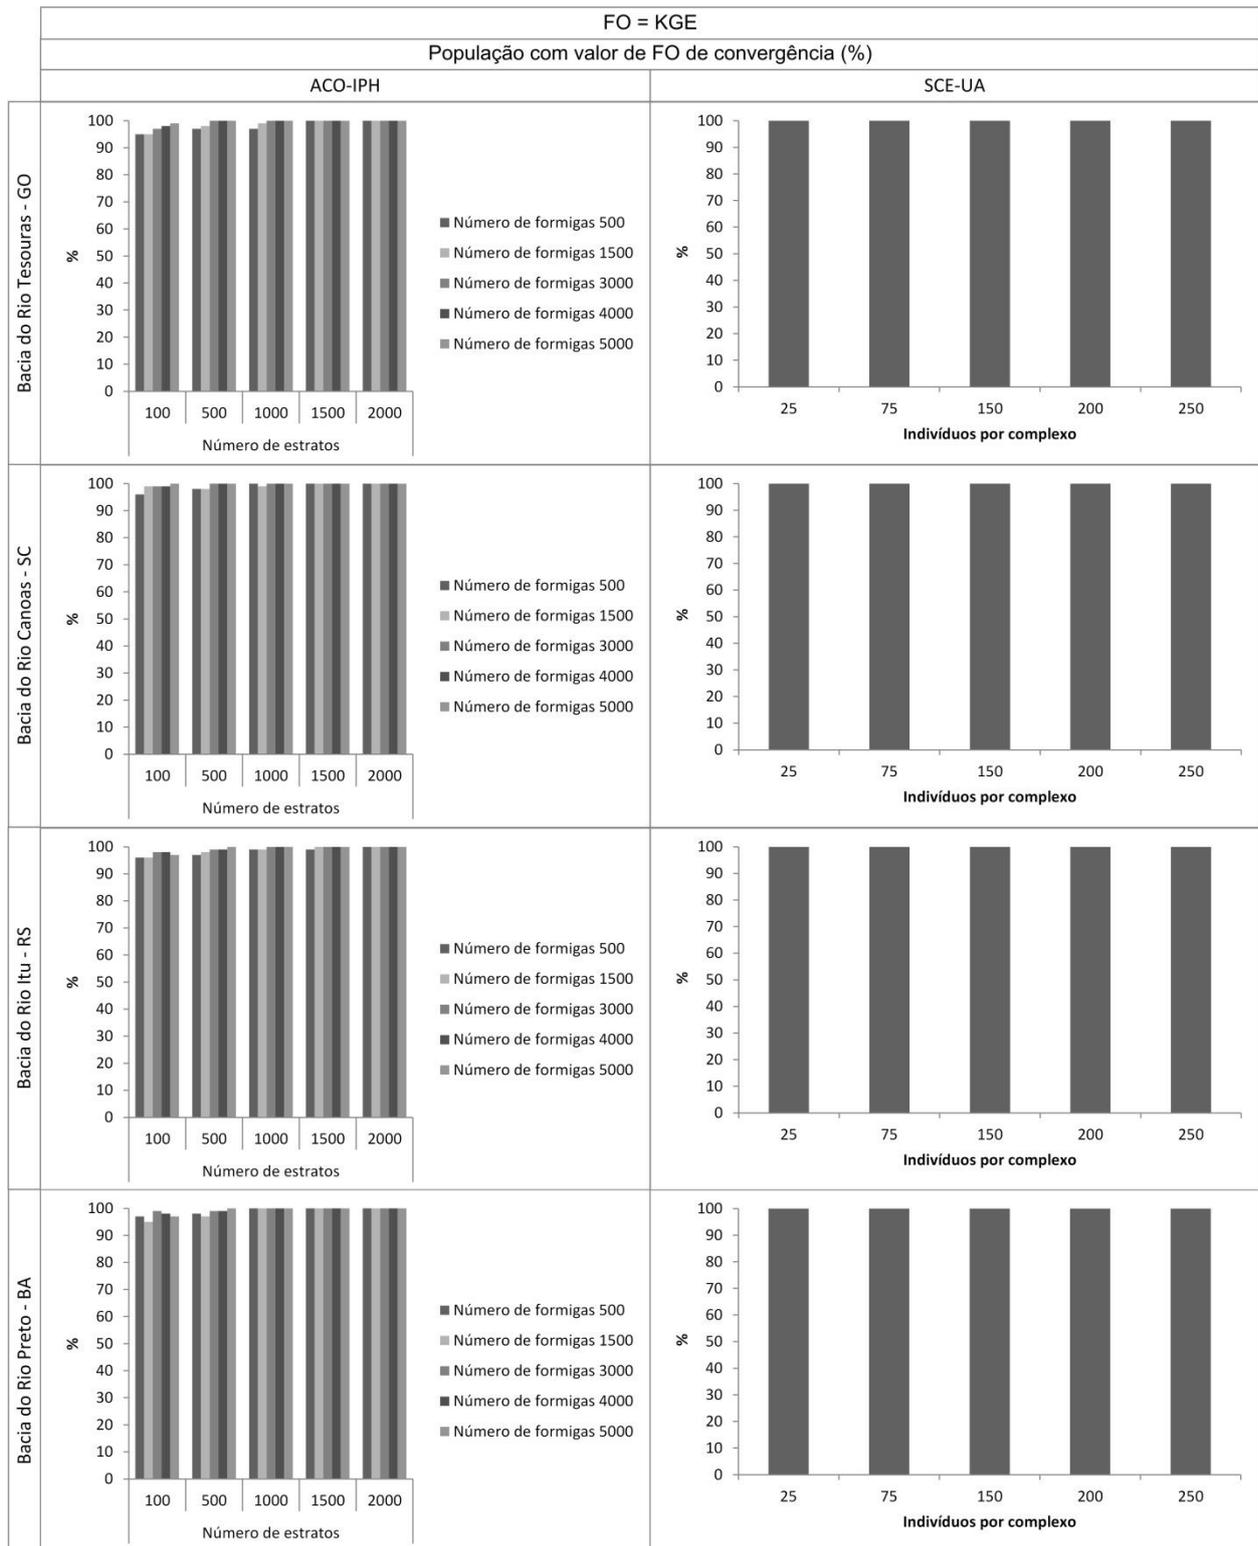
**Figura 48.** Ciclos de convergência para a função KGE nas quatro bacias analisadas.



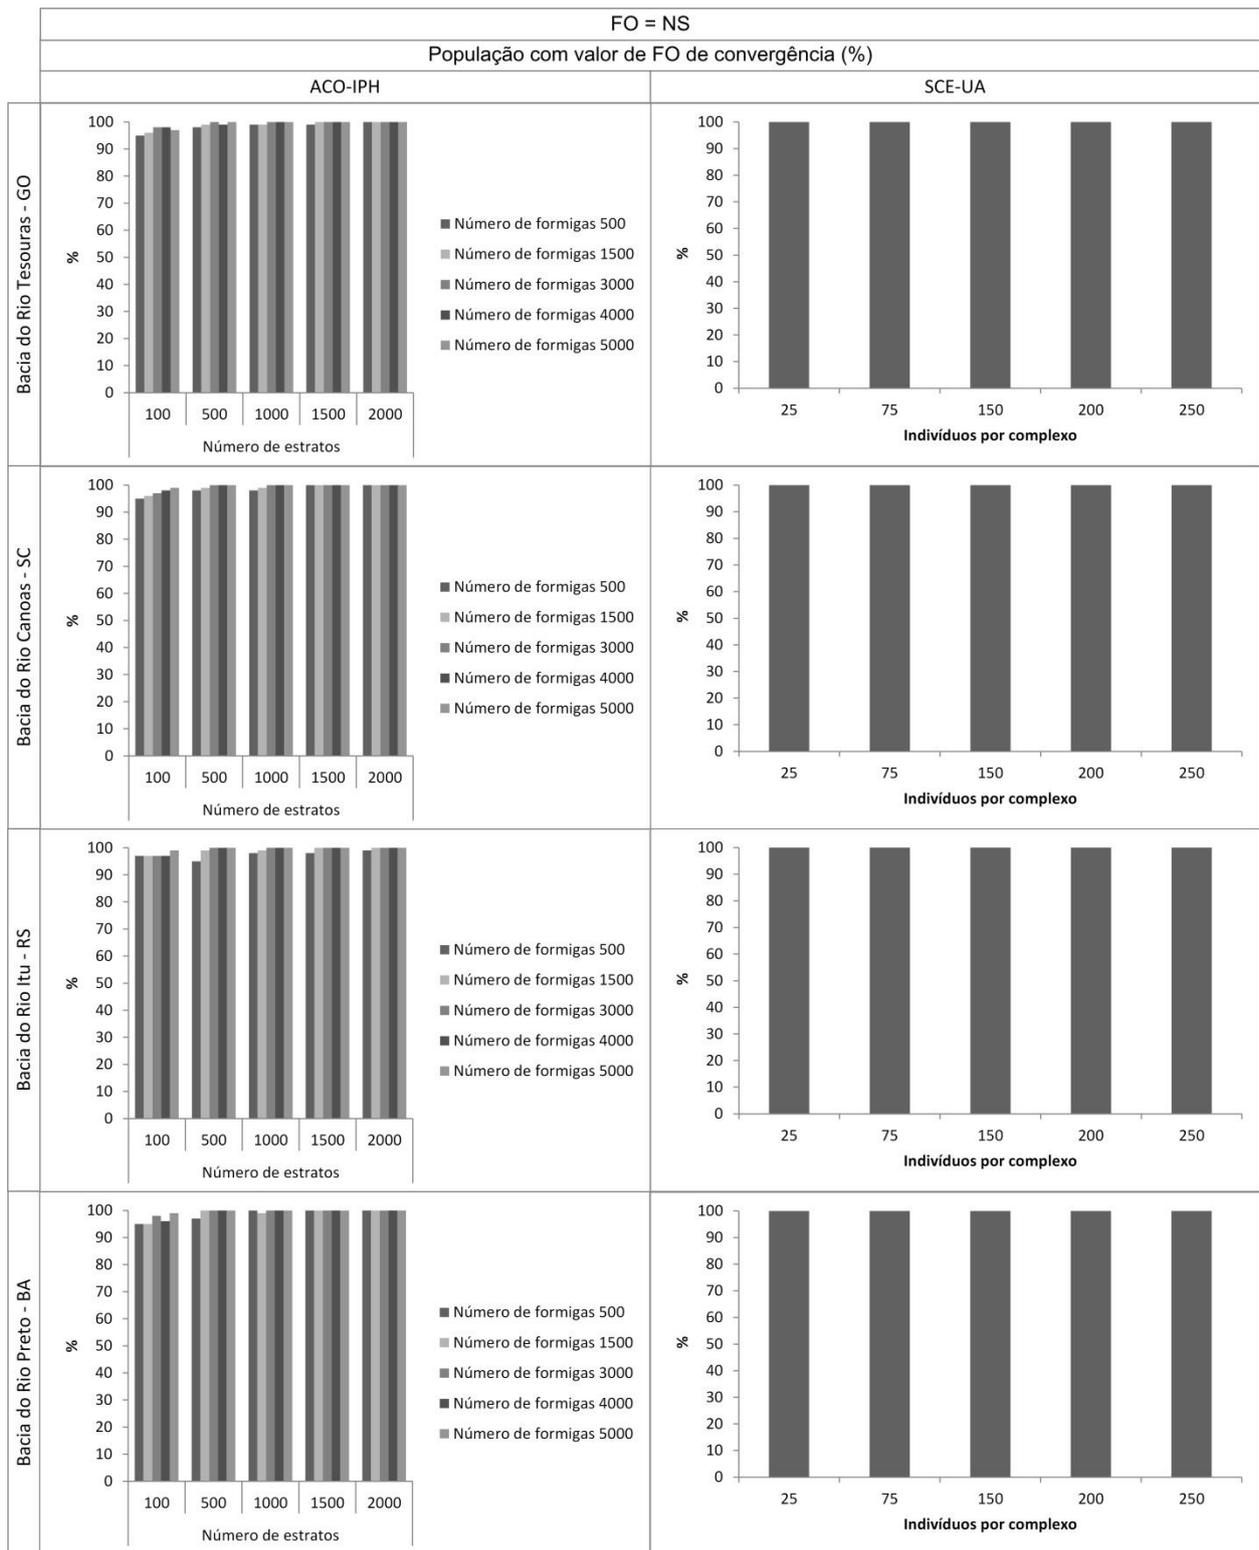
**Figura 49.** Ciclos de convergência para a função NS nas quatro bacias analisadas.



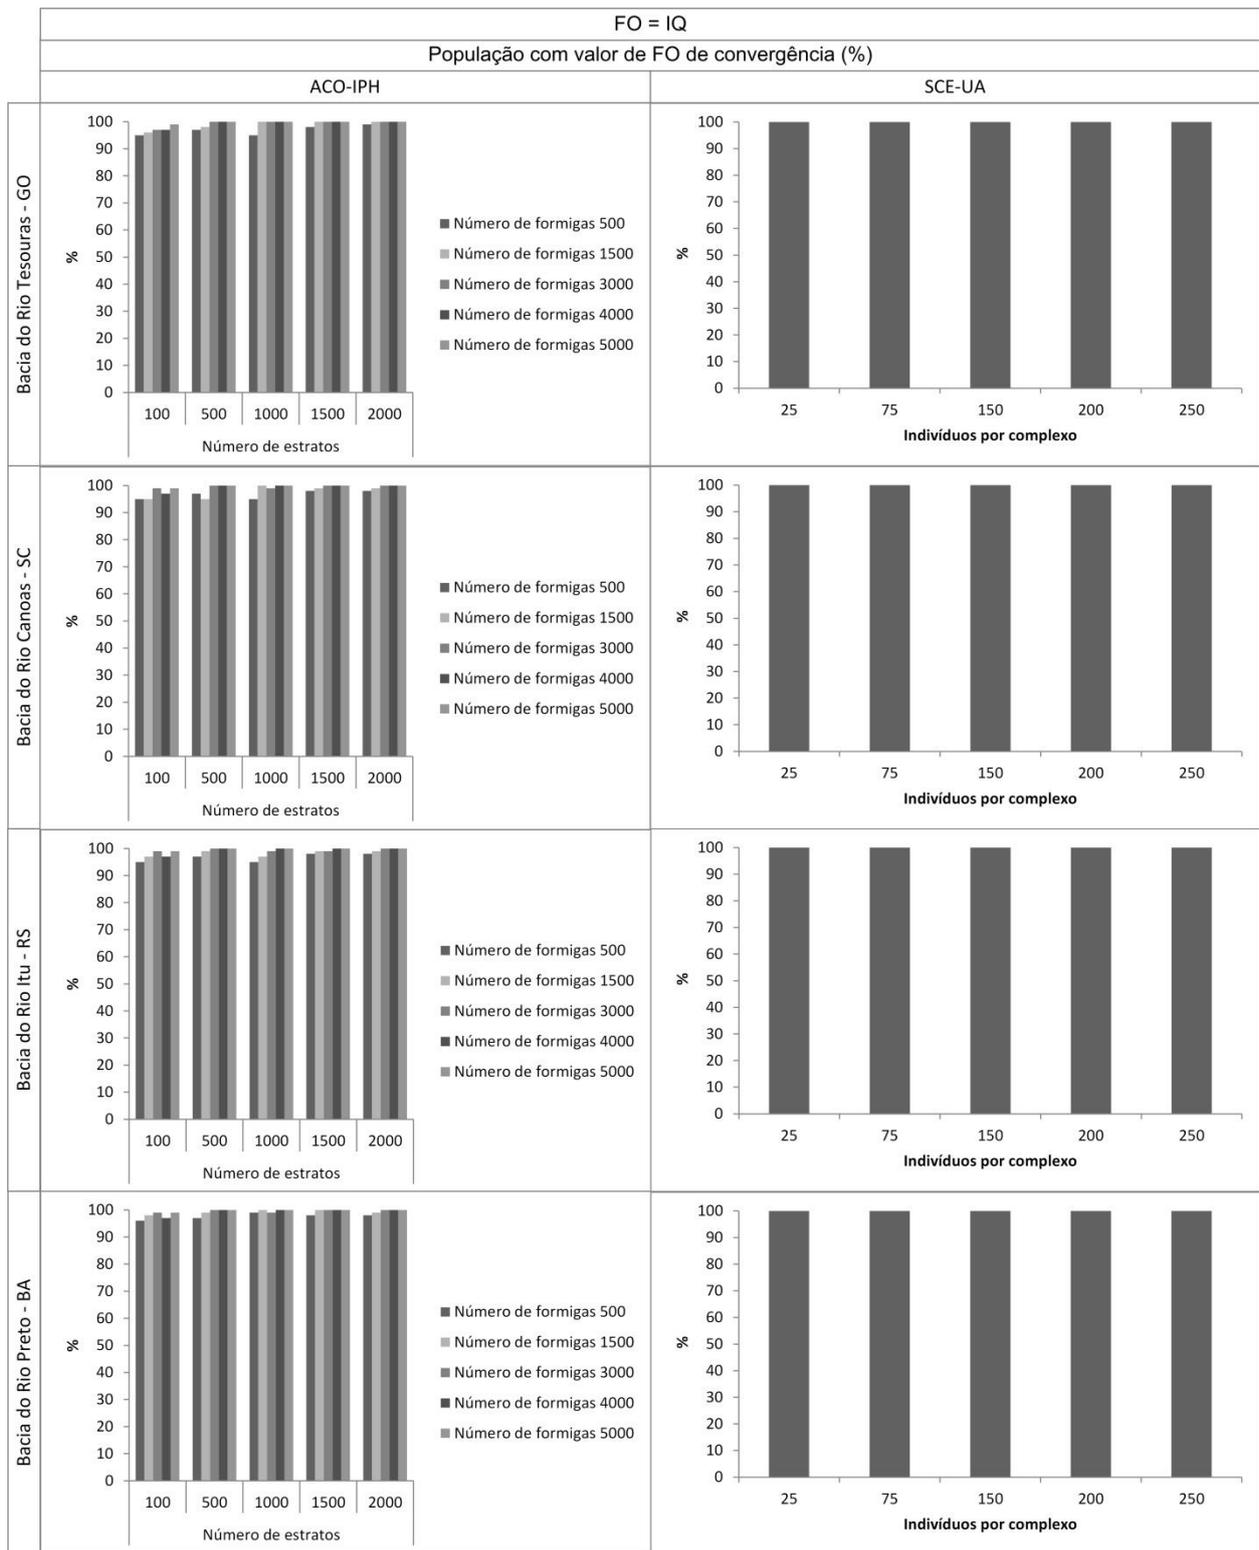
**Figura 50.** Ciclos de convergência para a função IQ nas quatro bacias analisadas.



**Figura 51.** População com valor de FO de convergência para a função KGE nas quatro bacias analisadas.



**Figura 52.** População com valor de FO de convergência para a função NS nas quatro bacias analisadas.



**Figura 53.** População com valor de FO de convergência para a função IQ nas quatro bacias analisadas.

Após feitos todos os testes de eficácia e eficiência, decidiu-se que a população ótima foi de 3000 formigas, e a divisão do espaço de busca foi de 1000 estratos, levando em consideração o desempenho em relação aos resultados numéricos e o tempo de processamento necessário. Até certo ponto, uma estratificação garante encontrar uma solução mais próxima à ótima, mas passando esse ponto, apenas é aumentado o tempo computacional sem produzir melhores resultados na busca do ótimo.

Quando analisados os resultados obtidos com a  $FO_{KGE}$  (Tabela 11) observa-se que o valor da FO encontrado pelo ACO-IPH fica muito próximo do encontrado pelo SCE-UA. Na maioria das bacias o SCE-UA encontra um valor da FO melhor que o encontrado pelo ACO-IPH, com exceção na bacia do Rio Canoas – SC onde o ACO-IPH encontrou um resultado um pouco melhor. Em relação aos valores dos parâmetros, também eles têm um valor menor no caso do ACO-IPH em relação aos valores obtidos com o SCE-UA, salvo exceções pontuais, onde não mais que um a dois parâmetros para cada caso.

A título de exemplo, o ajuste obtido entre as vazões observadas e calculadas, nas diferentes bacias com base nos valores dos parâmetros obtidos pelo uso da  $FO_{KGE}$  é apresentado nas Figura 54 à Figura 57, complementando com a curva de permanência para as quatro bacias analisadas, apresentada na Figura 58.

