

UNIVERSIDADE FEDERAL DE PELOTAS
Centro de Desenvolvimento Tecnológico
Programa de Pós-Graduação em Recursos Hídricos



Dissertação

**Concepção do modelo hidrológico LASH em MATLAB®: aprimoramento da
propagação em rios e da calibração**

Marcelle Martins Vargas

Pelotas, 2021

Marcelle Martins Vargas

**Concepção do modelo hidrológico LASH em MATLAB®: aprimoramento da
propagação em rios e da calibração**

Dissertação apresentada ao Programa de Pós-Graduação em Recursos Hídricos, do Centro de Desenvolvimento Tecnológico da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Mestre em Recursos Hídricos.

Orientador: Samuel Beskow

Coorientador: Carlos Rogério de Mello

Pelotas, 2021

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação na Publicação

V297c Vargas, Marcelle Martins

Concepção do modelo hidrológico LASH em MATLAB® :
aprimoramento da propagação em rios e da calibração /
Marcelle Martins Vargas ; Samuel Beskow, orientador ;
Carlos Rogério de Mello, coorientador. — Pelotas, 2021.

171 f. : il.

Dissertação (Mestrado) — Programa de Pós-Graduação
em Recursos Hídricos, Centro de Desenvolvimento
Tecnológico, Universidade Federal de Pelotas, 2021.

1. Linguagem de programação interpretada. 2. Onda
cinemática. 3. Algoritmos de calibração multiobjetivo. 4.
Bacia hidrográfica do rio Camaquã. I. Beskow, Samuel,
orient. II. Mello, Carlos Rogério de, coorient. III. Título.

CDD : 627

Marcelle Martins Vargas

Concepção do modelo hidrológico LASH em MATLAB®: aprimoramento da
propagação em rios e da calibração

Dissertação aprovada, como requisito parcial, para obtenção do grau de Mestre em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas.

Data da Defesa: 25 de fevereiro de 2021

Banca Examinadora:



Prof. Dr. Samuel Beskow (Orientador)

Doutor em Engenharia Agrícola pela Universidade Federal de Lavras



Prof. Dr. Carlos Rogério de Mello (Coorientador)

Doutor em Ciência do Solo pela Universidade Federal de Lavras



Prof^a. Dr^a. Tirzah Moreira Siqueira

Doutora em Recursos Hídricos e Saneamento Ambiental pela Universidade Federal do Rio Grande do Sul



Prof. Dr. João Francisco Carlexo Horn

Doutor em Engenharia Agrícola pela Universidade Federal de Santa Maria

A minha mãe, Estael Cristina, e ao meu avô,
Belarmino (*in memoriam*).

DEDICO

Agradecimentos

Ao meu orientador, *Prof. Dr. Samuel Beskow*, pela dedicação, ensinamento, e amizade construída. Por ter me aceitado como voluntária no Laboratório de Hidrologia em 2013, e por ter apoiado e incentivado um tanto de ideias.

Ao meu co-orientador, *Prof. Dr. Carlos Rogério de Mello*, pela paciência, boa vontade e o leque de conhecimento distribuídos de forma tão esclarecedora.

Aos colegas do *Grupo de Pesquisa em Hidrologia e Modelagem Hidrológica em Bacias Hidrográficas*, em especial aos meus amigos *Maíra Moura*, *Zandra Cunha*, *Tamara Caldeira* e *João Pedro da Silveira*. À *Maíra*, por nossos trabalhos, pela incalculável mentoria e conselhos de que “às vezes só precisamos lembrar de acender a luz”. À *Zandra*, pela constante troca de ideias, por segurar minha mão tantas vezes e por não permitir que eu esqueça de acreditar em mim. À *Tamara*, por ter me ensinado a base de tanto do que aprendi. Ao *João*, por ouvir minhas dúvidas sobre programação e por partilhar uma amizade desde os tempos da Hídrica.

À *Maria Clotilde Carré Chagas Neta* e à *Joana Gusmão*, pela amizade construída. É com muita alegria no coração que carrego os momentos desses anos e conto com a certeza de que nossos abraços e palavras são curadores.

Às minhas amigas de infância, *Ariadni Peres*, *Mauren Costa* e *Nathalia Silva* e da vida, *Patricia Macedo*, por provarem a existência de amizades verdadeiras.

Ao meu companheiro, *Salomão Fernandes*, por entender e apoiar minha rotina, por incentivar minha paixão pela natureza e pelos números. Obrigada por ser a pessoa com quem eu quero viver cada dia da minha vida.

À minha mãe *Estael Cristina Kopp Martins*, e irmã, *Marianna Martins Vargas*, que sempre acreditaram e apoiaram minhas decisões com amor. Obrigada por me escutarem divagar um tanto de horas sobre um tanto de coisas há tanto tempo.

À minha avó, *Geneci Vargas*, por ter plantado em mim, a sede pelo conhecimento e a curiosidade pelo desconhecido.

Ao meu avô (*in memoriam*), *Berlamino Garcia Martins*, por ter me ensinado que eu posso ser tudo o que eu sonhar. Eu busco lembrar disso diariamente.

Ao *Programa de Pós-Graduação em Recursos Hídricos* e à *Universidade Federal de Pelotas*, pela oportunidade de estudo e aprendizado.

Ao apoio da *Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES)* – Código de Financiamento 001.

“Katherine Johnson knew: once you took the first step, anything was possible.”

Margot Lee Shetterly – Hidden Figures

“I would tell my younger self just be yourself – that who you are is good enough.”

Viola Davis

Resumo

VARGAS, Marcelle Martins. **Concepção do modelo hidrológico LASH em MATLAB®: aprimoramento da propagação em rios e da calibração**. 2021. 171f. Dissertação (Mestrado em Recursos Hídricos) - Programa de Pós-Graduação em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, Pelotas, 2021.

Diante da situação atual de uso e gestão dos recursos hídricos, a importância de estudos em bacias hidrográficas é imprescindível para subsidiar projetos e, quando for o caso, também comitês e planos de bacias hidrográficas. Para tal, modelos hidrológicos são fortemente recomendados e, dentre os modelos, o *Lavras Simulation of Hydrology* (LASH) tem sido utilizado com sucesso em bacias hidrográficas brasileiras. A principal contribuição deste estudo foi implementar o modelo LASH em linguagem *MATrix LABoratory* (MATLAB®), aprimorar seus módulos de propagação de cheias em rios e de calibração, e testá-lo como estudo de caso na bacia hidrográfica do rio Camaquã (BHRC), a qual possui um comitê e um plano de bacias hidrográficas associado. No capítulo 1, foram exploradas a concepção do LASH em MATLAB®, a implementação do módulo de propagação de vazões em rios de acordo com o método da Onda Cinemática e a inserção de um algoritmo de calibração multiobjetivo, o *A Multi-Algorithm Genetically Adaptive Multiobjective* (AMALGAM). Ao contrário do capítulo 1, em que foi realizada uma abordagem mais técnica e computacional, o capítulo 2 foi pautado na aplicação do LASH estruturado em MATLAB®, tendo como estudo de caso a BHRC. E ainda, dois cenários de calibração foram avaliados: i) cenário 1: parâmetros calibráveis do LASH concentrados e; ii) cenário 2: espacialização dos parâmetros λ e tempo de resposta do reservatório superficial (C_s) por sub-bacia. Os resultados do capítulo 1 permitiram constatar os ganhos da estruturação do modelo em linguagem MATLAB®, principalmente no que concerne: i) ao módulo de propagação da onda de cheias baseado na Onda Cinemática; ii) à facilidade do acoplamento do algoritmo de calibração multiobjetivo AMALGAM; iii) aos artifícios computacionais implementados para otimizar o tempo de processamento do modelo; e iv) à facilidade de alteração, atualização e ampliação do *script*, sendo o grande gargalo da implementação do LASH em MATLAB®. No tocante aos resultados do capítulo 2, estes foram satisfatórios e foi possível inferir que: i) a formulação do LASH em MATLAB® trouxe uma melhoria do módulo de propagação de vazões em rios, adicionando uma estrutura com viés mais hidráulico ao modelo, e viabilizou a implementação do cenário 2; ii) o cenário 2 permitiu realizar discussões acerca da heterogeneidade de regiões presentes na BHRC e do impacto das espacialização dos parâmetros λ e C_s sobre a modelagem hidrológica na BHRC, sendo uma ferramenta poderosa na gestão dos recursos hídricos; iii) a implementação do AMALGAM permitiu conduzir comparações em relação ao *Shuffled Complex Evolution* (SCE-UA), e apresentou ligeira superioridade nas calibrações para as funções objetivo utilizadas; iv) a utilização do AMALGAM tem potencial para diminuir as incertezas e equifinalidade relacionadas aos parâmetros calibráveis do LASH; e v) a formulação do LASH em MATLAB® trouxe excelentes ganhos, em termos de execução computacional.

Palavras-chave: Linguagem de programação interpretada. Onda cinemática. Algoritmos de calibração multiobjetivo. Bacia hidrográfica do rio Camaquã.

Abstract

VARGAS, Marcelle Martins. **Development of the LASH hydrological model in MATLAB®: enhancement of river routing and calibration**. 2021. 171f. Dissertation (Master's Degree in Water Resources) – Graduate Program in Water Resources, Center for Technological Development, Federal University of Pelotas, Pelotas, 2021.

In view of the current situation of water resources management, studies on watersheds are essential for supporting projects and, when applicable, watershed committees and master plans. In this sense, hydrological models are strongly recommended and, among them, the Lavras Simulation of Hydrology (LASH) has been successfully used in Brazilian watersheds. The main contribution of this study was the implementation of the LASH model in MATrix LABoratory language (MATLAB®), enhancement of its river routing and calibration modules, and its evaluation taking the Camaquã river watershed (CRW) as a case study, which has a watershed committee and a watershed master plan. Chapter 1 addressed technical and computational issues, such as the development of the LASH in MATLAB®, implementation of the river routing module according to the Kinematic Wave method and the insertion of a multi-objective optimization algorithm, known as A Multi-Algorithm Genetically Adaptive Multiobjective (AMALGAM). On the other hand, chapter 2 focused on the evaluation of LASH coded in MATLAB® taking CRW as a case study. Furthermore, two calibration schemes were considered in this study: i) scheme 1: all the LASH parameters were calibrated following a lumped scheme and; ii) scheme 2: two parameters – initial abstraction coefficient (λ) and response time of the surface reservoir (C_s) - were calibrated by subwatershed. The results of chapter 1 evidenced some benefits of coding the model in MATLAB® language, mainly with regard to the: i) river routing module based on the Kinematic Wave method; ii) ease of coupling the AMALGAM multi-objective calibration algorithm with LASH; iii) computational strategies applied to optimize the model's processing time; and iv) ease of editing, updating and enhancing the script, which are considered the major strength in the implementation of LASH in MATLAB®. The results of chapter 2 were satisfactory and allowed to infer that the: i) formulation of LASH in MATLAB® improved the river routing, adding a hydraulic structure to the model, and enabled the implementation and appraisal of scheme 2; ii) scheme 2 made it possible some discussions about both the heterogeneity of regions present in CRW and the impact of spatialization of λ and C_s on hydrological modeling at CRW, such that this scheme can be considered as a powerful tool for the water resources management; iii) implementation of AMALGAM along with LASH allowed comparisons between it and the Shuffled Complex Evolution (SCE-UA), such that the former algorithm presented a slightly superior performance for the objective functions used; iv) use of AMALGAM has the potential to reduce the level of uncertainties and equifinality related to the LASH calibration parameters; and v) formulation of LASH in MATLAB® brought excellent benefits in terms of computational performance.

Keywords: Interpreted programming language. Kinematic Wave. Multiobjective calibration algorithms. Camaquã river watershed.

Lista de Figuras

Figura 1 – Representação do ciclo hidrológico a nível global.	22
Figura 2 – Representação da bacia hidrográfica como um sistema hidrológico.	23
Figura 3 – Etapas da modelagem hidrológica.	24
Figura 4 – Exemplo de pontos locais e de máximo global em um dado espaço amostral.....	29
Figura 5 – Estrutura, em <i>pocket algorithm</i> , de um AG genérico.....	31
Figura 6 – Exemplo do conceito de Frente de Pareto, considerando o espaço amostral do conjunto de parâmetros (a) e o espaço das FOs (b).	33
Figura 7 – Esquematisação dos conceitos hidrológicos da atual versão do modelo LASH.....	35
Figura 8 – Esquema do método de diferenças finitas.	40
Figura 9 – Fluxograma da Onda Cinemática para resolução não-linear de forma implícita.	41
Figura 10 – Exemplos de rotinas com e sem os artifícios de melhoramento de desempenho no MATLAB®.....	43
Figura 11 – Esquematisação dos módulos do modelo hidrológico LASH.	48
Figura 12 – Fluxograma do SCE-UA com a estratégia evolutiva do algoritmo CCE.	61
Figura 13 – Ilustração do método evolutivo presente no algoritmo SCE-UA.....	63
Figura 14 – Pseudocódigo e fluxograma do AMALGAM.	66
Figura 15 – Tela inicial da implementação do LASH em MATLAB®.....	67
Figura 16 – Estrutura inicial da função LASH_func.m.	70
Figura 17 - Estrutura de implementação do módulo de propagação de vazões em rios.	75
Figura 18 – Configuração de entrada dos parâmetros do algoritmo SCE-UA e acoplamento com o LASH, em MATLAB®.....	76
Figura 19 – Configuração de entrada dos parâmetros do algoritmo AMALGAM e o acoplamento com o LASH, em MATLAB®.....	78
Figura 20 – Localização da BHRC-PM no contexto da bacia hidrográfica da Lagoa dos Patos, do estado do Rio Grande do Sul, do país e do continente sul-americano.	85
Figura 21 – Localização da barragem do arroio Duro no contexto de proximidade com a BHRC-PM.....	86

Figura 22 – Sub-bacias da bacia hidrográfica do rio Camaquã computadas no ArcLASH para modelagem semi-distribuída.....	87
Figura 23 – Modelo digital de elevação hidrologicamente consistente da BHRC-PM.	88
Figura 24 – Mapa de declividades da BHRC-PM.	88
Figura 25 – Classe de solos na BHRC.....	90
Figura 26 – Uso do solo na BHRC-PM.....	92
Figura 27 – Localização das estações de monitoramento pluviométrico, fluviométrico e meteorológico utilizadas para modelagem na BHRC.	94
Figura 28 – a) Régua linimétrica de monitoramento fluviométrico do rio Camaquã, da seção de controle Passo do Mendonça; b) seção de controle com vistas da largura do rio Camaquã, município de Cristal (RS).	95
Figura 29 – Representação das sub-bacias e trechos dos cursos d'água na bacia hidrográfica do rio Camaquã no pacote hidrológico HEC-GeoHMS.....	96
Figura 30 – Obtenção da largura dos trechos de forma visual no <i>Google Earth Pro</i>	97
Figura 31 – Sub-bacias de validação no LASH à montante da seção de controle Passo do Mendonça da bacia hidrográfica do rio Camaquã.	101
Figura 32 – Calibração (a) e validação (b) do LASH para a seção de controle da BHRC-PM considerando os algoritmos SCE-UA e AMALGAM para o cenário 1....	114
Figura 33 – Validações do LASH nas sub-bacias Passo do Cação (a) e Passo das Carretas (b), considerando os parâmetros calibrados na seção de controle da BHRC-PM para o cenário 1.....	115
Figura 34 – Hidrogramas observados e estimados convertidos de escala diária para mensal no período de calibração (a) e validação (b) do LASH, para a seção de controle da BHRC-PM considerando os algoritmos SCE-UA e AMALGAM para o cenário 1.....	117
Figura 35 – Hidrogramas observados e estimados convertidos de escala diária para mensal no período de validação nas sub-bacias Passo do Cação (a) e Passo das Carretas (b), considerando os parâmetros calibrados na seção de controle da BHRC-PM para o cenário 1.....	118
Figura 36 – Curvas de permanência considerando a calibração (a) e validação (b) do LASH para a seção de controle da BHRC-PM considerando os algoritmos SCE-UA e AMALGAM para o cenário 1.....	119

Figura 37 – Curvas de permanência para as validações do LASH nas sub-bacias Passo do Caçã (a) e Passo das Carretas (b), considerando os parâmetros calibrados na seção de controle da BHRC-PM para o cenário 1.	120
Figura 38 – Vazões mínimas (a), médias (b) e máximas (c) diárias observadas na BHRC-PM, estimadas pelo LASH no período de calibração (1996 – 2000) e validação (2001 – 2005), considerando os algoritmos SCE-UA e AMALGAM para o cenário 1.....	122
Figura 39 – Espacialização dos valores de λ para as sub-bacias da BHRC-PM, considerando os algoritmos (a) SCE-UA e (b) AMALGAM para o cenário 2.....	125
Figura 40 – Espacialização dos valores de C_s para as sub-bacias da BHRC-PM, considerando os algoritmos (a) SCE-UA e (b) AMALGAM para o cenário 2.....	126
Figura 41 – Calibração (a) e validação (b) do LASH para a seção de controle da BHRC-PM considerando os algoritmos SCE-UA e AMALGAM para o cenário 2....	131
Figura 42 – Validações do LASH nas sub-bacias Passo do Caçã (a) e Passo das Carretas (b), considerando os parâmetros calibrados na seção de controle da BHRC-PM para o cenário 2.....	132
Figura 43 – Hidrogramas observados e estimados convertidos de escala diária para mensal no período de calibração (a) e validação (b) do LASH, para a seção de controle da BHRC-PM considerando os algoritmos SCE-UA e AMALGAM para o cenário 2.....	133
Figura 44 - Hidrogramas observados e estimados convertidos de escala diária para mensal no período de validação nas sub-bacias Passo do Caçã (a) e Passo das Carretas (b), considerando os parâmetros calibrados na seção de controle da BHRC-PM para o cenário 2.....	134
Figura 45 – Curvas de permanência considerando a calibração (a) e validação (b) do LASH para a seção de controle da BHRC-PM considerando os algoritmos SCE-UA e AMALGAM para o cenário 2.....	135
Figura 46 – Curvas de permanência para as validações do LASH nas sub-bacias Passo do Caçã (a) e Passo das Carretas (b), considerando os parâmetros calibrados na seção de controle da BHRC-PM para o cenário 2.	136
Figura 47 - Vazões mínimas (a), médias (b) e máximas (c) diárias observadas na BHRC-PM, estimadas pelo LASH no período de calibração (1996 – 2000) e validação (2001 – 2005), considerando os algoritmos SCE-UA e AMALGAM para o cenário 2.....	138

Figura 48 - Banda de incertezas nas curvas de permanência computadas por meio das melhores populações do SCE-UA (a) e do AMALGAM (b) para o cenário 1....	140
Figura 49 – Distribuição cumulativa de GLUE utilizando o SCE-UA (a) e o AMALGAM (b).	142
Figura 50 – Variação das estatísticas de desempenho C_{NS} (a), C_{NS-LOG} (b) e P_{BIAS} (c) e da vazão média (d) na calibração (C), na validação (V) e na C+V para o SCE-UA (2.380 iterações) e AMALGAM (5.000 iterações).	144
Figura 51 – Gráficos <i>box plots</i> dos conjuntos de parâmetros equifinais considerando a calibração pelo SCE-UA e pelo AMALGAM.	146
Figura 52 – Resultados retornados pelo AMALGAM, contendo: a média e desvio padrão de Pareto dos parâmetros calibrados pelo LASH, bem como a correlação de Pareto entre cada um dos parâmetros para o cenário 1.	150
Figura 53 – (a) Frente de Pareto das FOs utilizadas no AMALGAM; (b) soluções normalizadas da Frente de Pareto; e (c) probabilidade de seleção individual de cada sub-algoritmo, considerando o cenário 1.	152

Lista de Tabelas

Tabela 1 – Atributos referentes a cada classe de solo presente na BHRC-PM.	91
Tabela 2 – Atributos referentes ao uso do solo presente na BHRC-PM.	93
Tabela 3 - Estações de monitoramento fluviométrico empregadas para calibração e validação à montante da seção de controle da BHRC	95
Tabela 4 – Parâmetros de entrada e considerações no modelo LASH referente à propagação de vazões em rios	98
Tabela 5 – Parâmetros calibrados para a BHRC-PM, considerando os algoritmos SCE-UA e AMALGAM, para o cenário 1	105
Tabela 6 – Estatísticas de desempenho do LASH para cada algoritmo de calibração, considerando a escala diária e mensal, para o cenário 1	109
Tabela 7 – Médias e desvios padrões das vazões observadas nos períodos considerados para simulações na BHRC-PM e nas sub-bacias 1 e 2	110
Tabela 8 – Parâmetros calibrados para a BHRC-PM, considerando os algoritmos SCE-UA e AMALGAM, para o cenário 2	124
Tabela 9 - Estatísticas de desempenho dos hidrograma estimados para cada algoritmo, considerando a escala diária e mensal, para o cenário 2	128
Tabela 10 – Características do processamento do LASH implementado em MATLAB®, para cada algoritmo de calibração utilizado no estudo de caso da BHRC-PM considerando os parâmetros concentrados por sub-bacia (cenário 1) e o λ e C_s distribuídos por sub-bacia (cenário 2)	155

Lista de Quadros

Quadro 1 – Características dos modelos empíricos, conceituais e fisicamente baseados.....	25
Quadro 2 – Parâmetros de calibração do LASH, o componente do ciclo hidrológico que estão incorporados, a equação em que estão inseridos e o intervalo de simulação.	58

SUMÁRIO

1	Introdução.....	18
1.1	Objetivos	20
1.1.1	Geral	20
1.1.2	Específicos.....	20
2	Revisão de Literatura.....	22
2.1	Hidrologia e modelagem hidrológica.....	22
2.2	Técnicas de calibração de modelos hidrológicos.....	28
2.3	O modelo hidrológico <i>Lavras Simulation of Hydrology</i> (LASH).....	35
2.4	Linguagem de programação MATLAB®	41
Capítulo 1 – Desenvolvimento do modelo LASH em MATLAB® e aprimoramento dos módulos de propagação de vazões em rios e calibração automática		44
1	Introdução.....	45
2	Material e Métodos.....	47
2.1	Implementação do LASH em MATLAB®	47
2.1.1	Módulo de balanço hídrico do solo.....	48
2.1.2	Módulo de propagação nos reservatórios	56
2.1.3	Módulo de propagação de vazões nos trechos de cursos d'água.....	57
2.1.4	Parâmetros de calibração	57
2.2	Implementação dos algoritmos de calibração no LASH	59
2.2.1	SCE-UA.....	59
2.2.2	AMALGAM	64
3	Resultados e discussão	67
4	Conclusões.....	80
Capítulo 2 – Avaliação da calibração e validação do modelo LASH em MATLAB®: estudo de caso na bacia hidrográfica do rio Camaquã (RS).....		81
1	Introdução.....	82
2	Material e métodos.....	84
2.1	Área de estudo	84
2.2	Parametrização do modelo hidrológico LASH	86
2.2.1	Base de dados espaciais	87

2.2.2 Base de dados temporais.....	93
2.2.3 Base de dados para o módulo de propagação de vazões em rios.....	96
2.3 Calibração e validação do modelo hidrológico LASH	98
2.4 Análise de desempenho	101
2.5 Análise de incertezas e equifinalidade.....	103
3 Resultados e discussão	105
3.1 Calibração e validação – cenário 1: parâmetros obtidos	105
3.2 Calibração e validação – cenário 1: estatísticas de desempenho	108
3.3 Calibração e validação – cenário 2: parâmetros obtidos	123
3.4 Calibração e validação – cenário 2: estatísticas de desempenho	128
3.5 SCE-UA versus AMALGAM: incertezas, equifinalidade e diferenças computacionais.....	139
3.6 Formulação do LASH em MATLAB® sob o estudo de caso na BHRC-PM	155
4 Conclusões.....	157
5 Considerações finais	158
Referências	159

1 Introdução

Com o intuito de prover o gerenciamento dos recursos hídricos frente às distintas esferas da sociedade, se faz necessário compreender a disponibilidade hídrica de regiões de interesse. No entanto, no Brasil, o monitoramento hidrológico fluviométrico (e.g. nível e descarga líquida) comumente abrange bacias hidrográficas de médio a grande porte, haja vista sua importância estratégica para geração hidrelétrica e outros aproveitamentos. A densidade de estações de monitoramento nem sempre supre as necessidades de projetos na área recursos hídricos (e.g. construção de estruturas hidráulicas, pontes, estudos de cheias e manchas de inundação), nesse sentido, modelos hidrológicos têm sido desenvolvidos com o propósito de subsidiar estudos técnicos e científicos nessas regiões.

Dentre estes modelos, destaca-se o *Lavras Simulation of Hydrology* (LASH) (VIOLA, 2008; BESKOW, 2009; CALDEIRA, 2016) por sua aplicabilidade crescente no Brasil, já tendo sido avaliado em bacias hidrográficas dos estados de Minas Gerais, Rio Grande do Sul e Tocantins, representando diferentes biomas e condições edafoclimáticas (<https://rpubs.com/gphidrologia/baciaslash>). Outrossim, o modelo se sobressai principalmente devido à pequena quantidade de informações de entrada necessárias e de um número pequeno de parâmetros a serem calibrados. O LASH pode ser aplicado para quantificar os processos do ciclo hidrológico, tais como: evapotranspiração, interceptação, ascensão capilar, armazenamento de água no solo, escoamento superficial direto, escoamento subsuperficial e escoamento de base. É sabida a dificuldade em se mensurar os processos supracitados utilizando monitoramento hidrológico, o que engrandece a utilização de modelos como o LASH.

O histórico de desenvolvimento do LASH foi pautado em três versões, a saber: i) a 1ª versão, desenvolvida por Viola (2008) em *.xlsx sob forma semi-distribuída por sub-bacias; ii) a 2ª versão, desenvolvida e aprimorada por Beskow (2009) em ambiente de programação Delphi, além da implementação da discretização distribuída por células e o módulo de calibração automática; e iii) a 3ª versão, aprimorada por Caldeira (2016) em linguagem de programação Delphi, e que contou com o desenvolvimento de dois módulos para tratamento dos dados de entrada ao LASH, e ainda, a implementação da discretização espacial semi-distribuída por sub-bacias. Todas as versões do LASH consideraram o método de

Muskingum-Cunge Linear (CUNGE, 1969) para propagação de vazões em rios. Todavia, esse método carrega algumas subjetividades, como o cálculo de alguns de seus parâmetros. Nesse sentido, o método da Onda Cinemática (LIGHTHILL; WHITHAM, 1955a, 1955b) pode ser implementado de forma inédita no LASH, permitindo uma representação mais hidráulica do processo de propagação.

Modelos hidrológicos podem ser construídos e aprimorados metodologicamente em ambientes de programação, explorando e acompanhando os avanços computacionais do estado-da-arte. Nesse sentido, linguagens de programação interpretadas e de alto nível, e.g. *MATrix LABoratory* (MATLAB®), R e Python, quando comparadas a linguagens compiladas, e.g. Delphi, C e C++, possuem melhor aplicação no âmbito da Engenharia dada a simplicidade do código. Prechelt (2000) explica que programas escritos em linguagens interpretadas (e.g. R e MATLAB®) são geralmente mais curtos do que programas equivalentes escritos em linguagens compiladas. A linguagem de programação MATLAB® (MATLAB, 2019) possui aplicabilidade no âmbito da hidrologia computacional, devido à disponibilidade de bibliotecas e pacotes de alto nível.

Há alguns modelos hidrológicos desenvolvidos e implementados em MATLAB®, possuindo, desta forma, um leque abrangente de exploração na área de hidrologia computacional. Dentre esses, pode-se destacar o TOP-MODEL (ROMANOWICZ, 1997); o HBV-EDU (HRL, 2013); o MISDc e o MILc (BROCCA *et al.*, 2011); o SEHR-ECHO v1.0 (SCHAEFLI, 2015); o HMETs (FRANCOIS, 2016); o *Tank Model*, desenvolvido na extensão *Simulink* (SONG *et al.* 2017); e o *Nonstationary Conceptual Rainfall Runoff Toolbox* (SADEGH *et al.* 2019), que inclui os modelos GR4J, GR5J, GR6J, HYMOD e HBV.

Dentre as técnicas utilizados para calibração de modelos hidrológicos, a abordagem mono-objetiva conhecida como *Shuffled Complex Evolution* (SCE-UA) (DUAN; SOROOSHIAN; GUPTA, 1992) ganhou destaque por contornar a problemática de utilização de um dos métodos mais utilizados para otimização, o algoritmo de busca local *Downhill Simplex Method*, como é explicado por Naeini *et al.* (2019). Desde então, o SCE-UA tem sido aplicado com sucesso como uma técnica de busca global, resultando em variantes para melhorar as limitações do algoritmo ou torná-lo multiobjetivo.

A calibração do LASH, em sua 1ª versão, foi realizada via planilhas *.xlsx por meio da ferramenta *solver*. A partir de sua 2ª versão, o modelo foi calibrado

utilizando a técnica mono-objetiva SCE-UA, o qual tem apresentado resultados satisfatórios de calibração dos parâmetros do LASH (BESKOW *et al.*, 2011; BESKOW; NORTON; MELLO, 2011; BESKOW *et al.*, 2016; CALDEIRA *et al.*, 2019). Todavia, testar o LASH com uma abordagem multiobjetiva é crucial para subsidiar estudos sobre as incertezas embutidas nos parâmetros calibráveis do modelo e testar diferentes objetivos para as funções de otimização, com vistas a melhorar a calibração em termos tanto de desempenho quanto de representação física dos processos hidrológicos. Nesse sentido, a utilização de uma técnica como o *A Multi-Algorithm Genetically Adaptive Multiobjective* (AMALGAM) (VRUGT; ROBINSON, 2007) pode possibilitar outro nível de análise, principalmente em relação à escolha de funções objetivo (FOs) que, em conjunto, representem os processos do ciclo hidrológico de uma forma mais adequada.

1.1 Objetivos

1.1.1 Geral

O objetivo geral desta dissertação concerne em estruturar o modelo hidrológico LASH na linguagem de programação MATLAB® e associar, de forma inédita, ao método de propagação de vazões em rios da Onda Cinemática e a uma técnica de calibração multiobjetivo.

1.1.2 Específicos

Os objetivos específicos são:

- i) calibrar e validar o LASH em MATLAB® sob estudo de caso na bacia hidrográfica do rio Camaquã, a fim de subsidiar a gestão dos recursos hídricos na bacia;
- ii) utilizar um algoritmo de calibração multiobjetivo robusto baseado na teoria evolutiva e comparar com o algoritmo mono-objetivo que vem sendo utilizado para calibrar os parâmetros do modelo hidrológico LASH, tomando como estudo de caso a bacia hidrográfica do rio Camaquã;
- iii) verificar as diferenças, em termos de resposta hidrológica, frente à utilização dos parâmetros calibráveis do LASH de forma concentrada por sub-bacia (cenário 1) e de forma distribuída por sub-bacia (cenário 2);

- iv) avaliar as diferenças de incertezas e equifinalidade na calibração utilizando as abordagens mono-objetiva SCE-UA e multiobjetiva AMALGAM; e
- v) avaliar os ganhos na implementação do LASH em MATLAB®.

2 Revisão de Literatura

2.1 Hidrologia e modelagem hidrológica

A compreensão dos processos do ciclo hidrológico e suas interações é imprescindível para estudos hidrológicos com subsídio à gestão dos recursos hídricos. Chow, Maidment e Mays (1988) explicam a interação entre os processos do ciclo hidrológico (Figura 1) e, resumidamente, descrevem os principais componentes como sendo: a evapotranspiração, a condensação ou o transporte de vapor d'água na atmosfera, a precipitação, a interceptação da precipitação pela vegetação, o escoamento sobre a superfície do solo (ou escoamento superficial direto), a infiltração e o escoamento subterrâneo.




Figura 1 – Representação do ciclo hidrológico a nível global.

Fonte: Vetorizado e adaptado de Chow, Maidment e Mays (1988).

O ciclo hidrológico em escala de bacia hidrográfica pode ser compreendido como um sistema hidrológico (Figura 2) com uma entrada (precipitação) e algumas saídas (o escoamento total e a evapotranspiração). Basicamente, um sistema hidrológico é definido como um volume, cercado por um limite, que recebe água de

diferentes entradas, as opera internamente e as produz como saídas (CHOW; MAIDMENT; MAYS, 1988).




Figura 2 – Representação da bacia hidrográfica como um sistema hidrológico.

Fonte: Vetorizado e adaptado de Chow, Maidment e Mays (1988).

Para compreender os processos do ciclo hidrológico e suas relações e interações em um sistema hidrológico, i.e. bacia hidrográfica, modelos hidrológicos podem ser utilizados. A principal premissa da aplicação de modelos hidrológicos é a escassez de monitoramento hidrológico, haja vista que, normalmente, regiões com interesse socioeconômico e hidroenergético possuem maior densidade de monitoramento pluviométrico e fluviométrico (VARGAS, 2018). Beskow *et al.* (2018) explicam que a modelagem hidrológica é bastante utilizada para quantificar o impacto nos recursos hídricos sob cenários de uso do solo e mudanças climáticas, e ainda, os modelos são ferramentas importantes para previsões de cheias e auxiliam na gestão dos recursos hídricos. A Figura 3 elenca as principais etapas da modelagem hidrológica com vistas a representar da forma mais fidedigna possível os processos físicos que ocorrem em uma bacia hidrográfica.




Figura 3 – Etapas da modelagem hidrológica.

Os modelos hidrológicos podem ser classificados sob diferentes critérios e necessidade de informações. Frequentemente, os modelos são classificados, dentre outras formas (RENNÓ; SOARES, 2007): i) de acordo com o tipo de variáveis utilizadas na modelagem (estocásticos ou determinísticos); ii) o tipo de relações entre essas variáveis (empíricas ou conceituais); iii) a forma de representação dos dados (discretos ou contínuos); iv) a existência ou não de relações espaciais (concentrados, distribuídos ou semi-distribuídos); e v) a existência de dependência temporal (estacionários ou dinâmicos).

Os modelos determinísticos fornecem a mesma saída para um único conjunto de valores de entrada, enquanto que nos modelos estocásticos, diferentes valores de saída podem ser produzidos para um único conjunto de entradas (DEVI; GANASRI; DWARAKISH, 2015). Ainda segundo os autores, os modelos empíricos são baseados apenas em observações de dados, de modo que os modelos conceituais são baseados em processos hidrológicos, e.g. precipitação, evapotranspiração e escoamento. O Quadro 1 ilustra as principais diferenças entre os modelos empíricos, conceituais e ainda, uma terceira categoria, os modelos fisicamente baseados.

Quadro 1 – Características dos modelos empíricos, conceituais e fisicamente baseados.

Modelos empíricos	Modelos conceituais	Modelos fisicamente baseados
Baseado em dados ou “caixa preta”	Paramétrico ou “caixa cinza”	Metaheurístico ou “caixa branca”
Envolve equações matemáticas	Baseado na modelagem de reservatórios e equações semi-empíricas com base física	Baseado na distribuição espacial e avalia os parâmetros que descrevem características físicas
Baixa consideração dos processos do sistema	Os parâmetros são derivados de dados de campo e calibração	Exige dados sobre o estado inicial do modelo e morfologia da bacia
Alto poder preditivo e baixa capacidade explicativa	Simples e pode ser facilmente implementado em <i>scripts</i>	Complexo e exige experiência e poder computacional
Não pode ser gerado para outras bacias hidrográficas	Exige dados hidrológicos e meteorológicos	Sofre de problemas relacionados à escala
Redes Neurais Artificiais, Hidrograma unitário	Modelos HBV e TOPMODEL	Modelos MIKE SHE, SWAT e LASH
Válido dentro dos limites do domínio principal	A calibração envolve o ajuste da curva, dificultando a interpretação física	Válido para uma ampla gama de situações

Fonte: Adaptado de Devia, Ganasri e Dwarakish (2015).

Em relação à forma de representação dos dados, de acordo com Caldeira *et al.* (2018), os modelos discretos são baseados em eventos ou períodos isolados da série histórica, ao passo que modelos contínuos contemplam longos períodos e captam o comportamento hidrológico. Ainda segundo Caldeira *et al.* (2018), nos modelos concentrados, os parâmetros, as entradas e as saídas são valores médios únicos que representam toda a bacia hidrográfica; nos modelos distribuídos, a bacia é representada por um *grid* de células, de modo que é considerada a variabilidade espacial dos parâmetros, das entradas e das saídas; e nos modelos semi-distribuídos, a caracterização é realizada por meio da divisão da bacia hidrográfica em sub-bacias. Por fim, segundo Devia, Ganasri e Dwarakish (2015) os modelos estacionários e dinâmicos são baseados no fator tempo, o modelo estacionário exclui o tempo, enquanto o modelo dinâmico inclui o tempo.

Alguns modelos hidrológicos se destacam por obterem bons resultados em distintos estudos científicos devido às suas características. O *Limburg Soil Erosion Model* (LISEM) (DE ROO; WESSELING; RITSEMA, 1996; VARGAS, 2018) é um modelo determinístico, fisicamente baseado, discreto e distribuído. Os modelos *Soil*

and Water Assessment Tool (SWAT) (ARNOLD *et al.*, 1998) e *Systeme Hydrologique European* (MIKE SHE) (REFSGAARD; STORM, 1995) são modelos determinísticos, fisicamente baseados, de longo termo e semi-distribuídos, porém o SWAT é semi-distribuído considerando unidades de resposta hidrológica (*Hydrologic Response Units* – HRUs). Por fim, os modelos hidrológicos *Hydrologiska Byrans Vattenbalansavdelning* (HBV) (BERGSTROM, 1976), *Topography Based Hydrological Model* (TOP-MODEL) (BEVEN; KIRKBY, 1979), Modelo de Grandes Bacias do Instituto de Pesquisas Hidráulicas (MGB-IPH) (COLLISCHONN, 2001) e *Lavras Simulation of Hydrology* (LASH) (3ª versão – CALDEIRA, 2018) são modelos enquadrados como determinísticos, conceituais, de longo tempo e semi-distribuídos.