Na Figura 54 se visualiza para o caso da bacia do Rio Tesouras que a vazão calculada calibrada com o algoritmo SCE-UA consegue acompanhar de maneira aceitável tanto as cheias como as estiagens, no caso da vazão calculada calibrada com o algoritmo ACO-IPH consegue acompanhar bem as cheias, mas não assim as estiagens, mostrando um comportamento mais suave que em relação ao observado e ao calculado com o SCE-UA. Para ambos os casos, as vazões são subestimadas em todo momento. Para complementar a análise, observando à curva de permanência de ambas as vazões calculadas, visualizadas na Figura 58a, na qual se observa que os valores calculados com o SCE-UA são maiores até que se interceptam aos 35  $m^3/s$  aproximadamente, e desde este ponto os valores obtidos com a calibração feita pelo ACO-IPH são ligeiramente maiores até o final da curva.

No caso da bacia do rio Preto (Figura 55), ambos os algoritmos conseguem acompanhar de maneira aceitável as crescidas e as estiagens, acompanhando de melhor maneira a forma do hidrograma a calibração feita com o SCE-UA, superestimando um pouco nas cheias em quase todos os intervalos. Em relação à curva de permanência das vazões calculadas (Figura 58b), observa-se que ambas as curvas são muito similares em relação aos valores.

Observando os hidrogramas da Figura 56, correspondentes à bacia do Rio Itú, observa-se que o hidrograma calibrado com o SCE-UA consegue acompanhar melhor as subidas e as estiagens com certa subestimação, e no caso do ACO-IPH observa-se que novemente nas

estiagens demonstra um comportamento mais tranquilo que o observado, e também vem sempre subestimado, inclusive mais subestimado que o hidrograma do SCE-UA. Na curva de permanência (Figura 58c) observa-se que os valores do SCE-UA são maiores que os valores do ACO-IPH até quase o final da curva, onde se inverte a situação, mas so por pouco margem a diferença para este caso, em comparação com os valores de ambas as curvas antes da intercepção.

E finalmente, analisando o comportamento dos hidrogramas calculados na bacia do rio Canoas (Figura 57), o hidrograma do SCE-UA consegue acompanhar bem as cheias, com subestimação, e no caso das estiagens se comporta de maneira mais sinuosa que o hidrograma observado, mas na maioria das vezes apresentando um valor subestimado. No caso do hidrograma calculado com o ACO-IPH, consegue ter uma boa acurácia no acompanhamento das ceias, não assim nas estiagens, onde se comporta muito tranquilo em relação ao hidrograma observado. De maneira complementar, se visualiza na curva de permanência das vazões calculadas com ambos os algoritmos de calibração (Figura 58d), que os valores calculados são maiores até o ponto de intercepção das curvas, com valor de 55% nos eixos de abscisas e de 35 m<sup>3</sup>/s no eixo das ordenadas, depois do qual os valores obtidos com o ACO-IPH são maiores até o final da curva.

Observa-se que apesar de terem sido obtidos resultados muito próximos em termos do valor da FO, resultados um pouco diferentes são encontrados em termos das vazões simuladas. O SCE-UA consegue acompanhar tanto as subidas como as descidas, enquanto o ACO-IPH consegue acompanhar bem as cheias, mas não tanto as estiagens, onde demonstra um comportamento mais suave em relação ao observado, que se mostra um pouco mais sinuoso. Em ambos os casos existe uma tendência à subestimativa dos valores de vazão ao longo do tempo.

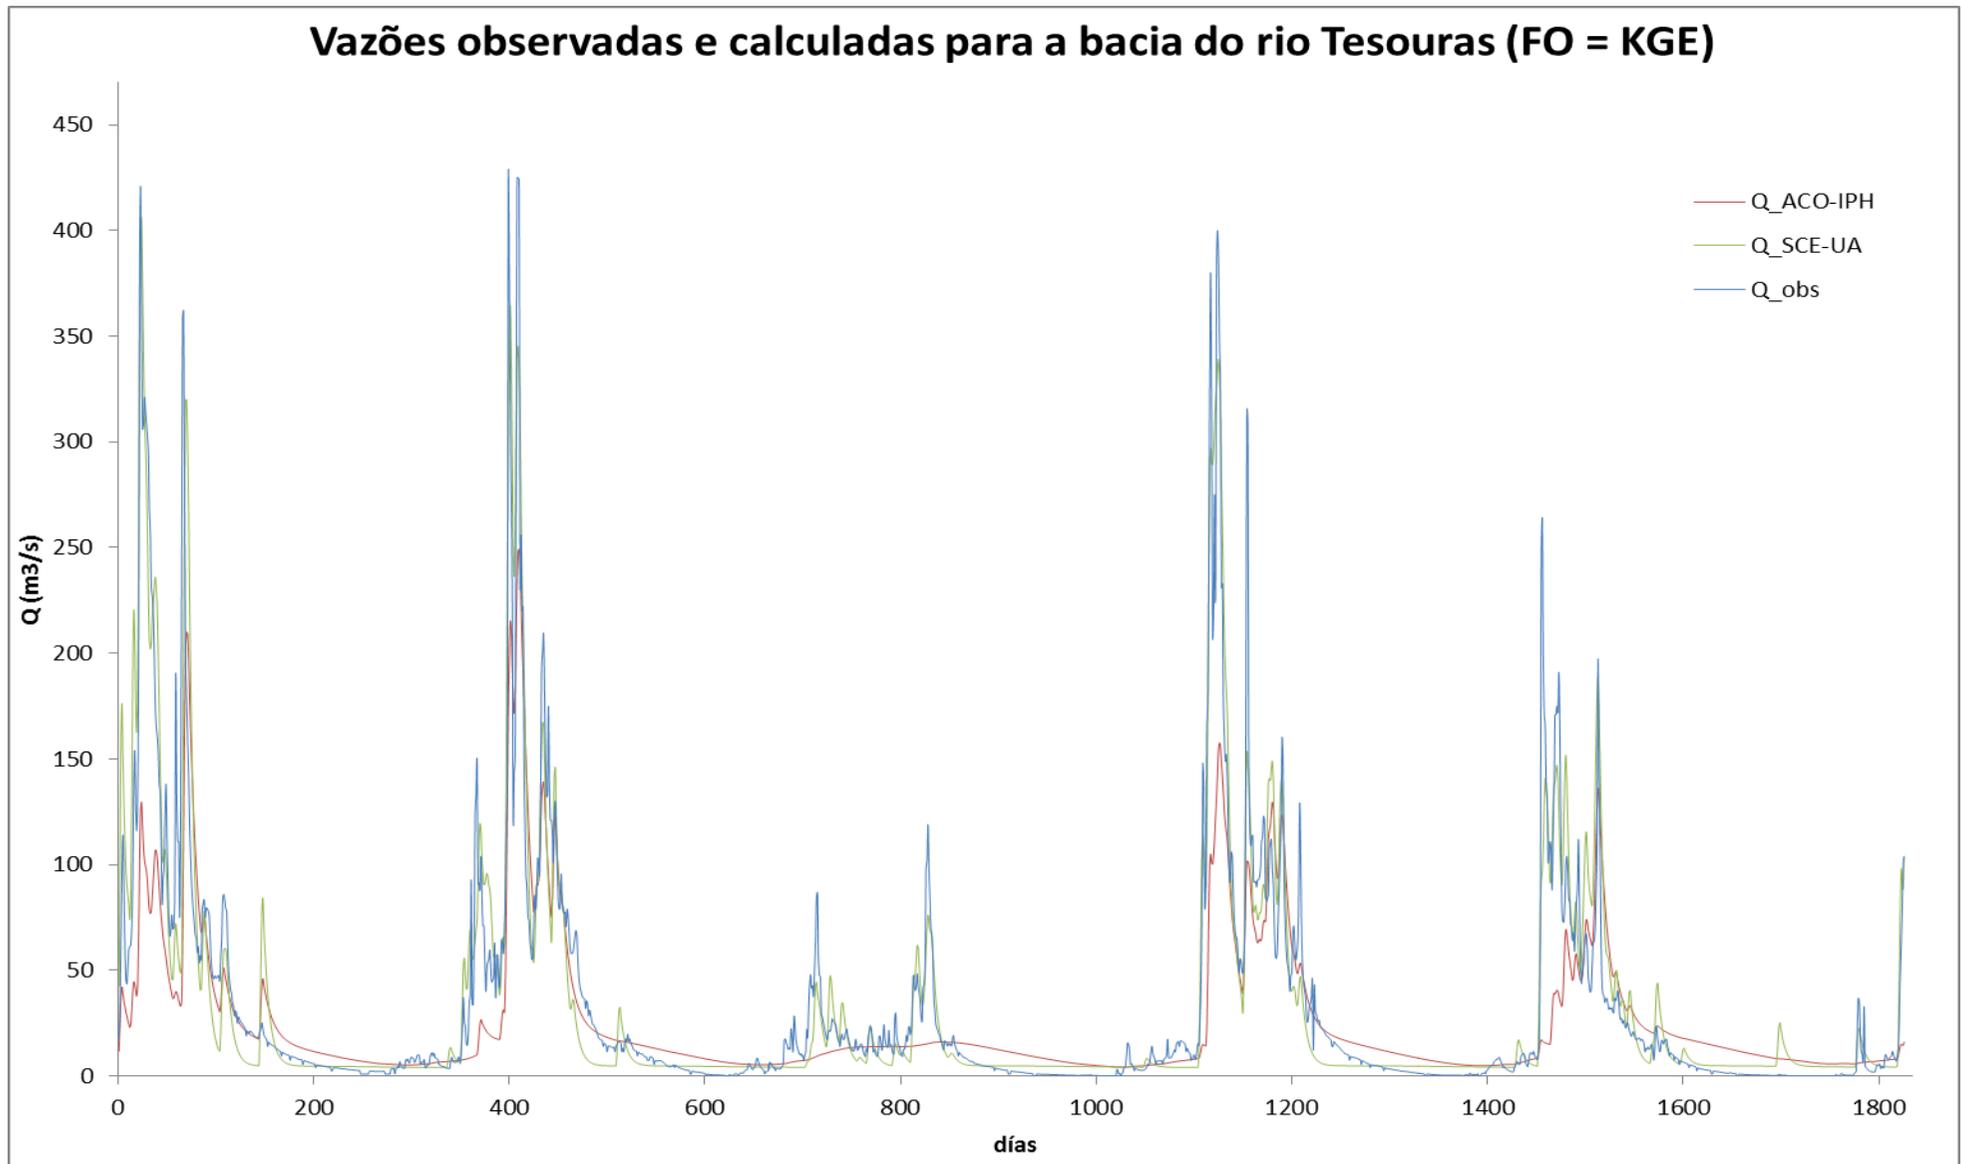
**Tabela 11.** Resultados obtidos para KGE e parâmetros do IPH-II nas quatro bacias analisadas.

		<b>Bacia do Rio Tesouras - GO</b>	
		<b>SCE-UA</b>	<b>ACO-IPH</b>
<b>FO</b>	<b>KGE</b>	0,9269	0,7645
<b>Parâmetros</b>	<b>Io</b>	45,0333	75,9861
	<b>Ib</b>	0,3744	1,0543
	<b>H</b>	0,9182	0,967
	<b>Ks</b>	5,9245	9,8651
	<b>Ksub</b>	498,8266	13,6403
	<b>Rmáx</b>	0,0003	8,2867
	<b>Alfa</b>	4,5963	16,9514

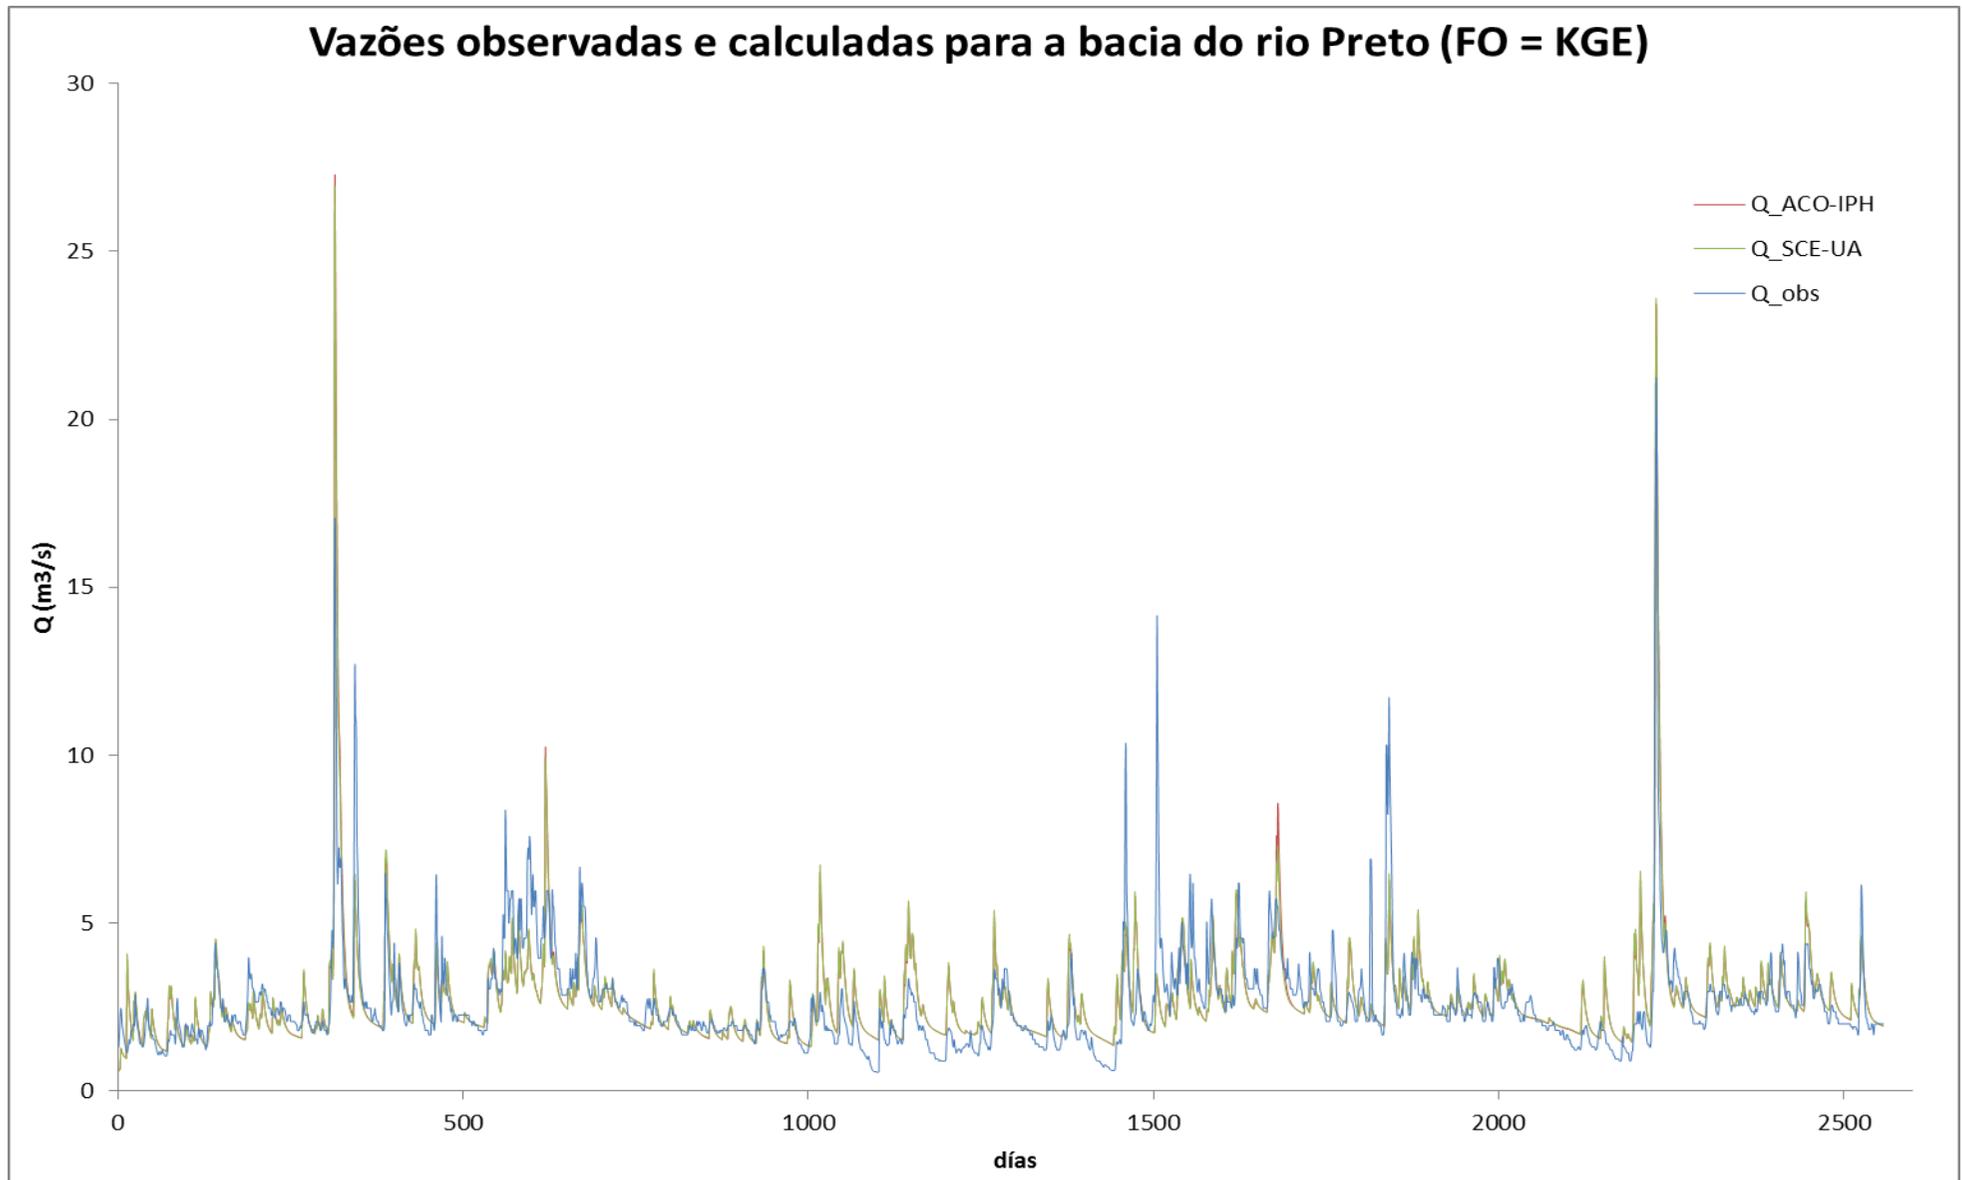
		<b>Bacia do Rio Preto - BA</b>	
		<b>SCE-UA</b>	<b>ACO-IPH</b>
<b>FO</b>	<b>KGE</b>	0,7714	0,7692
<b>Parâmetros</b>	<b>Io</b>	238,1403	236,0891
	<b>Ib</b>	0,6663	0,6631
	<b>H</b>	0,7532	0,7538
	<b>Ks</b>	4,9179	5,2805
	<b>Ksub</b>	10,0044	10,2285
	<b>Rmáx</b>	8,9976	8,6697
	<b>Alfa</b>	19,9473	9,8992

		<b>Bacia do Rio Canoas - SC</b>	
		<b>SCE-UA</b>	<b>ACO-IPH</b>
<b>FO</b>	<b>KGE</b>	0,8654	0,9053
<b>Parâmetros</b>	<b>Io</b>	10,3612	50,1441
	<b>Ib</b>	0,3775	8,3908
	<b>H</b>	0,0102	0,0208
	<b>Ks</b>	4,2377	8,5973
	<b>Ksub</b>	227,6581	445,8785
	<b>Rmáx</b>	0,0408	4,4996
	<b>Alfa</b>	18,8887	3,3185