Após a estruturação e classificação do modelo hidrológico, há três etapas que devem ser avaliadas para verificar a confiabilidade de suas respostas: a análise de sensibilidade, a calibração e a validação do modelo. Beskow *et al.* (2011) explicam que a análise de sensibilidade expressa a influência de diferentes parâmetros na resposta de uma variável, de modo que quanto maior a diferença na resposta, mais sensível são os parâmetros. A calibração consiste no ajuste, para a bacia hidrográfica em análise, de um conjunto de parâmetros cujos valores são desconhecidos ou indiretamente mensuráveis, indicados pela análise de sensibilidade (CALDEIRA *et al.*, 2018). De acordo com Her e Chaubey (2015), a calibração do modelo identifica os valores dos parâmetros que maximizam a relação entre as variáveis medidas e simuladas de resposta da bacia hidrográfica. A calibração é necessária quando esses parâmetros não são diretamente mensuráveis. Segundo Caldeira *et al.* (2018), a validação é o processo de simulação utilizando os valores dos parâmetros obtidos na calibração, de forma a conferir a adequabilidade dos parâmetros calibrados. Klemeš (1986) propôs 4 testes de validação, sendo estes:

- i) *Split sample*: teste para aplicação de dois períodos de tempo distintos, um período para calibração e outro para validação na mesma bacia hidrográfica;
- ii) *Proxy-basin*: teste para quando há necessidade de transposição geográfica de um modelo. O modelo deve ser calibrado na bacia A e validado na bacia B e vice-versa. Somente se os resultados da validação forem aceitáveis e similares, o modelo poderá ser aplicado na bacia C, com características edafoclimáticas semelhantes às bacias A e B;

- iii) *Differential Split-sample*: teste aplicado quando a calibração do modelo ocorre em um período anterior a alguma alteração presente na bacia, e.g. climática, e a validação, em um período posterior a essa alteração;
- iv) *Proxy-basin differential split-sample*: combinação dos testes *Proxy-basin* e *differential Split-sample*.

Os testes *Split sample* e *Proxy basin* devem ser aplicados para processos estacionários, os quais, de acordo com Klemeš (1986) são condições físicas que não mudam sensivelmente com o tempo. Logo, os testes *Differential Split-sample* e *Proxy-basin differential split-sample* são aplicados a processos não-estacionários.

A construção de modelos hidrológicos requer a compreensão de alguns termos, como equifinalidade e o princípio da parcimônia. De acordo com Triana *et al.* (2019), a equifinalidade é a ocorrência de vários conjuntos de parâmetros que satisfazem a descrição do sistema, avaliados por meio do desempenho do modelo. A equifinalidade é inevitável, a menos que todas as observações que podem regular as equações e parâmetros do modelo estejam disponíveis (HER; SEONG, 2018). Segundo Her e Chaubey (2015), a equifinalidade pode ser mais severa no caso da calibração de modelos distribuídos, os quais podem apresentar “*over-parametrization*”. Ou seja, quando há mais parâmetros utilizados em um modelo do que podem ser identificados com base nas informações disponíveis (SEIBERT; STAUDINGER; VAN MEERVELD, 2019). Nesse sentido, alguns modelos baseados no princípio da parcimônia foram idealizados para evitar a *over-parametrization*. O princípio da parcimônia é a representação adequada do comportamento de um processo ou de um sistema por um modelo com o menor número possível de parâmetros (TUCCI, 2005). De acordo com Seibert, Staudinger e Van Meerveld (2019), o número de parâmetros varia de três a seis para modelos baseados no princípio da parcimônia e até mais de 100 para modelos complexos.

Em suma, a utilização de modelos hidrológicos se destaca frente à gestão dos recursos hídricos, principalmente nos âmbitos hidrológico, climático, hidráulico e geomorfológico, subsidiando estudos de cheias e estiagem, cenários de mudanças climáticas, dimensionamento de estruturas hidráulicas e avaliação de usos do solo.

2.2 Técnicas de calibração de modelos hidrológicos

O desempenho paramétrico de modelos conceituais chuva-vazão depende da boa estimativa, por meio de calibração, de seus parâmetros (NAEINI *et al.*, 2019), como é representado na Equação 1.

$$y = f(x, \theta) + \varepsilon \quad (1)$$

em que y é a saída, x é a entrada do modelo, θ representa os parâmetros ajustáveis e ε , representa os erros.

A calibração manual dos parâmetros é uma técnica ainda presente em alguns modelos hidrológicos, e que permite analisar a sensibilidade dos parâmetros. No entanto, é laboriosa e altamente dependente de conhecimentos prévios acerca do espaço amostral dos parâmetros e sua interação nos processos hidrológicos. Nesse sentido, técnicas de calibração automática têm sido implementadas para calibração de modelos hidrológicos. Na calibração em geral, o objetivo é encontrar valores para um conjunto de variáveis que se aproximem da realidade, porém na calibração manual são testadas diferentes combinações, enquanto na calibração automática são utilizados artifícios computacionais (CALDEIRA *et al.*, 2018).

As técnicas de otimização geralmente apresentam um espaço de busca, onde estão todas as possíveis soluções para o problema, e uma função que as avalia (FREITAS; FREITAS, 2020). Estas soluções podem estar alocadas em máximos locais ou em um máximo global. A principal diferença é que os máximos locais são mais fáceis de serem alcançados na otimização, enquanto o máximo global é mais custoso computacionalmente, no entanto, mais assertivo. A Figura 4 ilustra um espaço amostral com inúmeros pontos de máximos locais e o ponto de máximo global.




Figura 4 – Exemplo de pontos locais e de máximo global em um dado espaço amostral.

Fonte: Adaptado de MATLAB (2019).

Exposto o conceito de busca em um espaço amostral, Bravo, Collischonn e Tucci (2009) explicam que as técnicas de calibração automática mono e multiobjetivo foram desenvolvidas para facilitar e tornar o processo de otimização mais eficiente. Cabe ressaltar que os algoritmos de calibração multiobjetivo também podem ser utilizados para calibração mono-objetivo, embora não tenham sido desenvolvidos com esse propósito.

A grande parte dos algoritmos de calibração mono ou multiobjetivo são ou partem dos conceitos de algoritmos evolucionários. Os algoritmos evolucionários ou meta-heurísticas são técnicas estocásticas de busca e otimização, poderosas e largamente aplicáveis, inspiradas nos mecanismos da evolução e da genética (CASTRO, 2018). Uma meta-heurística é um algoritmo projetado para resolver uma ampla gama de problemas de otimização rígida sem precisar se adaptar profundamente a cada problema (BOUSSAÏD, LEPAGNOT; SIARRY, 2013). Os algoritmos meta-heurísticos normalmente partem de inspiração biológica e, segundo Piotrowski *et al.* (2017), podem ser classificados em: i) algoritmos genéticos (AGs); ii) estratégias de evolução; iii) programação genética; iv) evolução diferencial; v) otimização de enxame de partículas; ou vi) otimização de colônia de formigas. O termo algoritmo genético foi apresentado por Holland (1975), e é análogo aos

princípios da genética e da seleção natural. De acordo com Tucci (2005), os AGs se baseiam na seleção de espécies que ocorrem nas leis naturais, considerando que os indivíduos que possuem características semelhantes se adaptam melhor ao mesmo ambiente e possuem maior chance de sobrevivência. Nesse sentido, com vistas a compreender a lógica presente nos AGs, é importante destacar a terminologia utilizada na concepção desses algoritmos (CASTRO, 2018):

- cromossomo: cadeia de caracteres representando alguma informação relativa às variáveis do problema; cada cromossomo representa uma solução;
- gene: unidade básica do cromossomo, onde cada cromossomo tem um determinado número de genes, cada um descrevendo uma variável do problema;
- população: conjunto de cromossomos ou soluções;
- geração: número da iteração que o AG executa;
- operações genéticas: operações que o AG realiza sobre cada um dos cromossomos;
- espaço de busca: espaço que compreende as soluções possíveis do problema a ser otimizado;
- função objetivo: função a ser otimizada e que contém a informação numérica do desempenho de cada cromossomo na população;
- critérios de parada de um AG: quando o AG atingir um dado número de gerações, o valor ótimo da função objetivo ou seguindo algum critério de convergência, ou seja, quando não ocorrer melhora significativa no cromossomo de maior aptidão (GALVÃO *et al.*, 1999).

De acordo com Galvão *et al.* (1999), o processo evolutivo do algoritmo é quando a população é avaliada e cada cromossomo recebe uma nota (aptidão), refletindo a qualidade da solução; e os operadores *crossover* ou de mutação selecionam os membros que podem sofrer modificações, gerando descendentes para a próxima geração. Em suma, Castro (2018) explica que os AGs operam com populações de indivíduos representados por cromossomos, os quais, durante o processo de evolução, são submetidos ao procedimento de seleção e reprodução, onde são aplicadas operações de *crossover* e mutação. Quanto melhor o valor de

aptidão de um indivíduo, maior é a probabilidade de ser escolhido para participar do processo de evolução (BRAVO; COLLISCHONN; TUCCI, 2009).

Freitas e Freitas (2020) explicam sobre as vantagens da utilização dos AGs frente aos métodos convencionais, tais como: partem de um conjunto de possíveis soluções (população) e não de um único ponto; utilizam diretamente a FO e não as derivadas 1ª ou 2ª; e utilizam paralelismo implícito.

A Figura 5 compreende a estrutura, em *pocket algorithm*, de um AG genérico.

pocket algorithm – Algoritmo Genético genérico

Seja $S(t)$ a população de cromossomo na geração t

$t \leftarrow 0$

inicializar $S(t)$

avaliar $S(t)$ (função objetivo)

enquanto o critério de parada não for satisfeito, faça (evolução)

$t \leftarrow t+1$

selecionar $S(t)$ a partir de $S(t-1)$ (selecionar indivíduos para reprodução)

aplicar *crossover* sobre $S(t)$

aplicar mutação sobre $S(t)$

avaliar $S(t)$

fim enquanto

Fim

pocket algorithm – Algoritmo Genético genérico

Figura 5 – Estrutura, em *pocket algorithm*, de um AG genérico.

Fonte: Adaptado de Galvão *et al.* (1999) e Castro (2018).

Outra tipologia de meta-heurística que é importante destacar é a meta-heurística híbrida, isto é, os algoritmos meméticos ou híbridos. Os algoritmos híbridos apresentam a capacidade evolucionária de uma grande exploração global da região viável aliada a uma boa eficiência de buscas locais (CASTRO, 2018). De acordo com Vrugt (2015), os algoritmos híbridos aceleram a evolução em direção à solução global e são produtivos, porque a superfície de resposta das FOs geralmente varia consideravelmente entre diferentes problemas de otimização.

Dentre os algoritmos mono-objetivos, ou seja, que trabalham com apenas uma FO, presentes na literatura, se destacam: o *Nelder-Mead* (NELDER; MEAD, 1965); o *Shuffled Complex Evolution* (SCE-UA) (DUAN; SOROOSHIAN; GUPTA, 1992); e o *Particle Swarm Optimization* (PSO) (KENNEDY; EBERHART, 1995). O

Nelder-Mead é o método mais utilizado para resolver problemas de otimização irrestrita, porém possui a desvantagem de ser um algoritmo de busca local, o que restringe sua utilização. O SCE-UA é o mais utilizado para abordagens determinísticas e probabilísticas (VARGAS *et al.*, 2019a) e, de acordo com Naeini *et al.* (2019), é uma junção de pontos fortes de alguns conceitos eficazes de otimização global. Dentre os algoritmos supracitados, o PSO não é um algoritmo genético, mas sim um meta-heurístico baseado na otimização de enxame de partículas.

Na otimização multiobjetivo se destacam duas soluções, segundo Bravo, Collischonn e Tucci (2009): i) soluções dominadas, em que são obtidos os piores valores, em todas as FOs, se comparadas às outras soluções; e ii) soluções não-dominadas ou ótimas de Pareto, em que são obtidos valores de FOs que, comparados às outras soluções, serão melhores em uma ou mais FOs e piores em outra(s). Basicamente, segundo Vrugt e Robinson (2007), a presença de múltiplos objetivos em um problema de otimização dá origem a um conjunto de soluções ótimas de Pareto (soluções não-dominadas), em vez de uma única solução ótima.

A Figura 6 representa o exemplo adaptado de Bravo, Collischonn e Tucci (2009) acerca dos conceitos que envolvem a otimização multiobjetivo. O exemplo é baseado em um modelo teórico de parâmetros θ_1 e θ_2 e FOs F_1 e F_2 . Alguns conjuntos de parâmetros são associados às FOs pelo espaço amostral (Figura 6a). O conjunto de parâmetros identificados pelo ponto A define o ótimo da F_2 e de forma análoga, os parâmetros no espaço do ponto B definem o ótimo da F_1 . A curva, em que os extremos são os pontos A e B, é a Frente de Pareto (Figura 6b). Percebe-se que a Frente de Pareto identifica as soluções não-dominadas, e.g. C e D, e à medida que se parte do ponto A ao ponto B, a F_1 é melhorada, ao passo que a F_2 , piora.




Figura 6 – Exemplo do conceito de Frente de Pareto, considerando o espaço amostral do conjunto de parâmetros (a) e o espaço das FOs (b).

Fonte: Vetorizado e adaptado de Bravo, Collischonn e Tucci (2009).

O uso de múltiplas FOs pode reduzir a equifinalidade e a incerteza, aplicando restrições adicionais e compensações entre FOs na calibração de parâmetros (HER; SEONG, 2018). Liechti *et al.* (2014) explicam que a equifinalidade e a frente de Pareto demonstram a importância da não exclusividade de uma solução ideal para a calibração do modelo. E ainda, que é possível que nenhuma solução ótima seja encontrada sem um grau apreciável de subjetividade.

Dentre as técnicas multiobjetivos, alguns se destacam pela utilização difundida, a saber: o *Multi-objective Complex Evolution – University of Arizona* (MOCOM-UA) (YAPO; GUPTA; SOROOSHIAN, 1998); o *Multiple Objective Particle Swarm Optimization* (MOPSO) (COELLO; LECHUGA, 2002); os algoritmos da família *Nondominated Sorting Genetic Algorithm* (NSGA-II) (DEB *et al.*, 2002) e o ϵ -NSGA-II (KOLLAT; REED, 2006); o *Multi-objective Shuffled Complex Evolution Metropolis – University of Arizona* (MOSCEM-UA) (VRUGT *et al.*, 2003a); e o algoritmo *A Multi-Algorithm Genetically Adaptive Multiobjective* (AMALGAM) (VRUGT; ROBINSON, 2007).

O algoritmo MOCOM-UA é uma extensão do algoritmo de busca global e de objetivo único SCE-UA, porém multiobjetivo (YAPO; GUPTA; SOROOSHIAN, 1998). De acordo com os desenvolvedores, o algoritmo combina os pontos fortes da pesquisa aleatória controlada, a evolução competitiva, *ranking* de Pareto e o método de pesquisa multi-objetiva *downhill simplex*. O MOPSO é um algoritmo meta-

heurístico baseado na otimização de enxame de partículas. De acordo com Coello e Lechurga (2002), o algoritmo utiliza o conceito de dominância de Pareto para determinar a direção de voo de uma partícula e mantém seus vetores não-nomeados anteriormente em um repositório global, o qual será utilizado por outras partículas como orientação. Ainda segundo os desenvolvedores, o registro histórico das melhores soluções encontradas por uma partícula pode ser utilizado para armazenar soluções não-denominadas encontradas anteriormente, isso seria equivalente ao processo de elitismo nos AGs.

Os algoritmos da família NSGA são baseados na meta-heurística de estratégias de evolução e empregam alguma forma de elitismo. O elitismo combina a população atual com a população anterior e escolhe manter as melhores soluções da população combinada (DEB, 2011), e é o que ocorre no NSGA-II, por exemplo. De acordo com Kollat e Reed (2006), o ϵ -NSGA-II incorpora conceitos do algoritmo evolutivo anterior e de dominância ϵ para melhorar a eficiência, confiabilidade e facilidade de uso do NSGA-II original. O conceito de dominância ϵ permite ao usuário especificar a precisão com a qual deseja quantificar cada objetivo em um problema de múltiplos objetivos (KOLLAT; REED, 2006).

O algoritmo MOSCEM-UA é uma melhoria, de forma multiobjetiva, do *Shuffled Complex Evolution Metropolis* (SCEM-UA) (VRUGT *et al.*, 2003b). O MOSCEM-UA combina uma estratégia probabilística de busca e evolução (*covariance-annealing*), a mistura de complexos (subconjuntos de soluções candidatas) e uma regra de atribuição de aptidão baseada nos conceitos de dominância e não-dominância de Pareto (BRAVO; COLLISCHONN; TUCCI, 2009).

O AMALGAM é um algoritmo híbrido e que, de acordo com Liechti *et al.* (2014), utiliza vários algoritmos (sub-algoritmos) específicos que incorporam conceitos diferentes e combina seus resultados. Segundo Asadzadeh e Tolson (2013), o AMALGAM, inicialmente, divide a população entre seus sub-algoritmos e, após cada geração, arquiva os resultados com base na classificação de dominância e distância de aglomeração. Ainda de acordo com os autores, para as gerações posteriores, o AMALGAM divide as soluções-pais entre os sub-algoritmos.

Na literatura há uma vasta gama de algoritmos multiobjetivos, os quais alguns não foram esmiuçados, mas partem de premissas semelhantes às da meta-heurística e merecem ser destacados, dentre eles: o *Multi-Objective Genetic Algorithm* (MOGA) (FONSECA; FLEMING, 1993); o *Strength Pareto Evolutionary*

Algorithm (SPEA2) (ZITLER; THIELE, 1999); o *Shuffled Complex Evolution Metropolis* (SCEM-UA) (VRUGT *et al.*, 2003b) e o *Differential Evolution Adaptive Metropolis* (DREAM) (VRUGT *et al.*, 2008).

2.3 O modelo hidrológico *Lavras Simulation of Hydrology* (LASH)

O LASH foi idealizado por pesquisadores da Universidade Federal de Lavras (UFLA) e da Universidade de Purdue (EUA), em 2008. Em sua 1ª versão (VIOLA, 2008), o LASH foi implementado, de forma semi-distribuída (sub-bacias), em arquivo de planilhas *.xlsx. Em seguida, o modelo foi idealizado para a linguagem de programação Delphi por meio de um *Graphical User Interface* (GUI), oferecendo uma interface para modelagem distribuída (*grid*) e ainda, calibração automática utilizando o AG SCE-UA, resultando na 2ª versão do modelo (BESKOW, 2009). Devido aos estudos supracitados, foi possível acoplar ao modelo os módulos de banco de dados temporal e espacial, sendo estes, respectivamente, o *System of Hydrological Data Acquisition and Analysis* (SYHDA) (VARGAS *et al.*, 2019b) e o ArcLASH (SANTOS *et al.*, 2019), o que originou a 3ª versão do LASH em Delphi (CALDEIRA, 2016). Nesta versão, a modelagem era pautada na distribuição por sub-bacias (semi-distribuída). A Figura 7 ilustra a estrutura do LASH em sua versão atual.




Figura 7 – Esquematização dos conceitos hidrológicos da atual versão do modelo LASH.

Após a idealização das versões, os estudos de Mello *et al.* (2008), Viola *et al.* (2009), Beskow *et al.* (2011), Beskow, Mello e Norton (2011), Viola *et al.* (2012), Beskow, Norton e Mello (2013), Viola *et al.* (2013; 2014; 2015), Beskow *et al.* (2016), Caldeira *et al.* (2019) e Andrade *et al.* (2020) expõem a utilização do LASH e os bons resultados obtidos com o modelo.

Mello *et al.* (2008), no primeiro estudo publicado do LASH, simularam as respostas hidrológicas da bacia hidrográfica do rio Grande (BHRG), em Minas Gerais, com área de drenagem de 2.080 km², em sua formulação semi-distribuída. Viola *et al.* (2009) conduziram um estudo de calibração e validação utilizando a 1ª versão do LASH na bacia do rio Aiuruoca (BHRA), localizada na região Alto rio Grande, Sul de Minas Gerais, com área de drenagem de 2.094 km². Os resultados foram satisfatórios e importantes para impulsionar a aplicabilidade e potencial do LASH. Beskow, Mello e Norton (2011) realizaram um estudo de sensibilidade, reduzindo o intervalo de parâmetros de calibração e incertezas do LASH, descrevendo a 2ª versão do modelo. Identificaram-se os parâmetros mais sensíveis associados aos componentes do ciclo hidrológico do escoamento de base e superficial. Beskow *et al.* (2011) calibraram e validaram a 2ª versão do LASH na bacia hidrográfica do ribeirão Jaguara (BHRJ) de 32 km², localizada no sul de Minas Gerais. A calibração do modelo se deu por meio do algoritmo de busca global SCE-UA e os parâmetros calibrados foram mantidos constantes para a etapa de validação. Os autores constataram a eficiência do LASH em prever vazões de pico e estiagem e consolidaram o modelo como uma ferramenta para gestão de recursos hídricos em bacias de condições semelhantes à BHRJ.

Viola *et al.* (2012) calibraram e validaram a 1ª versão do LASH para a bacia hidrográfica do rio Lontra (BHRL), localizada no norte do Tocantins e com área de drenagem de 3.470 km². A boa performance dos resultados do modelo permitiu evidenciar sua aplicabilidade na gestão dos recursos hídricos para a região. Beskow, Norton e Mello (2013) também utilizaram a versão distribuída do LASH (2ª versão), mas com vistas a estudar a mudança de cenários de uso do solo na BHRJ. Viola *et al.* (2013) conduziram a calibração da versão semi-distribuída do LASH na cabeceira BHRG, sul de Minas Gerais. Os bons resultados, confirmados pela análise dos principais processos hidrológicos simulados pelo modelo, foram coerentes com as características hidrológicas das bacias analisadas. Viola *et al.* (2015) avaliaram, por meio da versão semi-distribuída, os cenários de mudanças de uso do solo na

BHRG, e constataram que as mudanças de uso podem tornar a bacia mais susceptível a inundações. Viola *et al.* (2015) também realizaram um estudo na BHRG, por meio da versão semi-distribuída do LASH, porém com vistas à análise de cenários de mudanças climáticas. O estudo permitiu verificar a sazonalidade dos componentes do escoamento e subsidiou uma análise detalhada dos cenários futuros com respaldo à gestão dos recursos hídricos da região.

Beskow *et al.* (2016) avaliaram a potencialidade da versão distribuída do LASH para a bacia hidrográfica do arroio Fragata (BHAF), com escassez de monitoramento, localizada no sul do Rio Grande do Sul e área de drenagem de 132 km². O estudo foi pioneiro na avaliação do LASH em uma bacia de bioma Pampa e demonstrou grande potencial do modelo ao representar os componentes do escoamento. Caldeira *et al.* (2019) conduziram um estudo de análise comparativa da discretização espacial do LASH na BHAF, utilizando o modelo em suas versões distribuída e semi-distribuída. Os autores constataram que a versão distribuída apresentou melhor desempenho, embora a versão semi-distribuída também tenha apresentado bons resultados com menor custo computacional.

Andrade *et al.* (2020) adaptaram a 1ª versão para trabalhar com Unidades de Respostas Hidrológicas (*Hydrological Response Units – HRUs*) e avaliaram o armazenamento de água no solo na BHRG. Observou-se uma boa relação dos processos hidrológicos estimados nas HRUs, de modo que as estimativas de armazenamento de água no solo refletiram a classe de solos, o uso dos solos e a topografia da bacia hidrográfica de estudo. O estudo de Andrade *et al.* (2020) é precursor no sentido de incorporar as HRUs ao LASH, possibilitando essa implementação nas outras versões e/ou versões futuras do modelo.

A localização das bacias hidrográficas supracitadas e de bacias que estão sendo avaliadas no modelo podem ser visualizadas no aplicativo *web* <https://rpubs.com/gphidrologia/baciaslash>, desenvolvido em ambiente de programação R e alojado no servidor Rpubs, com vistas a divulgar as aplicações do LASH no Brasil.

Em suma, o LASH foi construído para suprir a lacuna de modelos hidrológicos de grande potencialidade e que utilizem poucos parâmetros de calibração, seguindo o princípio da parcimônia e evitando problemas de *over-parametrization*. O maior diferencial do LASH está no conjunto de metodologias do estado-da-arte frente a um modelo com estrutura dinâmica, o que permite e facilita sua estruturação distribuída

ou semi-distribuída. E ainda, sua implementação em distintos ambientes de programação, impulsionando a utilização de técnicas de otimização robustas, potencializando estudos com vistas à gestão dos recursos hídricos.

Mediante o exposto, apesar da grande aplicabilidade do LASH, o leque de módulos e ferramentas que ainda podem ser inseridos no modelo deve ser explorado, tais como os módulos de calibração multiobjetivo, de propagação de vazões por trechos de rios, hidrodinâmico para estudos de manchas de inundação, para quantificar a erosão e transporte de sedimentos, etc. Para explorar esses potenciais módulos, é necessário que o ambiente de programação que o modelo está implementado permita essas inserções com celeridade e facilidade, o que justifica as premissas apresentadas e discutidas ao longo deste estudo.

2.3 Propagação da onda de cheia

De acordo com Rocha (2008), as equações da continuidade e quantidade de movimento (ou equações de *Saint-Venant*) subsidiam a modelagem do escoamento em rios e canais. O autor classifica os modelos como: i) hidrodinâmicos, que utilizam as equações de *Saint-Venant* em sua forma mais completa; ii) de difusão, que não consideram os termos de inércia; iii) de onda cinemática, que não consideram os termos de inércia e pressão; e iv) de armazenamento, que levam em conta apenas os efeitos de armazenamento do escoamento.

No módulo de propagação de vazões em rios, até a 3ª versão do LASH, o método de Muskingum-Cunge Linear (CUNGE, 1969) foi utilizado. O Muskingum-Cunge Linear é amplamente utilizado devido à sua simplicidade e poucos parâmetros de entrada, porém esse método imprime subjetividade na escolha de alguns parâmetros necessários ao cálculo do número de subtrechos de propagação de vazões nos canais. Nesse sentido, para contornar essa subjetividade, pode ser implementado o método da Onda Cinemática (LIGHTHILL; WHITHAM, 1955a, 1955b).

A Onda Cinemática é um modelo hidráulico de propagação e que descreve a onda de cheia variando lentamente ao longo do curso d'água (JETTEN, 2018). O movimento da onda é descrito principalmente pelas equações de *Saint-Venant*, sendo estas a equação da continuidade hidráulica (Equação 2) e a equação do momento (Equação 3), de modo que os termos de aceleração e pressão na equação

do momento podem ser desprezíveis (Equação 4) (CHOW; MAIDMENT; MAYS, 1988).

$$\frac{\partial Q}{\partial x} + \frac{\partial A}{\partial t} = q \quad (2)$$

$$\frac{1}{A} \cdot \frac{\partial Q}{\partial t} + \frac{1}{A} \cdot \frac{\partial}{\partial x} \cdot \left(\frac{Q^2}{A} \right) + g \cdot \frac{\partial y}{\partial x} - g \cdot (S_0 - S_f) = 0 \quad (3)$$

$$S_0 = S_f \quad (4)$$

em que Q é a vazão, x é o intervalo espacial, A é a área, t é o intervalo de temporal, q é a vazão de entrada lateral, g é a aceleração da gravidade, S₀ o termo referente à gravidade e S_f, o termo referente ao atrito.

Ao desconsiderar os termos de pressão e inércia, o modelo apresenta algumas simplificações que restringem sua aplicabilidade, haja vista que considera os efeitos de montante, não podendo ser aplicado em regiões com influência de jusante, e.g. rios que desembocam no oceano (ROCHA, 2008).

As equações de continuidade e momento para Onda Cinemática podem ser combinadas e resultam na Equação 48, em que a única variável dependente é a vazão (CHOW; MAIDMENT; MAYS, 1988).

$$\frac{\partial Q}{\partial x} + \alpha \cdot \beta \cdot Q^{\beta-1} \cdot \frac{\partial Q}{\partial t} = q \quad (5)$$

em que α e β são parâmetros do trecho de propagação.

As equações de *Saint-Venant*, para propagação de cheias, não são passíveis de solução analítica. Nesse sentido, os esquemas numéricos transformam as equações diferenciais parciais em um conjunto de equações algébricas de diferenças finitas, que podem ser lineares ou não lineares (CHOW; MAIDMENT; MAYS, 1988). Na Figura 8, está representado o esquema de resolução das diferenças finitas.




Figura 8 – Esquema do método de diferenças finitas.

Fonte: Adaptado de Jetten (2018) e Chow, Maidment e Mays (1988).

Em relação à precisão da resolução numérica, Ponce (1989) explica que a ordem de precisão de um modelo numérico mede a capacidade do esquema de reproduzir os termos da equação diferencial. Ainda segundo o autor, os esquemas de 1º ordem geram dispersão e difusão numérica e os esquemas de 2º ordem geram apenas dispersão. Na prática, isso significa que a equação da Onda Cinemática pode descrever a translação da onda de cheia, mas não sua atenuação, conforme ela se propaga a jusante, e embora não seja difusa, sofre mudança na forma durante a propagação devido a não linearidade (PONCE, 1991).

A resolução por meio de diferenças finitas pode ser realizada por um esquema explícito ou implícito. A principal diferença, em termos de resolução numérica entre os dois, de acordo com Chow, Maidment e Mays (1988), é que: i) no método explícito, os valores desconhecidos são resolvidos sequencialmente ao longo de uma linha do tempo de um ponto de distância para o próximo; e ii) no método implícito, os valores desconhecidos em uma determinada linha do tempo são todos determinados simultaneamente. No tocante às diferenças de estabilidade numérica, Moraes (2019) explica que: i) nos métodos explícitos, por serem condicionalmente estáveis, o passo de tempo é limitado por um passo temporal (Δt) para garantir a estabilidade do modelo; e apesar da limitação imposta pelo Δt , é um método de fácil implementação e de baixo custo computacional; e ii) os métodos implícitos são incondicionalmente estáveis, por isso permitem Δt maiores, mas por serem mais laboriosos, possuem um alto custo computacional. Apesar da desvantagem dos métodos implícitos, a sua independência aos valores de Δt e passo espacial (Δx) para a estabilidade do número de *Courant* é de grande valia

quando se trata de modelos com passo diário. A Figura 9 representa o fluxograma da Onda Cinemática com resolução não linear de forma implícita.




Figura 9 – Fluxograma da Onda Cinemática para resolução não-linear de forma implícita.

Fonte: Chow, Maidment e Mays (1988).

2.4 Linguagem de programação MATLAB®

A linguagem de programação MATLAB® faz parte do *software* comercial desenvolvido pela *MATrix LABoratory* (MATLAB, 2019) e é um exemplo de linguagem interpretada de alto nível. O MATLAB®, além de combinar computação e poder de visualização, possui centenas de funções nativas e integradas, possibilitando a importação de bibliotecas idealizadas por outros usuários e que ficam disponíveis na plataforma MathWorks®. Por ser uma linguagem de alto nível, o MATLAB® possui inúmeras funcionalidades e possibilidades, dentre as quais, a programação paralela se destaca por contornar problemas de processamento de um grande volume de dados. Luszczek (2009) explica que há cinco formas de paralelismo no MATLAB®:

- i) paralelismo implícito – *threading* de baixo nível: quando são delegadas funções para processadores *multithreading* e multi-core. Neste caso, o usuário não determina quais partes do código são executadas em paralelo;
- ii) paralelismo explícito – *loops* com `parfor`: é útil em situações que exigem muitas iterações de *loop* de um cálculo simples. A principal desvantagem desse paralelismo é que os *loops* não podem ser dependentes entre si;
- iii) paralelismo explícito – `smpd`: `smpd` é o acrônimo para *single program multiple data*. Neste caso há um código único para execução por cada núcleo paralelo, mas cada núcleo possui seus próprios dados para operar. E ainda, qualquer código executado no `smpd` pode se comportar diferente em cada núcleo;
- iv) paralelismo explícito – matrizes distribuídas: é a utilização de indexação e vetorização prévia das variáveis. Basicamente, uma classe chamada *codistributor* carrega as funções de criação de matriz do MATLAB® (e.g. `zeros`) e retorna um objeto de matriz distribuída; e
- v) paralelismo explícito – passagem de mensagem: é o paradigma de programação paralela mais extremo dentre os supracitados. As funções sincronizam e trocam dados entre os núcleos do processador.

Na plataforma MathWorks® estão disponíveis as técnicas de vetorização e pré-alocação para melhorar o desempenho de execução de um *script* em MATLAB® (Figura 9).




Figura 10 – Exemplos de rotinas com e sem os artifícios de melhoramento de desempenho no MATLAB®.

Outro mecanismo que pode auxiliar no tempo de processamento é a alocação de variáveis globais. Variáveis globais são objetos que se comportam como qualquer outra variável local, mas na verdade são *pointers* na memória principal em vez de uma alocação de pilha (ALTMAN, 2014). Ainda segundo Altman (2014): i) as variáveis globais têm *global scope*, o que significa que estão acessíveis em qualquer ambiente na sessão atual do MATLAB®, mesmo fora do seu escopo de declaração; ii) utilizar as variáveis globais em vez de repassar os parâmetros para as funções melhora o desempenho, custando a legibilidade e a manutenção do código, ocultando as dependências funcionais que existem entre as diferentes funções; e iii) as variáveis globais geralmente não são seguras em ambientes *multithread*, ou seja, não se aplica para caso de paralelização.

Frente ao exposto, a justificativa de implementação de *scripts* em linguagem de programação MATLAB® concerne na otimização do tempo de processamento e na facilidade em trabalhar com linguagens interpretadas com vasta disponibilidade de funções nativas e bibliotecas acopladas.

Capítulo 1 – Desenvolvimento do modelo LASH em MATLAB® e aprimoramento dos módulos de propagação de vazões em rios e calibração automática

1 Introdução

Nas últimas décadas, a hidrologia tem testemunhado grandes avanços, especialmente devido ao desenvolvimento de recursos computacionais e ao crescimento de bases de dados (SLATER *et al.*, 2019). Nesse contexto, a construção de modelos hidrológicos em ambientes de linguagens programação interpretadas ganha espaço e margeia a utilização de artifícios robustos, tais como técnicas de calibração por meio de algoritmos de calibração multiobjetivo. O modelo hidrológico LASH, pela sua formulação e interação dos componentes do ciclo hidrológico, é passível de ser implementado em distintos ambientes de programação, principalmente naqueles de alto nível e que permitam o acoplamento de bibliotecas e funções.

Quanto aos módulos do LASH, até a 3ª versão do modelo (CALDEIRA, 2016), para a propagação de vazões em rios tem sido aplicado o modelo vazão-vazão Muskingum-Cunge Linear (CUNGE, 1969). No entanto, este método carrega a subjetividade de escolha de alguns parâmetros, além de considerar apenas o armazenamento do escoamento. Para contornar essa problemática, o método da Onda Cinemática (LIGHTHILL; WHITHAM, 1955a, 1955b) pode ser aplicado, objetivando maior representação hidráulica com menor subjetividade, adicionando, desta forma, um módulo com viés hidráulico ao LASH, representado pela equação de Manning. Em relação ao módulo de calibração dos parâmetros, como a 1ª versão foi implementada em planilhas eletrônicas (*.xlsx), a calibração era realizada pela ferramenta *solver*, de modo que a calibração automática (SCE-UA) foi introduzida na 2ª e 3ª versões do modelo.

O sucesso de aplicação das versões anteriores do LASH em bacias hidrográficas distintas remete ao seguinte questionamento: por que não continuar utilizando o LASH nas versões *.xlsx ou Delphi? Apesar dos bons resultados, é necessário que a estrutura computacional do modelo acompanhe as ferramentas disponíveis, permitindo um *upgrade* de programação. *Upgrade* esse que possibilita, por exemplo, acoplar novos módulos (e.g. propagação de vazões) e esquemas de discretização espacial, testar novas funcionalidades (e.g. algoritmos multiobjetivos) e melhorar o desempenho de execução do modelo. Estas premissas seriam bastante difíceis ou inviáveis de serem implementadas em *.xlsx ou Delphi, devido às limitações ou dificuldades impostas por esses ambientes.

Dentre os ambientes de programação disponíveis e de alto nível, o MATLAB® tem se destacado por apresentar uma sintaxe acessível, funções nativas e *toolboxes* que permitem processamentos laboriosos. Desta forma, o MATLAB® pode subsidiar o desenvolvimento de modelos hidrológicos e o teste de diferentes algoritmos de calibração, propiciando uma análise detalhada de resposta do modelo às inicializações populacionais e ao comportamento dos algoritmos, por exemplo. Outra linha de utilização do MATLAB®, concerne no uso de artifícios (e.g. paralelização, pré-alocação, vetorização e globalização de variáveis) para otimizar o tempo de execução dos modelos. Tal Premissa ainda é um fator limitante para explorar, em tempo hábil, todos os cenários de simulação que um modelo hidrológico propicia, como testes de diferentes algoritmos de calibração dos parâmetros distribuídos por sub-bacia.

No que concerne aos algoritmos utilizados para calibração dos parâmetros de modelos hidrológicos, os AGs têm adquirido espaço de utilização frente às mais diversas formulações de modelos (EFSTRATIADIS; KOUTSOYIANNIS, 2010; NAENI *et al.*, 2019). Enquanto os métodos de calibração e busca convencionais trabalham geralmente de forma seqüencial, avaliando a cada instante uma possível solução, os AGs trabalham com um conjunto de possíveis soluções simultaneamente (FREITAS; FREITAS, 2020). Além do AG SCE-UA, que é fortemente consolidado como algoritmo de calibração para modelos hidrológicos (NAENI *et al.*, 2019), o algoritmo híbrido AMALGAM foi desenvolvido com vistas a suprir as lacunas apresentadas pelos AGs.