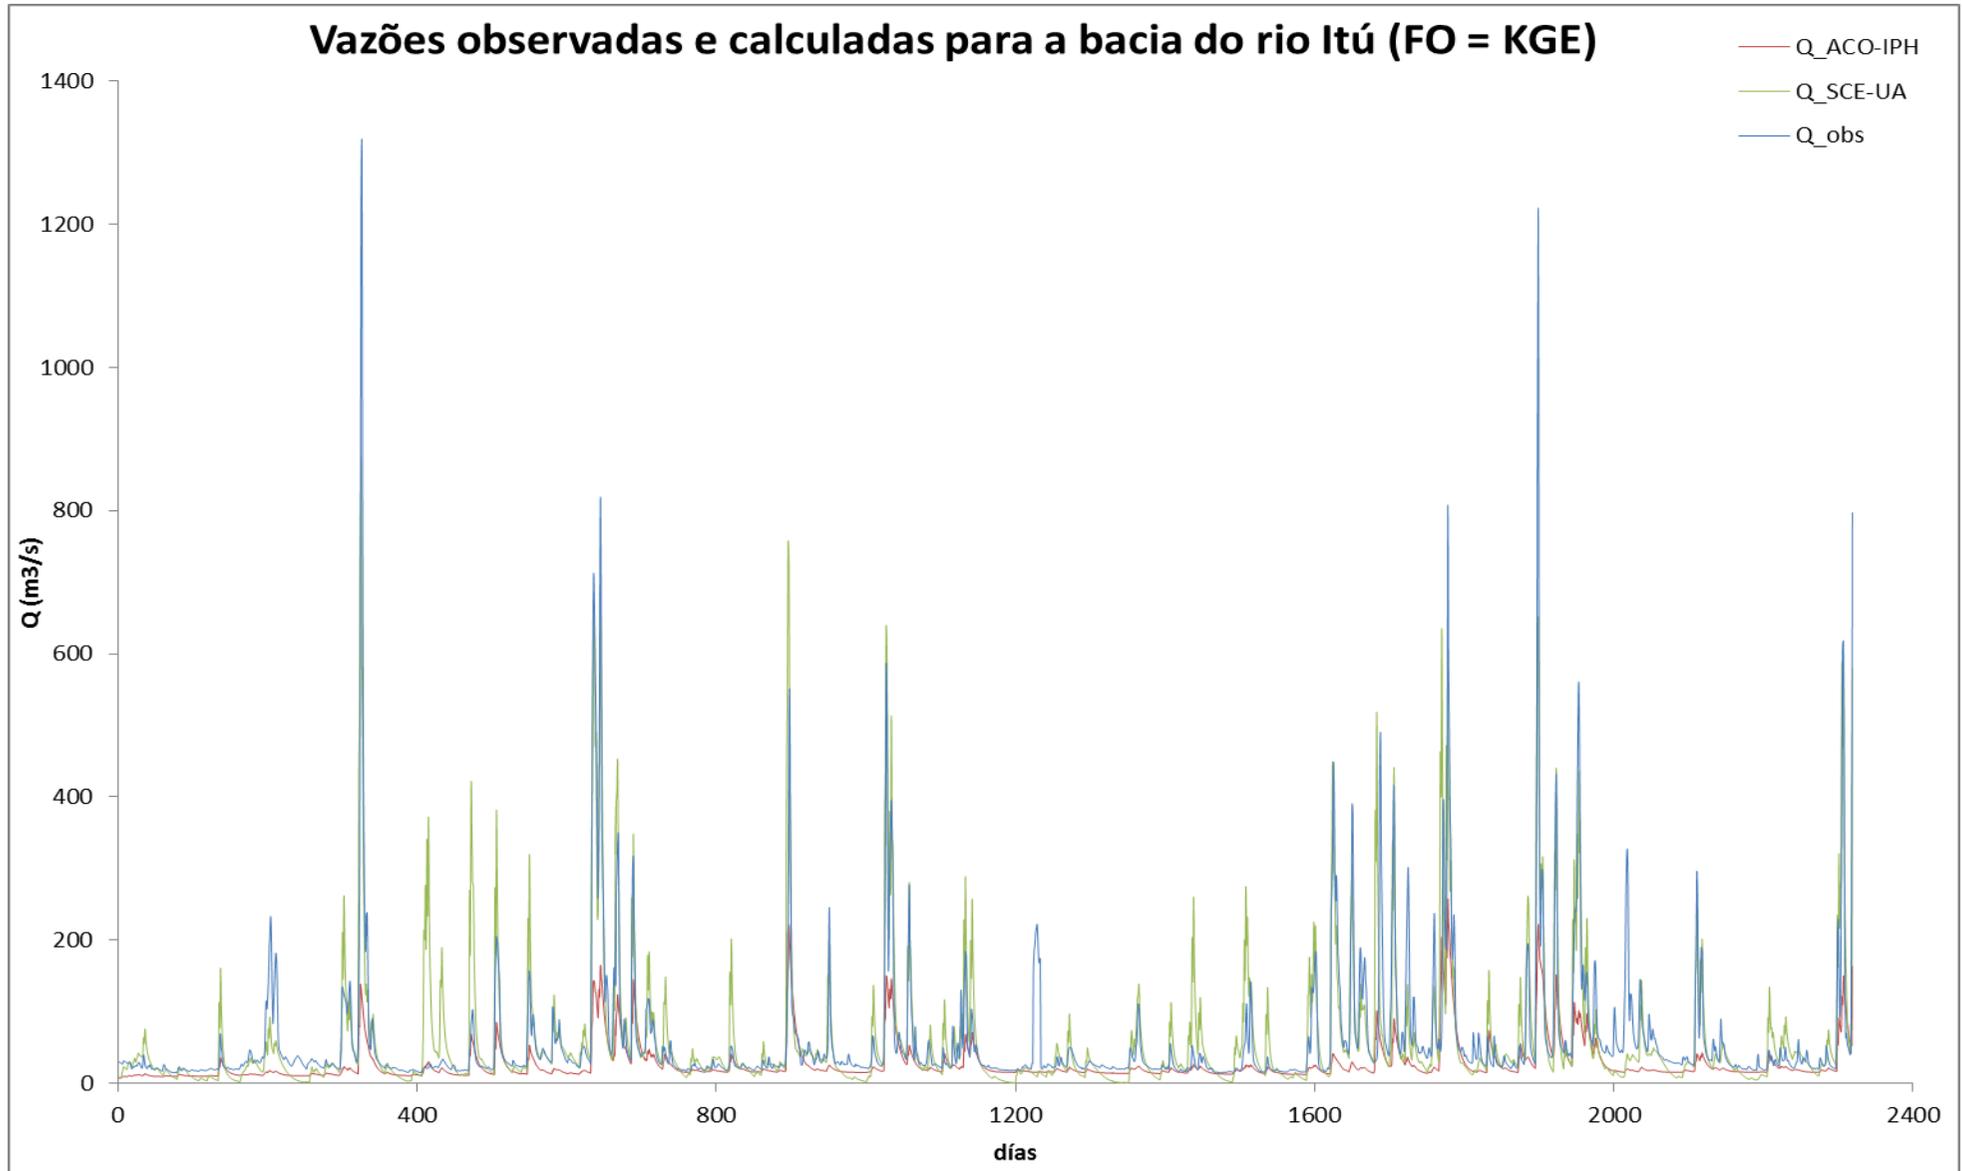
		<b>Bacia do Rio Itu - RS</b>	
		<b>SCE-UA</b>	<b>ACO-IPH</b>
<b>FO</b>	<b>KGE</b>	0,9144	0,7322
<b>Parâmetros</b>	<b>Io</b>	90,6035	177,7896
	<b>Ib</b>	2,3524	0,6842
	<b>H</b>	0,0656	0,9107
	<b>Ks</b>	2,2150	7,5794
	<b>Ksub</b>	10,0182	209,2104
	<b>Rmáx</b>	0,7906	7,9272
	<b>Alfa</b>	1,6524	0,0108



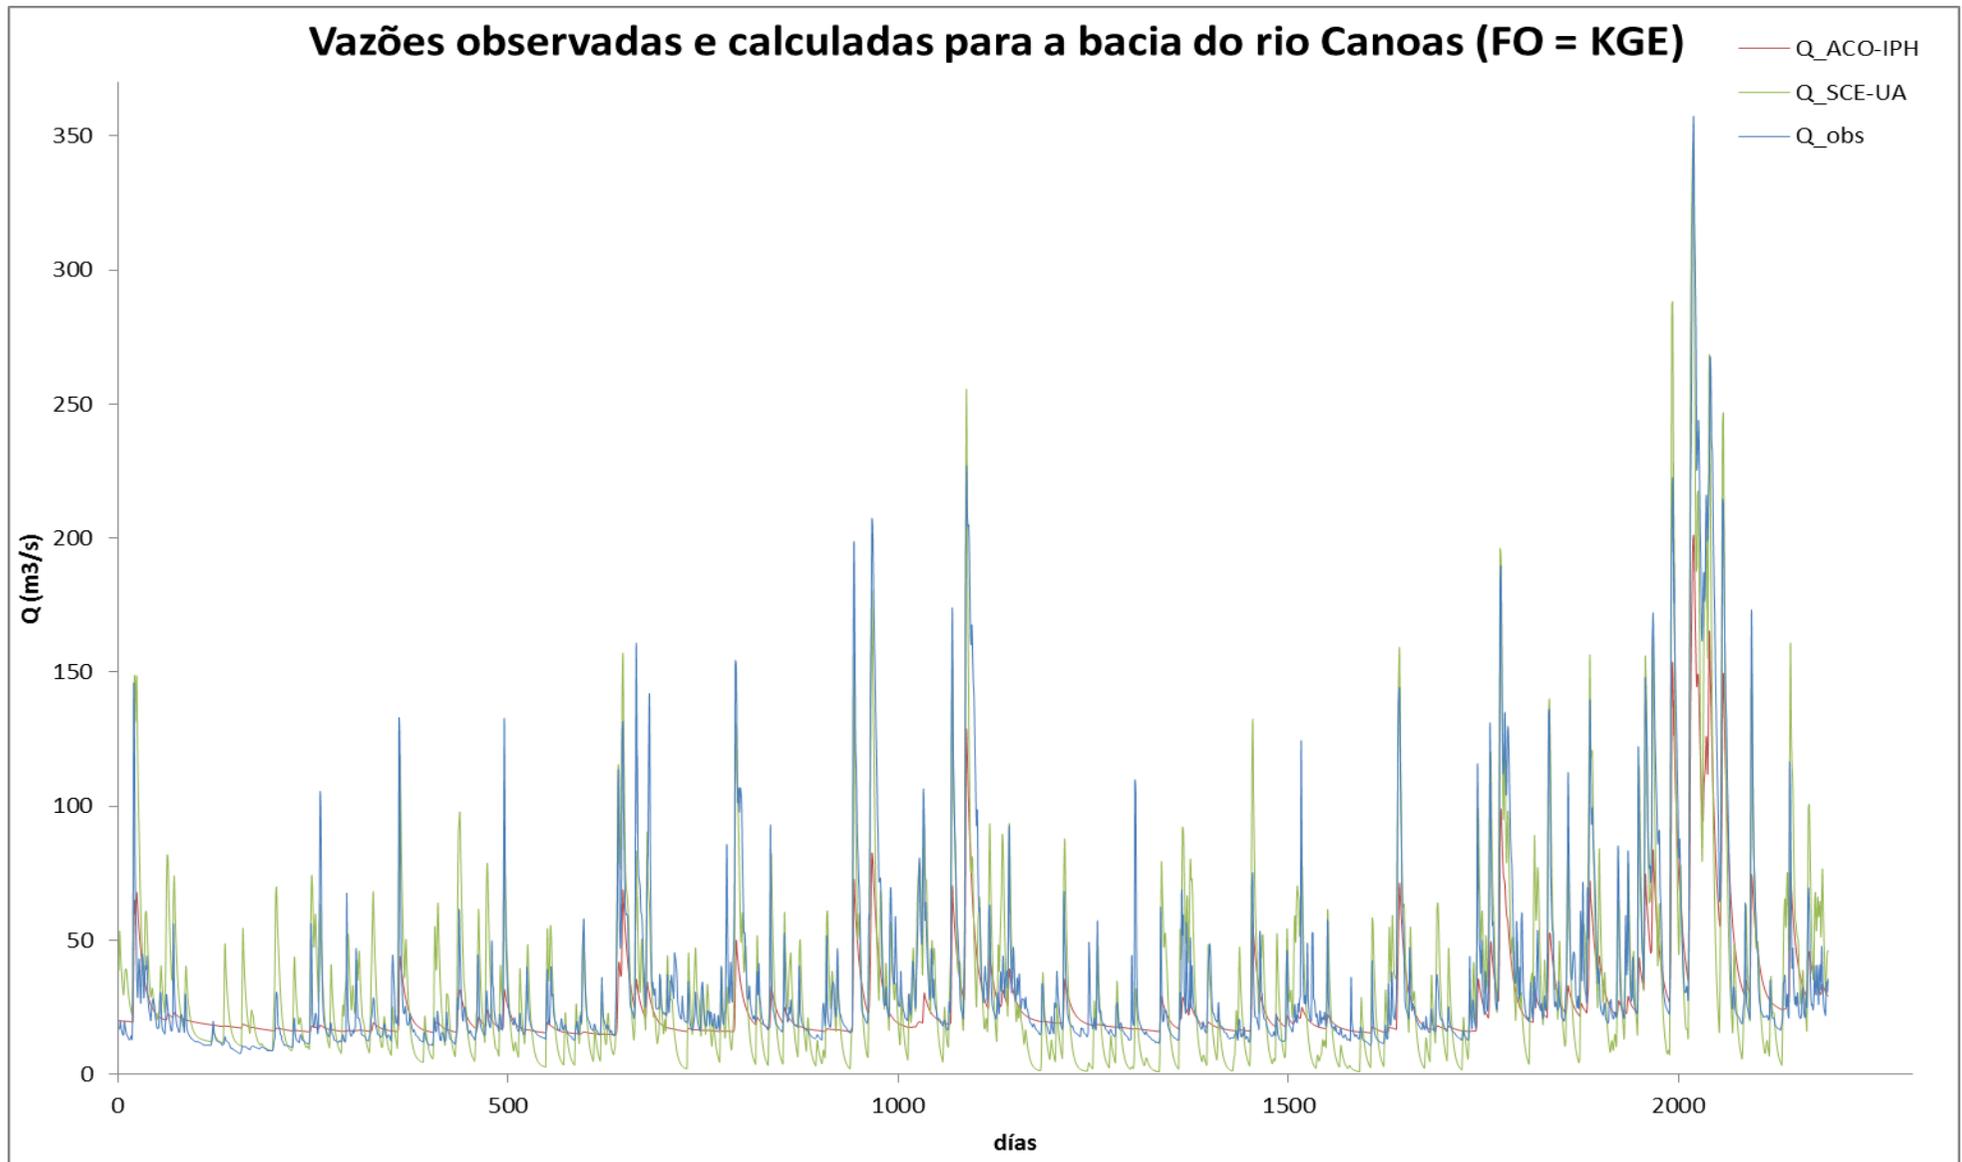
**Figura 54.** Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função KGE – Rio Tesouras.



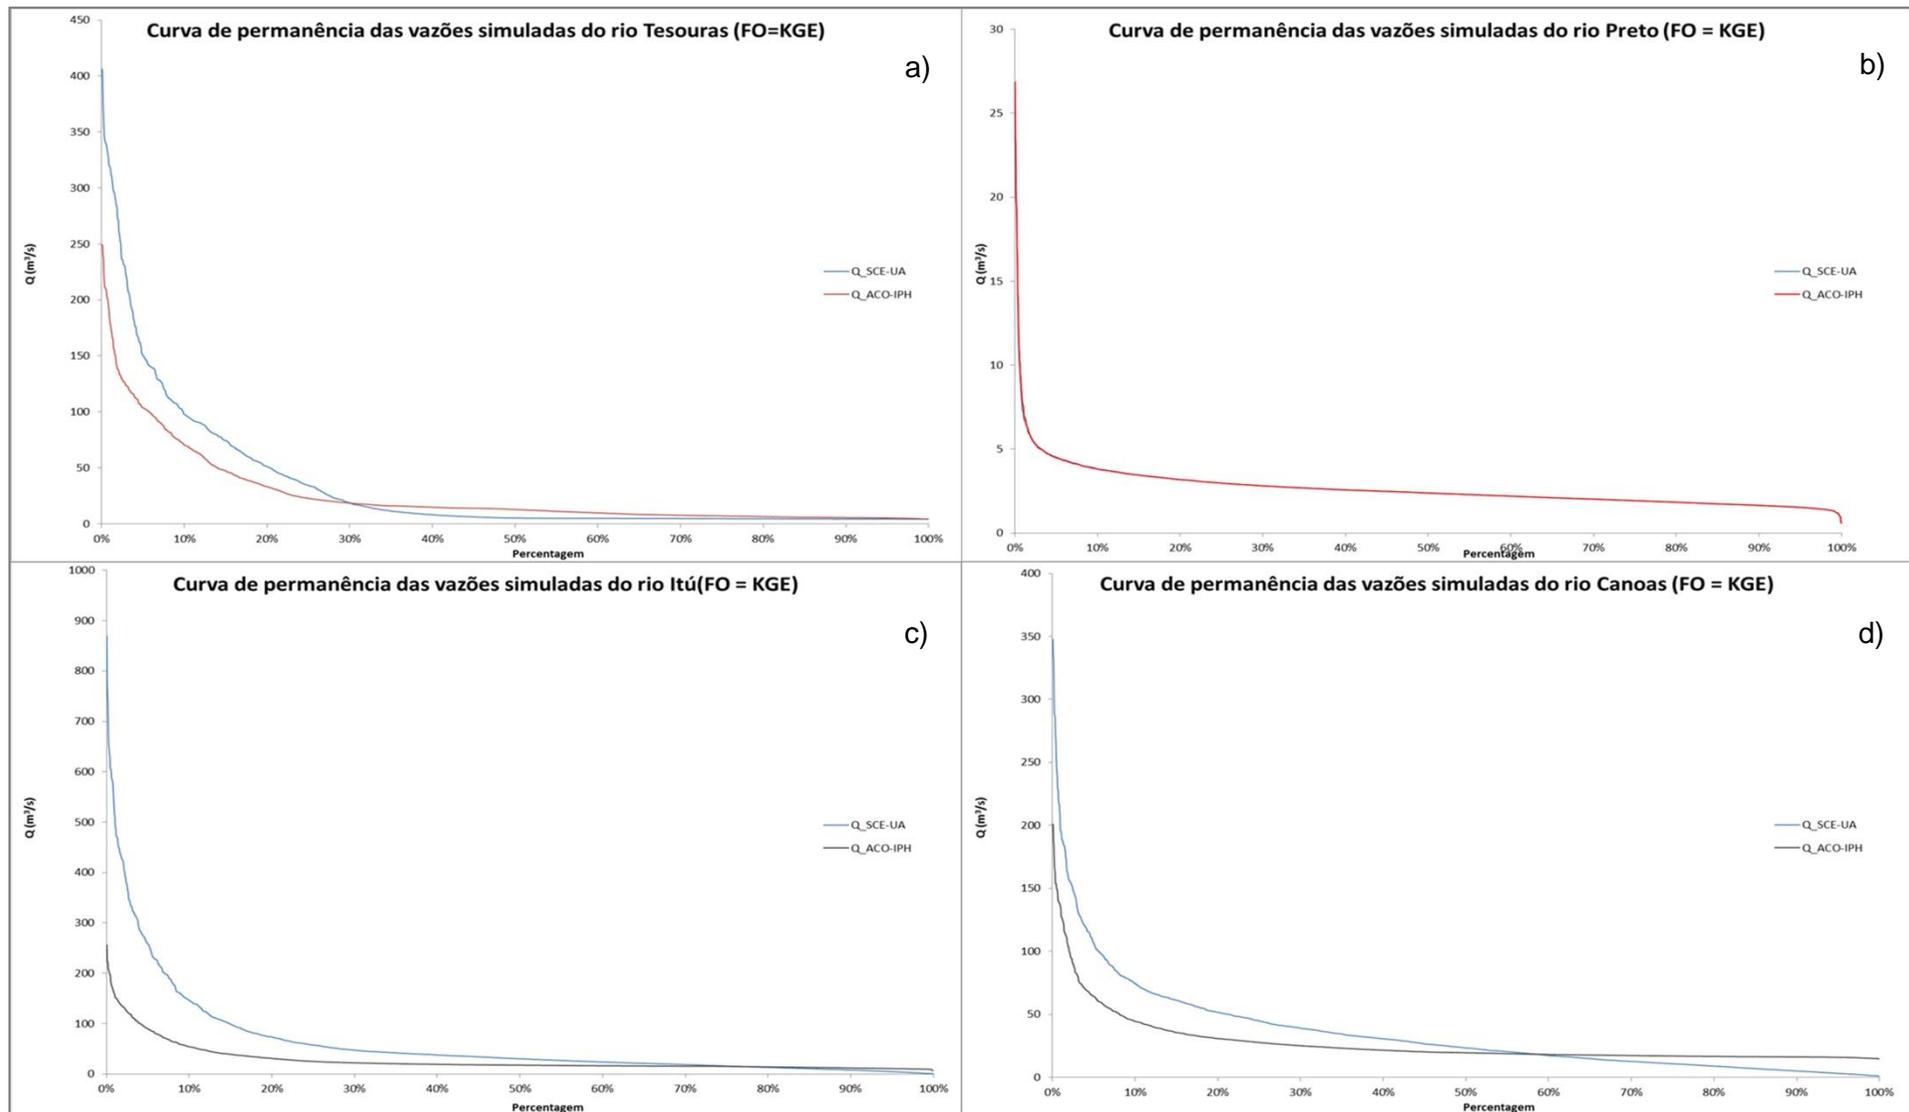
**Figura 55.** Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função KGE – Rio Preto.



**Figura 56.** Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função KGE – Rio Itú.



**Figura 57.** Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função KGE – Rio Canoas.



**Figura 58.** Curvas de permanência das vazões simuladas das quatro bacias analisadas para FO = KGE. a) Bacia do Rio Tesouras; b) Bacia do Rio Preto; c) Bacia do Rio Itú; d) Bacia do Rio Canoas

Para a  $FO_{NS}$  (Tabela 12), observa-se que os valores da FO encontrados pelo ACO-IPH não ficam muito próximos dos encontrados pelo SCE-UA no caso da bacia do rio Tesouras – GO e do rio Itu – RS. Nas outras duas bacias os resultados são bem mais próximos, inclusive sendo levemente melhor no caso da bacia do rio Preto. Em relação aos valores dos parâmetros, apenas na bacia do rio Preto os resultados do ACO-IPH e SCE-UA são muito próximos, enquanto que nas demais bacias os valores encontrados pelo ACO-IPH são, em geral, maiores que os encontrados pelo SCE-UA.

A título de exemplo, o ajuste obtido entre as vazões observadas e calculadas, nas diferentes bacias com base nos valores dos parâmetros obtidos pelo uso da  $FO_{NS}$  é apresentado nas Figura 59 à Figura 62, complementando com a curva de permanência das vazões simuladas para as quatro bacias analisadas, apresentada na Figura 63.

Na Figura 59 se visualiza para o caso da bacia do Rio Tesouras que as vazões calculadas calibradas com o algoritmo SCE-UA conseguem acompanhar de maneira aceitável tanto as cheias como as estiagens, mas são quase sempre subestimadas as vazões em relação ao observado, tanto para as subidas como para as descidas do hidrograma. No caso das vazões calculadas calibradas com o algoritmo ACO-IPH consegue acompanhar bem as cheias, mas não assim as estiagens, mas mostra uma pequena melhoria em relação ao desempenho na função KGE, mas em geral superestima nas secas e subestima nas cheias. Para complementar a análise, observando à curva de permanência de ambas as vazões calculadas, visualizadas na Figura 63a, na qual se observa que os valores calculados com o SCE-UA são menores até que se interceptam aos  $10 \text{ m}^3/\text{s}$  aproximadamente, e desde este ponto os valores obtidos com a calibração feita pelo ACO-IPH são ligeiramente menores até o final da curva.

No caso da bacia do rio Preto (Figura 60), ambos os algoritmos conseguem acompanhar de maneira aceitável as crescidas e as estiagens, observando-se que em quase todos os intervalos ambos os hidrogramas são quase iguais e que em poucas ocasiões ocorre uma pequena superestimação do hidrograma calibrado com o ACO-IPH nas crescidas, e ambos são, maiormente, superestimados nas estiagens. Em relação à curva de permanência das vazões calculadas (Figura 63b), observa-se que ambas as curvas são muito similares em relação aos valores, pois são quase superpostas ambas as curvas.

Observando os hidrogramas da Figura 61, correspondentes à bacia do Rio Itú, observa-se que o hidrograma calibrado com o SCE-UA consegue acompanhar melhor as subidas e as estiagens com certa superestimação, maiormente observado nas estiagens, e no caso do ACO-IPH observa-se que novamente nas estiagens demonstra um comportamento mais tranquilo que o observado, e também vem na maioria das vezes subestimadas tanto nas subidas como nas descidas do hidrograma, inclusive mais subestimado que o hidrograma do

SCE-UA. Na curva de permanência (Figura 63c) observa-se que os valores do SCE-UA são maiores que os valores do ACO-IPH até o valor de 70 m<sup>3</sup>/s aproximadamente, e a partir de tal valor as curvas são quase superpostas até o final.

E finalmente, analisando o comportamento dos hidrogramas calculados na bacia do rio Canoas (Figura 62), o hidrograma do SCE-UA consegue acompanhar bem, tanto as cheias como as estiagens com certa subestimação, maiormente observado nas secas. No caso do hidrograma calculado com o ACO-IPH, consegue ter uma boa acurácia no acompanhamento das cheias, não assim nas estiagens, onde se comporta muito tranquilo em relação ao hidrograma observado, demonstrando para ambas as situações uma subestimação em relação ao valor observado em quase todo o hidrograma. De maneira complementar, se visualiza na curva de permanência das vazões calculadas com ambos os algoritmos de calibração (Figura 63d), que os valores calculados são maiores até o ponto de intercepção das curvas, com valor de 55% nos eixos de abscisas e de 25 m<sup>3</sup>/s no eixo das ordenadas, depois do qual os valores obtidos com o ACO-IPH são maiores até o final da curva.

Observa-se que no caso do SCE-UA, se consegue acompanhar tanto as subidas como as descidas em todos os casos, enquanto o uso do ACO-IPH na bacia do rio Tesouras – GO não mostra uma boa calibração, pois o hidrograma se comporta menos sinuoso do que deveria ser. No caso da bacia do rio Preto – BA e da bacia do rio Canoas - SC, ele consegue talvez o seu melhor desempenho, pois tanto nas cheias como nas estiagens o ACO-IPH consegue acompanhar bem o hidrograma observado, e no caso da bacia do rio Itu – RS se consegue um bom acompanhamento do hidrograma nas subidas e nas descidas, mas com uma tendência a subestimativa das vazões.

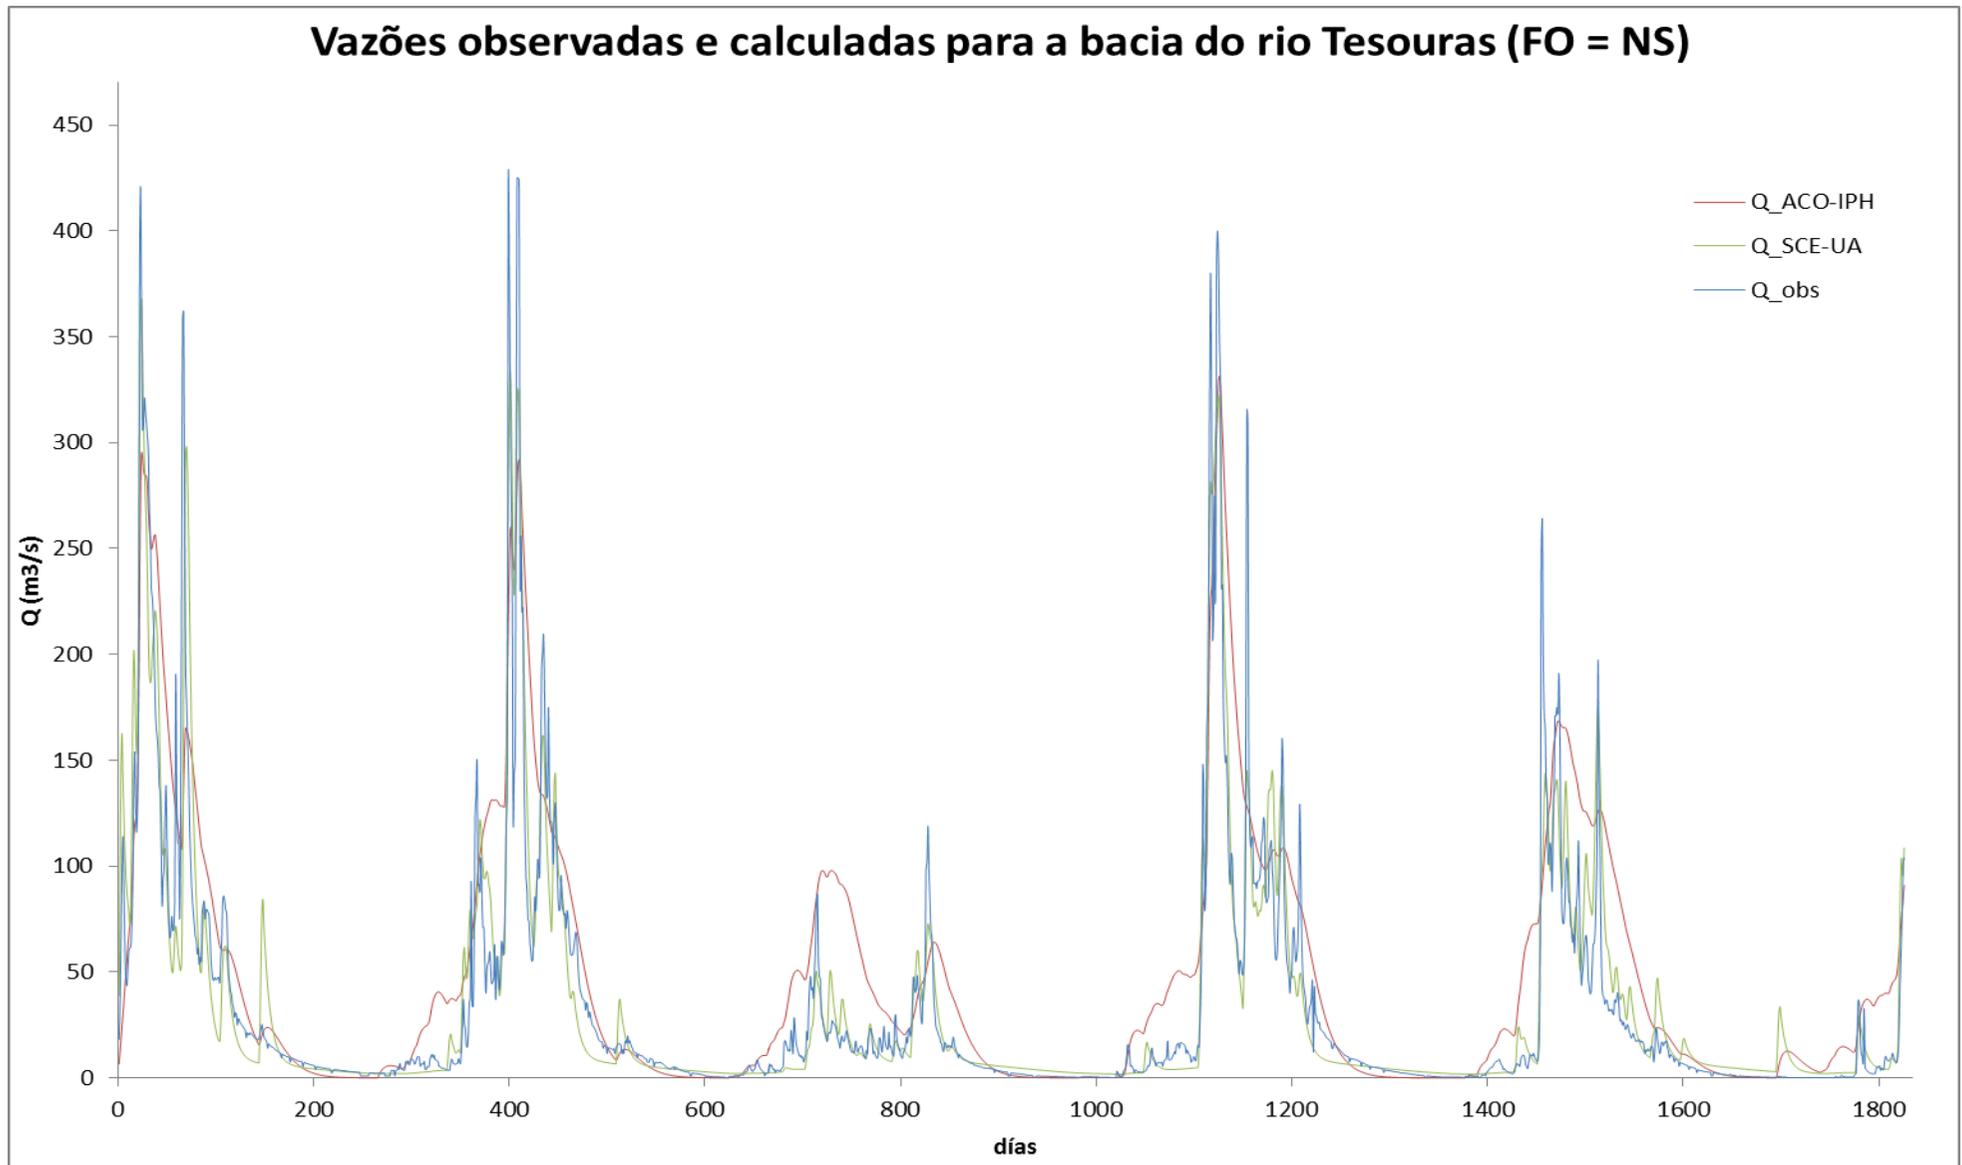
**Tabela 12.** Resultados obtidos para NS e parâmetros do IPH-II nas quatro bacias analisadas.

		Bacia do Rio Tesouras - GO	
		SCE-UA	ACO-IPH
FO	NS	0,8569	0,6967
Parâmetros	Io	38,5932	114,2696
	Ib	0,4269	9,7573
	H	0,934804082	0,5675
	Ks	6,6443	9,8038
	Ksub	11,4193	10,2229
	Rmáx	0,0001	8,3284
	Alfa	19,9811	0,0208

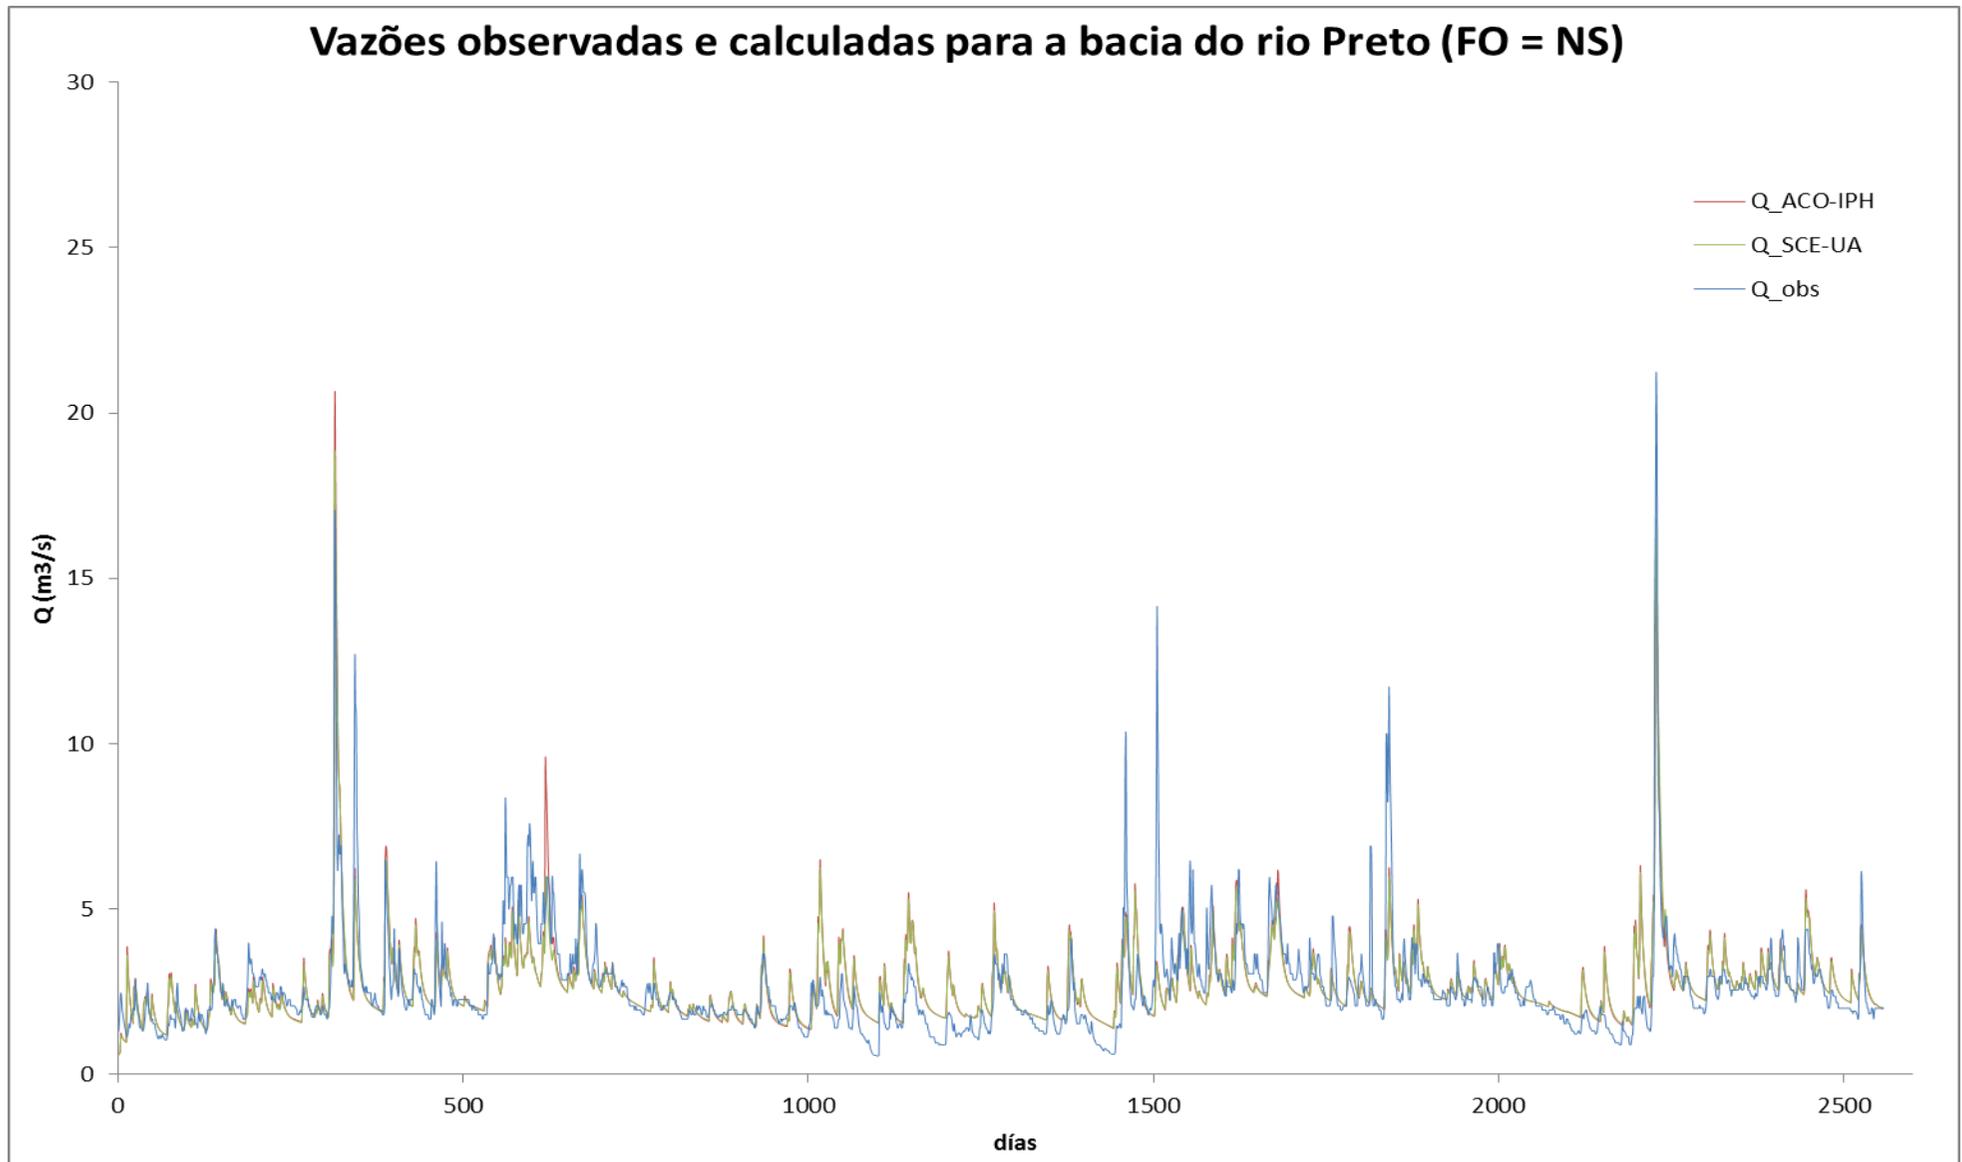
		Bacia do Preto - BA	
		SCE-UA	ACO-IPH
FO	NS	0,6146	0,6171
Parâmetros	Io	249,7139	274,3300
	Ib	0,6756	0,6797
	H	0,7579	0,7241
	Ks	5,9316	5,3985
	Ksub	10,0194	10,7052
	Rmáx	8,9920	8,6385
	Alfa	19,9878	15,9090