Mediante ao exposto, este capítulo apresenta a implementação do modelo hidrológico LASH em ambiente MATLAB®, associado com a melhoria do módulo de propagação de vazões em rios por meio da Onda Cinemática, o acoplamento dos algoritmos mono-objetivo SCE-UA e multiobjetivo AMALGAM e a otimização do tempo de processamento do modelo.

2 Material e Métodos

2.1 Implementação do LASH em MATLAB®

Os processos hidrológicos considerados no LASH, no MATLAB®, foram representados por funções (*functions*) incorporadas ao *script* principal (*main script*), facilitando a leitura do código. Estas *functions* representam os principais processos do ciclo hidrológico, i.e., evapotranspiração potencial e real, escoamento superficial direto, escoamento subsuperficial e escoamento de base. O restante dos processos do ciclo hidrológico é computado dentro de dois *loops* principais, os quais remetem ao número de sub-bacias, previamente computadas no ArcLASH, e ao passo de tempo das variáveis de entrada, no caso deste estudo, diário. A extração das informações da parametrização do LASH por sub-bacias, referente ao equacionamento do modelo, também é tratada no ArcLASH. O ArcLASH é um módulo do LASH idealizado, conforme explica Caldeira (2016), com base na identificação dos mapas e informações que constituem a base de dados espaciais do modelo. O ArcLASH foi projetado como uma *Toolbox* a ser utilizada no software ArcGIS 10.1 ou superior, mais especificamente em sua componente ArcMap (SANTOS *et al.*, 2019).

Outra necessidade iminente é a utilização de ferramentas mais potentes que possam ser acopladas ao código do LASH, como a *Parallel Computing Toolbox* - MATLAB®. Todavia, mediante a inviabilidade de paralelizar *scripts* dependentes entre si, foi realizado um paralelismo implícito no código do LASH, utilizando matrizes e vetores distribuídos, por meio da pré-alocação e vetorização. E ainda, foi utilizado o artifício de globalização das variáveis, que equivale a um *pointer* na memória principal, ou seja, como as variáveis globais são acessíveis em qualquer seção do MATLAB®, não há necessidade de repassá-las às funções, otimizando o tempo de processamento.

O equacionamento do LASH é apresentado a seguir, subdividido em módulos hidrológicos, conforme descrito em Beskow *et al.* (2011), Beskow, Mello e Norton (2011) e Caldeira (2016). A implementação do LASH em MATLAB® foi estruturada para operar com a unidade de análise de sub-bacia e passo de simulação diário, similar à 3ª versão (Figura 11).




Figura 11 – Esquematização dos módulos do modelo hidrológico LASH.

2.1.1 Módulo de balanço hídrico do solo

Todos os processos físicos considerados pelo modelo são fundamentos na equação do balanço hídrico, tomando como base uma camada de controle (BESKOW *et al.*, 2011) (Equação 6). O armazenamento de água no solo é uma variável essencial para a modelagem hidrológica, pois exerce influência na evapotranspiração e na geração de escoamento superficial direto, escoamento subsuperficial e escoamento de base (CALDEIRA *et al.*, 2019).

$$\frac{A_t - A_{t-1}}{\Delta_t} = \frac{P + D_{CR} - ET_R - D_B - D_{SS} - D_{SUP}}{\Delta_t} \quad (6)$$

em que A_t é o armazenamento atual de água no solo (mm) e A_{t-1} é o armazenamento de água no solo (mm) no intervalo de tempo imediatamente anterior à t , Δ_t é o intervalo de tempo (1 dia no caso deste estudo), P é a precipitação média (mm) descontada a interceptação, D_{CR} é a ascensão capilar (mm), ET_R é a evapotranspiração real (mm), D_B é o escoamento de base (mm), D_{SS} é o escoamento subsuperficial (mm) e D_S é o escoamento superficial direto (mm).

Todos os processos hidrológicos considerados no LASH, conforme apresentados na Equação 6, foram considerados, neste estudo, no nível de discretização espacial por sub-bacia hidrográfica. Ou seja, além dos processos hidrológicos terem sido computados por sub-bacia hidrográfica, todos os parâmetros de entrada foram considerados a partir de valores médio no mesmo nível de discretização espacial, conforme descrito em detalhes na sequência.

Após seu início, a precipitação é armazenada na cobertura vegetal até que seja atingido o armazenamento máximo de interceptação (BESKOW *et al.*, 2011). O modelo estima a capacidade do reservatório de interceptação (CRI) de cada sub-bacia hidrográfica.

$$CRI = \alpha \cdot IAF \quad (7)$$

em que CRI é a capacidade do reservatório de interceptação (mm), α é a capacidade máxima de armazenamento de água por unidade de área das folhas, considerada 0,2 mm neste estudo (COLLISCHONN *et al.*, 2007) e IAF, o índice de área foliar ($m^2 \cdot m^{-2}$).

Após determinar a CRI para cada sub-bacia, o modelo realiza o balanço hídrico no reservatório de interceptação considerando a lâmina armazenada no reservatório no tempo $t-1$ (LI_{t-1}), precipitação total no tempo t (P_t) e a lâmina armazenada no tempo t (LI_t) do seguinte modo:

- se $LI_{t-1} = 0$ e $P_t > CRI$ ou $P_t + LI_{t-1} > CRI$: então $LI_t = CRI$.
- se $LI_{t-1} = 0$ e $P_t < CRI$: então $LI_t = P_t$.
- se $LI_{t-1} + P_t < CRI$: então $LI_t = LI_{t-1} + P_t$.

Realizadas essas considerações, o modelo estima a parcela da lâmina de precipitação (P), em termos médios, que atingiu o solo no tempo t em cada sub-bacia.

$$P = P_t - (LI_t - LI_{t-1}) \quad (8)$$

em que LI_t é a lâmina interceptada durante o intervalo de tempo (mm), LI_{t-1} é a lâmina no reservatório de interceptação ao início do intervalo de tempo (mm), P_t é a precipitação total (mm) e P é a precipitação descontada a interceptação (mm).

Ao final do tempo t , o LASH então determina o esvaziamento do reservatório de interceptação de cada sub-bacia hidrográfica.

$$I_{\text{esv}} = LI_t - ET_p \quad (9)$$

em que I_{esv} é o esvaziamento do reservatório de interceptação (mm) e ET_p , a evapotranspiração potencial (mm).

Para representar situações em que algumas áreas da bacia hidrográfica apresentam baixa disponibilidade de água no solo, implicando na elevação da água do aquífero raso para a camada do solo e tornando-a disponível para evapotranspiração, o componente de ascensão capilar (D_{CR}) foi incluído no LASH (BESKOW; MELLO; NORTON, 2011). Quando A_t é inferior ao armazenamento limite (A_{CR}) para ocorrer fluxo de água por ascensão capilar, a Equação 10 é utilizada.

$$D_{\text{CR}} = K_{\text{CAP}} \left(\frac{A_{\text{CR}} - A_t}{A_{\text{CR}}} \right) \quad (10)$$

em que D_{CR} é a ascensão capilar ($\text{mm} \cdot \text{dia}^{-1}$), K_{CAP} é o fluxo máximo retornado ao solo por ascensão capilar ($\text{mm} \cdot \text{dia}^{-1}$), A_t é o armazenamento atual de água no solo (mm) e A_{CR} o armazenamento limite para ocorrer ascensão capilar (mm).

No tocante ao módulo da evapotranspiração, este foi fundamentado em dados meteorológicos normalmente disponíveis, aplicados à equação de Penman-Monteith (ALLEN *et al.*, 1998) para estimativa de uma série histórica de evapotranspiração da cultura (ET_c) por sub-bacia hidrográfica:

$$ET_c = \frac{0,408 \cdot \Delta \cdot (R_n - G) + \left(\frac{86400 \cdot \gamma \cdot \varepsilon}{T_{\text{KV}} \cdot R \cdot r_a} \right) \cdot (e_s - e_a)}{\Delta + \gamma \cdot \left(1 + \frac{r_s}{r_a} \right)} \quad (11)$$

em que ET_c é a evapotranspiração da cultura (mm), Δ a declividade da curva de pressão de saturação da água ($\text{kPa} \cdot ^\circ\text{C}^{-1}$) na temperatura do ar T ($^\circ\text{C}$), R_n a radiação líquida ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$), e_a a pressão atual do vapor d'água (kPa), e_s a pressão de saturação do vapor d'água (kPa), G é o fluxo de energia para o solo ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$), considerado nulo, γ a constante psicrométrica ($\text{kPa} \cdot ^\circ\text{C}^{-1}$), ε uma razão do peso molecular do vapor d'água/ar seco (0,622, adimensional), T_{KV} a temperatura virtual

(K), R a constante de gás específico ($0,287 \text{ KJ} \cdot \text{kg}^{-1} \cdot \text{K}^{-1}$), r_a a resistência aerodinâmica ($\text{s} \cdot \text{m}^{-1}$) e r_s a resistência estomatal ($\text{s} \cdot \text{m}^{-1}$).

As equações subseqüentes comportam as inter-relações entre as variáveis presentes na Equação 11 e estão descritas em Allen *et al.* (1998).

A declividade da curva de pressão de saturação da água ($\text{kPa} \cdot ^\circ\text{C}^{-1}$), é dada por:

$$\Delta = \frac{4098 \cdot \left[0,6108 \cdot \exp\left(\frac{17,27 \cdot T}{T + 237,3}\right) \right]}{(T + 237,3)^2} \quad (12)$$

em que T é a temperatura média do ar ($^\circ\text{C}$).

A radiação líquida ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$) é expressa pela Equação 13 e suas componentes, nas Equações 14, 15 e 16.

$$R_n = R_{ns} - R_{nl} \quad (13)$$

$$R_{ns} = (1 - a) \cdot R_s \quad (14)$$

Se $R_s \leq R_{so}$, então R_{nl} :

$$R_{nl} = \sigma \cdot \left(\frac{T_{\text{máx},K}^4 + T_{\text{mín},K}^4}{2} \right) \cdot (0,34 - 0,14 \cdot \sqrt{e_a}) \cdot \left(1,35 \cdot \frac{R_s}{R_{so}} - 0,34 \right) \quad (15)$$

Se $R_s > R_{so}$, então R_{nl} :

$$R_{nl} = \sigma \cdot \left(\frac{T_{\text{máx},K}^4 + T_{\text{mín},K}^4}{2} \right) \cdot (0,34 - 0,14 \cdot \sqrt{e_a}) \quad (16)$$

em que R_{ns} é a radiação de ondas curtas ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$), R_{nl} é a radiação de ondas longas ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$), a é o albedo, R_s a radiação solar incidente ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$), σ a constante de Stefan-Boltzmann ($4,903 \cdot 10^{-9} \text{ MJ} \cdot \text{K}^{-4} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$), $T_{\text{máx},K}$ a temperatura máxima (K), $T_{\text{mín},K}$ a temperatura mínima (K), R_{so} a radiação de ondas curtas que ocorre quando não há nuvens no céu ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$).

Os componentes e_a (kPa), e_s (kPa), R_{so} ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$) são computados por:

$$e_a = \frac{e_s \cdot U_R}{100} \quad (17)$$

$$e_s = \frac{\left[0,6108 \cdot \exp\left(\frac{17,27 \cdot T_{\min}}{T_{\max} + 237,3}\right)\right] + \left[0,6108 \cdot \exp\left(\frac{17,27 \cdot T_{\max}}{T_{\min} + 237,3}\right)\right]}{2} \quad (18)$$

$$R_{so} = [0,75 \cdot (0,00002 \cdot z)] \cdot R_a \quad (19)$$

em que U_R é a umidade relativa média do dia (%), $T_{\min}$ é a temperatura mínima (°C), $T_{\max}$ é a temperatura máxima (°C), z é a altitude (m a.n.m), R_a é a radiação que atinge o topo da atmosfera ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$).

A radiação que atinge o topo da atmosfera ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$) e suas componentes são dadas por:

$$R_a = \frac{(24 \cdot 60)}{\pi} \cdot G_{sc} \cdot d_r \cdot [\omega_s \cdot \sin(\varphi) \cdot \sin(\delta) + \cos(\varphi) \cdot \cos(\delta) \cdot \sin(\omega_s)] \quad (20)$$

$$d_r = 1 + 0,033 \cdot \cos\left(\frac{2 \cdot \pi}{365} \cdot J\right) \quad (21)$$

$$\omega_s = \arcsin[-\tan(\varphi) \cdot \tan(\delta)] \quad (22)$$

$$\delta = 0,409 \cdot \sin\left(\frac{2 \cdot \pi}{365} \cdot J - 1,39\right) \quad (23)$$

em que G_{sc} é a constante solar ($0,0820 \text{ MJ} \cdot \text{m}^{-2} \cdot \text{min}^{-1}$), d_r é a distância relativa inversa Terra-Sol (adimensional), ω_s o ângulo horário ao nascer ou pôr do sol (radianos), φ é a latitude (radianos), δ é a declinação solar (radianos) e J é o número do dia no calendário Juliano.

A constante psicrométrica ($\text{kPa} \cdot ^\circ\text{C}^{-1}$), presente na Equação 11, e os componentes de seu cálculo são dados por:

$$\gamma = 0,000665 \cdot P \quad (24)$$

$$P = 101,3 \cdot \left(\frac{293 - 0,0065 \cdot z}{293}\right)^{5,26} \quad (25)$$

em que P é a pressão atmosférica (kPa).

Quanto aos componentes relacionados à resistência aerodinâmica ($s \cdot m^{-1}$) e à resistência estomatal ($s \cdot m^{-1}$), as seguintes Equações foram utilizadas:

Se altura da vegetação (h) ≤ 10 m, então r_a :

$$r_a = \frac{6,25}{U_{10}} \cdot \left[\text{LN} \left(\frac{10}{h/10} \right) \right]^2 \quad (26)$$

Se altura da vegetação $h > 10$ m, então r_a :

$$r_a = \frac{94}{U_{10}} \quad (27)$$

$$U_{10} = v_{\text{emp}} \cdot \frac{\text{LN} \left(\frac{10}{h/10} \right)}{\text{LN} \left(\frac{2}{h/10} \right)} \quad (28)$$

em que U_{10} é a velocidade do vento a 10 m da superfície ($m \cdot s^{-1}$), v é a velocidade do vento média diária ($m \cdot s^{-1}$), v_{emp} é a velocidade do vento empregada ($m \cdot s^{-1}$), a qual foi calculada seguindo as Equações 29 ou 30.

Se a altura da estação meteorológica, a partir da superfície do terreno (m) – $h_{\text{estação}} = 2$ m, então v_{emp} :

$$v_{\text{emp}} = v \quad (29)$$

Se a altura da estação meteorológica, a partir da superfície do terreno ($h_{\text{estação}}$, em m) for diferente de 2 m, então v_{emp} :

$$v_{\text{emp}} = \frac{v}{4,87 / \text{LN}[(67,8 \cdot h_{\text{estação}}) - 5,42]} \quad (30)$$

Se o armazenamento de água no solo for menor que um determinado limite de disponibilidade de água no solo, a evapotranspiração real (ET_R) será menor ou igual à ET_C . Nesse sentido, a relação entre ET_C e ET_R pode ser realizada por meio do coeficiente de estresse hídrico (K_S).

$$ET_R = ET_C \cdot K_S \quad (31)$$

em que K_S é um coeficiente adimensional que representa um decaimento exponencial da relação entre a ET_R e ET_C a partir de um armazenamento limite de água no solo (A_L).

$$K_S = \frac{\ln(A_t - A_{PMP})}{\ln(A_L - A_{PMP})} \quad \text{se } A_t < A_L \quad (32)$$

$$K_S = 1 \quad \text{se } A_t \geq A_L \quad (33)$$

em que K_S é o coeficiente de umidade do solo (adimensional), A_L é o armazenamento limite a partir do qual ocorre decréscimo da evapotranspiração (mm), e A_{PMP} é o armazenamento de água no solo no ponto de murcha permanente (mm).

O escoamento superficial direto (D_S) corresponde à fração de chuva que não é interceptada, armazenada nas micro depressões ou infiltrada. O LASH estima esse processo hidrológico, também por sub-bacia hidrográfica, por meio do método Curva-Número (CN) (SCS, 1971) (*Soil Conservation Service – Natural Resources Conservation Services do United States Department of Agriculture*) modificado por Mishra *et al.* (2003).

$$D_S = \frac{(P_t - I_a) \cdot (P_t - I_a + M)}{P_t - I_a + M + S} \quad (34)$$

$$M = 0,5 \cdot [-(1 + \lambda) \cdot S] + \sqrt{(1 - \lambda)^2 \cdot S^2 + 4 \cdot P_5 \cdot S} \quad (35)$$

$$I_a = \frac{\lambda \cdot S^2}{S + M} \quad (36)$$

$$S = (\theta_S - \theta_A) \cdot h \quad (37)$$

$$S = A_m - A_t \quad (38)$$

em que D_S é a lâmina de escoamento superficial direto (mm), P_t é a precipitação total que atinge o solo (mm), I_a é a abstração inicial (mm), M é a umidade antecedente (mm), S corresponde ao armazenamento potencial de água no solo

compreendido entre o conteúdo de água no solo no ponto de saturação (θ_s) e o conteúdo atual de água no solo (θ_A), podendo ser estimado pela Equação 37 ou Equação 38, h é a profundidade da camada de controle do solo (mm) e λ é o coeficiente de abstração inicial.

As parcelas de escoamento subsuperficial (D_{SS}) e do escoamento de base (D_B) são estimadas pelo LASH, para cada sub-bacia hidrográfica, seguindo recomendações de Rawls *et al.* (1993).

$$D_{SS} = K_{SS} \cdot \left(\frac{A_t - A_{cc}}{A_m - A_{cc}} \right)^{\left(3 + \frac{2}{P_r}\right)} \quad \text{se } A_t \geq A_{cc} \quad (39)$$

$$D_{SS} = 0 \quad \text{se } A_t < A_{cc} \quad (40)$$

em que D_{SS} é o escoamento subsuperficial ($\text{mm} \cdot \text{dia}^{-1}$), K_{SS} é a condutividade hidráulica do reservatório subsuperficial ($\text{mm} \cdot \text{dia}^{-1}$), P_r é o índice de porosidade do solo (adimensional) e A_{cc} representa o armazenamento de água no solo a partir do qual ocorre escoamento subsuperficial (mm).

$$D_B = K_B \cdot \left(\frac{A_t - A_c}{A_m - A_c} \right) \quad \text{se } A_t \geq A_c \quad (41)$$

$$D_B = 0 \quad \text{se } A_t < A_c \quad (42)$$

em que D_B é o escoamento de base ($\text{mm} \cdot \text{dia}^{-1}$), K_B é a condutividade hidráulica do reservatório subterrâneo ($\text{mm} \cdot \text{dia}^{-1}$), e A_c representa o armazenamento de água no solo a partir do qual ocorre escoamento subterrâneo (mm).

Conforme pode ser observado no equacionamento dos 3 componentes de escoamento (D_S , D_{SS} e D_B), bem como ET_R (por causa de K_S) e D_{CR} , a representação destes processos está diretamente ligada ao A_t . Ou seja, os escoamentos, ET_R e D_{CR} variam em função de A_t , propiciando ao modelo captar a resposta da bacia a flutuações de A_t .

2.1.2 Módulo de propagação nos reservatórios

Após o cálculo de D_S , D_{SS} e D_B , o modelo converte cada componente em vazão, considerando três reservatórios lineares (superficial, subsuperficial e subterrâneo) (BESKOW *et al.*, 2011) para representar o efeito de armazenamento em cada sub-bacia.

$$Q_S = \frac{D_S \cdot A_{\text{sub-bacia}}}{C_S \cdot T_c} = \frac{V_S}{C_S \cdot T_c} \quad (43)$$

$$Q_{SS} = \frac{D_{SS} \cdot A_{\text{sub-bacia}}}{C_{SS} \cdot T_c} = \frac{V_{SS}}{C_{SS} \cdot T_c} \quad (44)$$

$$Q_B = \frac{D_B \cdot A_{\text{sub-bacia}}}{C_B} = \frac{V_B}{C_B} \quad (45)$$

em que Q_S , Q_{SS} e Q_B são as vazões de saída dos reservatórios superficial, subsuperficial e subterrâneo ($\text{m}^3 \cdot \text{s}^{-1}$), respectivamente, $A_{\text{sub-bacia}}$ é a área de drenagem de cada da sub-bacia (m^2), V_S , V_{SS} e V_B representam o volume nos reservatórios superficial, subsuperficial e subterrâneo (m^3), respectivamente, T_c representa o tempo de concentração da sub-bacia (s), e C_S , C_{SS} e C_B são parâmetros de calibração da propagação dos reservatórios superficial, subsuperficial e de base, respectivamente, sendo C_B o tempo de recessão. Cabe ressaltar que $C_S \cdot T_c$ é menor que $C_{SS} \cdot T_c$, devido a um tempo de residência diferente em cada reservatório (BESKOW; MELLO; NORTON, 2011). Por fim, todas as conversões foram realizadas na estrutura para comportar as unidades de entrada de modo a resultar em $\text{m}^3 \cdot \text{s}^{-1}$.

As Equações 46, 47 e 48 representam o volume de água que permanecem nos reservatórios após cada intervalo de tempo, de forma a atualizar os valores de V_S , V_{SS} e V_B a cada iteração.

$$V_S = V_S - Q_S \cdot t \quad (46)$$

$$V_{SS} = V_{SS} - Q_{SS} \cdot t \quad (47)$$

$$V_B = V_B - Q_B \cdot t \quad (48)$$

em que t é o intervalo de tempo de simulação (segundos).

2.1.3 Módulo de propagação de vazões nos trechos de cursos d'água

A equação de implementação do esquema não linear da Onda Cinemática parte da forma finita da combinação das equações da continuidade e do momento, considerando o rearranjo dos termos, conforme a Equação 49.

$$\frac{\Delta t}{\Delta x} Q_{i+1}^{j+1} + \alpha(Q_{i+1}^{j+1})^\beta = \frac{\Delta t}{\Delta x} Q_i^{j+1} + \alpha(Q_{i+1}^j)^\beta + \Delta t \left(\frac{q_{i+1}^{j+1} + q_{i+1}^j}{2} \right) \quad (49)$$

em que Q é a vazão, Δx é o intervalo espacial, A é a área, Δt é o intervalo de temporal, e q é a vazão de entrada lateral.

Foi adaptada e acoplada ao LASH a função não linear da Onda Cinemática de 1º ordem, resolvida de forma implícita pelo método de Newton-Raphson, seguindo as premissas apresentadas da revisão de literatura, desenvolvida por Paiva (2007) em MATLAB®. Os dados necessários à função são: o hidrograma de entrada, o intervalo temporal, o número de subtrechos em que o curso d'água será dividido, o coeficiente de rugosidade de Manning (n), o comprimento, a largura e a declividade de cada trecho de propagação. É importante destacar que essa função não faz uso da vazão de entrada lateral (sendo $q = 0$ para a Equação 49).

2.1.4 Parâmetros de calibração

Conforme supracitado nos equacionamentos dos módulos anteriores, o LASH possui 7 parâmetros de calibração, os quais foram delineados como os mais sensíveis, segundo o estudo de Beskow, Mello e Norton (2011). Mediante a implementação do módulo de propagação da Onda Cinemática, neste estudo, foi incorporado um 8º parâmetro para calibração, o coeficiente de rugosidade de Manning (n), com vistas a diminuir a subjetividade de escolha desse parâmetro e contribuir para uma aproximação das condições reais de escoamento.

Os intervalos sugeridos para os parâmetros para a simulação do modelo estão apresentados no Quadro 2, bem como a equação em que são utilizados e o componente do ciclo hidrológico em que se relacionam.

Quadro 2 – Parâmetros de calibração do LASH, o componente do ciclo hidrológico que estão incorporados, a equação em que estão inseridos e o intervalo de simulação.

Parâmetro	Símbolo	Componente / Equação	Intervalo
Coeficiente de abstração inicial	λ	D_S / Equação 34	0,01 – 0,20
Condutividade hidráulica do reservatório subsuperficial	K_{SS}	D_{SS} / Equação 39 ou Equação 40	0,10 – 180 mm·dia ⁻¹
Condutividade hidráulica do reservatório subterrâneo	K_B	D_B / Equação 41 ou Equação 42	0,10 – 6 mm·dia ⁻¹
Densidade de fluxo máxima para retorno por ascensão capilar	K_{CAP}	D_{CR} / Equação 10	0,10 – 5 mm·dia ⁻¹
Vinculado ao tempo de resposta do reservatório superficial	C_S	Q_S / Equação 43	condicionado à área de drenagem
Vinculado ao tempo de resposta do reservatório subsuperficial	C_{SS}	Q_{SS} / Equação 44	condicionado à área de drenagem
Tempo de retardo do escoamento de base	C_B	Q_B / Equação 45	-
Coeficiente de rugosidade de Manning	n	Q_{i+1}^{j+1} / Equação 49 ¹	0,025 – 0,160 ² s·m ^{-1/3}

¹ Parâmetro intrínseco à resolução da Equação 49.

² Limites relacionados às condições de canais de grande porte considerando planícies de inundação, conforme Baptista e Lara (2014).

É importante destacar que os limites inferior e superior dos parâmetros C_S e C_{SS} são condicionados à magnitude da área de drenagem das sub-bacias hidrográficas. De forma análoga, os limites do parâmetro n de Manning podem ser distintos aos apresentados no Quadro 2, conforme literatura.

Na implementação do LASH em MATLAB®, a discretização da calibração foi conduzida de forma semi-distribuída, assim como na 1ª e 3ª versões (*.xlsx e Delphi). Vale lembrar que Caldeira *et al.* (2019), ao comparar as versões semi-distribuída (3ª versão) e distribuída (2ª versão), obtiveram resultados satisfatórios para a 3ª versão com menor custo computacional, justificando, desta forma, o desenvolvimento do LASH de forma semi-distribuída em MATLAB®. Outrossim, a calibração dos parâmetros foi implementada para ser extraída de duas formas: i) concentrada por sub-bacia; e ii) distribuída por sub-bacia. A discretização espacial da modelagem como um todo e a discretização da calibração são duas premissas diferentes. No primeiro, é como a modelagem é realizada, neste caso, por sub-bacias e no segundo, como os parâmetros são calibrados, concentrados por sub-bacia (um valor constante do parâmetro para todas as sub-bacias) ou distribuídos por sub-bacia (um valor do parâmetro para cada sub-bacia).

2.2 Implementação dos algoritmos de calibração no LASH

Frente à estruturação do modelo LASH na linguagem MATLAB®, de forma inédita, foi implementado o módulo de calibração do modelo pautado em um algoritmo multiobjetivo. Neste sentido, foi testado o algoritmo de calibração multiobjetivo AMALGAM (VRUGT; ROBINSON, 2006) comparativamente ao algoritmo mono-objetivo SCE-UA (DUAN; SOROOSHIAN; GUPTA, 1992), o qual vem sendo tradicionalmente empregado junto ao LASH.

2.2.1 SCE-UA

O algoritmo mono-objetivo SCE-UA tem sido amplamente utilizado para calibração automática de modelos hidrológicos. O SCE-UA é baseado em quatro conceitos, os quais combinados tornam o método eficaz e robusto, além de flexível e eficiente (DUAN; SOROOSHIAN; GUPTA, 1994): i) a combinação de abordagens determinísticas e probabilísticas; ii) a evolução sistemática de um complexo de pontos que abrangem o espaço de parâmetros, na direção da melhoria global; iii) a evolução competitiva; e vi) a combinação de complexos.

De acordo com Duan, Sorooshian e Gupta (1992), o SCE-UA possui um componente chave, que é o algoritmo *Competitive Complex Evolution* (CCE), utilizado para evoluir cada complexo. O CCE é baseado no esquema de pesquisa *Simplex downhill* do algoritmo Nelder-Mead (NELDER; MEAD, 1965). O SCE-UA contém muitos componentes probabilísticos e determinísticos que são controlados por alguns parâmetros, os quais devem ser escolhidos cuidadosamente para uma execução ótima do algoritmo, sendo (DUAN, 2003):

- m: número de pontos em um complexo (≥ 2);
- q: número de pontos em um sub-complexo ($2 \geq q \leq m$);
- p: número de complexos;
- $p_{\min}$: número mínimo de complexos necessários na população ($1 \geq p_{\min} \leq p$);
- α : número de filhos consecutivos gerados por cada sub-complexo (≥ 1); e
- β : o número de etapas de evolução realizadas por cada complexo (≥ 1).

Duan, Sorooshian e Gupta (1994) recomendam ainda:

- $m = 2n + 1$;
- $q = n + 1$;
- $\alpha = 1$; e
- $\beta = m$.

Duan (2003) relata que o parâmetro mais importante do SCE-UA é o número de complexos (p), o qual é altamente dependente da complexidade do problema e do número de parâmetros a serem otimizados. Os estudos de Duan, Sorooshian e Gupta (1992; 1993; 1994) apresentam estas terminologias e descrevem o passo-a-passo metodológico do SCE-UA, cujo fluxograma está representado na Figura 12.

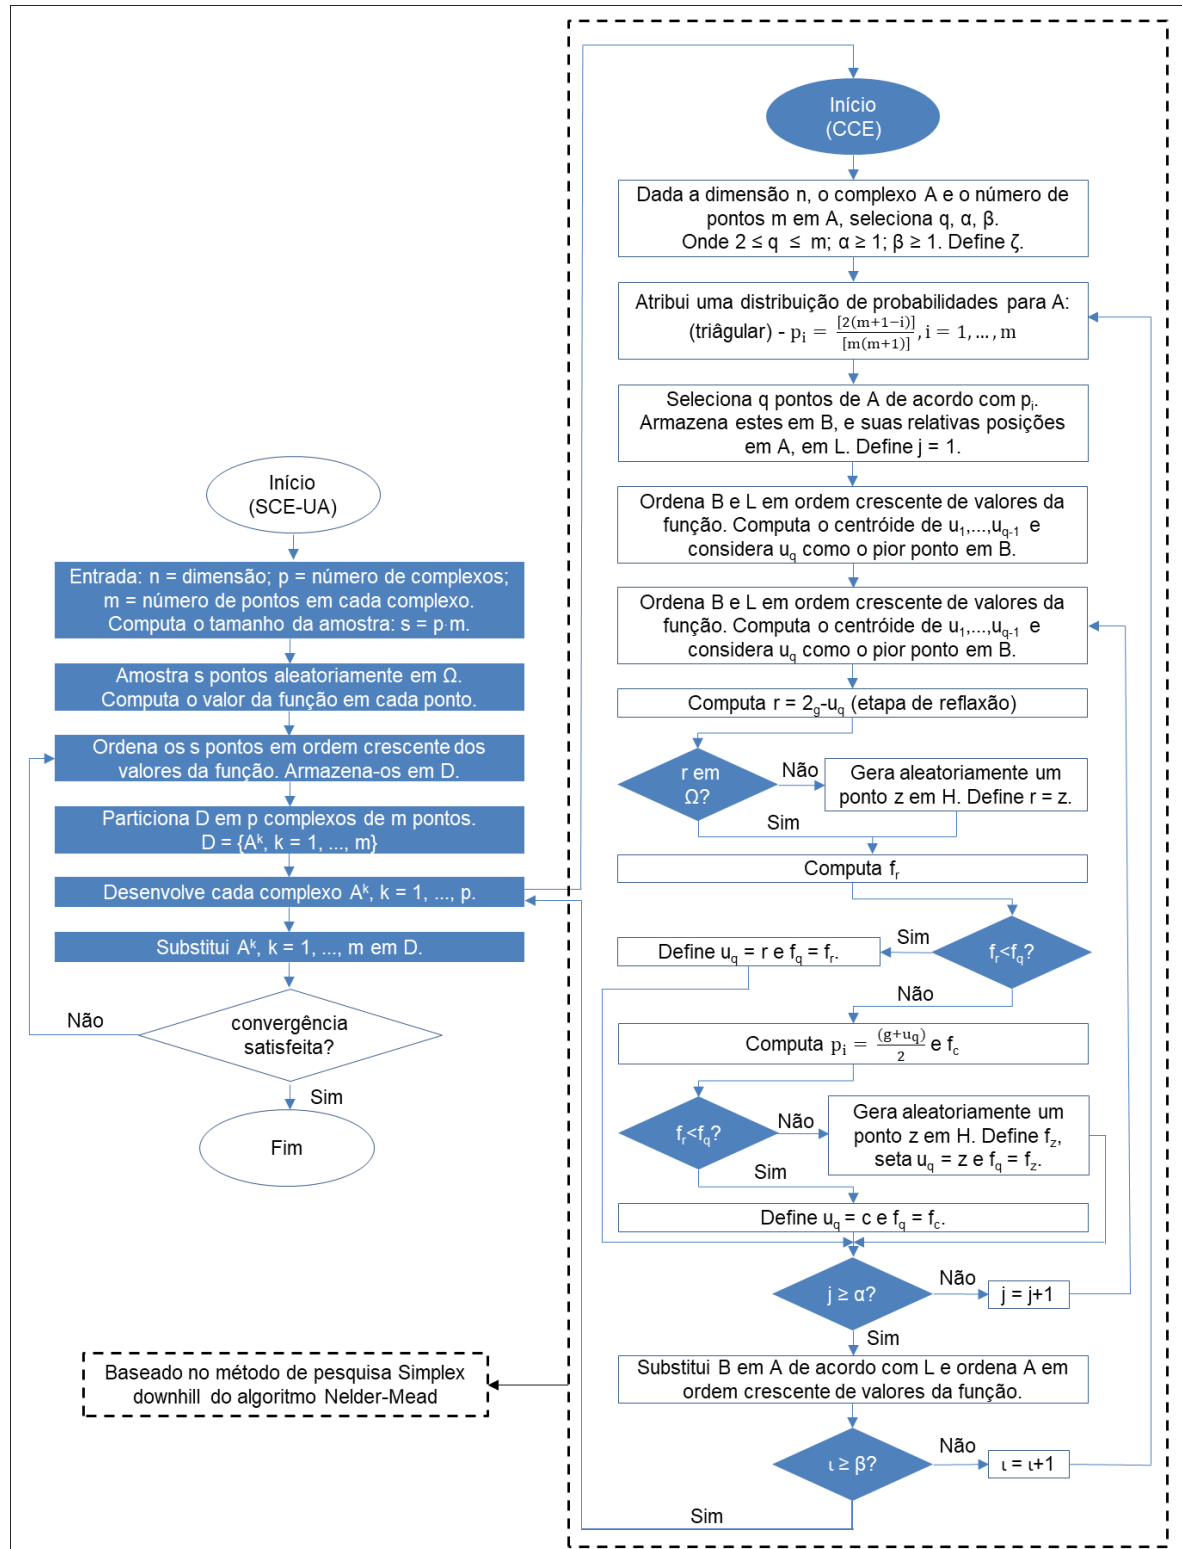


Figura 12 – Fluxograma do SCE-UA com a estratégia evolutiva do algoritmo CCE.

Fonte: Adaptado de Duan, Sorooshian e Gupta (1992).

A Figura 13 ilustra, por meio de um exemplo bidimensional, o método de convergência utilizado no SCE-UA. Duan, Sorooshian e Gupta (1994) explicam que

as linhas de contorno representam uma superfície de uma dada função com um ótimo global localizado em (4,2) e um ótimo local localizado em (1,2), e ainda:

- i) em (a), uma amostra contendo dez pontos é dividida em dois complexos (p), marcados pelos símbolos • e *, e cada uma contendo cinco membros (m). Como cada complexo passa por um processo de evolução independente, o complexo marcado por * está convergindo para o ótimo local, enquanto o outro está convergindo para o ótimo global;
- ii) as localizações dos membros nos dois complexos evoluídos, ao final do 1º ciclo, são ilustradas em (b). Observa-se que os complexos estavam convergindo para dois ótimos distintos, um local e outro global, e para demonstrar isso foram utilizadas dez etapas por cada complexo ($\beta = 10$). Posteriormente, os complexos evoluídos são embaralhados de acordo com as premissas do SCE-UA;
- iii) em (b) está ilustrado as novas posições dos dois complexos evoluídos após o embaralhamento;
- iv) por fim, os complexos são ilustrados em (d), ao final do 2º ciclo de evolução. Pode-se notar que agora os dois complexos estão evoluindo para o ótimo global.




Figura 13 – Ilustração do método evolutivo presente no algoritmo SCE-UA.

Fonte: Vetorizado e adaptado de Duan, Gupta e Sorooshian (1994).

Duan, Sorooshian e Gupta (1994) explicam que no algoritmo CCE, cada ponto de um complexo é um potencial 'pai' com capacidade de participar do processo de reprodução da prole; um sub-complexo funciona como um par de pais, exceto pelo fato de poder compreender mais de dois membros; e a ideia de competitividade é introduzida na formação de sub-complexos, com base na ação de que o filho com melhores características genéticas sobrevive e gera filhos mais saudáveis do que os filhos com piores características genéticas.

Em suma, segundo Beskow (2009): i) o primeiro passo do SCE-UA é criar aleatoriamente um complexo de pontos em todo espaço possível; ii) a técnica de clusterização é empregada para tornar possível guiar a busca na mais promissora das regiões identificadas no complexo inicial; iii) uma estratégia de complexo evolutivo sistemático, neste caso o algoritmo CCE, é essencial para fornecer robustez à busca e, de forma adicional, para o direcionamento de busca baseado na FO escolhida; e iv) a incorporação de um procedimento de evolução competitiva é útil para melhorar a eficiência da convergência global.

Para incorporar o SCE-UA como algoritmo de calibração do LASH, foi utilizado o algoritmo transcrito em MATLAB® por Duan (2004) e disponível no repositório da MathWorks®.

2.2.2 AMALGAM

O AMALGAM combina dois conceitos: a pesquisa multimétodo simultânea e a criação de filhos adaptativa para garantir uma solução rápida e computacionalmente eficiente para problemas de calibração multiobjetivo (VRUGT, 2007). Segundo Liechti *et al.* (2014), o AMALGAM trabalha alterando as soluções de forma adaptativa utilizando 4 algoritmos de calibração: i) o NSGA-II (DEB *et al.*, 2002); ii) o PSO (KENNEDY; EBERHART, 1995); iii) o algoritmo *Adaptive Metropolis Search* (AMS) (HAARIO; SAKSMAN; TAMMINEN, 2001); e iv) o algoritmo *Differential Evolution* (DE) (STORN; PRICE, 1997). Ao fazer isso, o AMALGAM extrai os pontos fortes específicos dos algoritmos de melhor desempenho para cada problema, com potencial de alcançar melhores resultados e com mais eficiência (LIECHTI *et al.*, 2014). Vrugt e Robinson (2007) explicam sucintamente os algoritmos presentes no AMALGAM:

- i) NSGA-II (algoritmo genético evolutivo): utiliza os conceitos de operadores genéticos de seleção, cruzamento e mutação para criar uma nova população de ponto (Q_{t+1}) a partir de uma população existente (P_{t+1});
- ii) PSO (algoritmo enxame de partículas evolutivo): trabalha com um grupo de soluções em potencial (partículas) e procura soluções ideais, modificando continuamente essa população nas gerações subsequentes. Para começar, as partículas são atribuídas a uma localização e velocidade aleatórias no

espaço de pesquisa n -dimensional. Após a inicialização, uma partícula ajusta iterativamente sua posição de acordo com a sua experiência de voo e de todas as outras partículas, fazendo uso da melhor posição encontrada por ela mesma (x_{best}), e por toda a população (p_{best});

- iii) AMS (algoritmo genético de estratégia evolutiva): é um amostrador de *Markov Chain Monte Carlo*, que adota uma estratégia evolutiva que permite substituir pais com filhos de menor aptidão física. E ainda, é muito eficiente na amostragem de distribuições de alta dimensão. Nesse sentido, se o AMALGAM progrediu em direção ao ótimo de Pareto, o algoritmo AMS pode explorar toda a distribuição de Pareto, gerando um grande número de soluções;
- iv) DE (algoritmo de evolução diferencial): diferente de outros algoritmos evolutivos na fase de mutação e recombinação, de modo que utiliza diferenças ponderadas entre vetores de solução para criar novas soluções de descendentes da população existente.

O AMALGAM utiliza diferentes algoritmos de calibração simultaneamente para desenvolver uma população de partículas (ou pais) através de um espaço de pesquisa multidimensional em busca da distribuição de Pareto (VRUGT, 2015). Vrugt (2007) comenta que as avaliações conduzidas usando problemas de teste multiobjetivos sintéticos mostraram que o AMALGAM é da ordem de três a dez vezes mais eficiente que os algoritmos de calibração multiobjetivo SPEA2 ϵ -NSGA-II, e fornece uma população final que se aproxima da solução ótima de Pareto. O pseudocódigo e o fluxograma do AMALGAM são expostos na Figura 14.

Para incorporar o AMALGAM como algoritmo de calibração do LASH, foi utilizado o *script* implementado em MATLAB® por Vrugt e Robinson (2007) e explicado detalhadamente em Vrugt (2016).

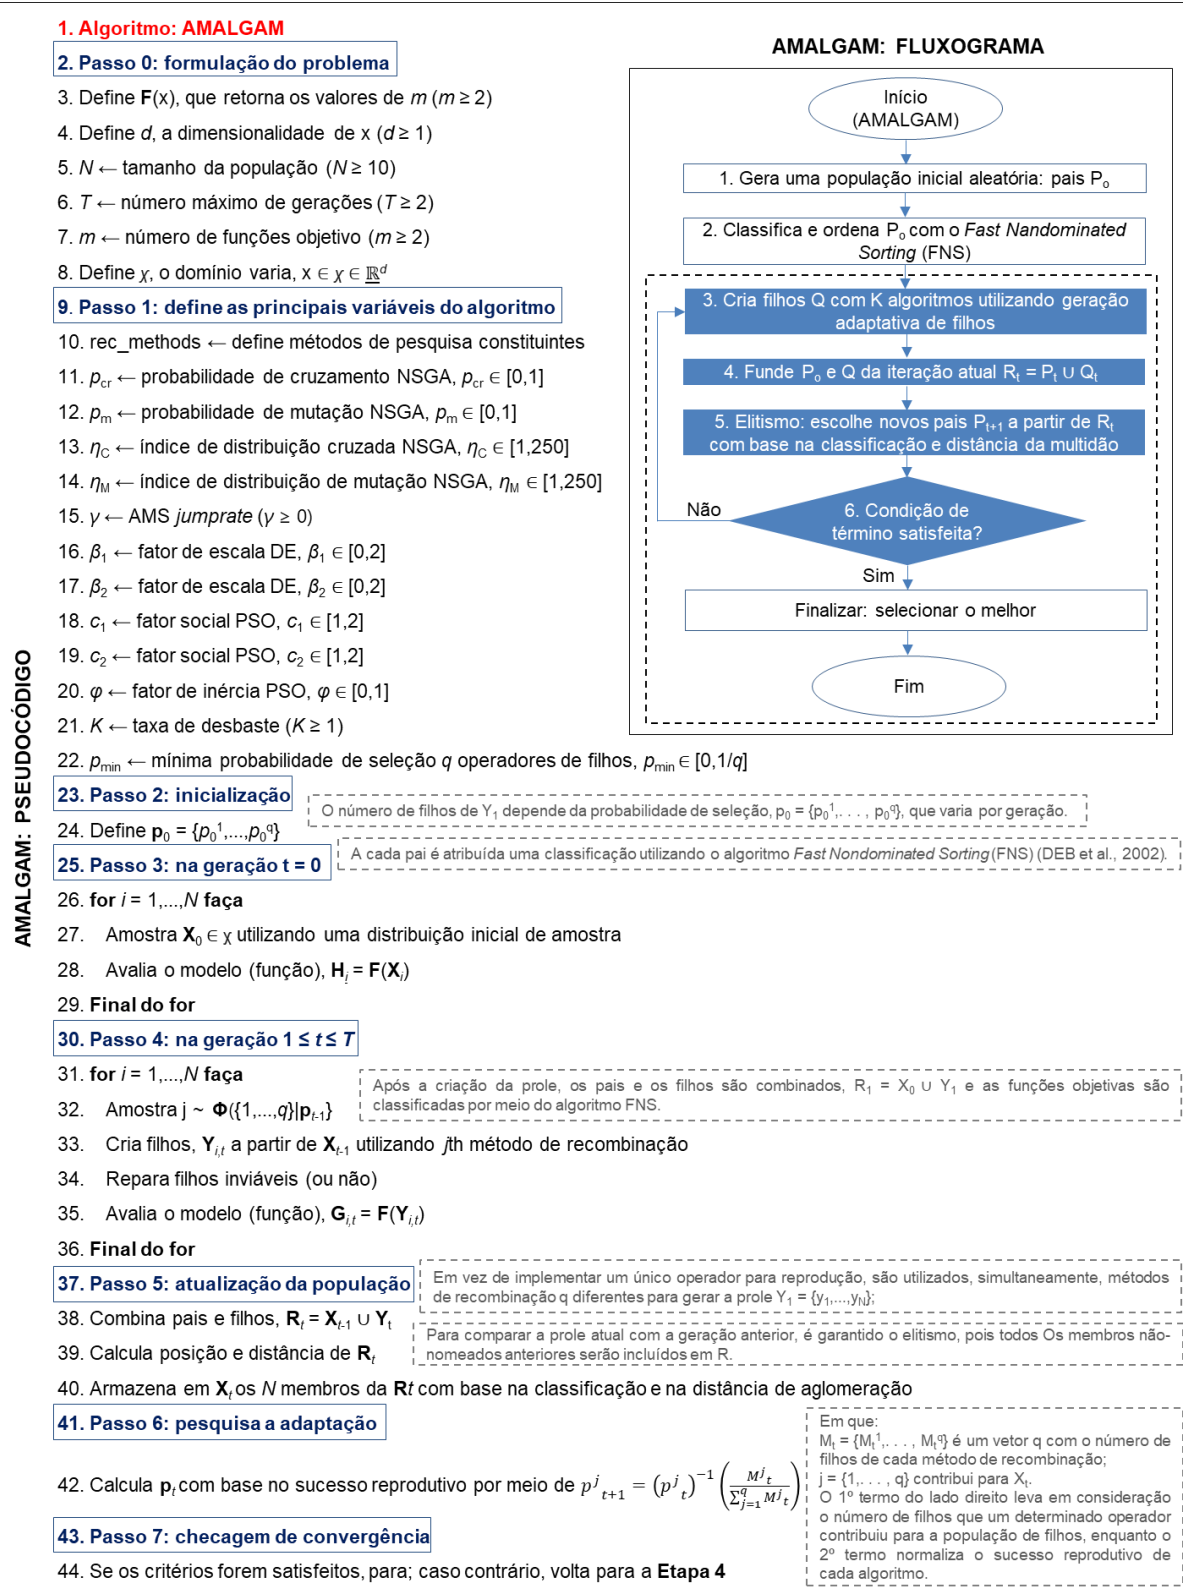


Figura 14 – Pseudocódigo e fluxograma do AMALGAM.


Fonte: Adaptado de Wiekenkamp (2012) e Vrugt (2015).

3 Resultados e discussão

A seção de resultados do capítulo 1 possui uma abordagem técnica para introduzir os resultados do capítulo 2, de modo que as especificidades dos algoritmos serão discutidas em conjunto com os resultados resultantes da aplicação do modelo para a bacia hidrográfica empregada como estudo de caso.

3.1 Estrutura do LASH em MATLAB®

A estrutura inicial de implementação do LASH em MATLAB® é apresentada na Figura 1.



```

1  %%
2  % #####
3  % ##### LAVRAS SIMULATION OF HIDROLOGY (LASH) #####
4  % #####
5  %
6  % # autora:
7  % # Marcelle Martins Vargas
8  %
9  % # data de desenvolvimento:          16/12/2019
10 % # data da implementação da Onda Cinemática: 12/10/2020
11 % # data da última atualização:      12/10/2020
12 %
13 % #####

```

Figura 15 – Tela inicial da implementação do LASH em MATLAB®.

O LASH foi estruturado por meio de dois *scripts* *.m: i) o primeiro, `LASH.m`, remete à importação da base de dados, alocação em vetores específicos, definição das constantes iniciais do modelo, globalização das variáveis indexadas e definição da função de calibração (SCE-UA ou AMALGAM); e ii) o segundo *script*, `LASH_func.m`, concerne em uma função contendo a estrutura de repetição, por sub-bacia e por intervalo de tempo (diário), dos componentes do ciclo hidrológico representados pelo LASH. O `LASH.m` foi desenvolvido em 362 linhas e o `LASH_func.m`, em 740 linhas, totalizando 1.102 linhas de código considerando todas as funções implementadas. Em um comparativo com a 2ª e 3ª versões (em Delphi), por exemplo, houve uma redução expressiva no número de linhas de código, resultado da implementação em uma linguagem interpretada.

Além do número de linhas de código, outros comparativos sobre as vantagens do LASH em MATLAB® podem ser traçados em relação às versões anteriores, a saber: i) a facilidade de interpretação do código e, conseqüentemente, um melhor entendimento dos processos hidrológicos traduzidos para uma linguagem de

programação interpretada e não compilada; ii) a facilidade de implementação de funções externas ao *script* do modelo, possibilitando atualizações e ampliações de funcionalidades; iii) a melhoria do módulo de calibração se comparado à 1ª versão (em *.xlsx); e iv) o tempo de execução de calibração do modelo, o qual será discutido no capítulo 2.

Na parte inicial do LASH.m, foram implementadas as chamadas das variáveis de entrada, organizadas previamente em formato *.txt. Esse formato de arquivo facilita e otimiza a leitura dos dados tabulares. A seguir, estão dispostas as variáveis de entrada do LASH importadas para o *script* por meio da função nativa do MATLAB® `importdata`.

```

▪ vazao = importdata('01_daily_streamflow.txt');
▪ thiessen_clima = importdata('04_ThiessenWeather.txt');
▪ temperatura_min = importdata('05_temp_min.txt');
▪ temperatura_max = importdata('06_temp_max.txt');
▪ umidade_relativa = importdata('07_humidity.txt');
▪ velocidade_vento = importdata('08_wind_speed.txt');
▪ radiacao_solar = importdata('09_solar_radiation.txt');
▪ dados_subbacias = importdata('10_subwatersheds.txt');
▪ dados_solos = importdata('11_soilCharacteristics.txt');
▪ iaf = importdata('12_LAI.txt');
▪ uso_h_veg = importdata('13_vegHeight.txt');
▪ albedo = importdata('14_Albedo.txt');
▪ resist_est = importdata('15_stomatalRes.txt');
▪ prof_sist_rad = importdata('16_depth.txt');
▪ propag = importdata('17_propag_reaches.txt');
▪ contribuintes = importdata('18_propag_contributors.txt');

```

Os vetores `vazao`, `temperatura_min`, `temperatura_max`, `umidade_relativa`, `velocidade_vento` e `radiacao_solar` correspondem às séries históricas necessárias ao modelo. Além disso, a série histórica de chuva também se faz necessária, mas não é importada neste *script*. Para os dados de vazão ($\text{m}^3\cdot\text{s}^{-1}$), umidade relativa (%) e velocidade do vento ($\text{m}\cdot\text{s}^{-1}$), são utilizados os

valores médios diários disponibilizados pelos bancos de dados. Para os dados de temperaturas mínima e máxima ($^{\circ}\text{C}$), são utilizados os valores mínimos e máximos das séries históricas, respectivamente. Ao passo que para os dados de chuva (mm) e insolação (h) são utilizados o total diário e o somatório de horas do dia com presença solar, respectivamente.

A matriz `dados_subbacias` contém os dados de cada sub-bacia da bacia hidrográfica a ser analisada no LASH, tais como a área de drenagem (km^2), a latitude do centroide ($^{\circ}$), o tempo de concentração (minutos), a altitude média (m), o maior comprimento do curso d'água principal (m) e a declividade média do curso d'água principal ($\text{m}\cdot\text{m}^{-1}$). Vale destacar que essas informações foram obtidas junto ao processamento no ArcLASH. As características do solo, também extraídas no ArcLASH, são representadas no arquivo `dados_solos`, o qual contém informações para cada sub-bacia acerca da umidade de saturação ($\text{m}^3\cdot\text{m}^3$), umidade no ponto de murcha permanente e profundidade do solo (mm).

Quanto aos dados de propagação de vazões nos cursos d'água, estes são importados para o *script* por meio dos arquivos `propag` e `contribuintes`. Em `propag` estão dispostos os dados acerca de cada trecho oriundo do tratamento prévio na bacia hidrográfica, a saber: o número, a ordem, o comprimento (m), e a declividade média ($\text{m}\cdot\text{m}^{-1}$) de cada trecho, as sub-bacias e o número do trecho que cada trecho recebe. Em `contribuintes`, estão relacionados os dados de cada trecho com a sub-bacia hidrográfica afluente. O tratamento dos dados supracitados é realizado à parte do LASH e do ArcLASH, podendo ser utilizados *softwares* ou pacotes hidrológicos com apoio de um Sistema de Informações Geográficas (SIG).

A indexação das variáveis globais foi realizada no `LASH.m`, utilizando o artifício de indexação por *struct* para cada uma das variáveis necessárias ao *script* `LASH_func.m`, como por exemplo: `s.temp_min = temp_min`. Dessa forma, qualquer variável previamente indexada com *struct* (`s.`), pode ser acessada por qualquer seção ativa do MATLAB®, suprimindo o tempo de busca dessas variáveis na memória e otimizando o tempo de processamento. Ainda, no `LASH.m`, foram implementadas algumas funções de apoio para preparar a base temporal para a função `LASH_func.m`, a saber:

- `function [juliano_result]`: função para transformação da data gregoriana para formato juliano, facilitando, desta forma, trabalhar com datas no MATLAB®;
- `function [arc2lash_result]`: função para transformação do formato de saída dos dados tabulares do ArcLASH para formato matricial;
- `function [thiessen_result]`: função para o cálculo de dados meteorológicos médios por sub-bacia hidrográfica, considerando os pesos de influência de cada estação de monitoramento.

O condicionamento do *script* para a calibração do modelo é realizado no `LASH_func.m`, de modo que o início desse *script* apresenta a indexação da função que será chamada no `LASH.m`, além da indexação dos parâmetros calibráveis do modelo, como é ilustrado na Figura 16.

```

28  function [F] = LASH_func(x)
29
30  global s
31
32  %-----
33  % PARÂMETROS PARA CALIBRAÇÃO DO SCRIPT (.m)
34  %-----
35  % Fonte: Caldeira (2019)
36  % Lambda: coeficiente de abstração inicial (adimensional 0.01-0.2)
37  % Kss:    condutividade hidráulica do reservatório subsuperficial (0-180mm/dia)
38  % Kb:     condutividade hidráulica do reservatório subterrâneo (0-6mm/dia)
39  % Kcr:    densidade de fluxo máxima para retorno por ascensão capilar (0-5mm/dia)
40  % Cs:     parâmetro de tempo de resposta do reservatório superficial (adimensional)
41  % Css:    parâmetro de tempo de resposta do reservatório subsuperficial (adimensional)
42  % Cb:     parâmetro de tempo de retardo do escoamento de base
43
44  Lambda = x(1);
45  Kss    = x(2);
46  Kb     = x(3);
47  Kcr    = x(4);
48  Cs     = x(5);
49  Css    = x(6);
50  Cb     = x(7);
51  n_manning = x(8);

```

Figura 16 – Estrutura inicial da função `LASH_func.m`.

A estrutura `function [F] = LASH_func(x)` retorna os valores da(s) FO(s) alocadas no final dessa função. A função nativa `global s` permite que essa função acesse as variáveis declaradas como globais no *script* `LASH.m`. No exemplo da Figura 16, os parâmetros foram indexados para serem calibrados de forma concentrada por sub-bacia, indicando que esses valores são os mesmos para cada uma das n sub-bacias. No entanto podem ser condicionados para serem extraídos

de forma distribuída por sub-bacia da seguinte forma, por exemplo: `Lambda (sb)`
`= x(1:sb).`

Cabe destacar que a leitura dos dados de chuva, bem como seu tratamento para extrair a precipitação média por sub-bacia, foram computados no *script* `LASH_func.m`. Esse artifício foi utilizado, porque os dados de chuva são atualizados nos *loops* principais e restaurados a cada inicialização de uma nova população nos algoritmos de calibração. Além disso, os dados extraídos do ArcLASH relacionados à influência de cada estação de chuva nas sub-bacias, também foram alocados para serem importados nesse *script*:

- `thiessen_chuva = importdata('02_ThiessenRain.txt');`
- `chuva_diaria = importdata('03_daily_rainfall.txt');`

No *script* `LASH_func.m`, alguns vetores e matrizes utilizados nos *loops* principais foram pré-alocados utilizando a função nativa `zeros`, e.g. `Arm_atual = zeros(s.num_sub,1)`. Esse tipo de pré-alocação imprime uma paralelização implícita ao código, auxiliando no tempo de processamento e acesso das funções a esses vetores/matrizes.

No `LASH_func.m`, os seguintes sub-módulos também são computados: i) P_5 ; ii) profundidade de controle do balanço hídrico; iii) armazenamentos de água no solo; iv) evapotranspiração real (`ET_real`); v) interceptação; vi) escoamentos; vi) propagação nos reservatórios; e vii) volumes e vazões por sub-bacia. Nesse sentido, as funções externas ao *script* principal são apresentadas a seguir com a parte comentada dos parâmetros de entrada e parâmetros de saída.

```
▪ function [ETr_result]: evapotranspiração real;
% evapotranspiração pelo método de Penman-Monteith: ETr
% parâmetros de entrada:
% data_analisada
% lat_deg: latitude em graus da estação meteorológica
% altitude média: altitude média da estação meteorológica (m)
% tmin: temperatura mínima da estação meteorológica (°C)
% tmax: temperatura máxima da estação meteorológica (°C)
```

```

% UR_media: umidade relativa do ar da estação meteorológica
% rad_solar: radiação solar da estação met. (MJ.m-2.dia-1)
% v_vento_2m: velocidade do vento à 2 m (m.s-1)
% albedo
% h_veg: altura da vegetação (m)
% res_est: resistência estomatal
% Arm_atual: armazenamento atual de água no solo
% Arm_cap: armazenamento limite de água no solo
% Arm_pwp: armazenamento de água no ponto de murcha
permanente
% parâmetro de saída:
% ETr_result: evapotranspiração real da cultura (mm.dia-1)

▪ function [ETp_result]: evapotranspiração potencial;
% cálculo da evapotranspiração potencial: ETp
% parâmetros de entrada
% data_analisada
% lat_deg: latitude em graus da estação meteorológica
% altitude média: altitude média da estação meteorológica (m)
% tmin: temperatura mínima da estação meteorológica (°C)
% tmax: temperatura máxima da estação meteorológica (°C)
% UR_media: umidade relativa do ar da estação meteorológica
% rad_solar: radiação solar da estação met. (MJ.m-2.dia-1)
% v_vento_2m: velocidade do vento à 2m (m/s)
% albedo
% h_veg: altura da vegetação (m)
% res_est: resistência estomatal
% parâmetro de saída:
% ETp_result: evapotranspiração potencial

▪ function [Ds_result]: escoamento superficial direto;
% cálculo do escoamento superficial: método do CN Modificado
(Ds)
% parâmetros de entrada:
% Lambda: coeficiente de abstração inicial (0-0.2)

```

```

% P: precipitação total
% P5: precipitação acumulada 5 dias antecedentes
% Arm_potencial: potencial de armazenamento de água no solo
% Arm_atual: armazenamento atual de água no solo
% parâmetro de saída:
% Ds_result: escoamento superficial estimado

    ▪ function [Dss_result]: escoamento subsuperficial;
% cálculo do escoamento subsuperficial (Dss)
% parâmetros de entrada:
%     Kss: condutividade hidráulica do reservatório
subsuperficial ( $\text{mm}\cdot\text{dia}^{-1}$ )
% Arm_potencial: potencial de armazenamento de água no solo
% Arm_atual: armazenamento atual de água no solo
% Acc_perc: percentual de armazenamento de água no solo a
partir do qual ocorre escoamento subsuperficial
% Ar: índice de porosidade do solo
% parâmetro de saída:
% Dss_result: escoamento subsuperficial estimado

    ▪ function [Db_result]: escoamento de base;
% cálculo do escoamento de base (Db)
% parâmetros de entrada
% Kb: condutividade hidráulica do reservatório subterrâneo
% Arm_potencial: potencial de armazenamento de água no solo
% Arm_atual: armazenamento atual de água no solo
% Ac_perc: percentual de armazenamento de água no solo a
partir do qual ocorre escoamento subterrâneo
% parâmetro de saída:
Db_result: escoamento de base

    ▪ function [Dcr_result]: ascensão capilar;
% cálculo da ascensão capilar (Dcr)
% parâmetros de entrada:

```

```

    % Kcr: densidade de fluxo máxima para retorno por ascensão
    capilar (0-5mm/dia)
    % Arm_potencial: potencial de armazenamento de água no solo
    % Arm_atual: armazenamento atual de água no solo
    % Acr_perc: percentual do limite de disponibilidade de água
    no solo para que ocorra o aumento capilar
    % parâmetro de saída:
    % Dcr_result: ascensão capilar

```

▪ **function** [Qpropag_result]: propagação de vazões em rios.

```

% parâmetros de entrada:
% Qin: hidrograma de entrada ( $\text{m}^3 \cdot \text{s}$ )
% dt: intervalo de tempo (horas)
% N: número de subtrechos de rio
% Manning: coeficiente de rugosidade de Manning
% L: comprimento do rio (m)
% B: largura do rio (m)
% S0: declividade do fundo do rio ( $\text{m} \cdot \text{m}^{-1}$ )
% Q0: vazão de referência para o cálculo da celeridade
cinemática
% parâmetro de saída:
% Qpropag_result: vazão propagada

```

A P_5 , a profundidade controle e os armazenamentos de água no solo não são computadas por meio de funções externas, mas diretamente no código utilizando um condicional para o índice do *loop* temporal (t) e do *loop* das sub-bacias (sb), como é exemplificado a seguir:

```

▪ % cálculo da  $P_5$ 
    if (t <= 6)
        P5 = sum(chuva(1:(t-1), sb));
    else
        P5 = sum(chuva((t-5):(t-1), sb));
    end

```

- `% cálculo da profundidade controle`
`if (s.prof_sist_rad(t,sb) > s.prof_solo_sub(sb,1))`
`prof_controle = s.prof_solo_sub(sb,1);`
`else`
`prof_controle = s.prof_sist_rad(t,sb);`
`end`

A `function` [thiessen_result] também foi acoplada ao LASH_func.m, porque os dados de chuva são importados nessa função e não no LASH_func. Em relação à implementação do módulo de propagação de vazões em rios, esta foi representada mediante dois *loops* secundários, os quais foram criados após os *loops* que remetem ao número de sub-bacias e ao passo temporal (Figura 17).

84	<code>%-----</code>	
85	<code>% LOOP NAS SÉRIES HISTÓRICAS E SUB-BACIAS</code>	
86	<code>%-----</code>	
87		
88	<code>for t = 1:s.fim_sim</code>	
89		
90	<code> for sb = 1:s.num_sub...</code>	
181	<code> end</code>	
182		
183	<code>%%</code>	
184	<code>%-----</code>	
185	<code>% LOOP PARA PROPAGAÇÃO</code>	
186	<code>%-----</code>	
187		
188	<code>for k = 1:length(s.propag_ord)...</code>	
236		
237	<code>for cont = 1:length(s.contribuintes)...</code>	
238		

Figura 17 - Estrutura de implementação do módulo de propagação de vazões em rios.

Observação: o *script* aparece de forma resumida para contemplar os loops principais.

Os *loops* da propagação foram condicionados aos seguintes dados de entrada:

- `for k = 1:length(s.propag_ord)`
`% TR: trechos considerados (HEC-HMS)`
`% xL: comprimento dos trechos (m)`
`% B: largura dos trechos (m)`
`% S0: declividade dos trechos ( $m \cdot m^{-1}$ )`
`% SB1: subbacia 1 que os trechos recebem`
`% SB2: subbacia 2 que os trechos recebem`
`% T1: trecho 1 que os trechos recebem`

Cabe destacar que a vazão total é referente à vazão propagada até a última sub-bacia, sendo representada no fim do *script*, como por exemplo: `Qt(:,1) = Qfinal_sub(:,47)`. Onde 47, por exemplo, é o número da sub-bacia referente à seção de controle de uma dada bacia hidrográfica. Esse número varia conforme o número de sub-bacias resultantes para calibração.

O módulo de propagação de vazões pela Onda Cinemática do LASH, implementado nesta versão em MATLAB®, possui margem para ser melhorado e automatizado em versões futuras, pois a estruturação dos trechos de propagação deve ser realizada à parte, de forma manual. Alguns *softwares* e pacotes hidrológicos podem auxiliar nessa estruturação dos trechos, acoplados a um SIG, como o ArcGIS, não havendo uma metodologia mais indicada, mas aquela que atenda às necessidades e aos conhecimentos do projetista. No capítulo 2 é mostrado como os trechos de propagação foram computados para o estudo de caso.

3.2 Implementação dos algoritmos de calibração no LASH em MATLAB®

O acoplamento dos algoritmos de calibração ao LASH em MATLAB® se deu, basicamente, por meio do artifício de *handle function* sendo considerada, neste caso, o *script* `LASH_func.m`. Os parâmetros dos algoritmos foram incorporados no final do *script* `LASH.m.`, sendo consideradas as suas especificidades, como ilustra as Figuras 18 e 19 e é discutido a seguir.

```

239 #####
240 ##### RUN SCE-UA #####
241 ##### Lavras Simulation of Hydrology (LASH) #####
242 #####
243
244 - !copy LASH_func.m functn.m
245
246 - x0 = [0.1 100 0.5 1 10 10000 30 0.050];
247 - b1 = [0.01 0.1 0.1 0.1 1 50 1 0.025];
248 - bu = [0.2 180 6 5 50 50000 100 0.160];
249
250 - ngs = 5;
251 - maxn = 5000 ; kstop = 5; pcento = 0.1; peps = 0.001; iseed = 1969; iniflg = 0;
252 - [bestx, bestf] = sceua(x0, b1, bu, maxn, kstop, pcento, peps, ngs, iseed, iniflg);
253
254 - return;

```

Figura 18 – Configuração de entrada dos parâmetros do algoritmo SCE-UA e acoplamento com o LASH, em MATLAB®

A linha 244 (`!copy LASH_func.m functn.m`) remete à cópia da *handle function* `LASH_func.m` para uma função generalizada de entrada do SCE-UA (`functn.m`). Esse artifício utilizado por Duan (2004) permite que qualquer função de calibração seja importada para o algoritmo, sem precisar alterar o código fonte do SCE-UA. Nesse sentido, todas as definições de entrada para o algoritmo podem ser realizadas à parte, sendo que `x0`, `bl` e `bu` são os parâmetros iniciais, inferiores e superiores, respectivamente, de inicialização do LASH ao algoritmo SCE-UA. E os parâmetros restantes específicos do algoritmo são descritos a seguir, conforme Duan (2004).

- `nsg`: número de complexos (sub-população);
- `maxn`: número máximo de avaliações de funções permitidas durante a calibração;
- `kstop`: número máximo de loops de evolução antes da convergência. O valor recomendado é de 5;
- `pcento`: variação percentual permitida nos loops de parada antes da convergência. O valor recomendado é de 0,01%;
- `peps`: nível de convergência para o conjunto de parâmetros (número menor significa menor diferença entre os parâmetros da população necessária para a parada);
- `iseed`: número aleatório de sementes (para fins de teste repetitivo). O valor recomendado é de qualquer número inteiro grande;
- `iniflg`: sinalizador para a matriz de parâmetros inicial (= 1 incluído na população inicial; caso contrário, não incluído).

```

245 ##### RUN AMAGALM #####
246 ##### Lavras Simulation of Hydrology (LASH) #####
247 #####
248
249 - AMALGAMPar.N = 50;
250 - AMALGAMPar.T = 100;
251 - AMALGAMPar.d = 8;
252 - AMALGAMPar.m = 3;
253 - Par_info.initial = 'latin';
254 - Par_info.boundhandling = 'reflect';
255 - Par_info.min = [0.01 0.1 0.1 0.1 1 50 1 0.025];
256 - Par_info.max = [0.2 180 6 5 50 50000 100 0.160];
257
258 - Func_name = 'LASH_func';
259
260 - options.parallel = 'no';
261 - options.IO = 'no';
262 - options.modout = 'no';
263 - options.save = 'yes';
264 - options.ranking = 'MATLAB';
265 - options.restar = 'no';
266 - options.density = 'crowding';
267 - options.print = 'yes';
268
269 - [X,F,output,Z,sim] = AMALGAM(AMALGAMPar,Func_name,Par_info,options);

```

Figura 19 – Configuração de entrada dos parâmetros do algoritmo AMALGAM e o acomplamento com o LASH, em MATLAB®.

De forma análoga ao SCE-UA, o AMALGAM também trabalha com a cópia da *handle function* LASH_func.m para a Func_name. De modo que, os parâmetros do algoritmo, segundo Vrugt (2016), podem ser descritos como:

- AMALGAMPar.N: tamanho da população;
- AMALGAMPar.T: número de gerações;
- AMALGAMPar.d: número de parâmetros do modelo;
- AMALGAMPar.m: número de funções objetivo;
- Par_info.initial: tipo de inicialização da população;
- Par_info.Boundhandling: método utilizado para quando os parâmetros estão fora de seus respectivos intervalos;
- Par_info.min: limites inferiores dos parâmetros de calibração do LASH;
- Par_info.max: limites superiores dos parâmetros de calibração do LASH;
- options[]: variáveis utilizadas para computar o algoritmo.

A opção `options.parallel` quando configuras em `'yes'`, permite que o MATLAB® compute o algoritmo de forma paralela, utilizando *workers*. O número de *workers* disponíveis varia de acordo com o processador da máquina.

A facilidade de utilizar o MATLAB® como ambiente de implementação do LASH possibilitou utilizar funções prontas dos algoritmos SCE-UA e AMALGAM. No caso das versões em Delphi, por exemplo, o SCE-UA precisou ser integralmente escrito na linguagem, algo que teria de ser realizado caso o AMALGAM também fosse implementado em Delphi. Essas premissas são importantes para elucidar a facilidade de utilização de uma linguagem como o MATLAB® em virtude de um maior aproveitamento de códigos bastante aplicados à hidrologia.

Em suma, o LASH foi incorporado ao ambiente de programação MATLAB® sob três implementações inéditas: i) o módulo de propagação da Onda Cinemática; ii) o acoplamento a um algoritmo multiobjetivo, o AMALGAM; e iii) a utilização de artifícios computacionais com vistas à diminuição significativa do tempo de processamento do modelo mediante a implementação de variáveis globais. Com vistas a explorar essas implementações, os resultados acerca da utilização desses módulos serão apresentados no capítulo 2 sob forma de estudo de caso na bacia hidrográfica do rio Camaquã.

4 Conclusões

A concepção do modelo hidrológico LASH em MATLAB® permitiu: i) a implementação do módulo de propagação de vazões em rios com maior representação hidráulica; ii) incorporar o n de Manning como calibrável ao modelo para evitar a subjetividade de escolha desse parâmetro; iii) facilidade do acoplamento do algoritmo de calibração multiobjetivo AMALGAM; e iv) incorporar artifícios computacionais para otimizar o tempo de processamento do modelo.

Nesse sentido, pode-se concluir que os resultados supracitados da implementação do modelo em MATLAB® facilitam a alteração, atualização e ampliação do *script*, sendo o grande gargalo da implementação do LASH em uma linguagem interpretada.

Capítulo 2 – Avaliação da calibração e validação do modelo LASH em MATLAB®: estudo de caso na bacia hidrográfica do rio Camaquã (RS)

1 Introdução

Como foi apresentado e discutido no capítulo 1, o LASH é um modelo hidrológico que tem se destacado por suas aplicações em bacias hidrográficas brasileiras com diferentes características edafoclimáticas e padrões hidrológicos (CALDEIRA *et al.*, 2019; VIOLA *et al.*, 2014). O algoritmo mono-objetivo SCE-UA tem sido utilizado para calibração dos parâmetros do LASH. Todavia, o modelo nunca foi avaliado utilizando um algoritmo multiobjetivo, como o AMALGAM.

A utilização de algoritmos multiobjetivos visa reduzir a equifinalidade e incertezas associadas aos parâmetros, principalmente em áreas onde as informações disponíveis são limitadas, como países em desenvolvimento (HER; SEONG, 2018). Além das incertezas associadas à calibração, a equifinalidade pode ser computada para verificar os impactos da modelagem utilizando um algoritmo multiobjetivo. A equifinalidade é um conceito importante vinculado aos modelos chuva-vazão, e significa que podem haver vários conjuntos de parâmetros aceitáveis, capazes de representar de forma semelhante os processos hidrológicos (CALDEIRA *et al.*, 2019).

A calibração de um modelo hidrológico e os impactos nas incertezas e equifinalidade devem ser levados em consideração, principalmente, para entregar resultados assertivos e mais próximos possíveis da realidade de cada bacia hidrográfica. Nesse sentido, dado o nível de aplicabilidade do LASH, comprovado por inúmeros estudos em bacias hidrográficas brasileiras, é imprescindível que seja realizada uma análise acerca das incertezas e equifinalidade dos parâmetros do modelo ao utilizar um algoritmo multiobjetivo, como o AMALGAM.

A compreensão do atual cenário de conflitos envolvendo o uso e gestão dos recursos hídricos é indispensável para mitigar, ou mesmo, evitar essa problemática. Para tal, modelos hidrológicos podem ser utilizados com vistas ao conhecimento da disponibilidade hídrica, simulações de mudanças do uso e cobertura do solo e de mudanças climáticas. Neste capítulo 2, a bacia hidrográfica do rio Camaquã (BHRC), localizada na região central do estado do Rio Grande do Sul, foi utilizada para compor o cenário de aplicação do LASH frente às implementações apresentadas no capítulo 1. A BHRC foi escolhida por possuir um comitê de gerenciamento e um plano para gestão dos recursos hídricos, o qual foi realizado para o período de 2005-2035 (GAMA, 2016). No entanto, problemas recorrentes associados à demanda e

disponibilidade hídrica têm causado conflitos pelo uso da água. A BHRC é de grande interesse socioeconômico devido à produção de arroz irrigado. Além das medidas mitigatórias relacionadas à escassez de água, os gestores do Comitê de Gerenciamento da BHRC têm se preocupado também com a ocorrência de eventos extremos (RODRIGUES *et al.*, 2020). Logo, o cenário atual na BHRC sugere a realização de projetos e estudos que possam auxiliar na tomada de decisões, por meio do comitê.