		Bacia do Rio Canoas - SC	
		SCE-UA	ACO-IPH
FO	NS	0,8183	0,8096
Parâmetros	Io	27,1216	63,7555
	Ib	9,8700	9,8765
	H	0,0101	0,0100
	Ks	4,9890	8,6405
	Ksub	11,8229	463,0060
	Rmáx	0,0620	3,5024
	Alfa	17,2724	10,5763

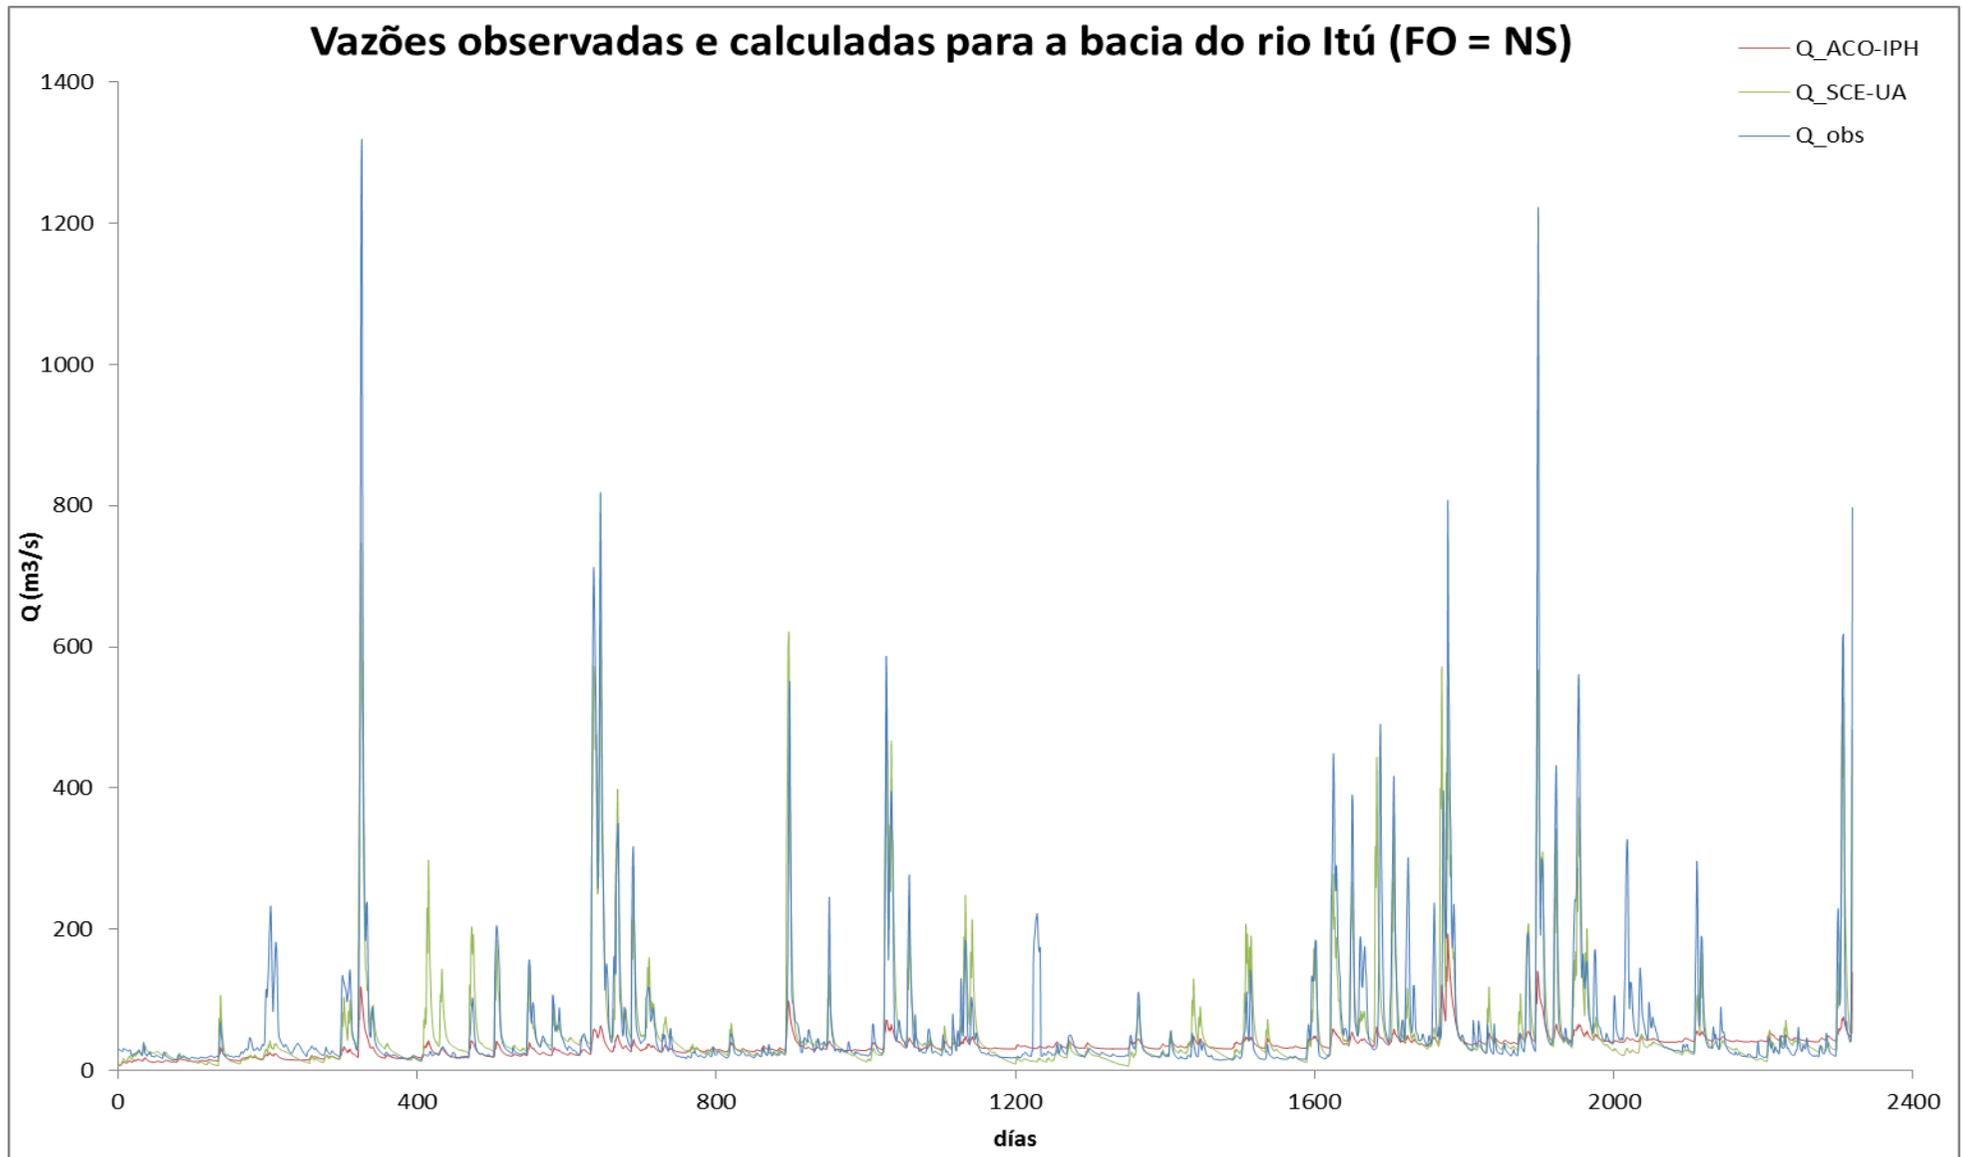
		Bacia do Rio Itu - RS	
		SCE-UA	ACO-IPH
FO	NS	0,7012	0,5355
Parâmetros	Io	174,2083	140,8996
	Ib	1,9731	3,1737
	H	0,1045	0,9960
	Ks	2,6959	5,5704
	Ksub	25,9258	89,6424
	Rmáx	0,0000	0,4596
	Alfa	2,2210	9,8104



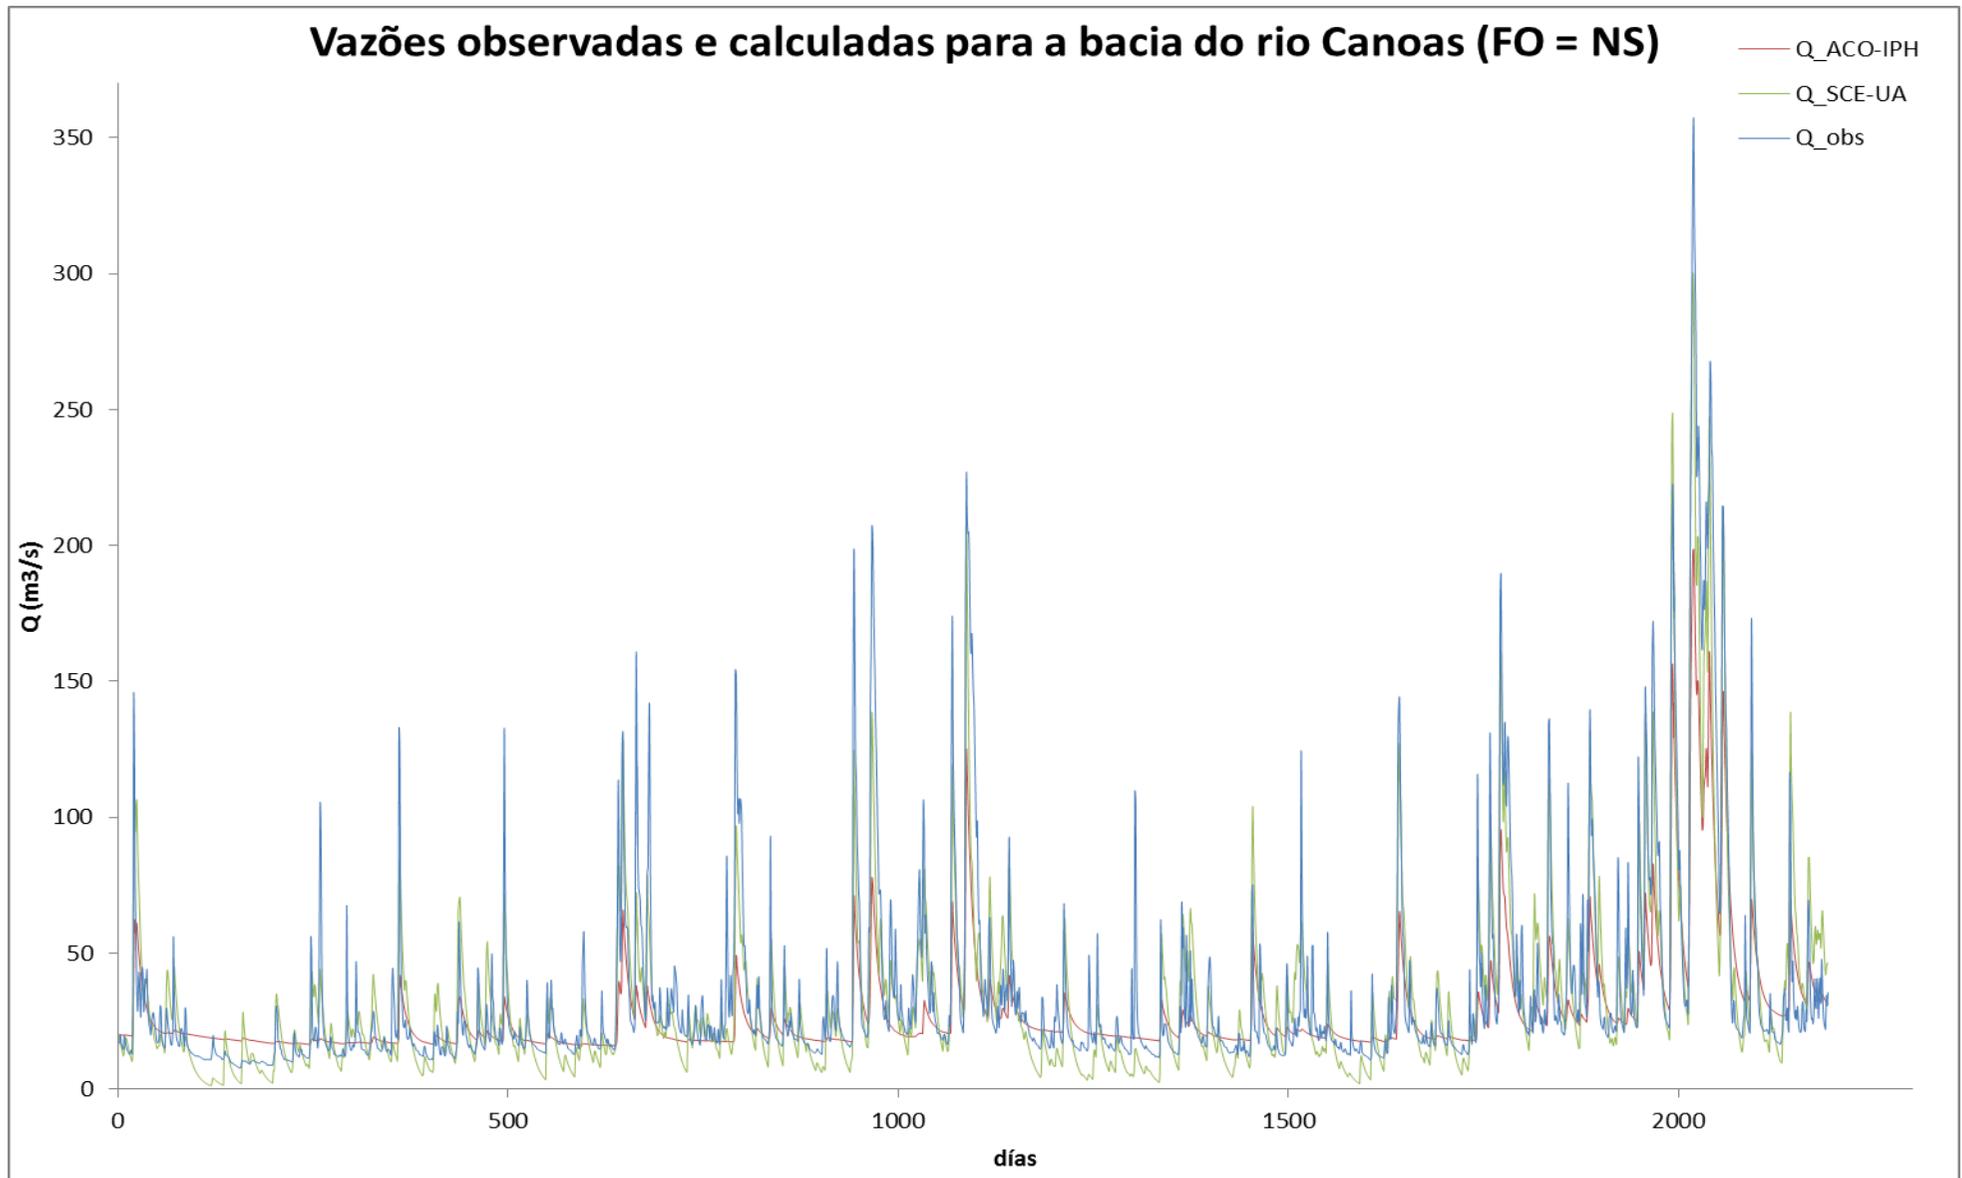
**Figura 59.** Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função NS – Rio Tesouras.



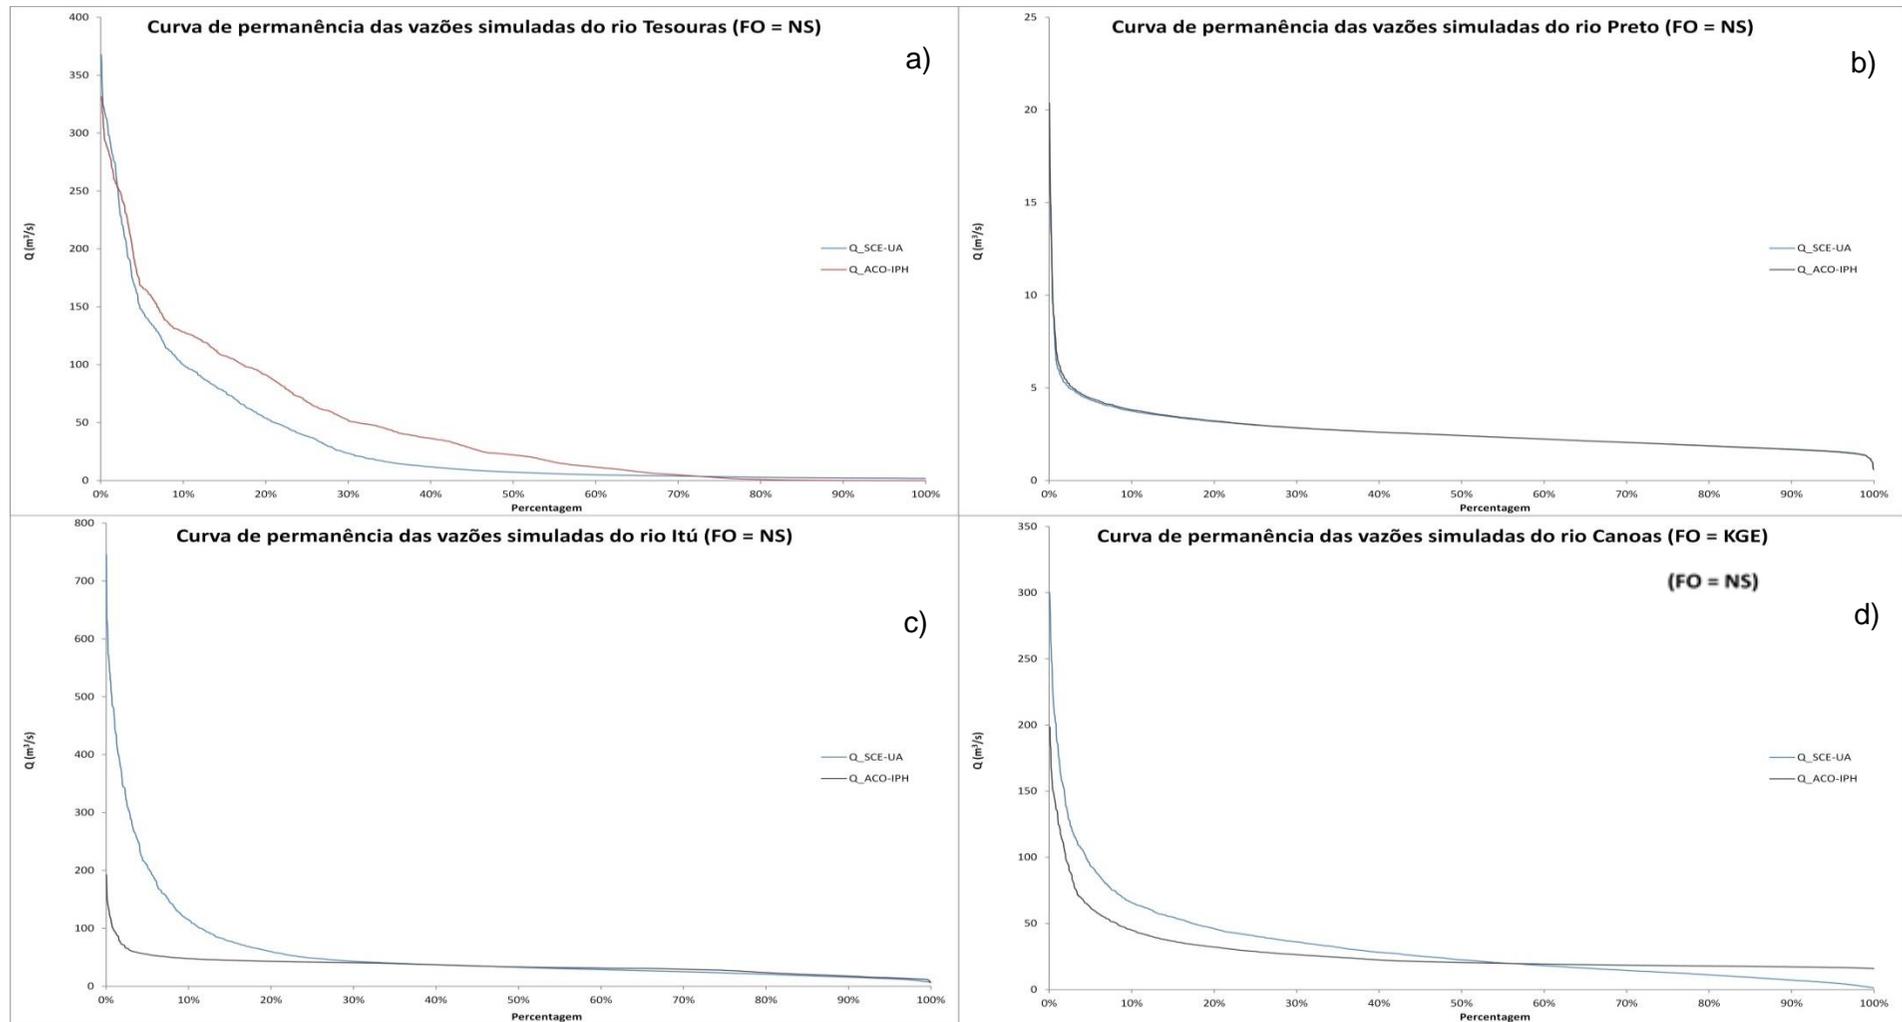
**Figura 60.** Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função NS – Rio Preto.