Este capítulo concerne na aplicação do LASH, conforme foi desenvolvido em MATLAB®, à BHRC mediante a utilização de um algoritmo mono-objetivo (SCE-UA) e de um algoritmo multiobjetivo (AMALGAM) para verificar a adequabilidade do modelo, análise de incertezas e equifinalidade dos parâmetros calibráveis. Outrossim, foi realizada a calibração dos parâmetros concentrados por sub-bacia (cenário 1) e dos parâmetros λ e C_s distribuídos por sub-bacia (cenário 2), a fim de verificar se houve melhora na representação dos componentes do ciclo hidrológico da BHRC. Desta forma, somando à literatura um estudo refinado acerca da implementação do LASH em MATLAB® e todas as funcionalidades acrescidas ao modelo neste estudo, como a propagação de vazões em rios pelo método da Onda Cinemática, o algoritmo multiobjetivo AMALGAM e a redução no tempo de processamento.

2 Material e métodos

2.1 Área de estudo

A BHRC está localizada na região central do Rio Grande do Sul e é uma sub-bacia da bacia hidrográfica da Lagoa dos Patos. Em sua totalidade, até a sua foz na Lagoa dos Patos, a BHRC possui uma área de drenagem de 21.600 km². A bacia contempla 28 municípios no estado do Rio Grande do Sul, sendo que os municípios de Amaral Ferrador, Arambaré, Camaquã, Chuvisca, Cristal e São Lourenço do Sul possuem total área territorial inserida na bacia. Segundo CGBHRC (2019), até 2010, último senso demográfico, a população inserida nos limites da bacia era de 365.000 habitantes. A BHRC caracteriza-se pelo uso rural com ênfase no desenvolvimento econômico e social advindo da agricultura, principalmente pelo cultivo do arroz irrigado. Na Figura 20, é apresentada a localização da BHRC delimitada na seção de controle Passo do Mendonça (BHRC-PM) com área de 15.571 km², cujo monitoramento é de responsabilidade da Agência Nacional de Águas (ANA).




Figura 20 – Localização da BHRC-PM no contexto da bacia hidrográfica da Lagoa dos Patos, do estado do Rio Grande do Sul, do país e do continente sul-americano.

A BHRC destaca-se, no contexto do Rio Grande do Sul, por possuir um comitê de bacias hidrográficas e um plano associado, margeando uma maior integralização de estudos realizados na mesma. De acordo com o Plano da Bacia Hidrográfica do Camaquã 2015-2035 (GAMA, 2016), a BHRC é sub-dividida em 6 Unidades de Planejamento e Gestão dos Recursos Hídricos (UPGRH): Alto Camaquã, Médio Camaquã, arroio Turuçu, Baixo Camaquã-Duro, arroio Velhaco e arroio Turuçu. Ainda segundo o Plano de Bacias, a parte baixa da BHRC é caracterizada pela existência de várzeas que propiciam a irrigação por inundação, sendo a região onde as demandas hídricas são mais intensas, causando um balanço hídrico crítico, resultando em conflitos pelo uso da água, principalmente localizados na UPGRH do arroio Velhaco.

Na região da UPGRH do Baixo Camaquã, está localizado o perímetro de irrigação do arroio Duro (Figura 21). O perímetro conta com a barragem do arroio Duro, que visa à regularização da vazão e permite o abastecimento de açudes a jusante, armazenando 150 milhões de m³ de água para irrigação (PORCIÚNCULA,

2019). A gestão do perímetro de irrigação do arroio Duro é realizada pela Associação de Usuários do Perímetro de Irrigação do Arroio Duro (AUD).




Figura 21 – Localização da barragem do arroio Duro no contexto de proximidade com a BHRC-PM.

2.2 Parametrização do modelo hidrológico LASH

Para compilar a base de dados espacial necessária ao LASH, foi utilizado o módulo ArcLASH (SANTOS *et al.*, 2019), o qual foi idealizado no ambiente ArcGIS. As informações foram subdivididas em 59 sub-bacias hidrográficas (Figura 22), as quais foram computadas com base em um limiar de delineamento da rede de hidrografia. As áreas das sub-bacias variaram de 0,23 km² a 1.088 km². Não há um número ideal de sub-bacias para modelagem semi-distribuída, porém foi escolhido um número que representasse de forma mais adequada possível a hidrografia da BHRC-PM.




Figura 22 – Sub-bacias da bacia hidrográfica do rio Camaquã computadas no ArcLASH para modelagem semi-distribuída.

A base de dados de entrada para o LASH, provém do ArcLASH e este por sua vez, requer informações acerca de:

- Modelo digital de elevação (MDE);
- Mapa de classe de solo e os parâmetros referentes a cada classe: umidade no ponto de saturação (θ_s), umidade no ponto de murcha permanente (θ_{PMP}) e profundidade do solo;
- Mapa de uso do solo e os parâmetros referentes a cada uso: resistência estomática, altura da vegetação, profundidade do sistema radicular, albedo e Índice de Área Foliar (IAF);
- Localização das estações pluviométricas;
- Localização das estações meteorológicas;
- Localização da seção de controle da BHRC-PM.

2.2.1 Base de dados espaciais

• Relevo

Para a caracterização do relevo da BHRC-PM, foram utilizados os dados da Missão Topográfica *Radar Shuttle* (*Shuttle Radar Topography Mission* - SRTM) com grade matricial de 30m obtidos junto ao *United States Geological Survey*

(USGS). O modelo digital de elevação hidrologicamente consistente (MDEHC), obtido junto ao ArcLASH, está representado na Figura 23.




Figura 23 – Modelo digital de elevação hidrologicamente consistente da BHRC-PM.

A partir do MDEHC foi possível obter o mapa de declividades (Figura 24), no ArcGIS® (ESRI, 2014), por meio da ferramenta *slope - Toolbox Hydrology*. A classificação da declividade foi dada de acordo com EMBRAPA (1979).




Figura 24 – Mapa de declividades da BHRC-PM.

- **Classe de solos**

As classes de solos da BHRC-PM foram obtidas junto ao Projeto RadamBrasil (BRASIL, 1981), atualizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE) de acordo com o Manual Técnico de Pedologia e disponibilizado pelo Catálogo de Metadados Geográficos (INDE). Foram utilizadas as folhas SH-21 e SH-22 com escala de 1:250.000, as quais contemplam o estado do Rio Grande do Sul.

Na Figura 25 estão expostas as classes de solo predominantes na BHRC-PM, até o 2º nível categórico, segundo a taxonomia do Sistema Brasileiro de Classificação de Solos (EMBRAPA, 2014), sendo: Neossolo Litólico (52,50%), Argissolo Vermelho-Amarelo (36,11%), Luvisolo Crômico (3,72%), Argissolo Vermelho (2,16%), Planossolo Háptico (2,12%), Chernossolo Ebânico (1,47%), Luvisolo Háptico (0,93%), Gleissolo Háptico (0,46%), Neossolo Flúvico (0,27%) e Chernossolo Argilúvico (0,08%). As classificações de corpo hídrico e urbano contemplam 0,11% e 0,07% da BHRC-PM, respectivamente. Todavia, dentro da disponibilidade de informações dos atributos do solo, estes foram obtidos considerando até o 3º nível categórico segundo a taxonomia do Sistema Brasileiro de Classificação de Solos (Tabela 1).




Figura 25 – Classe de solos na BHRC.

Fonte: Projeto RadamBrasil (BRASIL, 1981).

Para cada classe de solo, foram obtidas as informações de umidade no ponto de saturação (θ_s), umidade no ponto de murcha permanente (θ_{PMP}) e profundidade (Z_{SOLO}) (Tabela 1). Os atributos θ_s , θ_{PMP} e Z_{SOLO} são utilizados para o cálculo dos armazenamentos de água no solo, e que posteriormente são utilizados nos módulos dos escoamentos.

Tabela 1 – Atributos referentes a cada classe de solo presente na BHRC-PM.

Classe de solo	θ_s (m ³ ·m ⁻³)	θ_{PMP} (m ³ ·m ⁻³)	Z _{SOLO} (mm)
Argissolo Vermelho-Amarelo Distrófico	0,404 ^a	0,190 ^a	1000 ^b
Argissolo Vermelho-Amarelo Eutrófico	0,404 ^a	0,190 ^a	1500 ^b
Argissolo Vermelho Alumínico	0,441 ^a	0,207 ^a	1200 ^c
Argissolo Vermelho Distrófico	0,441 ^a	0,207 ^a	2000 ^b
Chernosso Ebânico Órtico	0,408 ^a	0,304 ^a	1000 ^c
Chernossolo Argilúvico Órtico	0,408 ^a	0,304 ^a	650 ^c
Gleissolo Háplico Ta Eutrófico	0,418 ^a	0,205 ^a	1000 ^b
Luvissolo Crômico Pálico	0,353 ^d	0,235 ^d	1580 ^e
Luvissolo Háplico Órtico	0,353 ^d	0,235 ^d	800 ^e
Neossolo Flúvico Ta Eutrófico	0,200 ^f	0,100 ^f	1800 ^g
Neossolo Litólico Eutrófico	0,200 ^f	0,100 ^f	200 ^c
Neossolo Litólico Chernossólico	0,200 ^f	0,100 ^f	200 ^c
Neossolo Litólico Distrófico	0,200 ^f	0,100 ^f	200 ^c
Planossolo Háplico Eutrófico	0,395 ^a	0,189 ^a	1050 ^g

^aOttoni *et al.* (2018); ^bCunha *et al.* (2000); ^cCunha, Silveira e Severo (2005); ^dGiarola, Silva e IMHOFF (2002); ^eCunha, Silveira e Severo (2006a); ^fSoares (2018); ^gCunha, Silveira e Severo (2006b).

• Uso e cobertura do solo

As informações de uso e cobertura do solo da BHRC-PM foram obtidas junto ao Laboratório de Geoprocessamento (LabGEO) da Universidade Federal do Rio Grande do Sul (UFRGS). Foi utilizado o mapeamento do uso e cobertura vegetal realizado em 2002 em escala de 1:250.000 (CORDEIRO, HASENACK; WEBER, 2002; HASENACK; CORDEIRO; WEBER, 2002), cuja iniciativa foi expandir o mapeamento desenvolvido no Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira para o Bioma Pampa (PROBIO).

O mapeamento do uso e cobertura vegetal, realizado no ano de 2002, foi escolhido por representar o período de aquecimento, calibração e validação do modelo, porém ainda há opções dos mapeamentos realizados nos anos de 2009 e 2015. Na Figura 26 estão expostos os usos presentes na BHRC-PM, sendo: campo nativo (52,76%), agricultura (20,15%), mata nativa (16,03%), pastagem (6,33%), silvicultura (2,96%) e solo exposto (1,44%), corpo hídrico (0,33%).




Figura 26 – Uso do solo na BHRC-PM.

Fonte: Laboratório de Geoprocessamento da Universidade Federal do Rio Grande do Sul.

Quanto aos atributos do uso do solo, a entrada no LASH requer a resistência estomatal (r_s), o albedo, a altura de vegetação (h_{VEG}), o índice de área foliar (IAF) e a profundidade do sistema radicular (Z_{RAD}). Esses atributos foram obtidos na literatura e estão apresentados na Tabela 2, considerando sua variabilidade sazonal. Os atributos r_s , albedo e h_{VEG} são utilizados no módulo de evapotranspiração do modelo, ao passo que o IAF é utilizado no módulo de interceptação e o Z_{RAD} , no cálculo da profundidade de controle para a obtenção dos armazenamentos de água no solo, e que posteriormente são utilizados nos outros módulos dos componentes do ciclo, i.e. D_{CR} , E_{TR} e escoamentos.

Tabela 2 – Atributos referentes ao uso do solo presente na BHRC-PM.

Uso do solo	Período sazonal	r_s (m·s ⁻¹)	Albedo	h_{VEG} (m)	IAF (m ² ·m ⁻²)	Z_{RAD} (mm)
Mata Nativa	Verão	140,00 ^a	0,13 ^f	10,00 ^e	5,67 ^c	2000,00 ^m
	Outono		0,15 ^f		4,00 ^c	
	Inverno		0,18 ^f		3,00 ^c	
	Primavera		0,16 ^f		3,67 ^c	
Sivicultura	Verão	112,00 ^a	0,13 ^f	5,00 ^e	4,01 ⁱ	1500,00 ^m
	Outono		0,15 ^f			
	Inverno		0,18 ^f			
	Primavera		0,16 ^f			
Campo nativo	Verão	65,00 ^b	0,14 ^g	0,50 ^h	0,60 ^j	500,00 ⁿ
	Outono		0,13 ^g			
	Inverno		0,13 ^g			
	Primavera		0,14 ^g			
Pastagem	Verão	60,00 ^c	0,16 ^g	0,50 ^h	3,99 ^l	500,00 ⁿ
	Outono	70,00 ^c	0,15 ^g		3,21 ^l	
	Inverno	80,00 ^c	0,17 ^g		1,86 ^l	
	Primavera	80,00 ^c	0,17 ^g		2,67 ^l	
Agricultura	Verão	60,00 ^c	0,16 ^g	1,33 ^h	5,33 ^c	500,00 ⁿ
	Outono	70,00 ^c	0,15 ^g	0,37 ^h	3,00 ^c	
	Inverno	80,00 ^c	0,17 ^g	0,37 ^h	1,00 ^c	
	Primavera	80,00 ^c	0,17 ^g	0,21 ^h	2,00 ^c	
Solo Exposto	Verão	545,30 ^d	0,15 ^c	0,05	0,00	300,00 ^o
	Outono		0,15 ^c			
	Inverno		0,17 ^c			
	Primavera		0,16 ^c			
Água	-	0,00 ^e	0,10 ^c	0,05 ^e	0,00	0,00

^aAndrew e Dymond (2007); ^bBathurst *et al.* (2011); ^cRuhoff *et al.* (2013); ^dCorreia, Alvalá e Manzi (2004); ^eCollischonn (2001); ^fMiranda *et al.* (1996); ^gGiongo, Padovani e Vettorazzi (2009); ^hBarros (2016); ⁱBerger *et al.* (2019); ^jHessel *et al.* (2003); ^kFagundes *et al.* (2006); ^mViola (2008); ⁿAllen *et al.* (1998); ^oMello *et al.* (2008).

2.2.2 Base de dados temporais

Os dados referentes às séries históricas de chuva foram obtidos junto ao portal Hidroweb da ANA, assim como os dados de vazão da seção de controle da BHRC-PM. Os dados meteorológicos foram obtidos junto ao Centro de Pesquisa Agropecuária Clima Temperado (CPACT) da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), ao Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) do Instituto Nacional de Meteorologia (INMet) e à Universidade

Federal do Rio Grande do Sul (UFRGS), a Estação Experimental Agronômica da Faculdade de Agronomia. A Figura 27 ilustra a distribuição espacial das estações meteorológicas, pluviométricas e fluviométricas que foram utilizadas para modelagem hidrológica na BHRC-PM.




Figura 27 – Localização das estações de monitoramento pluviométrico, fluviométrico e meteorológico utilizadas para modelagem na BHRC.

As estações pluviométricas foram escolhidas por proximidade à BHRC-PM, com boa incidência temporal, ao passo que as meteorológicas foram escolhidas mediante proximidade e disponibilidade de dados. Em relação às estações fluviométricas, foram utilizadas a seção de controle da BHRC-PM, Passo do Medonça, e duas estações fluviométricas à montante, Passo das Carretas e Passo do Cação, com vistas à validação. Na Tabela 3 estão dispostas as características das estações fluviométricas utilizadas neste estudo.

Tabela 3 - Estações de monitoramento fluviométrico empregadas para calibração e validação à montante da seção de controle da BHRC

Estação	Código	Latitude	Longitude	Altitude (m)	Monitoramento
Passo do Mendonça	87905000	-31.01	-52.05	14.88	1965 - 2019
Passo do Cação	87590000	-30.96	-53.49	120	1974 - 2005
Passo das Carretas	87670000	-30.97	-53.05	78.24	2001 - 2019

Na Figura 28 pode ser observado o conjunto de réguas linimétricas que estão localizadas na margem direita da seção de controle Passo do Mendonça, no rio Camaquã. As áreas de drenagem das bacias hidrográficas delimitadas pelas estações fluviométricas da Tabela 3 são: Passo do Mendonça – 15.571 km²; Passo do Cação (sub1) – 4.079 km² e Passo das Carretas (sub2) – 7.510 km².



Figura 28 – a) Réguas linimétricas de monitoramento fluviométrico do rio Camaquã, da seção de controle Passo do Mendonça; b) seção de controle com vistas da largura do rio Camaquã, município de Cristal (RS).

Fonte: Autora.

Por fim, cabe ressaltar que o teste de tendência de Mann-Kendall (KENDALL, 1975; MANN, 1945) foi aplicado para verificar a estacionariedade da série históricas de chuva e vazão. As séries históricas foram manuseadas no SYHDA (VARGAS *et*

al., 2019b), considerando as vazões médias anuais para as séries de vazão, e considerando a chuva total anual para as séries de chuva, ambas com limiar de falhas de 31 dias. O teste foi aplicado no MATLAB®, utilizando a função *MKMiss* (LEE, 2019), ao nível de 5% de significância com possibilidade de utilizar a série com presença de falhas (NA).

2.2.3 Base de dados para o módulo de propagação de vazões em rios

A base de dados para o módulo de propagação de vazões nos cursos d'água foi computada separadamente. Para tal, foi utilizado no ArcGIS (ESRI, 2014), o componente ArchIDRO e o pacote hidrológico *The Geospatial Hydrologic Modeling Extension* (HEC-GeoHMS) (USACE, 2013). Por meio da integração desses componentes no ArcGIS, foram calculados os parâmetros dos trechos de propagação dos cursos d'água da BHRC-PM.

Na Figura 29, pode-se observar a divisão da BHRC-PM em 59 sub-bacias e da condição de confluência das mesmas e dos trechos dos cursos d'água.




Figura 29 – Representação das sub-bacias e trechos dos cursos d'água na bacia hidrográfica do rio Camaquã no pacote hidrológico HEC-GeoHMS.

Foram computados, por meio da extensão do HEC-GeoHMS, os parâmetros de comprimento (X_L) e declividade do curso d'água (S_0). Mediante ao *layout* de integração entre as sub-bacias e os trechos, pode-se verificar quais sub-bacias

desaguam para um determinado trecho e quais trechos recebem outros trechos de curso d'água. Quanto ao parâmetro de largura do curso d'água (B), este foi obtido no *Google Earth Pro* (Figura 30), considerando um valor médio por trecho. Foi utilizada uma imagem de satélite datada mais próxima do período de calibração e validação, visando diminuir a subjetividade desse parâmetro. O coeficiente de rugosidade de Manning foi incorporado ao conjunto de parâmetros calibrados do modelo LASH, conforme apresentado no capítulo 1.




Figura 30 – Obtenção da largura dos trechos de forma visual no *Google Earth Pro*.

Na Tabela 4, está representada a análise supracitada, sendo uma tabela de entrada para o modelo LASH. A título de exemplo, no ID 18, o trecho de nº 13 recebe as sub-bacias 45 e 49 e os trechos 11 e 12. Nesse sentido, em termos hidrológicos, um determinado trecho pode receber, no máximo, duas sub-bacias e dois trechos. Além dos parâmetros e considerações expostos na Tabela 4, também foram computadas as sub-bacias que recebem cada trecho.

Tabela 4 – Parâmetros de entrada e considerações no modelo LASH referente à propagação de vazões em rios

ID ¹	TRECHO	X _L (m)	B (m)	S ₀ ² (m·m ⁻¹)	SB ₁	SB ₂	T ₁	T ₂
1	1	3459,8	30	0,0014	4	5	0	0
9	2	15372,9	40	0,0011	7	9	1	0
10	3	551,5	15	0,0000 ²	10	13	2	0
11	4	9747,2	25	0,0008	14	16	3	0
2	5	11980,0	20	0,0010	55	57	0	0
12	6	47171,6	40	0,0016	52	53	5	0
13	7	15642,0	30	0,0015	32	40	6	0
14	8	52713,4	35	0,0004	15	18	4	7
15	9	11729,7	45	0,0003	58	0	8	0
16	10	4879,6	55	0,0008	20	43	9	0
17	11	34733,1	70	0,0005	23	41	10	0
3	12	1060,7	80	0,0000 ²	50	51	0	0
18	13	11119,4	100	0,0000 ²	45	49	11	12
19	14	10973,8	80	0,0000 ²	59	0	13	0
4	15	2462,5	80	0,0000 ²	8	30	0	0
20	16	18183,4	75	0,0016	36	37	15	14
5	17	31145,1	30	0,0014	54	56	0	0
21	18	4772,9	90	0,0000 ²	33	39	16	17
22	19	7292,0	85	0,0007	11	31	18	0
23	20	17335,3	90	0,0007	19	26	19	0
24	21	16749,5	120	0,0004	24	42	20	0
25	22	5387,4	130	0,0002	34	38	21	0
6	23	1264,3	100	0,0016	3	28	0	0
26	24	6745,6	110	0,0001	27	29	23	22
27	25	24833,7	140	0,0005	17	22	24	0
7	26	10910,3	50	0,0009	2	6	0	0
28	27	17911,7	30	0,0008	12	21	26	25
29	28	9767,8	220	0,0004	1	25	27	0
8	29	21315,0	30	0,0011	44	48	0	0
30	30	1902,2	225	0,0000 ²	35	46	28	29

¹ Ordem de ocorrência dos trechos, considerada para processamento correto no modelo LASH.

² Quando $S_0 = 0 \text{ m} \cdot \text{m}^{-1}$, um valor ínfimo ($0,0000001 \text{ m} \cdot \text{m}^{-1}$) foi considerado para não prejudicar a abordagem de resolução numérica da Onda Cinemática.

2.3 Calibração e validação do modelo hidrológico LASH

A modelagem hidrológica na BHRC-PM foi conduzida empregando os dados observados entre 1995 e 2005, período este definido em função da disponibilidade de séries históricas de vazão, chuva e dados meteorológicos contínuos. O ano de 1995 foi utilizado para aquecimento do modelo LASH, haja vista que no passo de tempo inicial da simulação há incertezas relacionadas às condições iniciais dos

processos hidrológicos, e.g. umidade do solo (BESKOW *et al.*, 2016; CALDEIRA *et al.*, 2019).

Os algoritmos mono-objetivo SCE-UA e multiobjetivo AMALGAM, detalhados no capítulo 1, foram empregados na calibração do LASH para fins de comparação. Para o SCE-UA foi utilizada a FO C_{NS} (Equação 50). Ao passo que para o AMALGAM, a mesma FO acrescida do C_{NS-LOG} (Equação 51) e P_{BIAS} (Equação 52) foram testadas em conjunto.

$$C_{NS} = 1 - \frac{\sum_{i=1}^N (Q_{obs_t} - Q_{est_t})^2}{\sum_{i=1}^N (Q_{obs_t} - \overline{Q_{obs}})^2} \quad (50)$$

$$C_{NS-LOG} = 1 - \frac{\sum_{i=1}^N (\log(Q_{obs_t}) - \log(Q_{est_t}))^2}{\sum_{i=1}^N (\log(Q_{obs_t}) - (\log \overline{Q_{obs}}))^2} \quad (51)$$

$$P_{BIAS} = \frac{\sum_{i=1}^N (Q_{obs_t} - Q_{est_t})}{\sum_{i=1}^N (Q_{obs_t})} \cdot 100 \quad (52)$$

em que Q_{obs_t} é a vazão observada no tempo $t=i$, Q_{est_t} é a vazão estimada no tempo $t=i$, $\overline{Q_{obs}}$ é a vazão média observada, $\overline{Q_{est}}$ é a vazão média estimada e N é o número de ordenadas do hidrograma.

O SCE-UA e o AMALGAM foram utilizados mediante dois cenários: i) cenário 1: considerando os parâmetros calibráveis do LASH de forma concentrada por sub-bacia; e ii) cenário 2: considerando a espacialização de dois parâmetros do LASH por sub-bacia, o λ e o C_s , por serem, de acordo com avaliações prévias nsta bacia, os parâmetros com maior variabilidade e sensibilidade. De acordo com Mishra *et al.* (2003), os valores de λ são variáveis principalmente devido às diferenças de clima, chuva e condições de umidade do solo. O que pode ser justificado pela área de abrangência da BHRC-PM junto ao Rio Grande do Sul. A variabilidade do C_s está condicionada à magnitude das áreas de drenagem (CALDEIRA *et al.*, 2019), justificando a sua distribuição. Para cada cenário, as principais especificidades de cada algoritmo, previamente discutidas, foram definidas como:

i) SCE-UA

- número de complexos: 5;
- número máximo de avaliações: 5.000 (cenário 1) e 50.000 (cenário 2);
- variação percentual permitida nos *loops* de parada: 0,01%;

ii) AMALGAM

- tamanho da população: 50;
- número de gerações: 100 (cenário 1) e 1000 (cenário 2). Logo, o número de avaliações computadas pelo algoritmo foram 5.000 (cenário 1) e 50.000 (cenário 2), para igualar às avaliações do SCE-UA.

Os intervalos dos parâmetros calibráveis do LASH foram: λ de 0,01 a 0,2 (adimensional) ; K_{SS} de 0 a 180 mm·dia⁻¹, K_B de 0 a 6 mm·dia⁻¹; K_{CAP} de 0 a 5 mm·dia⁻¹; C_S de 0 a 50 (adimensional); C_{SS} de 50 a 50.000 (adimensional); C_B de 1 a 100 dias; e n de 0,025 a 0,160 (s·m^{-1/3}). Os intervalos de dos parâmetros λ , K_{SS} , K_B e K_{CAP} foram derivados do estudo de Beskow, Mello e Norton, (2011), e o n , de Baptista e Lara (2014).

Ademais, no tocante à validação do modelo, foi utilizado o *Split Sample Test* (KLEMEŠ, 1986) empregando o período de 2001 a 2005 para a BHRC-PM. Para as sub-bacias à montante da seção de controle Passo do Mendonça, localizadas na região da UPGRH Alto Camaquã, Passo das Carretas, com área de drenagem de 4.079 km² e Passo do Cação, com área de drenagem de 7.510 km² (Figura 31), foi utilizado o método de validação *Proxy-basin* (KLEMEŠ, 1986) para o período de 2001 a 2005.




Figura 31 – Sub-bacias de validação no LASH à montante da seção de controle Passo do Mendonça da bacia hidrográfica do rio Camaquã.

2.4 Análise de desempenho

Quanto à análise de desempenho, a função C_{NS} (Equação 50), o coeficiente de Nash-Sutcliffe na sua versão para valores logaritmizados (C_{NS-LOG}) (Equação 51), o percentual de viés (P_{BIAS}) (Equação 52) e a raiz quadrada do erro médio (RMSE) (Equação 53) foram utilizados.

$$RMSE = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (Q_{obs_t} - Q_{est_t})^2} \quad (53)$$

em que Q_{obs_t} é a vazão observada no tempo $t=i$, Q_{est_t} é a vazão estimada no tempo $t=i$, $\overline{Q_{obs}}$ é a vazão média observada, $\overline{Q_{est}}$ é a vazão média estimada e N é o número de ordenadas do hidrograma.

Cabe destacar que os limites das estatísticas supracitadas são: C_{NS} $(-\infty - 1]$; C_{NS-LOG} $(-\infty - 1]$, P_{BIAS} $(-\infty - +\infty)$ e $RMSE$ $[0 - +\infty)$.

Em relação ao C_{NS} , o coeficiente permite analisar o comportamento do hidrograma ao longo do tempo e ainda, segundo Guilhon e Rocha (2007), o C_{NS} verifica quantitativamente a eficiência do modelo para estimativas nos períodos de

cheia, ou seja, quando se observam vazões elevadas. Nash e Sutcliffe (1970) explicam que o C_{NS} é uma estatística normalizada que determina a magnitude relativa da variação residual – ruído – em comparação com a variação dos dados medidos. Quanto ao C_{NS-LOG} , Beskow (2009) afirma que o coeficiente possibilita verificar a capacidade do modelo em estimar vazões de estiagem. Deste modo, é inerente a utilização do C_{NS} em conjunto com o C_{NS-LOG} .

Uma das desvantagens do C_{NS} é a impossibilidade de identificar o viés do modelo (MORIASI *et al.*, 2015), para tal o P_{BIAS} pode ser empregado de forma complementar. De acordo com Gupta *et al.* (1999), o valor ideal do P_{BIAS} é 0, indicando a simulação precisa do modelo. Além disso, valores positivos indicam superestimativa e valores negativos, subestimativa e, de acordo com Moriasi *et al.* (2015), pode ser usado para determinar quão bem o modelo simula as magnitudes médias das vazões. Em suma, o P_{BIAS} avalia erros no balanço hídrico com capacidade para identificar, caso haja, baixo desempenho do modelo (MORIASI *et al.*, 2007). Em relação ao RMSE, esse foi escolhido seguindo recomendações de Legates e McCabe Jr. (1999), que indicam adicionar às métricas de desempenho uma estatística de índice de erro absoluto com informações adicionais. O RMSE estima a variância residual, que é a diferença entre os valores medidos e os estimados (MORIASI *et al.*, 2007).

Quanto às classificações das estatísticas:

- i) O C_{NS} pode ser avaliado considerando a classificação de Moriasi *et al.* (2007): $C_{NS} > 0,65$, muito bom; $0,54 < C_{NS} < 0,65$, bom; e $0,50 < C_{NS} < 0,54$, satisfatório;
- ii) O P_{BIAS} pode ser avaliado, segundo Kouchi *et al.* (2017), considerando: $|P_{BIAS}| < 10\%$, muito bom; $10\% \leq |P_{BIAS}| < 15\%$, bom; $15\% \leq |P_{BIAS}| < 25\%$, satisfatório; e $|P_{BIAS}| \geq 25\%$, insatisfatório; e
- iii) O RMSE pode ser avaliado, segundo Singh *et al.* (2005), em comparação com o desvio padrão (DP) dos dados observados. De modo que podem ser considerados baixos valores de RMSE aqueles menores que a metade do DP dos dados observados.

Para a calibração dos parâmetros utilizando o AMALGAM, foram escolhidas as FOS C_{NS} , C_{NS-LOG} e P_{BIAS} , por permitirem avaliar diferentes características do

hidrograma de resposta, como explicado anteriormente. Segundo Wöhling, Samaniego e Kumar (2013), a calibração dos modelos de forma multiobjetiva deve ser conduzida utilizando FOs que caracterizem o hidrograma ou outras observações reproduzidas pelo modelo. E ainda, enfatizam que o uso de FOs correlacionadas entre si, ou seja, que indicam a mesma resposta de avaliação, deve ser evitado. Por fim, cabe destacar que o P_{BIAS} foi utilizado no AMALGAM em sua forma absoluta ($|P_{BIAS}|$), porque o algoritmo tende a minimizar a FO e pelo fato do P_{BIAS} variar de $-\infty$ a $+\infty$, a calibração poderia ser comprometida e tendenciosa.

2.5 Análise de incertezas e equifinalidade

Para comparar o desempenho dos algoritmos SCE-UA e AMALGAM, uma análise de incertezas com base na metodologia *Generalized Likelihood Uncertainty Estimation* (GLUE) (BEVEN; BINLEY, 1992) foi realizada. A técnica de GLUE (Equação 54) é baseada no reconhecimento da importância do conjunto de parâmetros para reproduzir o comportamento do sistema, e não dos parâmetros individuais em si (ARABI; GOVINDARAJU; HANTUSH, 2007)

$$L(\rho|Y) = 1 - \frac{\sigma_s^2}{\sigma_o^2} \quad (54)$$

em que $L(\rho|Y)$ corresponde à medida de verossimilhança do conjunto de parâmetros (ρ) para os dados observados (Y); os valores σ_s^2 e σ_o^2 representam a variância do erro entre a predição do modelo e os dados observados, e a variância dos dados observados, respectivamente.

Para a aplicação da Equação 54, foi necessário estabelecer um critério de utilização das iterações com base no(s) melhor(es) valor(es) da(s) FO(s). Foram utilizadas as 500 melhores iterações para viabilizar a construção do gráfico de GLUE, conforme metodologia indicada por Beskow, Norton e Mello (2011). Esses melhores conjuntos foram então utilizados para calcular os pesos de verossimilhança, após isso, cada peso foi dividido pela soma dos pesos totais. Desta forma, seguindo as diretrizes de Beskow, Mello e Norton (2011), uma Distribuição

Cumulativa de Probabilidade (FDP) foi aplicada nos pesos de verossimilhança para estimar os limites de incerteza.

O método GLUE é subjetivo não apenas para a escolha da função de verossimilhança, mas também para o critério de corte usado para classificação das simulações (ARABI; GOVINDARAJU; HANTUSH, 2007). Todavia, é uma ferramenta útil para verificar as incertezas associadas aos parâmetros da modelagem e, no caso deste estudo, averiguar as diferenças nessas incertezas comparando o SCE-UA e o AMALGAM.

Em relação à análise de equifinalidade, foram computadas as análises recomendadas por Nemri e Kinnard (2020). Para tal, foi necessário extrair todas as iterações dos algoritmos, assim como para a análise de incertezas. Vale ressaltar que para extrair todas as iterações do SCE-UA, foi realizada uma modificação no código fonte do algoritmo implementado por Duan (2004). Os conjuntos de parâmetros que resultaram em C_{NS} dentro de 1% de seu valor ideal para o SCE-UA, e em C_{NS} , C_{NS-LOG} e P_{BIAS} dentro de 1% de seus valores ideais para o AMALGAM, foram utilizados. Essa escolha dos valores ideais se deu mediante a análise dos resultados da(s) FO(s) em cada iteração.

3 Resultados e discussão

Os resultados obtidos com o teste de Mann-Kendall indicaram que as séries de vazão média anual e de chuva total anual são estacionárias. Os resultados acerca da calibração e validação do modelo utilizando o SCE-UA e o AMALGAM, bem como a análise de incertezas, equifinalidade e diferenças computacionais entre os algoritmos e a otimização da implementação do LASH em MATLAB® estão dispostos nas seções a seguir.

3.1 Calibração e validação – cenário 1: parâmetros obtidos

Na Tabela 5 estão apresentados os valores dos parâmetros de calibração do LASH para o cenário 1 de modelagem, considerando os parâmetros concentrados para a BHRC-PM, utilizando os algoritmos SCE-UA e AMALGAM.

Tabela 5 – Parâmetros calibrados para a BHRC-PM, considerando os algoritmos SCE-UA e AMALGAM, para o cenário 1

Algoritmo	λ	K_{SS} (mm·dia ⁻¹)	K_B (mm·dia ⁻¹)	K_{CAP} (mm·dia ⁻¹)	C_s	C_{SS}	C_B (dia)	n (s·m ^{-1/3})
SCE-UA	0,20	0,11	2,27	0,87	11,41	10153,13	1,58	0,03
AMALGAM	0,19	0,19	1,76	2,99	11,97	47925,03	2,31	0,03

A calibração dos parâmetros de forma concentrada (Tabela 5) indica que esses valores foram os mesmos para cada uma das 57 sub-bacias da BHRC-PM, consideradas neste estudo. No caso do n , o parâmetro é mesmo para os diferentes trechos de rio considerados. Apesar do C_s e C_{SS} serem constantes, eles possuem impactos nas sub-bacias por dependerem do tempo de concentração de cada uma.

O λ está diretamente relacionado às perdas de água que ocorrem antes do início da geração de ESD (CALDEIRA *et al.*, 2019) e, de acordo com Caldeira (2019), é extremamente importante para um bom desempenho do modelo frente à estimativa das vazões associadas ao ESD. Além disso, o λ é um parâmetro que tende a variar por sub-bacia, devido aos condicionantes de atributos físicos das classes solo e da umidade antecedente, do uso do solo e do regime pluviométrico.

O K_{SS} impacta diretamente no cálculo do D_{SS} (lâmina de escoamento subsuperficial) e este, por sua vez, é diretamente proporcional ao cálculo do Q_{SS} que corresponde à vazão de saída do reservatório subsuperficial. O parâmetro K_B é

análogo ao K_{SS} nos cálculos de D_B e Q_B . O K_{SS} e o K_B são responsáveis pela condutividade hidráulica dos reservatórios subsuperficial e subterrâneo, respectivamente, e são fortemente dependentes do solo da bacia (CALDEIRA *et al.*, 2019). A região do Alto Camaquã apresenta solos rasos, pedregosos e valores muito baixos de condutividade hidráulica (CPRM, 2005), o que justifica os baixos valores de K_{SS} calibrados para a BHRC-PM.

A BHRC-PM possui predominância das classes de solo Neossolo Litólico (52,50%) e Argissolo Vermelho-Amarelo (36,11%). Cabe destacar que os solos predominantes na BHRC-PM compõem os grupos hidrológicos C e D, os quais são caracterizados, respectivamente, segundo Mello e Silva (2013) como: i) solos profundos a moderadamente profundos, que geram ESD acima normal, com infiltração estável entre 1 e 4 $\text{mm}\cdot\text{h}^{-1}$ e baixa permeabilidade superficial (e.g. solos com horizonte B textural); e ii) solos pouco profundos, com baixa capacidade de infiltração, maior capacidade na geração de ESD e infiltração estável $< 1 \text{ mm}\cdot\text{h}^{-1}$ (e.g. Neossolos Litólicos). Vargas (2019) calibrou valores de condutividade hidráulica do solo saturado (K_{SAT}) no LISEM, para uma sub-bacia da BHAP classificada nos mesmos grupos hidrológicos e mesmo bioma (Pampa) da BHRC-PM, na faixa de 0,50 $\text{mm}\cdot\text{h}^{-1}$ (12 $\text{mm}\cdot\text{dia}^{-1}$). Os valores de infiltração estável e K_{SAT} são próximos numericamente, de modo que Julià *et al.* (2004) afirmam que a taxa de infiltração diminui com o tempo até atingir um valor constante, sendo este valor equivalente à K_{SAT} . Enquanto o K_{SS} representa a facilidade com que a água escoar lateralmente no solo, a K_{SAT} é o valor máximo de K_{SS} quando o solo se encontra saturado (REICHARDT, 1990). Logo, os valores de K_{SS} , obtidos com o LASH, possuem sentido hidrológico em relação ao valor de K_{SAT} , obtido no estudo de Vargas (2019) para os grupos hidrológicos C e D, também presentes na BHRC-PM.

Para três bacias hidrográficas contíguas localizadas no Rio Grande do Sul (Bhaf, BHAP e BHRP), Caldeira (2019) encontrou, respectivamente, valores de K_{SS} de 4,39 $\text{mm}\cdot\text{dia}^{-1}$, 95,24 $\text{mm}\cdot\text{dia}^{-1}$ e 77,08 $\text{mm}\cdot\text{dia}^{-1}$ e valores de K_B de 0,79 $\text{mm}\cdot\text{dia}^{-1}$, 1,36 $\text{mm}\cdot\text{dia}^{-1}$ e 0,65 $\text{mm}\cdot\text{dia}^{-1}$. Vale destacar que a área de estudo das três bacias em conjunto equivale a aproximadamente 68% de predominância de Argissolo Amarelo, Argissolo Bruno-Acinzentado e Argissolo Vermelho-Amarelo. Collischonn *et al.* (2007), utilizando o MGB-IPH encontraram, para a bacia hidrográfica do Taquari- Antas, que possui solos rasos e argilosos, K_{SS} de 7,2 $\text{mm}\cdot\text{dia}^{-1}$ e K_B de 0,50 $\text{mm}\cdot\text{dia}^{-1}$.

Em relação ao K_{CAP} , segundo Caldeira (2019), os valores calibrados desse parâmetro indicam a máxima densidade de fluxo por ascensão capilar que a bacia apresentará em condições de umidade do solo propícias à sua ocorrência. Os valores de K_{CAP} variaram significativamente entre o SCE-UA e o AMALGAM, considerando a sua amplitude (0 a 5 $\text{mm}\cdot\text{dia}^{-1}$), sendo 0,87 $\text{mm}\cdot\text{dia}^{-1}$ e 2,99 $\text{mm}\cdot\text{dia}^{-1}$, respectivamente. Seguindo uma das premissas do conceito de capilaridade, quanto maior o número de microporos, maior será o valor de K_{CAP} , pois haverá maior condução de água em um meio saturado para um meio não-saturado. De acordo com Sartori, Neto e Genovez (2004), os solos enquadrados nos grupos C e D possuem predominância de textura argilosa, o que indica que há maior microporosidade em relação à macroporosidade. Todavia, dada a incerteza da calibração do K_{CAP} de forma concentrada por sub-bacia, não é possível afirmar qual algoritmo calibrou o valor com maior proximidade à realidade da bacia.

Os parâmetros C_S , C_{SS} e C_B tem uma relação com o esvaziamento dos reservatórios, ditando se as vazões vão crescer ou decrescer de forma mais suave ou mais rápida. O C_S e o C_{SS} indicam o tempo de resposta dos reservatórios superficial e subsuperficial e estão atrelados ao tempo de concentração de cada sub-bacia hidrográfica. A magnitude desses valores depende da área de drenagem da bacia hidrográfica, conforme discutido em Caldeira *et al.* (2019) e é imprescindível que $C_S < C_{SS}$ para que haja sentido hidrológico na calibração dos parâmetros. Os valores calibrados de C_S foram próximos considerando o SCE-UA e o AMALGAM, e o C_{SS} , embora tenham sido diferentes nos dois algoritmos, são aceitáveis dada a magnitude do intervalo escolhido para esse parâmetro (50 – 50.000).

O C_B está relacionado ao período de recessão do hidrograma, computado em dias. De acordo com Caldeira *et al.* (2019), o C_B pode ser calibrado ou derivado da análise do período de recessão do hidrograma observado, no entanto essa análise pode ser subjetiva, o que justifica a calibração desse parâmetro. Horn (2016) explica que o período de recessão tem seu desenho definido pelo escoamento de base, por consequência, o período de recessão contém as vazões com permanência acima de 50%. Nesse sentido, o C_B influencia no comportamento da curva de permanência, principalmente no trecho final, ou seja, nas permanências mais altas. Pode-se observar que o C_B calibrado pelo SCE-UA é cerca de duas vezes menor que o calibrado pelo AMALGAM, logo essa diferença na calibração pode ser verificada,

principalmente, na estatística que representa as vazões mínimas (C_{NS-LOG}) e nos quantis maiores da curva de permanência. Na análise de um período de recessão mais evidente no hidrograma observado da BHRC-PM, pode-se verificar um C_B de 17 dias. Todavia, vale mencionar que o C_B calibrado para a BHRC-PM é concentrado por sub-bacia, o que justifica a diferença em relação ao valor estimado. Tendo em vista que o valor estimado de C_B depende fortemente da experiência do hidrólogo, a calibração deste parâmetro pode reduzir as incertezas quanto ao mesmo, especialmente em bacias hidrográficas onde o escoamento de base é significativo (CALDEIRA, 2016). Além disso, a determinação do C_B requer um hidrograma e, no caso da análise de sub-bacias, isso se torna inviável pois não há monitoramento em todas as sub-bacias.

O coeficiente n de Manning convergiu para um mesmo valor ($0,03 \text{ s}\cdot\text{m}^{-1/3}$), utilizando o SCE-UA e o AMALGAM, indicando canais em boas condições e com presença de vegetação, conforme apresentado em Baptista e Lara (2014). Cabe lembrar que esse parâmetro foi adicionado como calibrável no LASH para diminuir a subjetividade de escolha no método da Onda Cinemática. Beskow, Norton e Mello (2011) analisaram e não verificaram sensibilidade do n de Manning no LASH para uma bacia pequena ($\sim 30 \text{ km}^2$), porém nessa versão o modelo utilizava o método de Muskingum-Cunge Linear para propagação da onda de cheia. Segundo Ajami *et al.* (2004), a não sensibilidade do coeficiente de rugosidade de Manning pode estar atrelada às características físicas homogêneas da bacia hidrográfica de estudo. Nesse sentido, estudos acerca da real sensibilidade do parâmetro na resposta hidrológica utilizando o método da Onda Cinemática podem ser realizados para verificar o impacto do n de Manning na modelagem.

3.2 Calibração e validação – cenário 1: estatísticas de desempenho

Para contrapor os parâmetros calibrados por meio dos algoritmos SCE-UA e AMALGAM, na Tabela 6 estão apresentadas as estatísticas de desempenho da calibração e validação (*Split Sample Test* e *Proxy-basin*), considerando os dois algoritmos supracitados nas escalas diária e mensal.

Tabela 6 – Estatísticas de desempenho do LASH para cada algoritmo de calibração, considerando a escala diária e mensal, para o cenário 1

	Algoritmo	Etapas	C _{NS}	C _{NS-LOG}	P _{BIAS} (%)	RMSE (m ³ ·s ⁻¹)
escala diária	SCE-UA	Calibração	0,75	0,70	1,31	230,97
		Validação	0,78	0,71	-2,51	228,30
		Validação - sub1	0,55	0,65	8,00	151,28
		Validação - sub2	0,68	0,51	-25,69	159,15
	AMALGAM	Calibração	0,75	0,73	5,17	232,77
		Validação	0,78	0,73	0,84	230,35
		Validação - sub1	0,54	0,67	10,85	153,45
		Validação - sub2	0,68	0,54	-21,95	160,13
escala mensal	SCE-UA	Calibração	0,84	0,75	0,91	120,68
		Validação	0,86	0,74	-2,70	124,03
		Validação - sub1	0,67	0,67	7,71	76,81
		Validação - sub2	0,73	0,55	-25,99	87,40
	AMALGAM	Calibração	0,84	0,78	5,22	119,03
		Validação	0,87	0,77	0,67	120,14
		Validação - sub1	0,67	0,69	10,58	77,08
		Validação - sub2	0,76	0,59	-22,23	81,96

De modo geral, visto que o C_{NS} indica a precisão do modelo em estimar vazões mais elevadas, o C_{NS-LOG}, a precisão do modelo em estimar vazões mais baixas e o P_{BIAS}, a capacidade do modelo em estimar corretamente o balanço hídrico, os resultados da Tabela 6 permitem afirmar que o LASH representou de forma adequada os processos hidrológicos na BHRC-PM. No tocante às estatísticas da validação nos exutórios das sub-bacias Passo do Cação (sub1) e Passo das Carretas (sub2), pode-se observar, no geral, um bom desempenho, levando em consideração que essas sub-bacias não foram calibradas, mas apenas validadas por meio dos parâmetros calibrados para estimativa do hidrograma na seção de controle da BHRC-PM. Os resultados obtidos neste tipo de validação (*Proxy basin*) são muito promissores, pois indicam a representatividade dos parâmetros calibrados e, conseqüentemente, os processos hidrológicos simulados pelo LASH para uma bacia (Alto Camaquã) cujos dados hidrológicos não foram aplicados à calibração.

Analisando as especificidades das estatísticas de desempenho supracitadas, pode-se observar que para as etapas de calibração e validação (na seção de controle), o C_{NS} foi enquadrado como “muito bom” (C_{NS} > 0,65), enquanto que nas validações nas sub1 e sub2, em escala mensal, foi classificado como “bom” e “muito bom”, respectivamente, e na escala diária, como “satisfatório” e “bom”,

respectivamente. Os valores de C_{NS-LOG} encontrados para a calibração e validação da BHRC-PM indicaram boa precisão do modelo em representar o comportamento de vazões mínimas da bacia. Os resultados dessa estatística nas sub1 e sub2, embora menores (0,51 a 0,69) também indicaram boa representatividade do LASH, principalmente devido ao fato do modelo não ter sido calibrado nessas sub-bacias. De forma análoga, os valores de P_{BIAS} também foram enquadrados como “bons” ($\leq \pm 10\%$) na maior parte das etapas. Os altos valores de RMSE são plausíveis quando comparados aos DPs das vazões observadas (Tabela 7), ao passo que Singh *et al.* (2005) indicam que são considerados baixos valores de $RMSE \leq 50\% \cdot DP$. Moriasi *et al.* (2015) explicam que o RMSE tende a dar mais peso aos valores altos do que aos valores baixos, o que justifica os valores de RMSE encontrados para a BHRC-PM, devido à magnitude de suas vazões.

Tabela 7 – Médias e desvios padrões das vazões observadas nos períodos considerados para simulações na BHRC-PM e nas sub-bacias 1 e 2

Etapa da modelagem	Vazões observadas em escala diária		Vazões observadas em escala mensal	
	Média ($m^3 \cdot s^{-1}$)	DP ($m^3 \cdot s^{-1}$)	Média ($m^3 \cdot s^{-1}$)	DP ($m^3 \cdot s^{-1}$)
Calibração na BHRC-PM	375,90	464,97	378,79	301,37
Validação na BHRC-PM	433,41	489,81	432,18	333,45
Validação na sub1	137,60	226,41	137,19	134,52
Validação na sub2	194,67	281,82	194,18	169,10

Caldeira (2019), para as bacias BHAF, BHAP e BHRP, localizadas no Rio Grande do Sul, encontrou valores de C_{NS} (0,52 a 0,73) e C_{NS-LOG} (0,58 a 0,82) satisfatórios para os períodos de calibração e validação. Porém, para o período de calibração nos exutórios das bacias, encontrou valores de ΔQ (erro relativo da estimativa de vazões ou de volumes – ΔV) $> -12\%$, o que indica que o modelo subestimou razoavelmente as vazões em relação aos valores estimados. Essa situação não ocorreu nesse estudo, como pode ser observado na Tabela 6, pois os valores de P_{BIAS} e ΔQ são similares, haja vista que o primeiro indica o desvio das vazões observadas em relação às estimadas e o segundo, o desvio das vazões estimadas em relação às observadas.

Outros estudos utilizando o LASH também apresentaram bom desempenho no que se refere às estatísticas C_{NS} e C_{NS-LOG} (MELLO *et al.*, 2008; VIOLA *et al.*, 2009; BESKOW *et al.*, 2011; VIOLA *et al.*, 2012; BESKOW *et al.*, 2016; CALDEIRA

et al., 2019). Desde sua idealização e propostas condicionadas à espacialização (distribuída ou semi-distribuída), o modelo sempre apresentou, no mínimo, $C_{NS} \geq 0,65$ e $C_{NS-LOG} \geq 0,58$ para calibração e $C_{NS} \geq 0,52$ e $C_{NS-LOG} \geq 0,70$ para validação em bacias hidrográficas dos estados do Rio Grande do Sul, Minas Gerais e Tocantins. O visualizador *web* desenvolvido na plataforma RPubS (<https://rpubs.com/gphidrologia/baciaslash>) apresenta as estatísticas em comum (C_{NS} e C_{NS-LOG}) dos trabalhos até então desenvolvidos utilizando o LASH.

Em relação à calibração e validação de outros modelos hidrológicos na BHRC-PM, foram encontrados os estudos de Lopes (2015) e Lopes *et al.* (2018). Lopes (2015) aplicou o MGB-IPH nas bacias hidrográficas constituintes da Laguna dos Patos com vistas a verificar a diferença das simulações utilizando os métodos de propagação de Muskingum-Cunge e inercial. A autora calibrou e validou o MGB-IPH na BHRC-PM e também na sub-bacia Passo do Cação (sub2). Para o período de calibração (01/01/1990 – 31/12/2010), foram encontrados valores de C_{NS} de 0,69, C_{NS-LOG} de 0,76 e ΔV de -1,47% na BHRC-PM e valores de C_{NS} de 0,40, C_{NS-LOG} de 0,65 e ΔV de -5,83% na sub2. Para o período de validação (01/01/1970 – 31/12/1989), valores de C_{NS} de 0,66, C_{NS-LOG} de 0,69 e ΔV de 6,37% foram obtidos na BHRC-PM e valores de C_{NS} de 0,49, C_{NS-LOG} de 0,65 e ΔV de -5,33% para a sub-bacia Passo do Cação. Os resultados supracitados foram computados considerando a propagação de vazões inercial do MGB – IPH. Lopes *et al.* (2018) conduziram outro estudo de modelagem hidrológica-hidráulica em grande escala rios-lagoa para previsão na bacia hidrográfica Laguna dos Patos, também utilizando o MGB-IPH. Dentre as sub-bacias da Laguna dos Patos utilizadas, a BHRC-PM foi calibrada e validada no modelo. Os autores encontraram valores de $C_{NS} > 0,76$, $C_{NS-LOG} > 0,61$ e erro de volume (ou P_{BIAS} absoluto) $< 10\%$ para o período de calibração (01/01/1990 – 31/12/2010). Quanto ao período de validação (01/01/1970 – 31/12/1989), os resultados das estatísticas de desempenho foram análogos ao período de calibração.

Comparando os resultados encontrados por Lopes (2015) aos deste estudo (Tabela 6), pode-se verificar uma superioridade do LASH na calibração e validação da BHRC-PM em relação ao C_{NS} , utilizando o SCE-UA e o AMALGAM. Em suma, o LASH ficou ligeiramente inferior apenas em termos de C_{NS-LOG} se comparado ao MGB – IPH, mas ainda sim, superior em termos de ΔV , indicando que o balanço hídrico da BHRC-PM foi melhor representado no LASH. Em relação à sub-bacia

Passo do Cação (sub2), Lopes (2015) calibrou o MGB – IPH na seção de controle dessa sub-bacia e, ainda sim, encontrou valores inferiores de C_{NS} quando comparados aos do LASH. Cabe ressaltar que o LASH não foi calibrado na sub2, apenas validado utilizando os parâmetros calibrados na seção de controle da BHRC-PM.

Em relação às validações nas sub1 e sub2, o LASH captou de forma mais satisfatória as vazões mínimas e médias da sub-bacia Passo do Cação (sub1) se comparado à sub-bacia Passo das Carretas (sub2), o que pode ser comprovado pelos valores de C_{NS-LOG} e P_{BIAS} e estar associado ao parâmetro C_B . Em outro sentido, o LASH captou melhor as vazões máximas na sub2 quando comparado à sub1, conforme indicam os valores de C_{NS} . Essa diferença pode estar associada: i) à magnitude da área da drenagem e ao tempo de concentração da sub2, indicando boa aderência aos parâmetros C_S e C_{SS} ; ii) ao fato da sub2 possuir a mesma predominância de solos que a BHRC-PM (Argissolo Vermelho-Amarelo e Neossolo Litólico), o que, conseqüentemente, indica que os parâmetros K_{SS} , K_B e K_{CAP} da sub2 são semelhantes aos calibrados para a BHRC-PM. Essa tipologia de validação *Proxy-basin* permite a transposição dos parâmetros calibrados em uma bacia hidrográfica A para outras bacias B e C, que possam não apresentar monitoramento fluviométrico, por exemplo. Nesse sentido, estudos que analisam a viabilidade da transposição dos parâmetros de modelos hidrológicos para outras bacias e ainda, bacias à montante ou jusante de onde foram calibrados, são imprescindíveis para entender a hidrologia dessas regiões (PEREIRA *et al.*, 2016; PONTES *et al.* 2016).

Pereira *et al.* (2016) utilizaram testes de validações na bacia hidrográfica do rio Pomba, no Sudeste do Brasil utilizando o modelo SWAT. Os autores utilizaram de duas metodologias por meio da validação *Proxy-basin*: i) *Proxy-basin* (bacias hidrográficas diferentes); e ii) *Proxy-basin* (à montante e jusante da seção de calibração). A segunda abordagem se assemelha ao realizado neste estudo, haja vista que as sub1 e sub2 estão localizadas à montante da seção de controle da BHRC-PM. Em relação às três bacias hidrográficas localizadas à montante da bacia de estudo, os autores encontraram valores, no geral, inferiores de C_{NS} (0,62, 0,27 e 0,47), C_{NS-LOG} (0,67, 0,16 e 0,59) e P_{BIAS} (10,5%, -27,8% e 15,3%) quando comparados aos valores encontrados para as sub-bacias da BHRC-PM (Tabela 7). Em relação às duas sub-bacias a jusante da seção de calibração, os autores encontraram resultados melhores de C_{NS} (0,81 e 0,76), C_{NS-LOG} (0,76 e 0,75) e P_{BIAS}

(11,7% e 8,3%). Pereira *et al.* (2016) ainda ressaltam que as bacias de validação a jusante possuem tempos de concentração superiores em relação àquelas a montante, justificando o melhor desempenho.

Pontes *et al.* (2016) também utilizaram o SWAT para calibração e validação da bacia hidrográfica do rio Camanducaia, na Serra da Mantiqueira, porém a validação *Proxy-basin* foi em uma bacia contígua, a bacia hidrográfica do rio Jaguarí. Foram encontrados valores de C_{NS} na ordem de 0,81 (1974 – 1983) e 0,69 (1984 – 1993) e P_{BIAS} de 7,90% (1974 – 1983) e 0,70% (1984 – 1993) para a validação *Proxy-basin*. Os autores enfatizam essa técnica de transposição de parâmetros como promissora e importante em bacias hidrográficas não calibradas com escassez de monitoramento. Os estudos supracitados são interessantes para discutir os resultados encontrados para a validação *Proxy-basin* utilizando o LASH, além de impulsionar o estudo de novas aplicabilidades, como em bacias a jusante da seção de calibração e aplicando a validação em diferentes períodos da série histórica.

A Figura 32 ilustra a calibração e validação do LASH utilizando os algoritmos SCE-UA e AMALGAM. Na Figura 33 estão representados os hidrogramas das validações do LASH para duas sub-bacias à montante da seção de controle da BHRC-PM, ou seja, utilizando os parâmetros calibrados no exutório da bacia (*Proxy-basin*).




Figura 32 – Calibração (a) e validação (b) do LASH para a seção de controle da BHRC-PM considerando os algoritmos SCE-UA e AMALGAM para o cenário 1.




Figura 33 – Validações do LASH nas sub-bacias Passo do Cação (a) e Passo das Carretas (b), considerando os parâmetros calibrados na seção de controle da BHRC-PM para o cenário 1.

Visualmente, os resultados dos hidrogramas da calibração e validação, considerando os algoritmos SCE-UA e o AMALGAM, foram bastante próximos. As diferenças entre os resultados originados dos algoritmos podem ser observadas nas estatísticas de desempenho (Tabela 6). Observa-se que o LASH captou de forma satisfatória o comportamento do hidrograma nos períodos de calibração e validação na BHRC-PM, com presença de subestimativa das vazões estimadas em relação às observadas no período de calibração, e superestimativa no período de validação na BHRC-PM, o que pode ser confirmado pelo P_{BIAS} (Tabela 6). Caldeira (2019) explica que essa subestimativa das vazões de pico é comum na modelagem hidrológica, de modo que isso pode estar atrelado ao passo temporal de simulação e a representatividade espacial de variáveis meteorológicas (e.g. chuva, temperatura, radiação solar). E ainda, no caso deste estudo na BHRC-PM, há necessidade de

analisar com cautela a curva-chave para os períodos de medição de descarga líquida em cotas altas. De acordo com Collishonn *et al.* (2007), essa subestimativa por parte dos modelos pode ser negligenciada quando da ocorrência de poucas medições de vazões em cotas superiores, porque as curvas-chaves, comumente, não estão bem definidas nestas cotas maiores.

Para os hidrogramas das validações nas sub1 e sub2, pode-se observar que o LASH captou melhor o comportamento das vazões da sub2 e subestimou consideravelmente as vazões máximas da sub1, o que pode estar relacionado à extrapolação da curva-chave da sub-bacia Passo do Cação, requerendo uma análise adicional minuciosa. Essas diferenças foram discutidas tomando como base os valores das estatísticas de desempenho e são consolidadas na representação visual dos hidrogramas. Ademais, para visualizar as diferenças de resultados dos algoritmos, convertidos para escala mensal, as Figuras 34 e 35 foram computadas.




Figura 34 – Hidrogramas observados e estimados convertidos de escala diária para mensal no período de calibração (a) e validação (b) do LASH, para a seção de controle da BHRC-PM considerando os algoritmos SCE-UA e AMALGAM para o cenário 1.




Figura 35 – Hidrogramas observados e estimados convertidos de escala diária para mensal no período de validação nas sub-bacias Passo do Cação (a) e Passo das Carretas (b), considerando os parâmetros calibrados na seção de controle da BHRC-PM para o cenário 1.

Pode-se notar uma maior proximidade dos hidrogramas observados e estimados, tanto na calibração, quando na validação da BHRC-PM na conversão de escala diária para escala mensal. Para as validações das sub1 e sub2, houve uma forte subestimativa e superestimativa, respectivamente, o que pode estar relacionado aos parâmetros relacionados aos tempos de resposta dos reservatórios superficial e subsuperficial (C_s e C_{ss}). Essa melhora de representatividade do LASH em escala mensal em relação à escala diária é comum devido à diferença de escalas, onde em escala mensal, o modelo consegue captar o comportamento médio de forma mais próxima ao comportamento observado. Segundo Caldeira (2019), a escala mensal tende a proporcionar melhores estatísticas de precisão, pois as oscilações diárias no período são atenuadas.

Para confrontar o comportamento do modelo frente à estimativa das vazões mínimas com maior nível de detalhamento, utilizando o SCE-UA e o AMALGAM, foram computadas as curvas de permanência. A curva de permanência é uma ferramenta importante na hidrologia, pois relaciona a frequência com que as vazões são igualadas ou excedidas. Dentre as aplicabilidades de utilização da curva de permanência, a extração de quantis de vazões mínimas (e.g. $Q_{90\%}$, $Q_{95\%}$ ou $Q_{99\%}$) subsidia projetos de outorga e análise de vazões de estiagem. As Figuras 36 e 37 ilustram as curvas de permanência observadas e estimadas para a BHRC-PM e suas duas sub-bacias utilizadas na validação.




Figura 36 – Curvas de permanência considerando a calibração (a) e validação (b) do LASH para a seção de controle da BHRC-PM considerando os algoritmos SCE-UA e AMALGAM para o cenário 1.




Figura 37 – Curvas de permanência para as validações do LASH nas sub-bacias Passo do Cação (a) e Passo das Carretas (b), considerando os parâmetros calibrados na seção de controle da BHRC-PM para o cenário 1.

Analisando as estimativas das curvas de permanência, verifica-se que os resultados obtidos pelo SCE-UA e pelo AMALGAM foram muito próximos em todas as situações. Na calibração, o LASH captou de forma precisa o comportamento da curva de permanência observada, sendo mais preciso nos quantis menores. Esse comportamento se manteve na validação da BHRC-PM. Beskow *et al.* (2016) explicam que o período de durações entre 0 e 95% das curvas de permanência é o intervalo considerado mais importante para gestão dos recursos hídricos. Nas curvas de permanência das sub1 e sub2, o modelo foi mais eficiente em representar o comportamento da sub1, se mantendo próximo inclusive nos quantis médios. Durante a análise prévia dos resultados de calibração do LASH na BHRC-PM, pode-se notar uma grande influência do parâmetro C_B na parte final do traçado da curva

de permanência (vazões mínimas), indicando que quanto maior o C_B , pior era a representação dos quantis de vazões mínimas. Esse comportamento condiz com a especificidade do C_B para períodos de recessão, conforme discutido anteriormente.

Ainda em relação à representação dos quantis mais altos ($Q_{100} \sim Q_{80}$), no geral, bacias de cabeceiras possuem pior representatividade desses quantis devido à influência do divisor freático em detrimento do topográfico, justificando a dificuldade do modelo em captar vazões de referência. Uma forma de tentar contornar essa problemática, é distribuir o parâmetro C_B , haja vista sua influência discutida no parágrafo anterior.

Além das vazões mínimas, a estimativa de vazões médias e máximas pelo modelo hidrológico é fundamental para subsidiar projetos na área de engenharia. Segundo Beskow *et al.* (2016), a vazão média é o indicador comumente utilizado para definição da disponibilidade hídrica e do potencial de regularização da vazão em reservatórios. Os indicadores de vazão máxima podem subsidiar análises de cheias e manchas de inundação na bacia. Nesse sentido, pode-se visualizar na Figura 38, os indicadores anuais observados e estimados pelo LASH.




Figura 38 – Vazões mínimas (a), médias (b) e máximas (c) diárias observadas na BHRC-PM, estimadas pelo LASH no período de calibração (1996 – 2000) e validação (2001 – 2005), considerando os algoritmos SCE-UA e AMALGAM para o cenário 1.

Em relação à Figura 38a, no geral, o modelo superestimou as vazões mínimas. Para o ano de 2005, a alta discrepância das vazões mínimas estimadas em relação às observadas, pode ser explicada devido à influência de evento de La-Niña no estado, caracterizando períodos de seca. Para as vazões médias (Figura 38b), o modelo representou com razoável proximidade as vazões observadas, principalmente no período de validação. Em relação às vazões máximas (Figura 38c), o LASH, no geral, subestimou as vazões de pico observadas, com exceção dos anos de 2001 e 2002. Para as estimativas dos três indicadores supracitados, tanto o SCE-UA quanto o AMALGAM, apresentaram resultados bastante próximos. Porém, quando houve superestimativa do modelo em relação aos valores observados, o AMALGAM apresentou tendência mais próxima aos dados observados e, quando houve subestimativa por parte do modelo, o SCE-UA apresentou maior proximidade com os dados observados.

Outra alternativa para explorar a aplicabilidade de diferentes algoritmos de calibração em um modelo hidrológico e analisar as premissas de seus parâmetros, é calibrá-lo considerando os parâmetros por sub-bacia, ou seja, distribuídos. Esse nicho é interessante para explorar bacias hidrográficas que abrangem diferentes biomas, condições edafoclimáticas ou que possuem regiões hidrográficas bastante distintas entre si, como a BHRC-PM. Todavia, até o momento o LASH havia sido pouco explorado nesse sentido, principalmente devido à viabilidade de execução do modelo, algo que foi um ponto avaliado neste trabalho, permitindo a composição de estudos desse cunho.

3.3 Calibração e validação – cenário 2: parâmetros obtidos

O cenário 2 buscou avaliar a representatividade do LASH às condições hidrológicas da BHRC-PM, considerando os parâmetros λ e C_s distribuídos por sub-bacia e utilizando os dois algoritmos de calibração aplicados neste estudo. Cabe lembrar que a escolha de λ e de C_s foi pautada, principalmente, na variabilidade desses parâmetros por sub-bacia. Na Tabela 8, estão apresentados os parâmetros calibrados do modelo para cada algoritmo, bem como a amplitude mínima e máxima do λ e do C_s .

Tabela 8 – Parâmetros calibrados para a BHRC-PM, considerando os algoritmos SCE-UA e AMALGAM, para o cenário 2

Algoritmo	λ	K_{SS} (mm·dia ⁻¹)	K_B (mm·dia ⁻¹)	K_{CAP} (mm·dia ⁻¹)	C_s	C_{SS}	C_B (dia)	n (s·m ^{-1/3})
SCE-UA	0,09 - 0,15	0,13	2,05	1,85	4,30 - 35,63	21.771,06	1,62	0,03
AMALGAM	0,02 - 0,20	0,13	1,41	0,14	4,90 - 46,42	12.035,63	1,76	0,03

Assim como no cenário 1, a grande maioria dos parâmetros calibrados no cenário 2 foram próximos entre si e, em termos hidrológicos, acarretando em uma discussão análoga à realizada na seção anterior, principalmente em relação ao K_{SS} . As maiores diferenças estão nos intervalos dos parâmetros λ e C_s , e também no C_{SS} . Quanto ao λ , no AMALGAM, a amplitude de convergência do parâmetro foi maior, se comparado ao SCE-UA. Isso pode estar relacionado ao fato do AMALGAM não possuir um valor inicial para calibração, considerando apenas os valores mínimos e máximos indicados ao λ para calibração (0,01 – 0,20), ao contrário do SCE-UA, que inicia as avaliações das populações em torno do valor inicial indicado (0,10). Outrossim, pode estar relacionado à convergência dos parâmetros, de modo que para o SCE-UA foi considerado até 50.000 avaliações e o modelo executou 48.160, o que pode indicar necessidade de um maior número de avaliações. Todavia, 50.000 avaliações é um número expressivo para convergência de 124 parâmetros, principalmente pelo SCE-UA ser um algoritmo mono-objetivo de busca global. Em relação ao C_s , o intervalo de convergência foi relativamente próximo entre os algoritmos, porém ainda assim se observa uma maior amplitude no AMALGAM, o que também pode estar relacionado ao exposto anteriormente. Para visualizar o impacto da variabilidade dos parâmetros λ e C_s , as Figuras 39 e 40 foram elaboradas.




Figura 39 – Espacialização dos valores de λ para as sub-bacias da BHRC-PM, considerando os algoritmos (a) SCE-UA e (b) AMALGAM para o cenário 2.

* Observação: o mapa de solos no canto inferior direito (figura sem escala) foi adicionado para subsidiar a discussão do λ em relação às classes de solos. As manchas acinzentadas no mapa se referem ao Neossolo Litólico, enquanto a predominância da cor alaranjada, ao Argissolo Vermelho-Amarelo.




Figura 40 – Espacialização dos valores de C_s para as sub-bacias da BHRC-PM, considerando os algoritmos (a) SCE-UA e (b) AMALGAM para o cenário 2.

Os principais contrastes nos valores de λ , de acordo com Mishra *et al.* (2003), são as diferenças climáticas, diferenças no padrão de precipitação e as condições de umidade inicial do solo. Caldeira (2016) explica que quanto menor o λ , mais rápido será o início do ESD, logo, o tipo de solo exerce grande influência na geração do ESD e, conseqüentemente, no valor desse parâmetro para cada sub-bacia. Observa-se que, tanto no AMALGAM quanto no SCE-UA, valores mais baixos de λ estão associados à presença de manchas de Neossolo Litólico (predominância da cor cinza) nas sub-bacias, o que condiz com o fato de que, por ser um solo mais

raso, permite o início mais rápido de ESD. A principal diferença entre os resultados dos dois algoritmos é em relação à amplitude do λ , conforme discutido sobre a Tabela 9. A modelagem utilizando parâmetros distribuídos por sub-bacias ainda é pouco utilizada e explorada na literatura, principalmente devido à viabilidade computacional. Todavia, no LASH, os estudos de Mello *et al.* (2008) e Viola *et al.* (2009) foram pioneiros em explorar o comportamento do modelo frente à essa estrutura, distribuindo todos os parâmetros na calibração, ao passo que Caldeira (2016) explorou a calibração distribuída do λ . Mello *et al.* (2008) empregaram a 1ª versão do LASH, distribuída por sub-bacias, na BHRG (Minas Gerais) e encontraram valores de λ entre 0,01 e 0,2. Viola *et al.* (2009) aplicaram a mesma versão para a BHRA (Minas Gerais) e também encontraram valores de λ entre 0,01 e 0,2. Caldeira (2016), utilizando a 3ª versão do LASH, calibrou valores de λ entre 0,017 e 0,465 para a BHAP e valores entre 0,018 e 0,463 para a BHAF, ambas no Rio Grande do Sul. Os estudos supracitados destacam a importância de calibração do λ para um bom desempenho do modelo na geração de ESD, além de gerar resultados mais confiáveis de λ .

Na espacialização do C_s , observa-se, tanto no SCE-UA quanto no AMALGAM, uma tendência de menores valores de C_s para bacias maiores e vice-versa. Essa constatação condiz com o módulo onde este parâmetro está equacionado no LASH. De forma que bacias maiores tendem a gerar vazões maiores de ESD, o que explica os valores menores de C_s . Além do λ , Mello *et al.* (2008) e Viola *et al.* (2008) também espacializaram os parâmetros K_{ss} , C_s e C_{ss} , e Viola *et al.* (2009) ainda espacializaram o K_B . Cabe destacar que na 1ª versão do LASH o parâmetro K_{CAP} era obtido na literatura, e o C_B , a partir da análise de um período de recessão bem caracterizado. Em relação ao C_s , Mello *et al.* (2008) e Viola *et al.* (2008) encontraram valores de 1,9 a 900 e de 2,3 a 33,4, respectivamente, para a BHRA (2094 km²) e para a BHRG (2080 km²). Não há uma base de valores para comparação desse parâmetro, porque, como discutido por Viola *et al.* (2008), este é puramente empírico. Entretanto, sua magnitude está atrelada à área de drenagem das bacias, uma vez que é um fator multiplicativo do tempo de concentração, sendo inversamente proporcional ao cálculo das vazões originadas do ESD.

3.4 Calibração e validação – cenário 2: estatísticas de desempenho

Para verificar a representatividade da calibração dos parâmetros, por parte dos algoritmos, representados na Tabela 8 e Figuras 39 e 40, as estatísticas de desempenho estão dispostas na Tabela 9.

Tabela 9 - Estatísticas de desempenho dos hidrograma estimados para cada algoritmo, considerando a escala diária e mensal, para o cenário 2

	Algoritmo	Etapa	C _{NS}	C _{NS-LOG}	P _{BIAS} (%)	RMSE (m ³ ·s ⁻¹)
escala diária	SCE-UA	Calibração	0,75	0,67	-1,71	233,64
		Validação	0,78	0,68	-4,98	228,23
		Validação - sub1	0,47	0,56	5,48	165,04
		Validação - sub2	0,67	0,45	-28,71	161,37
	AMALGAM	Calibração	0,76	0,73	5,54	228,48
		Validação	0,80	0,74	0,91	221,69
		Validação - sub1	0,52	0,62	10,69	157,18
		Validação - sub2	0,69	0,49	-22,12	157,17
escala mensal	SCE-UA	Calibração	0,84	0,72	-1,62	120,13
		Validação	0,88	0,77	1,44	116,59
		Validação - sub1	0,65	0,64	5,21	78,91
		Validação - sub2	0,71	0,50	-29,02	89,96
	AMALGAM	Calibração	0,85	0,78	5,62	116,94
		Validação	0,88	0,77	0,74	114,70
		Validação - sub1	0,65	0,67	10,44	78,65
		Validação - sub2	0,78	0,55	-22,39	78,45

Analisando a Tabela 9, no geral, o AMALGAM foi superior quando comparado ao SCE-UA, principalmente em relação ao C_{NS-LOG}. Embora o P_{BIAS}, resultante da calibração com o SCE-UA, tenha sido superior ao obtido com o AMALGAM, o desempenho desse parâmetro na validação da BHRC-PM foi superior quando da utilização do algoritmo multiobjetivo. Em comparação com o cenário 1, apenas o C_{NS-LOG} apresentou melhora, de modo que o C_{NS} basicamente não obteve variação e o P_{BIAS}, de modo geral, mostrou desempenho inferior. O RMSE obteve melhora, em relação ao cenário 1 com o AMALGAM.

Embora a espacialização dos parâmetros de modelos hidrológicos seja uma técnica de calibração que pode ser utilizada para contornar a heterogeneidade de regiões dentro de bacias hidrográficas, o processamento de execução desse cenário ainda é um fator limitante. Os estudos de Mello *et al.* (2008) e Viola *et al.* (2008)

utilizaram dessa metodologia no LASH, porém a versão do modelo utilizada era em planilha eletrônica (semi-distribuída) e calibração manual, o que tornava laborioso a espacialização dos parâmetros e a utilização de algoritmos de calibração. No entanto, isso não foi um limitante para o bom desempenho do LASH, de modo que Mello *et al.* (2008) encontraram valores de C_{NS} e C_{NS-LOG} de 0,81, e Viola *et al.* (2009) encontraram valores de C_{NS} e C_{NS-LOG} de 0,87 e 0,92, respectivamente, para o período de calibração. Na validação, Mello *et al.* (2008) encontraram C_{NS} e C_{NS-LOG} de 0,88 e 0,89, respectivamente, enquanto Viola *et al.* (2009) encontraram C_{NS} e C_{NS-LOG} de 0,92 e 0,94, respectivamente, indicando uma boa representação das respostas hidrológicas de duas bacias hidrográficas em Minas Gerais. A 3ª versão do LASH utilizada por Caldeira (2016) apresentava uma interface e módulo de calibração automática, utilizando o SCE-UA, deste modo, a autora encontrou para as bacias BHAF e BHAP C_{NS} de 0,71 e 0,60, e C_{NS-LOG} de 0,68 e 0,61, respectivamente, na calibração. Para o período de validação, foram encontrados C_{NS} de 0,53 e 0,61 e C_{NS-LOG} de 0,76 e 0,61 para a BHAF e BHAP, respectivamente. Além dos estudos mencionados acerca da espacialização dos parâmetros na modelagem hidrológica, os estudos de Ajami *et al.* (2004) e Xie *et al.* (2020) também relatam essa técnica de calibração considerando outros modelos hidrológicos.