**Figura 61.** Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função NS – Rio Itú.



**Figura 62.** Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função NS – Rio Canoas.



**Figura 63.** Curvas de permanência das vazões simuladas das quatro bacias analisadas para FO = NS. a) Bacia do Rio Tesouras; b) Bacia do Rio Preto; c) Bacia do Rio Itú; d) Bacia do Rio Canoas

Para a  $FO_{IQ}$ , (Tabela 13) observa-se que os valores da FO encontrados pelo ACO-IPH ficam muito próximos em todos os casos, apresentando diferenças somente a partir da quarta casa decimal no caso da bacia do rio Canoas – SC e do rio Itu – RS. Quanto aos valores dos parâmetros encontrados pelo ACO-IPH, estes ficaram muito próximos dos encontrados pelo SCE-UA em todas as bacias.

A título de exemplo, o ajuste obtido entre as vazões observadas e calculadas, nas diferentes bacias com base nos valores dos parâmetros obtidos pelo uso da  $FO_{IQ}$  é apresentado na Figura 64 à Figura 67, complementando com a curva de permanência das vazões simuladas para as quatro bacias analisadas, apresentada na Figura 68

Na Figura 64 se visualiza para o caso da bacia do Rio Tesouras que, tanto as vazões calculadas calibrada com o algoritmo SCE-UA como as calculadas com o ACO-IPH conseguem acompanhar de maneira aceitável tanto as cheias como as estiagens, estando quase sempre com valores maiores que os observados, com a exceção ao início e um pouco no meio do intervalo que se visualizam valores um pouco menores na estiagem. Para complementar a análise, observando à curva de permanência de ambas as vazões calculadas, visualizadas na Figura 68a, na qual se observa que os valores estão superpostos em quase toda a curva.

No caso da bacia do rio Preto (Figura 65), ambos os algoritmos conseguem acompanhar de maneira aceitável as crescidas e as estiagens, apresentando novamente valores quase iguais em todo o hidrograma, superestimando um pouco nas cheias em quase todos os intervalos e quase sempre subestimando nas estiagens. Em relação à curva de permanência das vazões calculadas (Figura 68b), observa-se que ambas as curvas são muito similares em relação aos valores.

Observando os hidrogramas da Figura 66, correspondentes à bacia do Rio Itú, observa-se que o hidrograma calibrado com o SCE-UA consegue acompanhar com boa acurácia tanto nas cheias como nas estiagens, com poucos erros de subestimação nas estiagens e superestimação nas cheias, e no caso do ACO-IPH observa-se que demonstra um comportamento muito particular, pois é um hidrograma bastante subestimado em todos os intervalos, reproduzindo só em algumas estiagens um valor aceitável. Na curva de permanência (Figura 68c) observa-se que os valores que a diferença de valores ~e muito grande nas máximas, sendo que entre os máximos valores há uma diferença de aproximadamente  $700 \text{ m}^3/\text{s}$ , e que a curva correspondente ao ACO-IPH tem a forma de quase uma reta.

E finalmente, analisando o comportamento dos hidrogramas calculados na bacia do rio Canoas (Figura 67), ambos os hidrogramas conseguem acompanhar bem as cheias, e no caso

do hidrograma correspondente ao ACO-IPH apresenta um comportamento mais tranquilo nas estiagens. De maneira complementar, se visualiza na curva de permanência das vazões calculadas com ambos os algoritmos de calibração (Figura 68d), que os valores são superpostos em quase todos os intervalos, sendo muito pouco o margem de distinção entre ambas as curvas..

Observa-se que em todos os casos foram bem representados os períodos de estiagens, conforme esperado pelo maior peso que a  $FO_{IQ}$  dá às vazões menores. No entanto, no caso da bacia no rio Itu – RS, apesar do ACO-IPH ter apresentado um valor do IQ levemente melhor que o SCE-UA, os valores das vazões são muito subestimados no período de cheias em relação às vazões observadas. Para as demais bacias, os valores das vazões calculadas apresentam um comportamento mais próximo dos valores observados nos períodos de cheias.

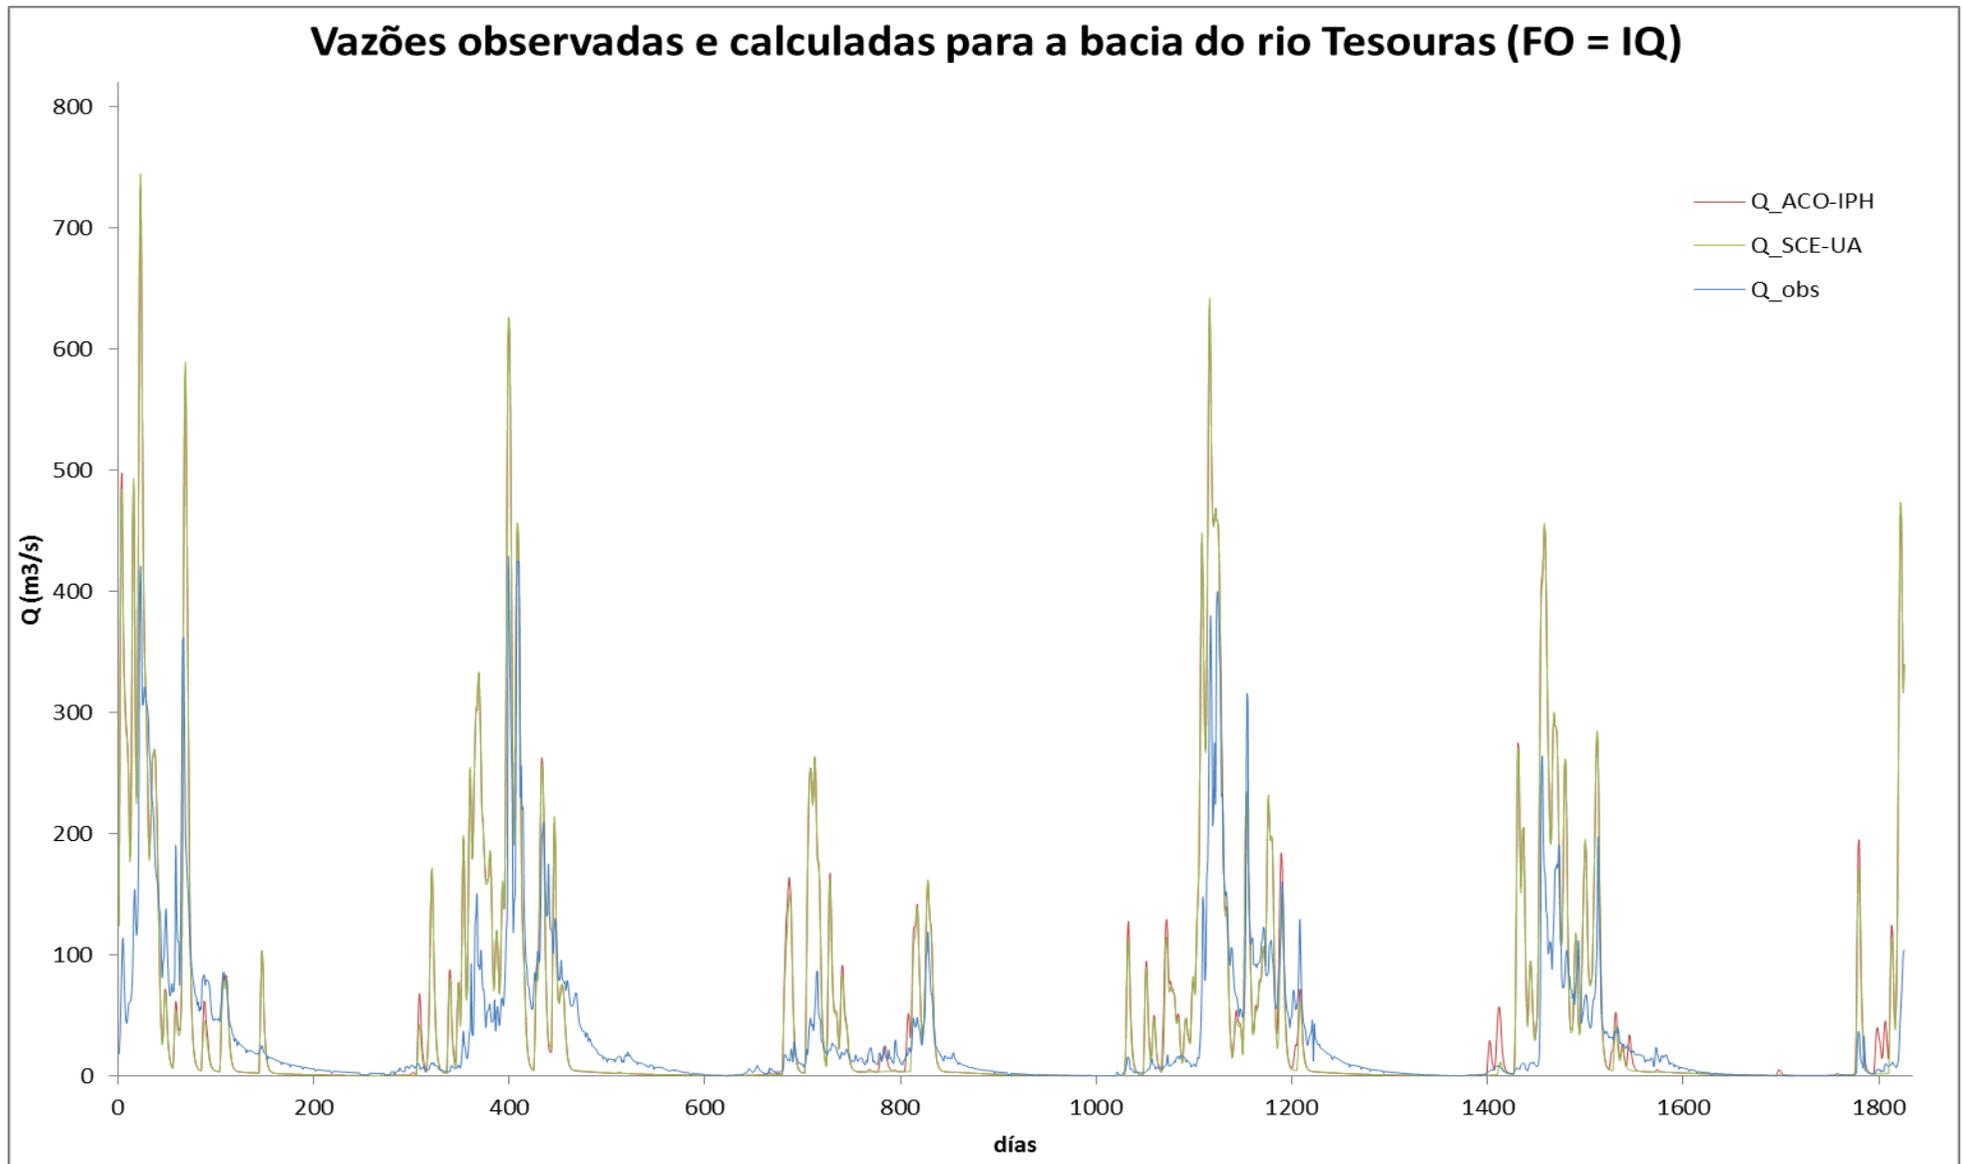
**Tabela 13.** Resultados obtidos para IQ e parâmetros do IPH-II nas quatro bacias analisadas.

		Bacia do Rio Tesouras - GO	
		SCE-UA	ACO-IPH
<b>FO</b>	<b>IQ</b>	0,9999	1,0323
<b>Parâmetros</b>	<b>Io</b>	39,5682	39,3952
	<b>Ib</b>	0,248	0,2155
	<b>H</b>	0,216601133	0,2542
	<b>Ks</b>	1,8848	1,9712
	<b>Ksub</b>	53,7254	56,7571
	<b>Rmáx</b>	4,1218	1,8276
	<b>Alfa</b>	0,0173	0,2199

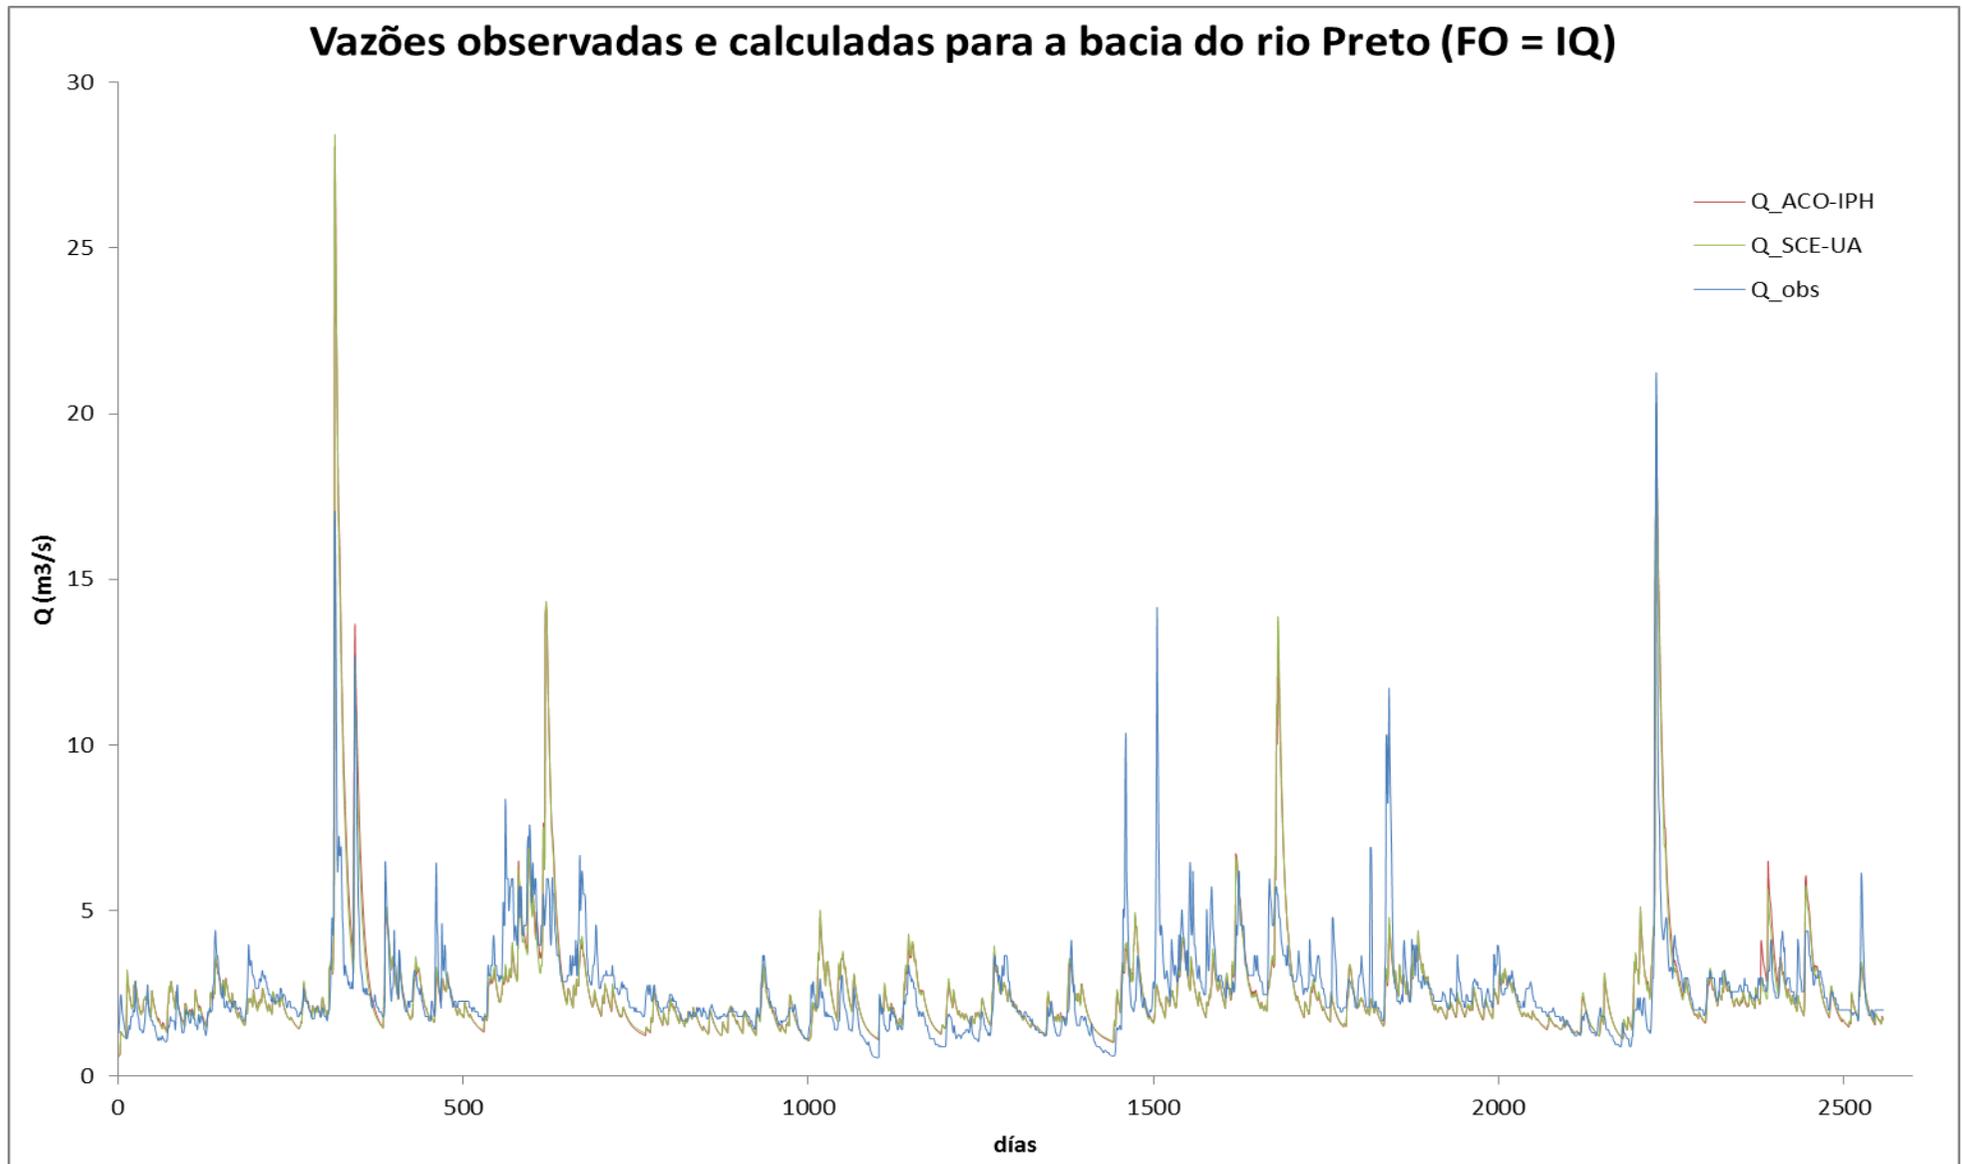
		Bacia do Rio Preto - BA	
		SCE-UA	ACO-IPH
<b>FO</b>	<b>IQ</b>	0,1575	0,1577
<b>Parâmetros</b>	<b>Io</b>	299,7521	293,1852
	<b>Ib</b>	0,4239	0,3914
	<b>H</b>	0,7074	0,7348
	<b>Ks</b>	8,9718	9,8202
	<b>Ksub</b>	10,0496	10,6968
	<b>Rmáx</b>	1,3097	0,1947
	<b>Alfa</b>	1,3158	1,5237

		Bacia do Rio Canoas - SC	
		SCE-UA	ACO-IPH
<b>FO</b>	<b>IQ</b>	0,0122	0,0127
<b>Parâmetros</b>	<b>Io</b>	29,6809	37,4162
	<b>Ib</b>	10,0000	9,1620
	<b>H</b>	0,0203	0,0433
	<b>Ks</b>	3,2610	3,2762
	<b>Ksub</b>	80,6368	73,4890
	<b>Rmáx</b>	0,0001	0,0021
	<b>Alfa</b>	3,5738	1,3978

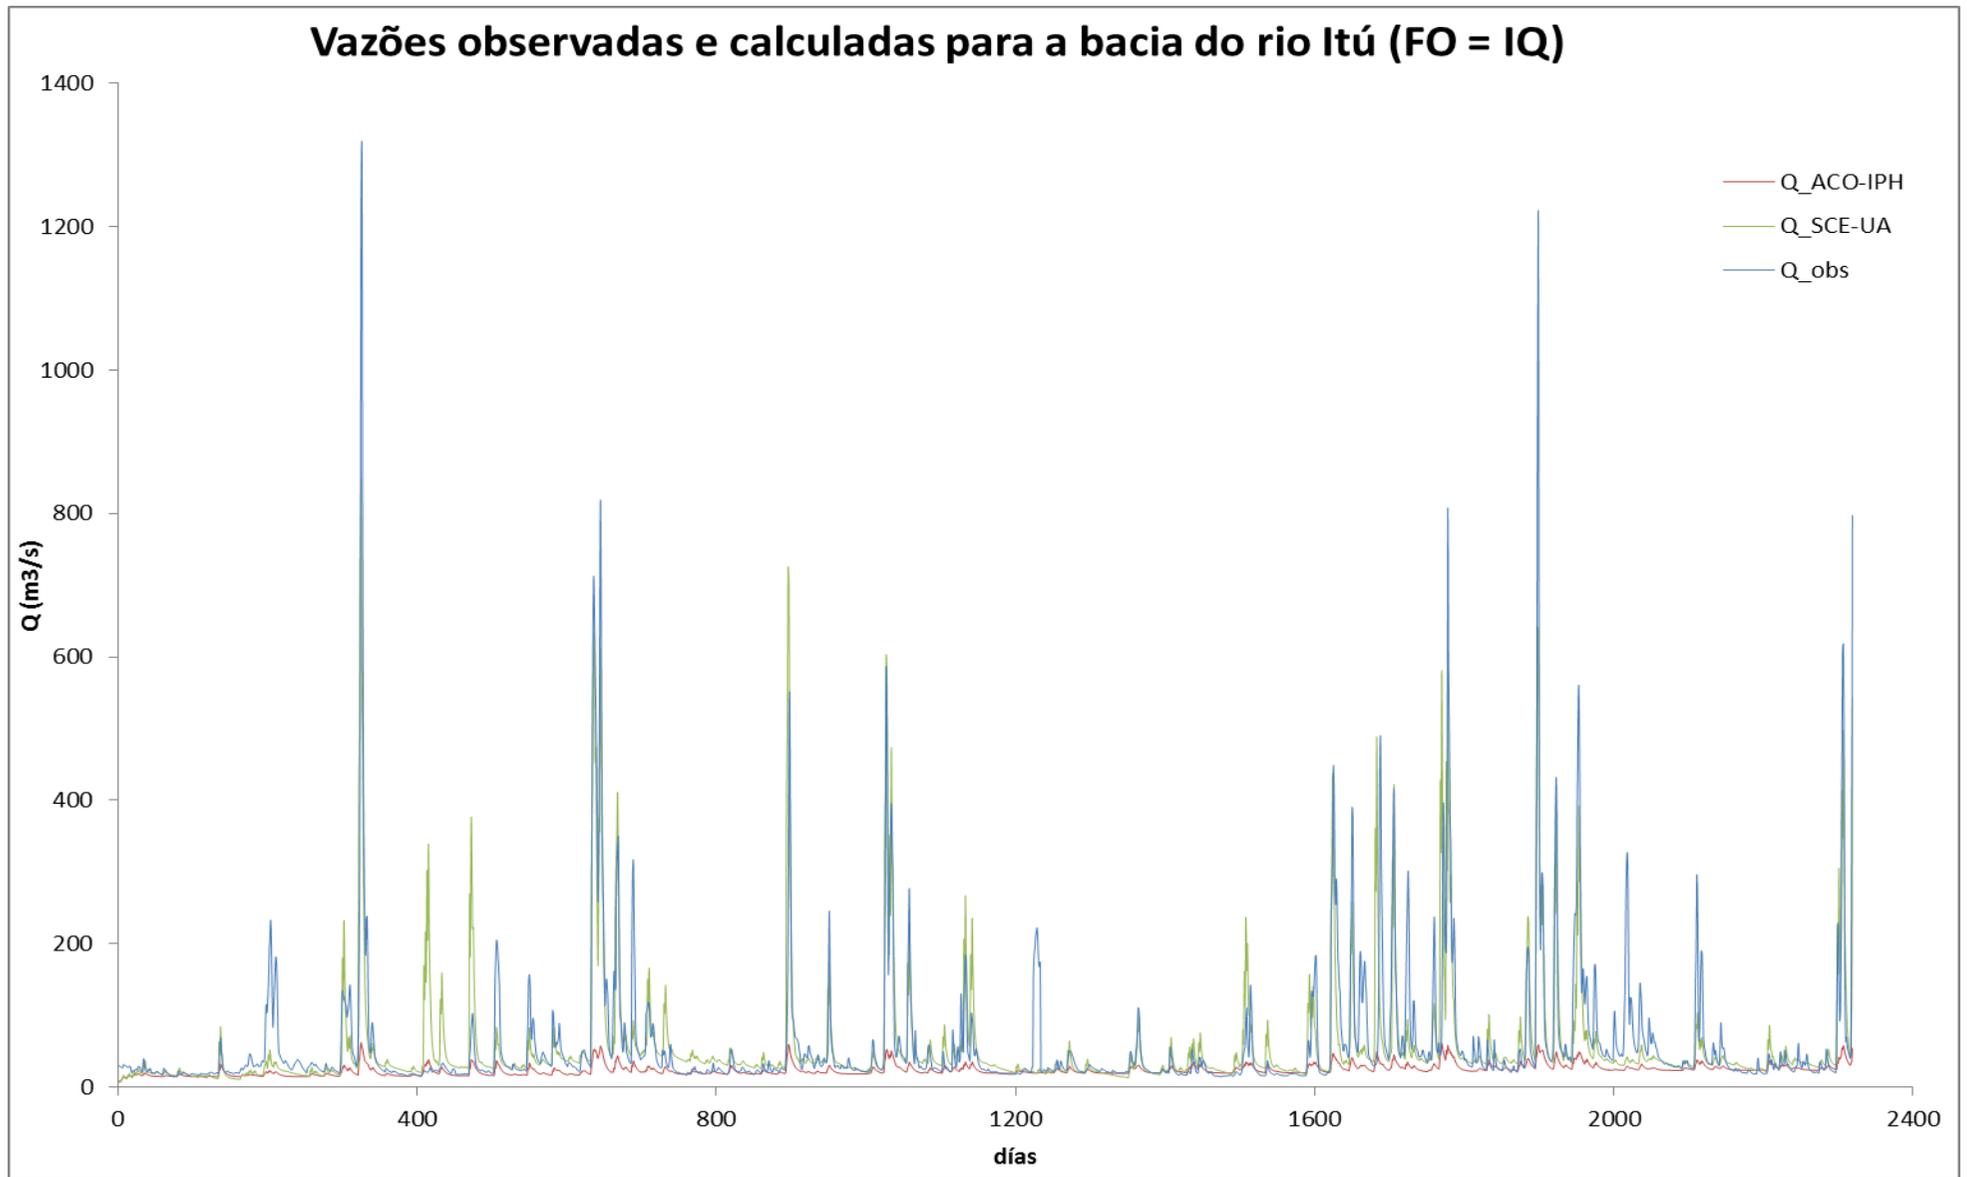
		Bacia do Rio Itu - RS	
		SCE-UA	ACO-IPH
<b>FO</b>	<b>IQ</b>	0,0134	0,0123
<b>Parâmetros</b>	<b>Io</b>	116,6903	244,4895
	<b>Ib</b>	3,0959	7,6606
	<b>H</b>	0,0322	0,9980
	<b>Ks</b>	2,2640	5,4397
	<b>Ksub</b>	77,4918	10,7459
	<b>Rmáx</b>	0,0009	8,9543
	<b>Alfa</b>	0,3124	5,3519



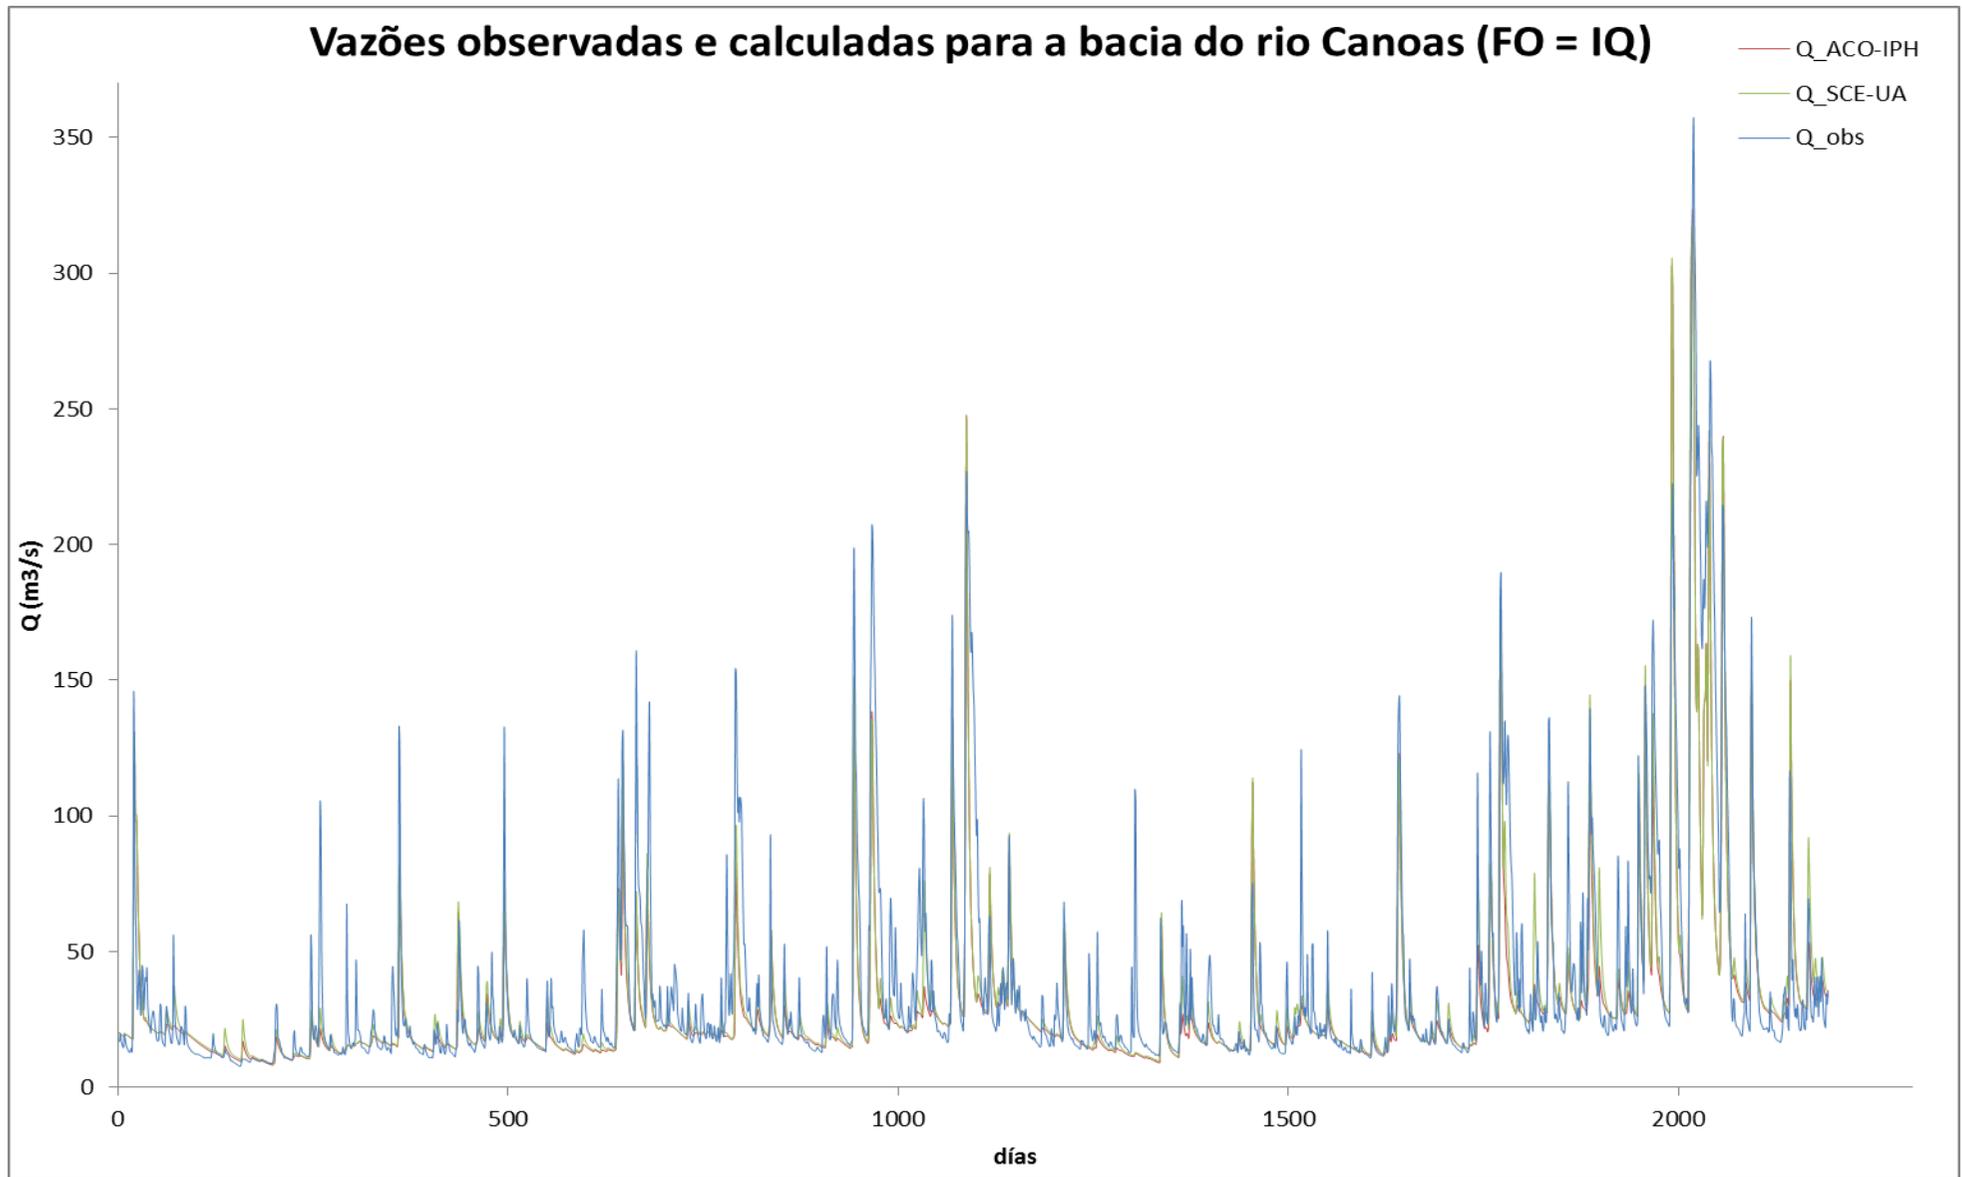
**Figura 64.** Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função IQ – Rio Tesouras.