Ajami *et al.* (2004) compararam três estratégias de calibração, concentrada (cenário 1), semi-distribuída, considerando os parâmetros concentrados por sub-bacia (cenário 2) e considerando os parâmetros distribuídos por sub-bacia (cenário 3), na bacia hidrográfica do rio Illinois, em Oklahoma (EUA) utilizando o modelo *Sacramento Soil Moisture Accounting*. No período de calibração, os autores encontraram valores de C_{NS} e P_{BIAS} de 0,63 e 17,03% (cenário 1), 0,68 e 1,32% (cenário 2) e 0,62 e 6,40% (cenário 3), respectivamente, utilizando o algoritmo SCE-UA. Na validação, encontraram valores C_{NS} e P_{BIAS} de 0,78 e 11,20% (cenário 1), 0,78 e -2,18% (cenário 2) e 0,76 e 1,42% (cenário 3), respectivamente. Ajami *et al.* (2004) constataram que o cenário 3 melhorou o comportamento do período de recessão representado pelo modelo. Todavia, a estratégia de calibração do cenário 3 em relação ao cenário 2 não apresentou melhoras significativas nas estatísticas de desempenho, o que os autores apontam estar relacionado à inicialização dos parâmetros. Outrossim, os autores indicam a aplicação desse cenário de alta complexidade distribuída em bacias hidrográficas que possuam regiões

heterogêneas entre si, como é o caso, por exemplo, da BHRC-PM, que apresenta regiões bastante distintas (Alto Camaquã x Baixo Camaquã Duro).

Xie *et al.* (2020) calibraram e validaram o modelo hidrológico distribuído *Variable Infiltration Capacity* (VIC) para três bacias hidrográficas na China. Foram comparadas as respostas hidrológicas das bacias considerando os parâmetros concentrados por sub-bacia (cenário 1) e distribuídos por sub-bacia (cenário 2). No período de calibração, foram encontrados valores de $C_{NS} \geq 0,75$ para o cenário 1 e $C_{NS} \geq 0,80$ para o cenário 2. Para o período de validação, foram encontrados valores de $C_{NS} \geq 0,60$ para o cenário 1 e de $C_{NS} \geq 0,70$ para o cenário 2. Os autores constataram superioridade do cenário 2, melhorando a precisão do modelo VIC. Xie *et al.* (2020) ainda discutiram a viabilidade de distribuição dos parâmetros em melhorar o desempenho da modelagem com um custo computacional viável, e constataram que as melhorias foram restringidas pelas incertezas no tempo de execução limitado pela calibração. Todavia, distribuir os parâmetros torna o modelo muito mais robusto para aplicações em sub-bacias sem dados de observação, assim, o custo computacional torna-se algo relativizado em comparação com o benefício obtido.

Via de regra, espera-se que as estatísticas de desempenho sejam superiores no cenário 2, em comparação com o cenário 1. Isso, porque a representatividade da espacialização de parâmetros como o λ e o C_s tende a captar o comportamento individual de cada sub-bacia. No entanto, essa melhora foi identificada apenas quando da utilização do AMALGAM e, especificamente, em torno do C_{NS-LOG} , sugerindo que o modelo, no âmbito do cenário 2, captou melhor as vazões mínimas da BHRC-PM. Para visualizar o comportamento dos hidrogramas estimados frente aos observados, as Figuras 41 e 42 representam a calibração e validação na BHRC-PM e as validações nas sub1 e sub2, respectivamente, para os algoritmos utilizados.




Figura 41 – Calibração (a) e validação (b) do LASH para a seção de controle da BHRC-PM considerando os algoritmos SCE-UA e AMALGAM para o cenário 2.




Figura 42 – Validações do LASH nas sub-bacias Passo do Cação (a) e Passo das Carretas (b), considerando os parâmetros calibrados na seção de controle da BHRC-PM para o cenário 2.

No geral, o comportamento do hidrograma diário tanto para a BHRC-PM, quanto para as sub-bacias de validação, é semelhante entre o SCE-UA e o AMALGAM. Comparando o cenário 2 ao cenário 1, visualmente, as respostas também foram semelhantes, impulsionando as principais diferenças nas estatísticas da Tabela 10. As Figuras 43 e 44 representam as respostas hidrológicas da BHRC-PM e sub-bacias de validação convertidas de escala diária para escala mensal.




Figura 43 – Hidrogramas observados e estimados convertidos de escala diária para mensal no período de calibração (a) e validação (b) do LASH, para a seção de controle da BHRC-PM considerando os algoritmos SCE-UA e AMALGAM para o cenário 2.




Figura 44 - Hidrogramas observados e estimados convertidos de escala diária para mensal no período de validação nas sub-bacias Passo do Cação (a) e Passo das Carretas (b), considerando os parâmetros calibrados na seção de controle da BHRC-PM para o cenário 2.

De forma semelhante à discussão anterior, os resultados em escala mensal também foram bastante próximos entre si, sendo próximos também aos valores observados. Esse comportamento é esperado, porque nessa escala o modelo não capta as oscilações diárias das variáveis hidrológicas. Ainda assim, tanto para a calibração e validação na BHRC-PM, quanto para as validações *Proxy-basin* nas sub1 e sub2, o modelo foi capaz de representar com boa proximidade os hidrogramas de saídas, considerando os dois algoritmos.

Assim como na seção anterior (3.1), as curvas de permanência das estão representadas nas Figuras 45 e 46.




Figura 45 – Curvas de permanência considerando a calibração (a) e validação (b) do LASH para a seção de controle da BHRC-PM considerando os algoritmos SCE-UA e AMALGAM para o cenário 2.




Figura 46 – Curvas de permanência para as validações do LASH nas sub-bacias Passo do Cação (a) e Passo das Carretas (b), considerando os parâmetros calibrados na seção de controle da BHRC-PM para o cenário 2.

As representações gráficas das curvas de permanência do cenário 2 também foram similares entre si, além de serem próximas às resultantes da aplicação do cenário 1. Essa análise dá respaldo à discussão de que embora o modelo tenha obtido ligeira melhora no C_{NS-LOG} utilizando o AMALGAM, no geral, os resultados considerando os parâmetros calibráveis do LASH para a BHRC-PM também foram satisfatórios. Isto indica que a espacialização dos parâmetros λ e C_s não melhorou os resultados, portanto uma análise mais precisa acerca da espacialização dos outros parâmetros, em estudos futuros, se faz necessária. Viola *et al.* (2009), para a BHRA, conseguiram ajustar e aplicar satisfatoriamente o LASH com estatísticas superiores às daquelas de outros modelos aplicados em diferentes bacias hidrográficas,

o que também pode estar atrelado à espacialização dos parâmetros λ , C_s , C_{ss} , K_{ss} e K_B , computada pelos autores.

A Figura 47 ilustra os indicativos de vazões mínimas, médias e máximas anuais observados e estimados por cada algoritmo.




Figura 47 - Vazões mínimas (a), médias (b) e máximas (c) diárias observadas na BHRC-PM, estimadas pelo LASH no período de calibração (1996 – 2000) e validação (2001 – 2005), considerando os algoritmos SCE-UA e AMALGAM para o cenário 2.

Assim como no cenário 1, as vazões estimadas pelo SCE-UA e AMALGAM foram semelhantes, indicando, além da boa representatividade do LASH em estimar as vazões mínimas, médias e máximas anuais, a boa capacidade dos algoritmos. No geral, observa-se uma superestimativa do SCE-UA em relação ao AMALGAM nas vazões mínimas e médias, e o contrário para as vazões máximas, indicando que o AMALGAM foi mais próximo dos valores observados. Em relação ao cenário 1, os valores de vazões mínimas estimados foram superiores, o que pode estar relacionado à melhora do C_{NS-LOG} . O mesmo ocorreu para os indicadores de médias e máximas, porém de forma menos significativa.

Pode-se atentar que tanto para os hidrogramas, curvas de permanência e indicadores de vazões apresentados no cenário 2, não houve diferenças visuais em relação ao cenário 1. O ligeiro ganho do cenário 2 em relação ao cenário 1 foi em relação às estatísticas de desempenho (Tabela 9), conforme discutido. Apesar da pouca diferença, em termos das estatísticas de desempenho, um modelo hidrológico com os parâmetros semi-distribuídos é uma ferramenta muito poderosa para a gestão dos recursos hídricos, principalmente para bacias sem monitoramento. O cenário 2, conforme mencionando anteriormente, é pouco utilizado devido à viabilidade computacional, uma vez que os parâmetros especializados calibrados são referentes ao número de sub-bacias acrescidos do restante dos parâmetros do modelo. Entretanto, quando é possível testá-lo frente a uma bacia hidrográfica com regiões heterogêneas, os ganhos em termos de resultados, são muito interessantes. Essas análises propiciam uma valiosa gestão dos recursos hídricos e entregam uma ferramenta que auxilia em projetos hidrológicos, principalmente em bacias hidrográficas que possuam um comitê, como é o caso da BHRC-PM.

3.5 SCE-UA versus AMALGAM: incertezas, equifinalidade e diferenças computacionais

As análises de incertezas e equifinalidade apresentadas nesta seção foram realizadas apenas para o cenário 1, a fim de otimizar as discussões e evitar repetições de resultados. Para elucidar sobre as principais diferenças, nas respostas hidrológicas do LASH, a Figura 48 foi computada considerando as melhores populações retornadas pelo SCE-UA (28 populações) e pelo AMALGAM (50 populações).




Figura 48 - Banda de incertezas nas curvas de permanência computadas por meio das melhores populações do SCE-UA (a) e do AMALGAM (b) para o cenário 1.

A Figura 48 sugere, com base nas populações finais, uma melhora das incertezas na modelagem com o AMALGAM em relação ao SCE-UA. A curva de permanência foi escolhida para demonstrar a banda de incertezas por possuir o eixo-y logaritmizado, o que destaca as diferenças. As linhas cinzas foram constituídas a partir das populações finais dos parâmetros, enquanto que a linha preta, foi resultante do conjunto de parâmetros escolhido com base na(s) FO(s) para representar a modelagem das vazões na BHRC-PM. As diferenças são observadas, principalmente, a partir da frequência de 60% ($Q_{60\%}$), de modo que com o AMALGAM, a banda de incertezas foi mais estreita, enquanto que com o SCE-UA, foi mais larga. Com o AMALGAM, a banda foi menor mesmo tendo quase o dobro de populações, indicando uma diminuição das incertezas de calibração.

Em relação à análise de incertezas por meio da técnica de GLUE, a curva FDP dos pesos de verossimilhança foi obtida considerando as 500 melhores combinações de parâmetros de cada algoritmo e as vazões médias obtidas dessas combinações para o período completo da série histórica (calibração e validação). Essa consideração foi realizada para tentar contornar a subjetividade de corte dos valores de peso de verossimilhança. Cavalcanti e Bravo (2013) realizaram algo semelhante, onde testaram o número de iterações e patamares de aceitação do C_{NS} para aplicação da metodologia de GLUE. Na Figura 49 é ilustrada a curva FDP dos pesos de verossimilhança (eixo-y) em relação às vazões médias (eixo-x). As linhas verticais tracejadas indicam a média das vazões observadas (em azul) e a vazão correspondente à mediana da FDP (em vermelho). As escalas do eixo-x possuem as mesmas variações para fins de comparação.




Figura 49 – Distribuição cumulativa de GLUE utilizando o SCE-UA (a) e o AMALGAM (b).

A diferença percentual entre a vazão média observada e a vazão correspondente à mediana de GLUE foi de 1,49% para o SCE-UA e de -0,71% para o AMALGAM (Figura 49). Beskow, Mello e Norton (2011) explicam que quanto mais próximas são as linhas tracejadas entre si, menores são as incertezas associadas à modelagem, logo o AMALGAM apresentou tendência na diminuição das incertezas. Pode-se observar que a linha que representa a vazão média observada está mais distante da mediana da FDP de GLUE para o SCE-UA, indicando que os resultados do algoritmo apresentam tendência de diminuição, algo que não ocorreu quando da utilização do AMALGAM.

Cerca de 7% e 59% das iterações do SCE-UA e do AMALGAM, respectivamente, forneceram uma vazão média diária menor que a observada ($405,1 \text{ m}^3\cdot\text{s}^{-1}$). Os resultados obtidos com o SCE-UA indicam tendência à diminuição, e esse comportamento pode ser observado com base na localização da reta da vazão média observada na Figura 49a. A FDP de GLUE para o AMALGAM (Figura 49b) apresentou menor variação em torno da vazão média de cada iteração se comparada à GLUE para o SCE-UA, o que pode indicar que o corte nas simulações do SCE-UA não foi representativo como foi para o AMALGAM.

O método de GLUE é comumente utilizado para avaliar as incertezas dos parâmetros e corrigir seus intervalos de calibração, como foi realizado por Beskow, Mello e Norton (2011) nos parâmetros do LASH. No entanto, pode ser utilizado para avaliar, como neste estudo, as diferenças dos algoritmos nas incertezas da calibração. Embora os resultados da aplicação da técnica de GLUE indiquem que a utilização do AMALGAM diminuiu as incertezas de calibração, essa ferramenta pode ser melhor explorada se as subjetividades de sua utilização forem contornadas. Dentre essas subjetividades, a função de verossimilhança, o corte na escolha das simulações e o período utilizado para extrair as vazões médias de cada iteração podem ter influenciado os resultados.

A Figura 50 foi elaborada para visualizar a variação das estatísticas de desempenho e da vazão média em cada iteração do SCE-UA (2.380 iterações) e AMALGAM (5.000 iterações), considerando a calibração e validação em separado e em conjunto.




Figura 50 – Variação das estatísticas de desempenho C_{NS} (a), C_{NS-LOG} (b) e P_{BIAS} (c) e da vazão média (d) na calibração (C), na validação (V) e na C+V para o SCE-UA (2.380 iterações) e AMALGAM (5.000 iterações).

Os valores de C_{NS} médio (Figura 50a) considerando o AMALGAM para os períodos de calibração (0,73) e validação (0,76) foram superiores aos encontrados considerando o SCE-UA, iguais a 0,72 e 0,75, respectivamente. Porém, percebe-se que o AMALGAM encontrou mais soluções piores do que o SCE-UA (Figura 50a), de modo que todos os *boxplots* do AMALGAM são superiores em relação aos do SCE-UA. Isto é, ele percorre locais não tão ótimos quanto os locais que o SCE-UA busca as soluções ótimas. Neste aspecto, e somente nestes, o SCE-UA parece ser mais eficiente, porém não gera os melhores resultados.

Os valores de C_{NS-LOG} médios (Figura 50b) obtidos utilizando o SCE-UA foram de 0,75 e 0,66, de modo que, para o AMALGAM, foram de 0,71 (calibração) e 0,71 (validação). Em relação aos P_{BIAS} médios (Figura 50c), os valores obtidos foram de 2,92% e 4,63% para o SCE-UA, e de 5,11% e 2,52% para o AMALGAM na calibração e validação, respectivamente. Embora os resultados médios de C_{NS-LOG} e P_{BIAS} para o SCE-UA tenham sido superiores em relação aos do AMALGAM, o fato das três estatísticas de desempenho terem sido utilizadas como FOs no algoritmo multiobjetivo deve ser levado em consideração. É importante destacar que a variação dos valores das estatísticas quando da utilização do AMALGAM pode ser melhorada caso o número de gerações seja diminuído, isso porque no AMALGAM, o número de iterações totais é controlado, algo que não acontece no SCE-UA. Esse estudo é interessante de ser realizado em análises futuras, principalmente para extrair melhorias nos resultados da implementação do algoritmo multiobjetivo.

As vazões médias observadas dos períodos de calibração, validação e completo foram de $375,9 \text{ m}^3\cdot\text{s}^{-1}$, $433,41 \text{ m}^3\cdot\text{s}^{-1}$ e $405,09 \text{ m}^3\cdot\text{s}^{-1}$, respectivamente. A Figura 50d apresenta as vazões médias de todas as iterações para os períodos de calibração ($379,8 \text{ m}^3\cdot\text{s}^{-1}$), validação ($450,2 \text{ m}^3\cdot\text{s}^{-1}$) e completo $416,5 \text{ m}^3\cdot\text{s}^{-1}$), utilizando o SCE-UA. Para esses períodos, foram obtidas vazões médias iguais a $358,1 \text{ m}^3\cdot\text{s}^{-1}$, $430,3 \text{ m}^3\cdot\text{s}^{-1}$ e $395,2 \text{ m}^3\cdot\text{s}^{-1}$ por meio do AMALGAM. No período de calibração, o SCE-UA diferiu 1% da média observada, enquanto o AMALGAM diferiu -5%. No período de validação houve superioridade do AMALGAM, diferindo em 0,73%, enquanto o SCE-UA diferiu 3,73%. Considerando o período completo, as diferenças foram de 2,74% para o SCE-UA, e -2,50% para o AMALGAM. Essas diferenças embasam a discussão anterior de buscar melhorias na utilização do AMALGAM e permitem constatar que o algoritmo multiobjetivo tem potencial para diminuir as incertezas na calibração.

Em relação à análise da equifinalidade dos parâmetros, a Figura 51 foi desenvolvida considerando a faixa de valores ideais da(s) FO(s).




Figura 51 – Gráficos *box plots* dos conjuntos de parâmetros equifinais considerando a calibração pelo SCE-UA e pelo AMALGAM.

Os valores ideais para separar os parâmetros equifinais foram escolhidos de acordo com os resultados das iterações dos algoritmos, sendo considerados o $C_{NS} = 0,75$ para o SCE-UA, e $C_{NS} = 0,75$, $C_{NS-LOG} = 0,74$ e $P_{BIAS} = 6\%$, para o AMALGAM. A faixa de valores das FOs para computar a equifinalidade utilizando o AMALGAM foi alterada de 1% para 3%, devido ao fato de que não houve combinações dos valores de C_{NS} , C_{NS-LOG} e P_{BIAS} que resultassem na faixa de 1%. Nesse sentido, 125 conjuntos de parâmetros foram classificados como equifinais, enquanto que para o SCE-UA, na faixa de 1%, foram 1.298 conjuntos de parâmetros classificados como equifinais.

Analizando a Figura 51, para os parâmetros λ , K_{SS} e K_B obtidos com o AMALGAM, 50% das simulações ficaram em um intervalo muito reduzido de valores, além de praticamente não apresentarem valores extremos, o que indica uma redução da equifinalidade para esses parâmetros utilizando o algoritmo multiobjetivo. Nesse sentido, por exemplo, o coeficiente de abstração inicial variou de 0,13 a 0,20 utilizando o SCE-UA e de 0,18 a 0,20 utilizando o AMALGAM. Para os parâmetros K_{CR} , C_S e o C_{SS} , embora o SCE-UA tenha apresentado 50% dos conjuntos em um intervalo menor, se comparado ao AMALGAM, apresentou também mais valores extremos em relação a esse intervalo, de modo que, para o AMALGAM, a representação em *box plot* foi mais homogênea. O C_B foi o que apresentou melhora quando da utilização do SCE-UA em relação ao AMALGAM. Por fim, o comportamento do n pode indicar que a calibração na BHRC-PM não foi sensível à este parâmetro.

O estudo de equifinalidade pode ter sido influenciado pelos valores ideais escolhidos para separar os parâmetros equifinais e, no caso do AMALGAM, pela combinação de valores ideais das FOs que resultaram em um número reduzido de parâmetros equifinais para traçar as análises. A utilização, por exemplo, de duas FOs ao invés de três, aumentaria o número de parâmetros equifinais e poderia refinar as análises por meio dos gráficos *box plot*. Essas observações são importantes para compreender a utilização de um algoritmo multiobjetivo e explorar, ao máximo, todas as suas vantagens. Para contrapor sobre os resultados encontrados neste estudo acerca da comparação do SCE-UA com o AMALGAM, foram encontrados alguns estudos hidrológicos que utilizaram o AMALGAM como algoritmo de calibração (ZHANG; SRINIVASAN; LIEW, 2010; WÖHLING; SAMANIEGO; KUMAR, 2013; LIECHTI *et al.*, 2014; NEMRI; KINNARD, 2020).

Zhang, Srinivasan e Liew (2010) calibraram o SWAT para quatro bacias hidrográficas localizadas no planalto tibetano na China, de forma a comparar os algoritmos AMALGAM, SPEA2 e NSGA-II. Os resultados encontrados indicam que o AMALGAM é competitivo ou superior quando comparado ao SPEA2 e NSGA-II, ambos algoritmos massivamente utilizados em estudos de modelos hidrológicos. Wöhling, Samaniego e Kumar (2013) calibraram os 53 parâmetros do Modelo Hidrológico de Mesoescala Distribuída (mHM) em 22 bacias hidrográficas no sul da Alemanha utilizando o AMALGAM, mediante as FOs C_{NS} , C_{NS-LOG} e a soma dos erros quadráticos dos fluxos mensais normalizados por área da bacia. Os autores encontraram resultados médios de C_{NS} na ordem de 0,78 e constataram a importância da escolha de FOs para calibração de modelos hidrológicos, principalmente pelo fato das FOs utilizadas possuírem pouca correlação entre si, como as escolhidas para o estudo de caso de aplicação do LASH na BHRC-PM (C_{NS} , C_{NS-LOG} e P_{BIAS}).

Liechti *et al.* (2014) calibraram o SWAT para a bacia hidrográfica do rio Zambezi, na África, utilizando o AMALGAM e encontraram resultados satisfatórios com aplicabilidade do modelo em simular cenários de desenvolvimento na bacia. Nemri e Kinnard (2020) compararam o SCE-UA e o AMALGAM para avaliar a equifinalidade e incerteza do modelo hidrológico GR4J-Cemaneige, com vistas à simulação de escoamento gerado por neve. Os autores constataram que a calibração com o AMALGAM reduziu o número de conjuntos de parâmetros equifinais. O estudo de equifinalidade de Nemri e Kinnard (2020) motivou as análises computadas na calibração do LASH para a BHRC-PM, principalmente em relação aos valores ideais dos parâmetros equifinais e às análises nos gráficos *box plot*. Por essas análises, os autores constataram maior homogeneidade na distribuição dos parâmetros e menor dispersão quando da utilização do AMALGAM, similar ao constatado neste estudo para os parâmetros λ , K_{SS} e K_B (Figura 51).

Os resultados obtidos pelos autores mencionados e os encontrados no caso de estudo da BHRC-PM enaltecem a utilização do algoritmo AMALGAM no LASH, buscando uma alternativa para diminuir as incertezas associadas aos parâmetros de calibração do modelo. Para tal, o impacto das FOs na calibração e o comportamento da incerteza dos parâmetros frente às FOs também devem ser avaliados (CALDEIRA, 2016; HER; SEONG, 2018; ZHANG *et al.*, 2018; HUO; LIU, 2020).

O estudo de Caldeira (2016) verificou o impacto da FO sobre a calibração do LASH utilizando separadamente o C_{NS} , C_{NS-LOG} e o RMSE, porém utilizando um algoritmo mono-objetivo (SCE-UA). Os resultados das análises de convergência indicaram que a estatística C_{NS-LOG} foi a que apresentou resultados mais satisfatórios, privilegiando a acurácia na estimativa de vazões de estiagem. Her e Seong (2018) investigaram como o desempenho, a equifinalidade e a incerteza dos parâmetros de calibração do SWAT, em três bacias hidrográficas localizadas em Virgínia (EUA), respondem ao número de FOs para compreender se a utilização de um algoritmo multiobjetivo (AMALGAM) pode auxiliar na qualidade da calibração. Foi constatado que a incerteza dos parâmetros diminuiu com o aumento do número de FOs, ao passo que a equifinalidade diminuiu considerando de um a quatro FOs, mas aumentou quando foram consideradas mais de quatro FOs. Segundo os autores, mediante os resultados encontrados, um grande número de FOs pode limitar a capacidade do algoritmo em localizar conjuntos ótimos de parâmetros, no entanto, a calibração multiobjetivo pode reduzir problemas de equifinalidade e incertezas.

Zhang *et al.* (2018) compararam a calibração mono e multiobjetivo utilizando o modelo FLEX-Topo em uma bacia hidrográfica na China, com o algoritmo MOSCEM-UA. Foram utilizadas as estatísticas C_{NS} e C_{NS-LOG} em conjunto para calibração multiobjetivo e separadamente, na calibração mono-objetivo. Os resultados apontaram que a simulação baseada no C_{NS} teve melhor desempenho, tanto na calibração multiobjetivo quanto em simular as vazões máximas. Em geral, foi constatado que a calibração multiobjetivo não melhorou o desempenho do modelo em relação à calibração mono-objetivo, sendo dependente da(s) FO(s) selecionadas. Os autores ainda sugerem a utilização de outras variáveis na calibração multiobjetivo, como o tempo de pico entre as vazões observadas e estimadas. Huo e Liu (2020), em seu estudo sobre a combinação de FOs para avaliação de modelos hidrológicos, constataram um grande número de conflitos entre FOs, pois as soluções de parâmetros ideais são difíceis de satisfazer os objetivos das funções. Ainda de acordo os autores, a combinação de FOs para calibração multiobjetivo deve ser escolhida cuidadosamente, caso contrário, os parâmetros ótimos obtidos não irão refletir as características reais da bacia hidrográfica.

Mediante as discussões anteriores, pode-se constatar a importância de escolha de FOs, quando da utilização de algoritmos multiobjetivos, que representem

as especificidades das respostas hidrológicas. Algo que buscou ser levado em consideração para aplicação do LASH na BHRC-PM por meio das estatísticas C_{NS} , C_{NS-LOG} e P_{BIAS} .

No tocante às diferenças, em termos computacionais, do SCE-UA e do AMALGAM, pode-se extrair algumas observações que auxiliam na discussão sobre os algoritmos. O AMALGAM, além de retornar o melhor conjunto de parâmetros de cada população, retorna também todas as avaliações e processamentos computados pelo algoritmo. Na Figura 52 estão representados a média, o DP e a correlação dos parâmetros de calibração do LASH, retornados pelo AMALGAM.

1	----- AMALGAM output file -----								
2	=====								
3	Variable	Mean	Std						
4	-----								
5	λ	0.19741	0.00228						
6	KSS	2.34350	15.66586						
7	KB	1.74004	0.35538						
8	KCAP	1.55538	1.01233						
9	CS	11.59972	0.63072						
10	CSS	43456.19424	5714.25670						
11	CB	4.30643	3.97830						
12	n	0.02553	0.00029						
13	=====								
14									
15	===== CORRELATION COEFFICIENTS =====								
16		λ	KSS	KB	KCAP	CS	CSS	CB	n
17	λ	1.00	-0.04	0.35	-0.06	0.37	0.01	-0.39	0.13
18	KSS	-0.04	1.00	-0.21	0.49	-0.49	0.10	-0.06	-0.13
19	KB	0.35	-0.21	1.00	-0.47	0.45	0.01	-0.58	0.26
20	KCAP	-0.06	0.49	-0.47	1.00	-0.29	0.10	0.09	-0.02
21	CS	0.37	-0.49	0.45	-0.29	1.00	0.27	-0.65	0.30
22	CSS	0.01	0.10	0.01	0.10	0.27	1.00	-0.32	0.19
23	CB	-0.39	-0.06	-0.58	0.09	-0.65	-0.32	1.00	-0.31
24	n	0.13	-0.13	0.26	-0.02	0.30	0.19	-0.31	1.00
25	=====								
26	----- End AMALGAM output file -----								

Figura 52 – Resultados retornados pelo AMALGAM, contendo: a média e desvio padrão de Pareto dos parâmetros calibrados pelo LASH, bem como a correlação de Pareto entre cada um dos parâmetros para o cenário 1.

Os resultados expostos na Figura 52 são interessantes para viabilizar uma análise mais detalhada acerca da correlação entre os parâmetros calibráveis do LASH, algo até então, não realizado. Pode-se observar uma correlação inversa (-0,58) entre o K_B e o C_B , o que indica que quanto maior a condutividade hidráulica do reservatório subterrâneo, menor o tempo de retardo do escoamento de base e maior as vazões do escoamento de base. Essa constatação possui sentido pelo

equacionamento desse módulo no LASH, justificando também os baixos valores de C_B encontrados neste estudo. A flutuação dos parâmetros K_{SS} e K_{CAP} está relacionada à sensibilidade do modelo aos componentes do ciclo hidrológico que esses parâmetros representam. Outra análise é em relação à média e o DP dos parâmetros, onde um valor menor de DP, por exemplo, indica uma facilidade na convergência, ou seja, não houve muita flutuação entre os valores testados do parâmetro.

No que se refere aos processamentos visuais resultantes do AMALGAM, a Figura 53 ilustra a Frente de Pareto das três FOs utilizadas (Figura 53a), as soluções normalizadas desta (Figura 53b) e a probabilidade de seleção individual de cada sub-algoritmo do AMALGAM (GA, PSO, AMS e DE) em cada geração (Figura 53c).




Figura 53 – (a) Frente de Pareto das FOs utilizadas no AMALGAM; (b) soluções normalizadas da Frente de Pareto; e (c) probabilidade de seleção individual de cada sub-algoritmo, considerando o cenário 1.

Como é possível perceber na Figura 53a, não há uma dominância entre os pontos da Frente de Pareto, indicando que a troca de soluções dentro desse conjunto de pontos, resulta na piora de uma das FOs. Cabe destacar que os valores de C_{NS} e C_{NS-LOG} , presente na Figura 53a, estão negativos devido ao *default* de maximização, e não minimização das FOs, no algoritmo. De acordo com Zhang *et al.* (2018), visto que todas as soluções ótimas de Pareto são igualmente importantes, pode ser difícil escolher uma solução em detrimento de outra. Nesse sentido, o AMALGAM entregou conjuntos de parâmetros que resultaram em melhores valores de P_{BIAS} em comparação àqueles apresentados na Tabela 6 (seção 3.2) e na Tabela 9 (seção 3.4), por exemplo. Entretanto, buscando melhorar a estatística C_{NS-LOG} , foi escolhido o conjunto de parâmetros que, ainda assim resultassem em um P_{BIAS} satisfatório ($\leq 10\%$), mas que também apresentassem um valor superior de C_{NS-LOG} . Essa situação só foi possível, porque o AMALGAM retorna todas as avaliações computadas. Embora, dentro de todas as soluções apresentadas na Figura 53a, aquelas da Fronteira de Pareto sejam as melhores, a escolha de uma melhor FO em detrimento de outra pode ser realizada. Isso ocorre quando uma FO, como o C_{NS-LOG} , contribui para uma melhora significativa de representação do LASH em vazões mínimas e não implica em uma piora de classificação do P_{BIAS} .

A Figura 53b representa a incerteza de Pareto para cada parâmetro, listados no eixo-x, onde o eixo-y define sua incerteza de intervalos normalizados. Cada linha cinza no gráfico representa uma solução de Pareto, de modo que as linhas coloridas representam as soluções das FOs, ou seja, correspondem a uma solução de parâmetros diferente. De acordo com Vrugt (2016), o AMALGAM gera uma aproximação bastante uniforme da Frente de Pareto quando as soluções de Pareto se aproximam das soluções de critério único. Outrossim, observa-se que para a grande maioria dos parâmetros do LASH, o conjunto de soluções de Pareto tende a se agrupar entre as soluções únicas das três FOs. No entanto, existe uma incerteza associada ao parâmetro K_{SS} , porque não há soluções de Pareto dentro das FOs. Ainda na Figura 53b, observa-se uma homogeneidade da grande maioria dos parâmetros do LASH nas soluções de Pareto. Apenas o K_{CAP} varia de forma significativa entre as soluções, o que pode ser explicado pelo seu alto DP ($1,01 \text{ mm} \cdot \text{dia}^{-1}$ dado o intervalo de convergência de 0 a $5 \text{ mm} \cdot \text{dia}^{-1}$). No geral, as Figuras 53a e 53b ilustram o quanto o modelo LASH é bem definido pela calibração em relação aos três critérios de desempenho.

Os quatro sub-algoritmos implementados no AMALGAM, diferem entre si por meio de seus operadores genéticos. Na Figura 53c, inicialmente, o algoritmo GA (ou NSGA-II) exibe o maior sucesso reprodutivo, acompanhado do algoritmo DE, enquanto o PSO e AMS flutuam bastante ao longo das gerações iniciais. Porém, após cerca de 15 gerações, o NSGA-II e o DE dominam o sucesso de reprodução, apresentando no final, o NSGA-II como o algoritmo com maior probabilidade de sucesso na geração de filhos. Vrugt (2016) explica que essa combinação de métodos prova ser extremamente eficaz no aumento da diversidade de soluções ao longo da Frente de Pareto (Figura 53a). Mashwani (2013), em seu estudo com viés computacional sobre problemas de calibração, observou uma superioridade do AMALGAM quando comparado ao NSGA-II. O autor atribui essa superioridade ao fato do AMALGAM ser um algoritmo híbrido e ressalta que essa formulação ainda é pouco estudada.

Quanto ao número de complexos e soluções utilizadas considerando o SCE-UA e o AMALGAM, não foram encontradas referências que indicam números ótimos acerca dessas variantes. O estudo de Bravo, Collischonn e Tucci (2009) verificou a eficiência e a eficácia do algoritmo multiobjetivo MOSCEM-UA no modelo hidrológico IPH II. Segundo os autores, a calibração utilizando esse algoritmo tende a melhorar com o aumento de dois parâmetros necessários: o número de complexos e o tamanho da população. Foram encontradas, aproximadamente 5.000 soluções não denominadas de Pareto, para 500 indivíduos e 25 complexos. Os autores constataram que o número de soluções foi extremamente satisfatório quando da utilização de 2 FOs. Os resultados de Bravo, Collischonn e Tuci (2009) confirmam as boas escolhas desses parâmetros para o AMALGAM, porém com 3 FOs, que também resultou em 5.000 soluções (tamanho da população = 50 e número de complexos = 100). A escolha desses parâmetros reflete, por exemplo, na boa representação das soluções extremas no gráfico da Frente de Pareto (Figura 53a).

Em termos hidrológicos, os dois algoritmos apresentaram valores de calibração dos parâmetros coerentes com a realidade da BHRC-PM. Todavia, quando do uso do AMALGAM e das FOs selecionadas (CNS, CNS-LOG e PBIAS), além da facilidade, os resultados, no geral, possuem maior confiabilidade, haja vista o uso de três FOs simultaneamente, quando comparados com o SCE-UA. Isso provém das escolhas das FOs, as quais possuem pouca relação entre si e são impactadas de forma distinta pelos processos hidrológicos. No mais, o AMALGAM tem potencial

para diminuir as incertezas e equifinalidade na modelagem, como discutido anteriormente. Ademais, permite explorar outras diretrizes de calibração e necessidades da modelagem, como a utilização de FOs diferentes das utilizadas nesse estudo, e.g. para representar melhor as vazões de referência, utilizar apenas FOs que expliquem apenas essas vazões. O bom desempenho do AMALGAM não diminui a aplicabilidade do SCE-UA, mas motiva a utilização de algoritmos multiobjetivos, principalmente com enfoque de explorar diferentes FOs e auxiliar na sensibilidade da modelagem por parte do projetista.

3.6 Formulação do LASH em MATLAB® sob o estudo de caso na BHRC-PM

Na Tabela 10, estão dispostos os tempos de processamento das calibrações computadas no estudo de caso na BHRC-PM mediante os dois cenários utilizados, bem como o número de avaliações da FO C_{NS} , no caso do SCE-UA, e das FOs C_{NS} , C_{NS-LOG} e P_{BIAS} , no caso do AMALGAM.

Tabela 10 – Características do processamento do LASH implementado em MATLAB®, para cada algoritmo de calibração utilizado no estudo de caso da BHRC-PM considerando os parâmetros concentrados por sub-bacia (cenário 1) e o λ e C_s distribuídos por sub-bacia (cenário 2)

Algoritmo	Cenário 1	Cenário 2
SCE-UA	2,5h* 2.380 avaliações	40,7h* ~ 48.000 avaliações
AMALGAM	3,3h* 5.000 avaliações	38,4h* 50.000 avaliações

* Tempos de processamentos válidos para um computador Intel(R) Core(TM) i5-4200U CPU 1.60 GHz, 2.30GHz, 16GB de RAM e placa de vídeo NVIDIA GEOFORCE 920M de 2GB, 59 sub-bacias e 2.192 dias de simulação para calibração .

Um ganho importante na formulação do LASH em MATLAB® foi em relação ao tempo de processamento, que em suas versões anteriores (Delphi e C++) era entre 48h e 72h para bacias com número de sub-bacias e séries históricas com tamanhos semelhantes aos da BHRC-PM, considerando o cenário 1. Os tempos de processamento dispostos na Tabela 10 estão atrelados, principalmente, à consideração de variáveis globais no MATLAB®, margeando diferentes testes e considerando as especificidades de cada algoritmo (e.g. número de complexos, número de iterações, etc.).

Cabe ressaltar que o período de calibração da BHRC-PM foi computado entre 01/01/1995 e 31/12/2000, resultando em 2.192 dias com uma subdivisão de 59 sub-

bacias hidrográficas. E ainda, para o cenário 1 foram calibrados oito parâmetros e para o cenário 2, 124 parâmetros (λ e C_s distribuídos por sub-bacia). Embora o tempo de processamento não seja o mais importante na modelagem, deve ser considerado devido ao custo computacional, principalmente quando o tipo de configuração do cenário 2 é utilizado. Vale ressaltar que, nas versões em Delphi e C++, a calibração dos parâmetros de forma distribuída (cenário 2) era impraticável. No estudo de Caldeira (2016), em que foi utilizada a 3ª versão do LASH (em Delphi), a calibração do parâmetro λ de forma distribuída por sub-bacia com o SCE-UA apresentou problemas relacionados à memória, impedindo que o algoritmo fizesse mais que 20.000 iterações. Nesse sentido, a implementação do LASH em MATLAB® contornou essa problemática encontrada por Caldeira (2016) e pode subsidiar um leque de análises acerca da distribuição de todos os parâmetros do modelo em um tempo de processamento aceitável.

Os resultados da formulação do LASH em MATLAB®, em termos de processamento, são animadores no que tange à utilização de um modelo hidrológico de longo termo e semi-distribuído, sendo um avanço considerável frente ao desenvolvimento do modelo. Esse avanço tende a facilitar atualizações, implementações de novos módulos, acoplamentos a diferentes algoritmos de calibração e testes em bacias hidrográficas, e.g. cenários de uso e cobertura do solo e de mudanças climáticas, de forma a dispor dos resultados das simulações do modelo em um tempo hábil.

4 Conclusões

Mediante ao exposto e contemplando, de forma geral, os objetivos deste estudo, conclui-se que:

- i) a calibração e a validação do LASH em MATLAB® para a BHRC-PM apresentaram resultados satisfatórios em termos de estatísticas de desempenho;
- ii) a implementação do AMALGAM permitiu conduzir comparações em relação ao SCE-UA, e apresentou ligeira superioridade nas calibrações e validações, em função das FOs utilizadas;
- iii) não houve grandes diferenças entre os cenários 1 e 2, configurando a necessidade de realizar estudo futuros acerca da distribuição dos outros parâmetros do LASH além dos utilizados no cenário 2;
- iv) a utilização do AMALGAM tem potencial para diminuir as incertezas e equifinalidade relacionadas aos parâmetros calibráveis do LASH; e
- v) a formulação do LASH em MATLAB® trouxe excelentes ganhos, em termos de execução computacional, para o modelo, com tempos de processamento de cerca de 2h para o cenário 1, e 40h para o cenário 2.

5 Considerações finais

Por fim, apresenta-se uma síntese de contribuições desse estudo, sendo:

- i) a implementação do LASH em MATLAB®;
- ii) a melhoria do módulo de propagação de vazões em rios;
- iii) o acoplamento a um algoritmo multiobjetivo, o AMALGAM;
- iv) a calibração dos parâmetros de forma distribuída (cenário 2); e
- v) a melhoria significativa no tempo de execução do LASH (cerca de 30x mais rápido).

Referências

- AJAMI, N, K. *et al.* Calibration of a semi-distributed hydrologic model for streamflow estimation along a river system. **Journal of hydrology**, v. 298, n. 1-4, p. 112-135, 2004. DOI: 10.1016/j.jhydrol.2004.03.033.
- ALLEN, R. G *et al.* **Crop evapotranspiration - Guidelines for computing crop water requirements - FAO Irrigation and drainage paper 56**. Rome: FAO, 1998. 300 p.
- ALTMAN, Y. M. **Accelerating MATLAB Performance: 1001 tips to speed up MATLAB programs**. CRC Press, 2014.
- ANDRADE, N. P.V. *et al.* Assessment of Spatial and Temporal Soil Water Storage Using a Distributed Hydrological Model. **Water Resources Management**, v. 34, n. 15, p. 5031-5046, 2020. DOI: 10.1007/s11269-020-02711-4.
- ANDREW, R.; DYMOND, J. A distributed model of water balance in the Motueka catchment, New Zealand. **Environmental Modelling & Software**, v. 22, n. 10, p. 1519-1528, 2007. DOI: 10.1016/j.envsoft.2006.10.006.
- ARABI, M.; GOVINDARAJU, R. S.; HANTUSH, Mohamed M. A probabilistic approach for analysis of uncertainty in the evaluation of watershed management practices. **Journal of Hydrology**, v. 333, n. 2-4, p. 459-471, 2007. DOI: 10.1016/j.jhydrol.2006.09.012.
- ARNOLD, J. G *et al.* Large area hydrologic modeling and assessment: part I: model development. **Journal of American Water Resources Association**, v. 34, n. 1, p. 73-89, 1998. DOI: 10.1111/j.1752-1688.1998.tb05961.x.
- ASADZADEH, M.; TOLSON, B. Pareto archived dynamically dimensioned search with hypervolume-based selection for multi-objective optimization. **Engineering Optimization**, v. 45, n. 12, p. 1489-1509, 2013. DOI: 10.1080/0305215X.2012.748046.
- BAPTISTA, M. B; LARA, M. **Fundamentos de engenharia hidráulica**. Belo Horizonte: UFMG, 2014.
- BARROS, Claudia Alessandra Peixoto de *et al.* **Dinâmica dos escoamentos na modelagem da produção de sedimentos em uma pequena bacia rural**. 2016. Tese de Doutorado. Universidade Federal de Santa Maria.
- BATHURST, J. *et al.* Forest impact on floods due to extreme rainfall and snowmelt in four Latin American environments 2: Model analysis. **Journal of Hydrology**, v. 400, n. 3-4, p. 292-304, 2011. DOI: 10.1016/j.jhydrol.2010.09.001.
- BERGER, R. *et al.* Índices de vegetação para a estimativa do índice de área foliar em plantios clonais de *Eucalyptus saligna* Smith. **Ciência Florestal**, v. 29, n. 2, p. 885-899, 2019. DOI: 10.5902/1980509816942.

BESKOW, S *et al.* Performance of a distributed semi-conceptual hydrological model under tropical watershed conditions. **Catena**, v. 86, p. 160–171, 2011. DOI: 10.1016/j.catena.2011.03.010.

BESKOW, S. **LASH Model: a hydrological simulation tool in GIS framework**. 2009. 118p. Tese (Doutorado em Engenharia Agrícola). Universidade Federal de Lavras. Lavra, Minas Gerais.

BESKOW, S. *et al.* 2016. Potential of the LASH model for water resources management in data-scarce basins: a case study of the Fragata River basin, Southern Brazil. **Hydrological Sciences Journal**, v. 61, p. 2567–2578, 2016. DOI: 10.1080/02626667.2015.1133912.

BESKOW, S.; MELLO, C. R.; NORTON, L. D. Development, sensitivity and uncertainty analysis of LASH model. **Scientia Agricola**, v. 68, p. 265–274, 2011. DOI: 10.1590/S0103-90162011000300001.

BESKOW, S.; NORTON, L.D.; MELLO, C.R. Hydrological prediction in a tropical watershed dominated by oxisols using a distributed hydrological model. **Water Resources Management**, v. 27, p. 341–363, 2013. DOI: 10.1007/s11269-012-0189-8.

BEVEN, K.; BINLEY, A. The future of distributed models: model calibration and uncertainty prediction. **Hydrological processes**, v. 6, n. 3, p. 279-298, 1992. DOI: 10.1002/hyp.3360060305.

BEVEN, K. J.; KIRKBY, M. J. A physically-based, variable contributing area model of basin hydrology. **Hydrological Sciences Bulletin**, v. 24, n. 1, p. 43-69, 1979. DOI: 10.1080/02626667909491834.

BOUSSAÏD, I.; LEPAGNOT, J.; SIARRY, Patrick. A survey on optimization metaheuristics. **Information sciences**, v. 237, p. 82-117, 2013. DOI: 10.1016/j.ins.2013.02.041.

BRASIL. Ministério das Minhas e Energia. Secretaria Geral. Projeto RADAMBRASIL: Folhas SH. 21/22. Uruguaiana/Porto Alegre; geologia, geomorfologia, pedologia, vegetação e uso potencial da terra. 1981.

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**, v. 14, n. 3, p. 37-50, 2009.

BROCCA, L. *et al.* Investigation of the hydrologic response of three experimental basins across Europe. **Die Bodenkultur**, v. 31, n. 62, p. 1-4, 2011. Disponível em: <http://hydrology.irpi.cnr.it/download-area/midsc-code/>.

CALDEIRA, T. L. 2016. **Aprimoramento computacional do modelo Lavras Simulation of Hydrology (LASH): aplicação em duas bacias do Rio Grande do Sul** (Dissertação de Mestrado, Universidade Federal de Pelotas). 2016. 247f

Dissertação (Mestrado em Engenharia) – Programa de Pós-Graduação em Recursos Hídricos, Universidade Federal de Pelotas, Pelotas, 2016.

CALDEIRA, T. L. **Impacto das mudanças climáticas sobre a hidrologia de sub-bacias da bacia hidrográfica Mirim-São Gonçalo**. 2019. 243f. Tese (Doutorado em Ciências) – Programa de Pós-Graduação em Manejo e Conservação do Solo e da Água, Universidade Federal de Pelotas, Pelotas, 2019.

CALDEIRA, T. L. *et al.* LASH hydrological model: an analysis focused on spatial discretization. **Catena**, v. 173, p. 183-193, 2019. DOI: 10.1016/j.catena.2019.10.009.

CALDEIRA, T. L. *et al.* Modelagem hidrológica determinística chuva-vazão em bacias hidrográficas: uma abordagem introdutória. **Revista Brasileira de Engenharia e Sustentabilidade**, v. 5, n. 1, p. 22-32, 2018. DOI: 10.15210/RBES.V5I1.13231.

CASTRO, R. E. **Inteligência artificial: algoritmos genéticos na prática**. 323p. 2018.

CAVALCANTI, R.; BRAVO, J. M. Influência da distribuição de probabilidade na geração de soluções candidatas iniciais para calibração automática de modelos hidrológicos. In *Anais do XX Simpósio Brasileiro de Recursos Hídricos*, 2013.

CGBHRC. Comitê de Gerenciamento da Bacia Hidrográfica do Rio Camaquã. A bacia hidrográfica, 2019. Disponível em: <<http://www.comitecamaqua.com/index.php/a-bacia-hidrografica/caracterizacao-geral>>.

COELLO, C. C.; LECHUGA, M. S. MOPSO: A proposal for multiple objective particle swarm optimization. In *Proceedings of the 2002 Congress on Evolutionary Computation. CEC'02 (Cat. No. 02TH8600)* (Vol. 2, pp. 1051-1056), 2002. DOI: 10.1109/CEC.2002.1004388.

COLLISCHONN, W. 2001. **Simulação Hidrológica de Grandes Bacias. Tese (Doutorado em Engenharia)**. Universidade Federal do Rio Grande do Sul. Porto Alegre, p. 194.

COLLISCHONN, W. *et al.* The MGB-IPH model for large-scale rainfall—runoff modelling. **Hydrological Sciences Journal**, v. 52, n. 5, p. 878-895, 2007. DOI: 10.1623/hysj.52.5.878.

CORDEIRO, J.L.P.; HASENACK, H.; WEBER, E.J. **Mosaico de imagens de satélite Landsat do Estado do Rio Grande do Sul – ano base 2002**. Porto Alegre: UFRGS IB Centro de Ecologia, 2015. 1a ed. ISBN 978-85-63843-17-3. Disponível em: <http://www.ufrgs.br/labgeo>.

CORREIA, F. W.; ALVALÁ, R.; MANZI, A. Distribuição sazonal e global da umidade do solo para inicialização em modelos numéricos de previsão de tempo e clima. In: **XIII congresso Brasileiro de Meteorologia**. 2004.

CPRM. Companhia de Pesquisa de Recursos Minerais. Mapa Hidrogeológico do Estado do Rio Grande do Sul, Porto Alegre, 2005,

CUNGE, J. A. On the subject of a flood propagation computation method (Muskingum method). **Journal of Hydraulic Research**, v, 7, n, 2, p, 205-230, 1969.

CUNHA, N. G. *et al.* **Estudo dos solos do município de Camaquã**. Pelotas: EMBRAPA/CPACT, 2000. 99 p.

CUNHA, N. G.; SILVEIRA, R. J. C.; SEVERO, C. R. S. **Estudo dos solos das regiões do planalto sul-rio-grandense e planícies costeiras**. Pelotas: EMBRAPA/CPACT, 2006a. 43 p.

CUNHA, N. G.; SILVEIRA, R. J. C.; SEVERO, C. R. S. **Estudo dos solos do município de Encruzilhada do Sul**. Pelotas: EMBRAPA/CPACT, 2005. 83 p.

CUNHA, N. G.; SILVEIRA, R. J. C.; SEVERO, C. R. S. **Estudo dos solos do município de São Lourenço do Sul**. Pelotas: EMBRAPA/CPACT, 2006b. 47 p.

DE ROO, A. P. J.; WESSELING, C. G.; RITSEMA, C. J. LISEM: a single-event physically based hydrological and soil erosion model for drainage basins. I: theory, input and output. **Hydrological Processes**, v. 10, n. 8, p. 1107-1117, 1996. DOI: 10.1002/(SICI)1099-1085(199608)10:8<1107::AID-HYP415>3.0.CO;2-4

DEB, Kalyanmoy. Multi-objective optimisation using evolutionary algorithms: an introduction. *In: Multi-objective evolutionary optimisation for product design and manufacturing*. Springer, London, 2011. p. 3-34.

DEB, K. *et al.* A fast and elitist multiobjective genetic algorithm: NSGA-II. **IEEE transactions on evolutionary computation**, v. 6, n. 2, p. 182-197, 2002. DOI: 10.1109/4235.996017.

DEVIA, G. K.; GANASRI, B. P.; DWARAKISH, G. S. A review on hydrological models. **Aquatic Procedia**, v. 4, p. 1001-1007, 2015. DOI: 10.1016/j.aqpro.2015.02.126.

DUAN, Q. Global optimization for watershed model calibration. **Calibration of watershed models**, v. 6, p. 89-104, 2003.

DUAN, QINGYUN. Shuffled Complex Evolution (SCE-UA) Method, MATLAB Central File Exchange. Retrieved July 8, 2020. 2004.

Disponível em: <https://www.mathworks.com/matlabcentral/fileexchange/7671-shuffled-complex-evolution-sce-ua-method>.

DUAN, Q.; SOROOSHIAN, S.; GUPTA, V. Effective and Efficient Global Optimization for Conceptual Rainfall-Runoff Models. **Water Resources Research**, v. 28, n. 4, p. 1015-1031, 1992. DOI: 10.1029/91WR02985.

DUAN, Q.; SOROOSHIAN, S.; GUPTA, V. Optimal use of the SCE-UA global optimization method for calibrating watershed models. **Journal of hydrology**, v. 158, n. 3-4, p. 265-284, 1994. DOI: 10.1016/0022-1694(94)90057-4.

DUAN, Q.; SOROOSHIAN, S.; GUPTA, V. Shuffled complex evolution approach for effective and efficient global minimization. **Journal of optimization theory and applications**, v. 76, n. 3, p. 501-521, 1993.

EFSTRATIADIS, A; KOUTSOYIANNIS, D. One decade of multi-objective calibration approaches in hydrological modelling: a review. **Hydrological Sciences Journal–Journal Des Sciences Hydrologiques**, v. 55, n. 1, p. 58-78, 2010. DOI: 10.1080/02626660903526292.

ESRI. Environmental Systems Research Institute, 2014.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Serviço Nacional de Levantamento e Conservação de Solos. Súmula da 10. Reunião Técnica de Levantamento de Solos**. Empresa Brasileira de Pesquisa Agropecuária. Rio de Janeiro. 1979.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Sistema brasileiro de classificação de solos**. Centro Nacional de Pesquisa de Solos: Rio de Janeiro, 2014.

FAGUNDES, J. L. *et al.* Características morfogênicas e estruturais do capim-braquiária em pastagem adubada com nitrogênio avaliadas nas quatro estações do ano. **Revista Brasileira de Zootecnia**, v. 35, n. 1, p. 21-29, 2006.

FONSECA, C.; FLEMING, P. Genetic Algorithms for Multiobjective Optimization: Formulation, Discussion and Generalization. *In*: Forrest, S., ed. Proceedings of the Fifth International Conference on Genetic Algorithms, University of Illinois, p. 416–423, 1993.

FRANCOIS. HMETs hydrological model. MATLAB Central File Exchange, 2016. Disponível em: <https://www.mathworks.com/matlabcentral/fileexchange/48069-hmets-hydrological-model>.

FREITAS, M. A. S.; FREITAS, G. B. **Inteligência artificial e machine learning: teoria e aplicações**. 2020.

GAMA – Engenharia e Recursos Hídricos. Serviços de Consultoria Relativos ao Processo de Planejamento da Bacia Hidrográfica do Camaquã Fases A, B e C. Relatório final e síntese. Secretaria do Ambiente e Desenvolvimento Sustentável, 2016.

GALVÃO, C. O *et al.* **Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais**. Editora da UFRGS. 1999.

GIAROLA, N. F. B.; SILVA, A. P.; IMHOFF, S. Relações entre propriedades físicas e características de solos da região sul do Brasil. **Revista Brasileira de Ciência do Solo**, v. 26, n. 4, p. 885-893, 2002.

GIONGO, R.; PADOVANI, R.; VETTORAZZI, A. Variabilidade espacial e temporal do albedo obtido a partir de imagens MODIS na região do Pantanal. *In* Simpósio Brasileiro de Sensoriamento Remoto, XIV, Natal-RN. CD de Anais, 2009.

GUILHON, L. G. F.; ROCHA, V. F. Comparação dos métodos de previsão de vazões naturais afluentes a aproveitamentos hidrelétricos. **Revista Brasileira de Recursos Hídricos**, v. 12, n. 3, p. 13-20, 2007.

GUPTA, H.V.S.; SOROOSHIAN, S.; YAPO, P.O. Status of automatic calibration for hydrologic models: comparison with multilevel expert calibration. **Journal of Hydrologic Engineering**, v. 4, n. 2, p. 135-143, 1999. DOI: 10.1061/(ASCE)1084-0699(1999)4:2(135).

HAARIO, H.; SAKSMAN, E.; TAMMINEN, J. An adaptive Metropolis algorithm. **Bernoulli**, v. 7, n. 2, p. 223-242, 2001.

HASENACK, H.; CORDEIRO, J.L.P; WEBER, E.J. (Org.). **Uso e cobertura vegetal do Estado do Rio Grande do Sul – situação em 2002**. Porto Alegre: UFRGS IB Centro de Ecologia, 2015. 1a ed. ISBN 978-85-63843-15-9. Disponível em: <http://www.ecologia.ufrgs.br/labgeo>

HER, Y.; CHAUBEY, I. Impact of the numbers of observations and calibration parameters on equifinality, model performance, and output and parameter uncertainty. **Hydrological Processes**, v. 29, n. 19, p. 4220-4237, 2015. doi: 10.1002/hyp.10487. DOI: 10.1002/hyp.10487.

HER, Y.; SEONG, C. Responses of hydrological model equifinality, uncertainty, and performance to multi-objective parameter calibration. **Journal of Hydroinformatics**, v. 20, n. 4, p. 864-885, 2018. DOI: 10.2166/hydro.2018.108.

HESSEL, R. *et al.* Soil erosion simulations of land use scenarios for a small Loess Plateau catchment. **Catena**, v. 54, n. 1-2, p. 289-302, 2003. DOI: 10.1016/S0341-8162(03)00070-5.

HOLLAND, J.H. **Adaptation in natural and artificial systems**, University of Michigan Press, Ann Arbor, Michigan, 1975.

HORN, J. F. C. **Estimativa de vazão com dados escassos: novas hipóteses para o método Silveira**. 2016. 540f. Tese de Doutorado (Doutorado em Engenharia Agrícola) – Programa de Pós-Graduação em Engenharia Agrícola, Universidade Federal de Santa Maria, Santa Maria, 2016.

HRL. HBV-EDU Hydrologic Model. MATLAB Central File Exchange, 2013. Disponível em: <https://www.mathworks.com/matlabcentral/fileexchange/41395-hbv-edu-hydrologic-model>.

HUO, J.; LIU, L. Evaluation Method of Multiobjective Functions' Combination and Its Application in Hydrological Model Evaluation. **Computational Intelligence and Neuroscience**, 2020. DOI: 10.1155/2020/8594727.

JETTEN, V. **LISEM user manual, version 4.96x**. Utrech: Utrecht University, 2018. 255p.

JULIÀ, M. F.; MONREAL, T. E.; DEL CORRAL JIMÉNEZ, A. S.; MELÉNDEZ, E. G. Constructing a saturated hydraulic conductivity map of Spain using pedotransfer functions and spatial prediction, **Geoderma**, v. 123, n. 3-4, p. 257-277, 2004. DOI: 10.1016/j.geoderma.2004.02.011.

KENDALL, M. G. Rank correlation methods. 4th ed. London: Charles Griffin, 1975.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: **Proceedings of ICNN'95-International Conference on Neural Networks**. IEEE, 1995. p. 1942-1948. DOI: 10.1109/ICNN.1995.488968.

KLEMEŠ, V. Operational testing of hydrological simulation. **Hydrological Sciences Journal**, v. 31, n. 1, p. 13-24, 1986. DOI: 0.1080/0262668609491024.

KOLLAT, J. B.; REED, P. M. Comparing state-of-the-art evolutionary multi-objective algorithms for long-term groundwater monitoring design. **Advances in Water Resources**, v. 29, n. 6, p. 792-807, 2006. DOI: 10.1016/j.advwatres.2005.07.010.

KOUCHI, D. H. *et al.* Sensitivity of calibrated parameters and water resource estimates on different objective functions and optimization algorithms. **Water**. v. 9, n. 6, p. 384, 2017. DOI: 10.3390/w9060384.

LEE, T. Mann-Kendall with Missing Values and Same Values MATLAB Central File Exchange, 2019.

Disponível em: <https://www.mathworks.com/matlabcentral/fileexchange/70408-mann-kendall-with-missing-values-and-same-values>.

LEGATES, D. R.; MCCABE JR, G. J. Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. **Water Resources Research**, v. 35, n. 1, p. 233-241, 1999.

LIECHTI, T. *et al.* Hydraulic–hydrologic model for water resources management of the Zambezi basin. **Journal of Applied Water Engineering and Research**, v. 2, n. 2, p. 105-117, 2014. DOI: 10.1080/23249676.2014.958581.

LIGHTHILL, M. J; WHITHAM, G. B. On kinematic waves I. Flood movement in long rivers. **Proceedings of the Royal Society of London. Series A. Mathematical and Physical Sciences**, v. 229, n. 1178, p. 281-316, 1955a. DOI: 10.1098/rspa.1955.0088.

LIGHTHILL, M. J; WHITHAM, G. B. On kinematic waves II. A theory of traffic flow on long crowded roads. **Proceedings of the Royal Society of London. Series A.**

Mathematical and Physical Sciences, v. 229, n. 1178, p. 317-345, 1955b. DOI: 10.1098/rspa.1955.0089.

LOPES, V. A. R. **Modelagem hidrológica integrada da bacia hidrográfica da Laguna dos Patos e seus complexos lagunares usando o modelo MGB-IPH com propagação inercial de vazões**. 2015. 84f. Trabalho de Conclusão de Curso. Bacharelado em Engenharia Ambiental. Universidade Federal do Rio Grande do Sul, Porto Alegre.

LOPES, V. A. R. *et al.* A first integrated modelling of a river-lagoon large-scale hydrological system for forecasting purposes. **Journal of hydrology**, v. 565, p. 177-196, 2018. DOI: 10.1016/j.jhydrol.2018.08.011.

LUSZCZEK, P. Parallel programming in MATLAB. **The International Journal of High-Performance Computing Applications**, v. 23, n. 3, p. 277-283, 2009. DOI: 10.1177/1094342009106194

MANN, H. B. Non-parametric test against trend. *Econometrica*, v.13, n. 3, p. 245-259, 1945.

MATLAB – MATrix LABoratory. The Mathworks, 2019. Disponível em: <https://www.mathworks.com>

MELLO, C. R. *et al.* Development and application of a simple hydrologic model simulation for a Brazilian headwater basin. *Catena*, v. 75, n. 3, p. 235-247, 2008. DOI: 10.1016/j.catena.2008.07.002.

MELLO, C. R. D.; SILVA, A. M. D. *Hidrologia: princípios e aplicações em sistemas agrícolas*. 1ª Ed. Lavras: UFLA, 2013. 455 p. ISBN 9788581280296.

MIRANDA, A. C. *et al.* **Carbon dioxide fluxes over a cerrado sensu stricto in central Brazil**. In: GASH, J. H. C., *et al.* Amazonian deforestation and climate. New York: Wiley, 1996. p. 353-364.

MISHRA, S. K. *et al.* A modified SCA-CN method: Characterization and testing. **Water Resources Management**, v. 17, n. 1, p. 37-68, 2003. DOI:10.1023/A:1023099005944.

MORAES, A. N. M. **Critério de estabilidade de um esquema explícito em diferenças finitas para o modelo de placas de Mindlin-Timoshenko**. 2019. 63f. Dissertação (Mestrado em Matemática) – Programa de Pós-Graduação em Matemática e Estatística, Universidade Federal do Pará, Belém, 2018.

MORIASI, D. N *et al.* Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. **Trans. ASABE**, v. 50, n. 3, p. 885-900, 2007. DOI: 10.13031/2013.23153.

MORIASI, D. N *et al.* Hydrologic and water quality models: Performance measures and evaluation criteria. **Transactions of the ASABE**, v. 58, n. 6, p. 1763-1785, 2015. DOI: 10.13031/trans.58.10715.

NAEINI, M. R. *et al.* Three decades of the Shuffled Complex Evolution (SCE-UA) optimization algorithm: Review and applications. **Scientia Iranica**, v. 26, n. 4, p. 2015-2031, 2019. DOI: 10.24200/sci.2019.21500.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models I: a discussion of principles. **Journal of Hydrology**, v. 10, n. 3, p. 282-298, 1970. DOI: 10.1016/0022-1694(70)90255-6.

NELDER, J. A.; MEAD, R. A simplex method for function minimization. **The computer journal**, v. 7, n. 4, p. 308-313, 1965. DOI: 10.1093/comjnl/7.4.308.

NEMRI, S.; KINNARD, C. Comparing calibration strategies of a conceptual snow hydrology model and their impact on model performance and parameter identifiability. **Journal of Hydrology**, v. 582, p. 124474, 2020. DOI: 10.1016/j.jhydrol.2019.124474.

OTTONI, M. V. *et al.* Hydrophysical database for Brazilian soils (HYBRAS) and pedotransfer functions for water retention. **Vadose Zone Journal**, v.17, n.1, 170095, 2018. DOI: 10.2136/vzj2017.05.0095.

Paiva, R. 2007. Método de propagação baseado na Onda Cinemática.

PEREIRA, D.R. *et al.* Hydrological simulation in a basin of typical tropical climate and soil using the SWAT model part I: Calibration and validation tests. **Journal of Hydrology: Regional Studies**, v. 7, p. 14-37, 2016. DOI: 10.1016/j.ejrh.2016.05.002.

PIOTROWSKI, A. P. *et al.* Are modern metaheuristics successful in calibrating simple conceptual rainfall-runoff models? **Hydrological Sciences Journal**, v. 62, n. 4, p. 606-625, 2017. DOI: 10.1080/02626667.2016.1234712.

PONCE, V. M. **Engineering hydrology: Principles and practices**. Englewood Cliffs, NJ: Prentice Hall, 1989.

PONCE, V. M. Kinematic wave controversy. **Journal of Hydraulic Engineering**, v. 117, n. 4, p. 511-525, 1991. DOI: 10.1061/(ASCE)0733-9429(1991)117:4(511).

PONTES, L. M. *et al.* Hydrological modeling of tributaries of cantareira system, Southeast Brazil, with the Swat model. **Engenharia Agrícola**, v. 36, n. 6, p. 1037-1049, 2016. DOI: 10.1590/1809-4430-eng.agric.v36n6p1037-1049/2016.

PORCIÚNCULA, G. S *et al.* Estudo para avaliação e revitalização do perímetro de irrigação do Arroio Duro. **Expressa Extensão**, v. 24, n. 3, p. 161-176, 2019. DOI: 10.15210/EEV12413.16268.

PRECHELT, L. An empirical comparison of seven programming languages. **Computer**, v. 33, n. 10, p. 23-29, 2000. DOI: 10.1109/2.876288.

RAWLS, W. J. *et al.* Infiltration and soil water movement. In: MAIDMENT, D. R. **Handbook of hydrology**. New York: McGraw-Hill, 1993. Cap. 50-07-039732-5, p. 1-51.

REFSGAARD, J.C.; STORM, B. Computer Models of Watershed Hydrology. In: Singh, V.P., (Ed.), **Water Resources Publication**, p. 809–846, 1995.

REICHARDT, K. **A água em sistemas agrícolas**. São Paulo: Manole, 1990. 188p.
 RENNÓ, C. D.; SOARES, J. V. **Conceitos Básicos de Modelagem Hidrológica**. In: Margareth Simões Penello Meirelles; Gilberto Camara; Cláudia Maria de Almeida. (Org.). **Geomática: Modelos e Aplicações Ambientais**. 1ed. Brasília: Embrapa Informação Tecnológica, 2007, v. 11, p. 529-556.

ROCHA, Henrique Lucini. **Propagação de onda de cheia em canais simplificados: Estudo comparativo de modelo hidrodinâmico e Muskingum-Cunge**. 2008. 38p. Trabalho de Conclusão de Curso. Bacharelado em Engenharia Sanitária e Ambiental. Universidade Federal de Santa Catarina, Florianópolis.

RODRIGUES, A. A. *et al.* Tendências temporais em séries de chuva e vazão na bacia hidrográfica do rio Camaquã. *In* Congresso Internacional de Engenharia Ambiental & 10ª Reunião de Estudos Ambientais, 2020.

ROMANOWICZ, R. A MATLAB implementation of TOPMODEL. **Hydrological processes**, v. 11, n. 9, p. 1115-1129, 1997. DOI: 10.1002/(SICI)1099-1085(199707)11:9<1115::AID-HYP548>3.0.CO;2-T.

RUHOFF, A. *et al.* Assessment of the MODIS global evapotranspiration algorithm using eddy covariance measurements and hydrological modelling in the Rio Grande basin. **Hydrological Sciences Journal**, v. 58, n. 8, p. 1658-1676, 2013. DOI: 10.1080/02626667.2013.837578.

SADEGH, M. *et al.* 2019, A Multi-Model Nonstationary Rainfall-Runoff Modeling Framework: Analysis and Toolbox. **Water Resources Management**, 33(9), 3011-3024. Disponível em: <http://amir.eng.uci.edu/software.php>. DOI: 10.1007/s11269-019-02283-y.

SANTOS, R. R.; MOURA, M. M.; CALDEIRA, T. L.; VIOLA, M. R.; MELLO, C. R.; BESKOW, S. Aprimoramentos computacionais da ferramenta ArcLASH. *In* **Anais XXVIII Congresso de Iniciação Científica da Universidade Federal de Pelotas**, 2019.

SARTORI, A.; LOMBARDI, F. N.; GENOVEZ, A. M. Classificação hidrológica de solos brasileiros para a estimativa da chuva excedente com o método do Serviço de Conservação do Solo dos Estados Unidos Parte 1: Classificação. **Revista Brasileira de Recursos Hídricos**, v. 10, n. 4, p. 05-18, 2005.

SCS. **National Engineering Handbook**. Washington: Soil Conservation Service/USDA, 1971.

SEIBERT, J.; STAUDINGER, M.; VAN MEERVELD, H. I. Validation and Over-Parameterization—Experiences from Hydrological Modeling. In: **Computer Simulation Validation**. Springer, Cham, 2019. p. 811-834.

SCHAEFLI, B. SEHR-ECHO v1.0: a Spatially Explicit Hydrologic Response model for ecohydrologic applications. MATLAB Central File Exchange, 2015.
Disponível em: <https://www.mathworks.com/matlabcentral/fileexchange/48626-sehr-echo-v1-0-a-spatially-explicit-hydrologic-response-model-for-ecohydrologic-applications>.

SINGH, J. *et al.* Hydrological modeling of the Iroquois river watershed using HSPF and SWAT 1. **Journal of the American Water Resources Association**, v. 41, n. 2, p. 343-360, 2005. DOI: 10.1111/j.1752-1688.2005.tb03740.x.

SLATER, L. J. *et al.* Using R in hydrology: a review of recent developments and future directions. **Hydrology and Earth System Sciences**, v. 23, n. 7, p. 2939-2963, 2019. DOI: 10.5194/hess-23-2939-2019.

SOARES, M. F. **Variabilidade espacial dos atributos físico-hídricos e do carbono orgânico do solo de uma bacia hidrográfica de cabeceira em Canguçu – RS**. Dissertação (Mestrado em Recursos Hídricos). Universidade Federal de Pelotas. Pelotas, p. 102. 2017.

SONG, J. *et al.* Simulink implementation of a hydrologic model: A Tank model case study. **Water**, v. 9, n. 9, p. 639, 2017.

STORN, R.; PRICE, K. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. **Journal of Global Optimization**, v. 11, n. 4, p. 341-359, 1997. DOI: 10.1023/A:1008202821328.

TRIANA, J. S. A. *et al.* Beyond model metrics: The perils of calibrating hydrologic models. **Journal of Hydrology**, v. 578, p. 124032, 2019. DOI: 10.1016/j.jhydrol.2019.124032.

TUCCI, C. E. M. **Modelos Hidrológicos**. 2ª. ed. Porto Alegre: UFRGS/ABRH, 2005. 678 p. ISBN 9788570258236.

USACE – US Army Corps of Engineers. Hec-GeoHMS Geospatial Hydrologic Modeling Extension. User's manual. 2013.

VARGAS, M. M *et al.* Alternativas computacionais para otimização dos parâmetros da IDF: abordagem inicial. In *Anais do XXIII Simpósio Brasileiro de Recursos Hídricos*, 2019a.

VARGAS, M. M *et al.* SYHDA—System of Hydrological Data Acquisition and Analysis. **Revista Brasileira de Recursos Hídricos**, v. 24, 2019b. DOI: 10.1590/2318-0331.241920180152.

VARGAS, Marcelle Martins. **Estimativa de hidrogramas de cheias utilizando o modelo hidrológico LISEM: estudo de caso em sub-bacia do arroio Pelotas**

(Rio Grande do Sul). 2018. 78p. Trabalho de Conclusão de Curso. Bacharelado em Engenharia Hídrica. Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, Pelotas.

VIOLA, M. R. 2008. **Simulação hidrológica na região do Alto Rio Grande a montante do Reservatório de Camargos/CEMIG**. Dissertação (Mestrado em Engenharia Agrícola). Universidade Federal de Lavras. Lavras, p. 120.

VIOLA, M.R. *et al.* Impacts of land-use changes on the hydrology of the Grande river basin headwaters, Southeastern, Brazil. **Water Resources Management**, v. 28, p. 4537–4550, 2014. DOI: 10.1007/s11269-014-0749-1.

VRUGT, J. A. Multi-criteria optimization using the AMALGAM software package: Theory, concepts, and MATLAB implementation. Manual, Version, 1, p. 1-53, 2016.

VRUGT, J. A. Comment on" How effective and efficient are multiobjective evolutionary algorithms at hydrologic model calibration?" by Y. Tang et al., Hydrology and Earth System Sciences Discussions, 10, 289? 307, 2006. **Hydrology and Earth System Sciences Discussions**, v. 4, n. 1, p. 179-182, 2007.

VRUGT, J. A. *et al.* A Shuffled Complex Evolution Metropolis algorithm for optimization and uncertainty assessment of hydrologic model parameters. **Water Resources Research**, v. 39, n. 8, 2003b. DOI: 10.1029/2002WR001642.

VRUGT, J. A. *et al.* Effective and efficient algorithm for multiobjective optimization of hydrologic models. **Water Resources Research**, v. 39, n. 8, 2003a. DOI: 10.1029/2002WR001746.

VRUGT, J. A. *et al.* Treatment of input uncertainty in hydrologic modeling: Doing hydrology backward with Markov chain Monte Carlo simulation. **Water Resources Research**, v. 44, n. 12, 2008. DOI: 10.1029/2007WR006720.

VRUGT; J. A.; ROBINSON, B. A. Improved evolutionary optimization from genetically adaptive multimethod search. **Proceedings of the National Academy of Sciences**, v. 104, n. 3, p. 708-711, 2007. DOI: 10.1073/pnas.0610471104.

WIEKENKAMP, Inge. **Possibilities and limitations of using global search algorithms for Electrical Resistivity Tomography (ERT) inversion**. Master Thesis. Earth Sciences, University of Amsterdam. 2012.

WÖHLING, T.; SAMANIEGO, L.; KUMAR, R. Evaluating multiple performance criteria to calibrate the distributed hydrological model of the upper Neckar catchment. **Environmental Earth Sciences**, v. 69, n. 2, p. 453-468, 2013. DOI: 10.1007/s12665-013-2306-2.

XIE, K. *et al.* Identification of spatially distributed parameters of hydrological models using the dimension-adaptive key grid calibration strategy. **Journal of Hydrology**, p. 125772, 2020.

YAPO, P.; GUPTA, H.; SOROOSHIAN, S. Multi-objective global optimization for

hydrologic models. **Journal of hydrology**, v. 204, n. 1-4, p. 83-97, 1998. DOI: 10.1016/S0022-1694(97)00107-8.

ZHANG, R. *et al.* Can multi-objective calibration of streamflow guarantee better hydrological model accuracy? **Journal of Hydroinformatics**, v. 20, n. 3, p. 687-698, 2018.

ZHANG, X.; SRINIVASAN, R.; LIEW, M. On the use of multi-algorithm, genetically adaptive multi-objective method for multi-site calibration of the SWAT model. **Hydrological Processes: An International Journal**, v. 24, n. 8, p. 955-969, 2010.