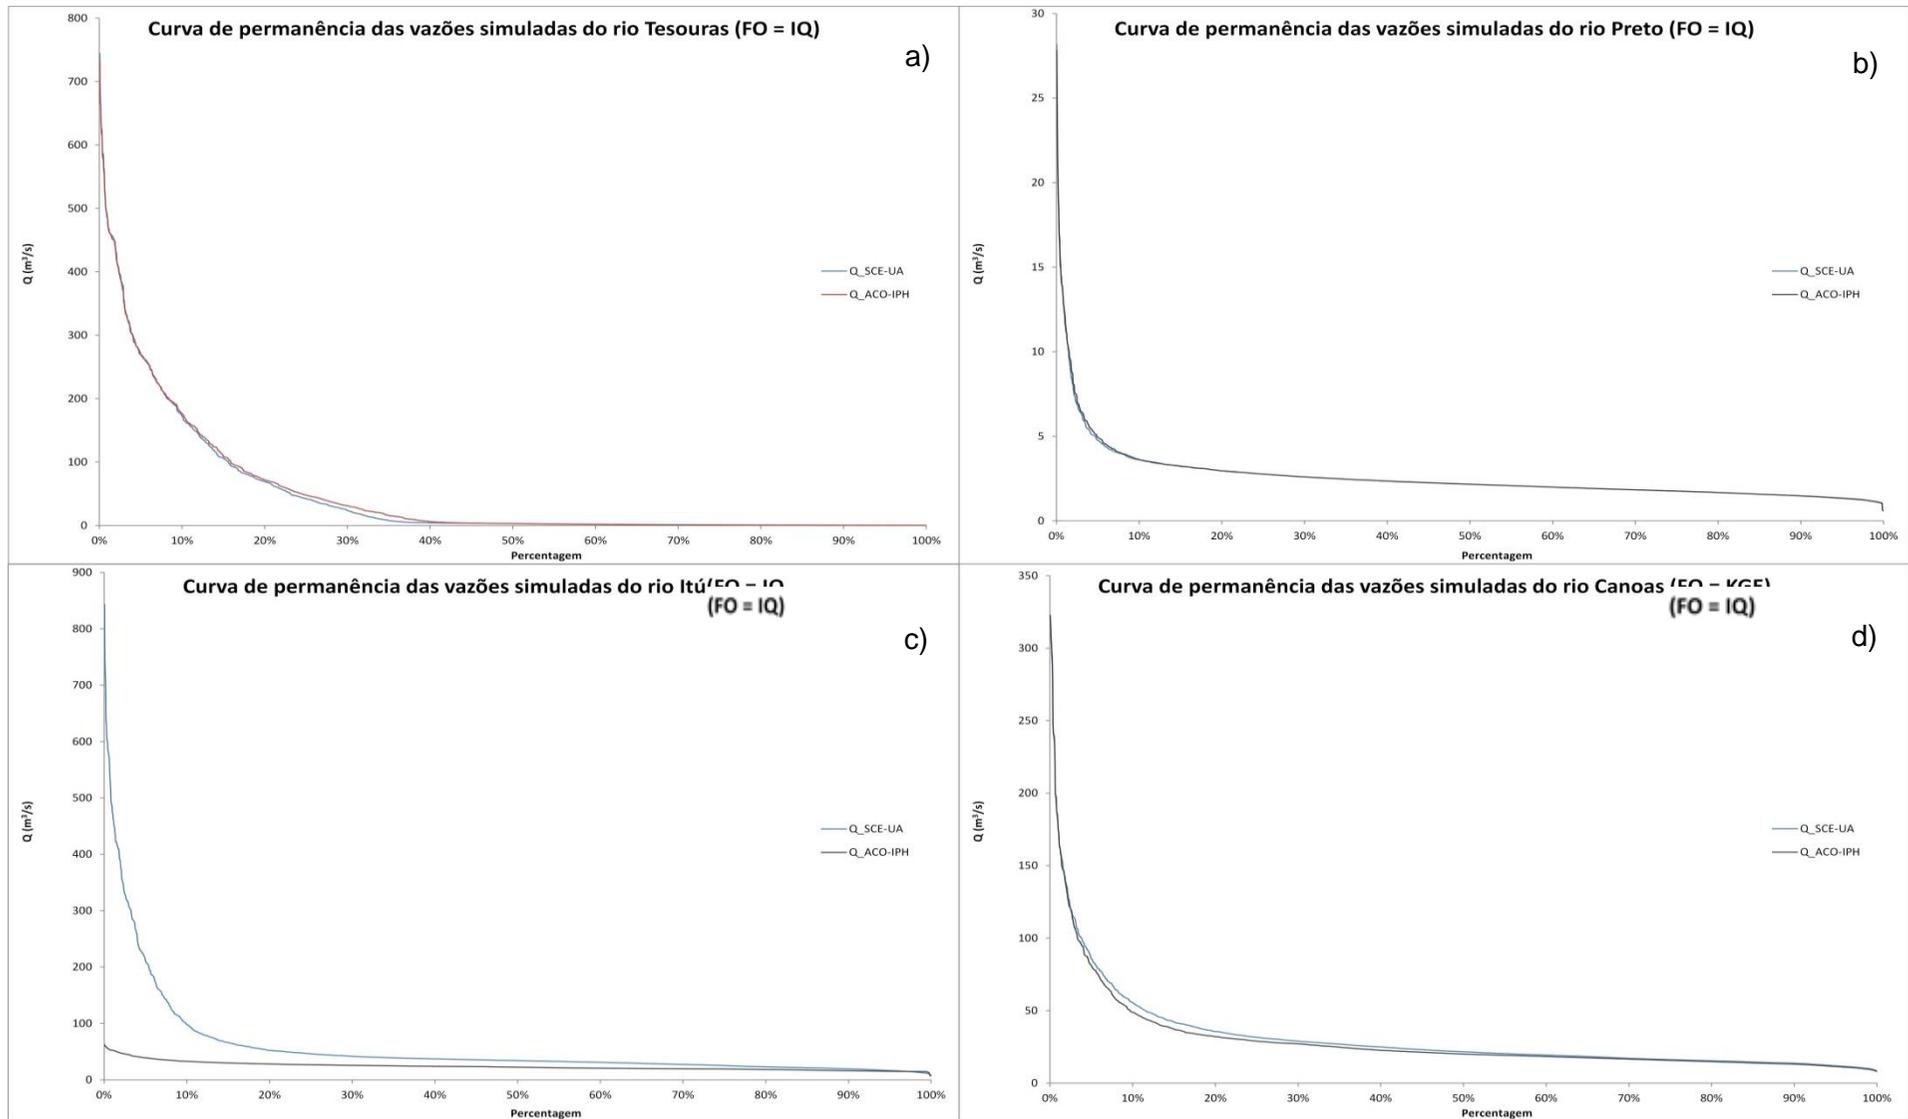
**Figura 65.** Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função IQ – Rio Preto.



**Figura 66.** Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função IQ – Rio Itú.



**Figura 67.** Vazões observadas vs calculadas com base nos valores dos parâmetros obtidos pelo uso da função IQ – Rio Canoas.



**Figura 68.** Curvas de permanência das vazões simuladas das quatro bacias analisadas para FO = IQ. a) Bacia do Rio Tesouras; b) Bacia do Rio Preto; c) Bacia do Rio Itú; d) Bacia do Rio Canoas

## **6- CONCLUSÕES E RECOMENDAÇÕES**

### **6.1- Aspectos gerais**

Novas ferramentas de otimização tem sido desenvolvidas recentemente e surge a necessidade de avaliar seu desempenho na calibração automática de modelos hidrológicos que utilizamos no dia-a-dia como, por exemplo, o IPH II. Nesse contexto, nessa pesquisa foi desenvolvido um algoritmo baseado no comportamento de colônias de formigas, denominado ACO-IPH. Os algoritmos baseados no comportamento de colônia de formigas, desde a sua concepção foram projetado para fins de otimização e testados, até a atualidade, em diversas aplicações, para as quais apresentou desempenhos aceitáveis, embora as aplicações na calibração de modelos hidrológicos sejam escassas.

O algoritmo ACO-IPH foi inicialmente testado usando funções matemáticas com ótimos conhecidos apresentando um desempenho muito superior em termos de eficácia quando comparado ao algoritmo ACO-IM, com uma leve perda de eficiência.

Posteriormente foi acoplado ao modelo hidrológico IPH II como uma alternativa na calibração automática mono-objetivo utilizando série sintética de vazões diárias, e posteriormente, utilizando séries reais de vazões diárias em quatro bacias hidrográficas. O desempenho do algoritmo foi avaliado em termos de eficácia e eficiência, para três diferentes funções-objetivo e utilizando como critério de comparação o algoritmo SCE-UA.

Durante o acoplamento do algoritmo ACO-IPH ao modelo IPH II não foram necessárias simplificações, sendo desenvolvido um algoritmo genérico que pode ser acoplado a diferentes modelos hidrológicos cujo código fonte esteja escrito em Fortran. No entanto, durante a definição do espaço de busca é importante ressaltar que, em função da estratificação necessária para utilização do ACO-IPH, algumas boas soluções podem ficar fora do espaço de busca. Isto tentou ser contornado em parte com a utilização da rotina de refinamento utilizada pelo ACO-IPH. Outro elemento importante quanto a estratificação adotada está relacionado à influência desta variável no tempo de processamento: quanto maior a estratificação, maior o tempo de processamento observado nos diferentes testes e maior a percentagem de falha em encontrar o ótimo para um mesmo número de formigas na população.

Uma vez acoplado ao IPH II, o ACO-IPH foi testado para série sintética de vazões, utilizando as funções-objetivo KGE, NS e IQ. Em relação ao valor da FO, em todos os casos o algoritmo ACO-IPH obteve um valor da FO muito próximo do valor ótimo, com um conjunto alternativo de valores de parâmetros muito próximo também dos valores ótimos. No caso dos indicadores de eficácia e eficiência, o algoritmo SCE-UA obteve, em geral, um desempenho melhor que o ACO-IPH, marcando a principal vantagem no tempo de processamento, onde o

SCE-UA apresentou um desempenho claramente superior. Finalmente, foram feitos os testes para séries reais de vazões, para os quais foram escolhidas quatro bacias hidrográficas e testadas as mesmas funções-objetivo testadas na série sintética, com o SCE-UA e o ACO-IPH.

Em relação aos indicadores de eficácia e eficiência, novamente foi o SCE-UA quem apresentou melhor desempenho, marcando a diferença mais acentuada no tempo computacional requerido para realizar o processo de calibração, pois ele sempre foi menor que o requerido pelo ACO-IPH.

Em termos dos valores encontrados das FO, os resultados foram muito próximos entre o ACO-IPH e o SCE-UA; no entanto, valores do conjunto de parâmetros um pouco diferentes foram encontrados se traduzindo em resultados também diferentes em termos das vazões simuladas. É importante ressaltar que na maioria das bacias e FO os valores dos parâmetros obtidos por ambos os algoritmos foram muito próximos. Ainda quanto ao algoritmo ACO-IPH, este apresentou resultados da FO levemente melhores que os encontrados pelo SCE-UA em ¼ dos testes executados.

Em termos gerais, os diferentes testes executados na calibração automática do modelo hidrológico IPH II mostraram que o ACO-IPH consegue encontrar boas soluções, porém não consegue apresentar um desempenho, em termos de eficiência e eficácia, comparável a algoritmos do estado da arte, como o algoritmo SCE-UA. A perda de eficiência do ACO-IPH em comparação ao SCE-UA é a mais importante, podendo demorar, em média, até 10 vezes mais até a convergência.

## **6.2- Recomendações**

Os estudos apresentados nesse trabalho podem ser estendidos a outras bacias e com outras funções-objetivo.

Em função dos resultados obtidos, observou-se uma perda importante no desempenho do algoritmo sequencial em termos da eficiência temporal. Essa limitação pode ser contornada com a paralelização do código, como feito por Randall e Lewis (2002) em um ACO para o TSP, e por Bravo *et al.* (2009) no algoritmo MOSCEM-UA, encontrado um ganho importante em termos de eficiência, com diminuição do tempo de processamento em mais de 40 %.

É comum o uso de algoritmos de calibração automática multi-objetivo de modelos hidrológicos, assim recomenda-se ainda o desenvolvimento de algoritmos baseados no comportamento de formigas multi-objetivo, como os aplicados por Jalali *et al.* (2006) e Kumar *et al.* (2006) na otimização da operação de reservatórios multi-propósito, para sua utilização na calibração automática do modelo IPH II. Pode ainda ser adaptado o algoritmo ACO-IPH para a resolução de problemas de otimização multi-objetivo.

Com o objetivo de melhorar a exploração do espaço de busca, o ACO-IPH pode ser inicializado com múltiplas colônias de formigas.

Outro estilo comumente abordado atualmente são os algoritmos híbridos, e uma proposta interessante seria hibridizar o algoritmo ACO-IPH, rodando-o sem o refinamento e, posteriormente refinar os resultados com o método Simplex de Nelder e Mead (1965).

Outro enfoque que poderia ser abordado é o de colocar limitações físicas aos parâmetros, o que poderia ser feito realizando-se uma primeira calibração e, posteriormente, um refinamento de acordo com os valores físicos possíveis dos parâmetros.

## 7- REFERÊNCIAS BIBLIOGRÁFICAS

AFSHAR, M. H. (2006). Improving the efficiency of ant algorithms using adaptive refinement: Application to storm water network design. *Advances in Water Resources*, 29(9), 1371-1382.

AFSHAR, M. H. (2010). A parameter free Continuous Ant Colony Optimization Algorithm for the optimal design of storm sewer networks: Constrained and unconstrained approach. *Advances in Engineering Software*, 41(2), 188-195.

ATAIE-ASHTIANI, B.; KETABCHI, H. (2010). Elitist Continuous Ant Colony Optimization Algorithm for Optimal Management of Coastal Aquifers. *Water Resources Management*, 25(1), 165-190.

BLUM, C.; DORIGO, M. (2004). The hyper-cube framework for ant colony optimization. *IEEE transactions on systems, man, and cybernetics. Part B, Cybernetics : a publication of the IEEE Systems, Man, and Cybernetics Society*, 34(2), 1161-1172.

BONTOUX, B.; FEILLET, D. (2008). Ant colony optimization for the traveling purchaser problem. *Computers Operations Research*, 35(2), 628-637.

BRAVO, J. M.; COLLISCHONN, W.; PILAR, J., GONÇALVES, A. Avaliação do desempenho de um algoritmo baseado no comportamento de formigas em problemas de caminho de mínimo custo em ambientes raster. *Revista Brasileira de Cartografia* No 60/01, Abril 2008. (ISSN 1808-0936)

BRAVO, J. M.; COLLISCHONN, W.; TUCCI, C.E.M. Verificação da Eficiência e Eficácia de um Algoritmo Evolucionário Multi-objetivo na Calibração Automática do Modelo Hidrológico IPH II, *Revista Brasileira de Recursos Hídricos*, Volume 14 n.3 Jul/Set 2009, 37-50

CHIRCOP, J.; BUCKINGHAM, C. D. (2014) A multiple pheromone ant clustering algorithm. *Volume 512*, 13-27.

CHOW, V. T.; KARELIOTIS, S. J. (1970). Analysis of Stochastic Hydrologic Systems, *Water Resources Research*, 6(6), 1569–1582.

COLLISCHONN, W.; TUCCI, C.E.M. Ajuste multi-objetivo dos parâmetros de um modelo hidrológico. *Revista Brasileira de Recursos Hídricos*, volume 8, número 3, 27-39, 2003.

COLORNI, A.; DORIGO, M.; MAFFIOLI, F.; MANIEZZO, V.; RIGHINI, G.; TRUBIAN, M. (1996). Heuristics from Nature for Hard Combinatorial Optimization Problems. *International Transactions in Operational Research*, 3(1), 1-21.

DORIGO, M.; BLUM, C. (2005). Ant colony optimization theory: A survey. *Theoretical Computer Science*, 344(2-3), 243-278.

DORIGO, M.; GAMBARDELLA, L. M. (1997). Ant colonies for the travelling salesman problem. *Bio Systems*, 43(2), 73-81.

DORIGO, M.; BONABEAU, E.; THERAULAZ, G. (2000). Ant algorithms and stigmergy. *Future Generation Computer Systems*, 16(8), 851-871.

DORIGO, M.; DI CARO, G.; STÜTZLE, T. (2000). Ant algorithms. *Future Generation Computer Systems*, 16(8), v-vii.

DORIGO, M.; MANIEZZO, V.; COLORNI, A. (1996). Ant System: Optimization by a Colony of Cooperating Agents. *Systems, Man, and Cybernetics, Part B: Cybernetics*, IEEE Transactions on. 26(1).

DUAN, Q.; SOROOSHIAN, S.; GUPTA, V. (1992). Effective and efficient global optimization for conceptual rainfall-runoff models. *Water Resources Research*, 28(4), 1015-1031.

FERNÁNDEZ-VARGAS, J. A.; BONILLA-PETRICIOLET, A.; SEGOVIA-HERNÁNDEZ, J. G. (2013). An improved ant colony optimization method and its application for the thermodynamic modeling of phase equilibrium. *Fluid Phase Equilibria*, 353, 121-131.

GOLDBERG, D.E. Genetic algorithms in search, optimization and machine learning. Addison Wesley Longman, Boston, 412 p., 1989.

HALLEMA, D. W.; MOUSSA, R.; ANDRIEUX, P., VOLTZ, M. (2013). Parameterization and multi-criteria calibration of a distributed storm flow model applied to a Mediterranean agricultural catchment. *Hydrological Processes*, 27(10), 1379-1398.

HASSANZADEH, Y.; ABDI, A.; TALATAHARI, S.; SINGH, V. P. (2011). Meta-Heuristic Algorithms for Hydrologic Frequency Analysis. *Water Resources Management*, 25(7), 1855-1879.

HOLLAND, J.H. *Adaption in Natural and Artificial Systems*, University of Michigan Press, Michigan, 1975.

HUANG, B.; LIU, N.; CHANDRAMOULI, M. (2006). A GIS supported Ant algorithm for the linear feature covering problem with distance constraints. *Decision Support Systems*, 42(2), 1063-1075.

HUANG, P.; LIN, F.; ZHOU, J. (2013). ACO-based routing algorithm for cognitive radio networks. *Mathematical Problems in Engineering*, 2013.

JALALI, M. R.; AFSHAR, A.; MARIÑO, M. A. (2006). Multi-Colony Ant Algorithm for Continuous Multi-Reservoir Operation Optimization Problem. *Water Resources Management*, 21(9), 1429-1447.

KUMAR, D. N.; REDDY, M. J. (2006). Ant Colony Optimization for Multi-Purpose Reservoir Operation. *Water Resources Management*, 20(6), 879-898.

LI, Y.; MA, Z.; CAO, Z. (2005). A mitigating stagnation-based ant colony optimization routing algorithm. *IEEE International Symposium on Communications and Information Technology*, 2005. ISCIT 2005, 1, 34-37.

MAHBOD, M.; ZAND-PARSA, S. (2010). Prediction of soil hydraulic parameters by inverse method using genetic algorithm optimization under field conditions. *Archives of Agronomy and Soil Science*, 56(1), 13-28.

MASRI, S. F.; BEKEY, G. A.; SAFFORD, F. B. An adaptive random search method for identification of large-scale nonlinear systems, *Identif. Syst. Parameter Estim. Proc. IFAC Symp.* 4th 1976. 246-255, 1978.

MAVROVOUNIOTIS, M.; YANG, S. (2013) Ant colony optimization algorithms with immigrants schemes for the dynamic travelling salesman problem. Vol. 490 (pp. 317-341).

MERKLE, D.; MIDDENDORF, M.; SCHMECK, H. (2002). Ant colony optimization for resource-constrained project scheduling. *IEEE Transactions on Evolutionary Computation*, 6(4), 333-346.

NELDER, J. A.; MEAD, R. A simplex method for function minimization, *Comput. J* 7(4), 308-313, 1965.

NICKLOW, J.; REED, P.; SAVIC, D.; DESSALEGNE, T.; HARRELL, L.; CHAN-HILTON, A.; KARAMOUZ, M.; MINSKER, B.; OSTFELD, A.; SINGH, A.; ZECHMAN, E. (2010). "State of the Art for Genetic Algorithms and Beyond in Water Resources Planning and Management." *J. Water Resour. Plann. Manage.*, 136(4), 412–432.

PEI, Y.; WANG, W.; ZHANG, S. (2012). Basic Ant Colony Optimization. 2012 International Conference on Computer Science and Electronics Engineering, 665-667.

PITAKASO, R.; ALMEDER, C.; DOERNER, K. F.; HARTL, R. F. (2007). A MAX-MIN ant system for unconstrained multi-level lot-sizing problems. *Computers Operations Research*, 34(9), 2533-2552.

RANDALL, M.; LEWIS, A. (2002). A Parallel Implementation of Ant Colony Optimization. *Journal of Parallel and Distributed Computing*, 62(9), 1421-1432.

SHELOKAR, P. S.; JAYARAMAN, V. K.; KULKARNI, B. D. (2004). An ant colony approach for clustering. *Analytica Chimica Acta*, 509(2), 187-195.

SKARDI, M. J. E.; AFSHAR, A.; SOLIS, S. S. (2013). Simulation-optimization model for non-point source pollution management in watersheds: Application of cooperative game theory. *KSCE Journal of Civil Engineering*, 17(6), 1232-1240.

SOROOSHIAN, S.; GUPTA, V.K. Model calibration In: Singh, V. J. (editor) *Computer models of watershed hydrology*. Water Resourc. Pub., Highlands Ranch. 1130 p., 1995.

STUTZLE, T.; HOOS, H. (1997). MAX-MIN Ant System and local search for the traveling salesman problem. *Proceedings of 1997 IEEE International Conference on Evolutionary Computation (ICEC '97)*, 309-314.

TALBI, E. G.; ROUX, O.; FONLUPT, C.; ROBILLARD, D. (2001). Parallel Ant Colonies for the quadratic assignment problem. *Future Generation Computer Systems*, 17(4), 441-449.

TASSI, R.; BRAVO, J.M.; MELLER, A.; COLLISCHONN, W. Avaliação do impacto de diferentes funções-objetivo na calibração automática multi-objetivo do modelo IPH II. XXII Congresso Latinoamericano de Hidráulica, Guayana, Venezuela, out. 2006, 1 CD.

TOKSARI, M. D. (2006). Ant colony optimization for finding the global minimum. *Applied Mathematics and Computation*, 176(1), 308-316.

TUCCI, C.E.M. *Modelos hidrológicos*. ABRH, Editora da UFRGS. Porto Alegre. 669 p., 1998.

VRUGT, J.A.; GUPTA, H.V.; BOUTEN, W.; SOROOSHIAN, S. A Shuffled Complex Evolution Metropolis algorithm for optimization and uncertainty assessment of hydrologic model parameters. *Water Resources Research*, v 39, n 8. 2003.

WAGENER, T.; WHEATER, H.; GUPTA, H.V. *Rainfall-Runoff modeling in gauged and ungauged catchments*. Imperial College Press. 306 p., 2004.

YAPO, P.O.; GUPTA; H.V.; SOROOSHIAN, S. Multiobjective global optimization for hydrologic models. *Journal of Hydrology*, v 204, p. 83-97, 1998.

ZECCHIN, A. C.; SIMPSON, A. R.; MAIER, H. R.; LEONARD, M.; ROBERTS, A. J.; BERRISFORD, M. J. (2005). Application of two ant colony optimisation algorithms to water distribution system optimisation.

ZHOU, Y.; LAI, X.; LI, Y.; DONG, W. (2012). Ant Colony Optimization With Combining Gaussian Eliminations for Matrix Multiplication. *IEEE transactions on systems, man, and cybernetics. Part B, Cybernetics: a publication of the IEEE Systems, Man, and Cybernetics Society*, 43(1), 347-357.