

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



Tese

R-LASH: implementação e aplicação do modelo hidrológico em linguagem R

Maíra Martim de Moura

Pelotas, 2023.

MAÍRA MARTIM DE MOURA

R-LASH: implementação e aplicação do modelo hidrológico em linguagem R

Tese apresentada ao Programa de Pós-Graduação em Recursos Hídricos da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Doutora em Recursos Hídricos.

Orientador: Prof. Dr. Samuel Beskow

Pelotas, 2023.

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação na Publicação

M929r Moura, Maíra Martim de

R-Lash : implementação e aplicação do modelo hidrológico em linguagem R / Maíra Martim de Moura ; Samuel Beskow, orientador. — Pelotas, 2023.

142 f.

Tese (Doutorado) — Programa de Pós-Graduação em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, 2023.

1. Módulo Arclash. 2. Algoritmo multiobjetivo. 3. Calibração automática. 4. Gestão de recursos hídricos. I. Beskow, Samuel, orient. II. Título.

CDD : 627

Maíra Martim de Moura

R-LASH: implementação e aplicação do modelo hidrológico em linguagem R

Tese aprovada, como requisito parcial, para obtenção do grau de Doutora em Recursos Hídricos, Programa de Pós-Graduação em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas.

Data da Defesa: 02/03/2023

Banca examinadora:

.....
Prof. Dr. Samuel Beskow (Orientador)
Doutor em Recursos Hídricos em Sistemas Agrícolas pela Universidade Federal de Lavras

.....
Prof.^a Dr.^a Lívia Alves Alvarenga
Doutora em Recursos Hídricos em Sistemas Agrícolas pela Universidade Federal de Lavras

.....
Prof. Dr. Marilton Sanhotene de Aguiar
Doutor em Ciência da Computação pela Universidade Federal do Rio Grande do Sul

.....
Prof.^a Dr.^a Danielle de Almeida Bressiani
Doutora em Engenharia Hidráulica e Saneamento pela Universidade de São Paulo

Agradecimentos

Ao meu orientador Prof. Dr. Samuel Beskow pela competência e excelência com que atua, pelo conhecimento compartilhado, pela orientação, dedicação acolhimento e motivação ao longo destes últimos anos.

Aos professores Hugo Alexandre Soares Guedes, Fabricio da Silva Terra e Tamara Leitzke Caldeira Beskow pela contribuição em minha formação como hidróloga, pelos conhecimentos e experiências compartilhadas.

Ao Grupo de Pesquisa em Hidrologia e Modelagem Hidrológica em Bacias Hidrográficas pelas oportunidades e pelo conhecimento compartilhado.

Aos meus pais, José e Rosane, por nunca me deixarem desistir e por acreditarem em todos meus sonhos e planos. Aos meus irmãos Cinara e Henrique por me apoiarem ao longo dessa caminhada, servindo de exemplo e inspiração.

Ao meu namorado e amigo Francisco Mazzarolo Seger, pelo carinho, apoio, compreensão e ajuda durante esta etapa. Por me inspirar em busca do desconhecido, me fazer sentir orgulho do que faço, de quem sou, compartilhando comigo bons e maus momentos, conhecimentos adquiridos e inúmeras madrugadas em claro.

Às melhores colegas de vida, Marcelle e Zandra, por toda a amizade, motivação e ajuda ao longo deste trabalho e de outros que foram e vem sendo desenvolvidos em conjunto. Sem vocês, nada disso seria possível. Ao João Pedro e ao Rafael, pelo apoio durante a realização deste trabalho.

Ao Programa de Pós-Graduação em Recursos Hídricos da Universidade Federal de Pelotas pela estrutura física e intelectual, e à Universidade Federal de Pelotas pela acolhida e oportunidades.

À Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelas bolsas concedidas.

"Pode se encontrar a felicidade mesmo nas horas mais sombrias, se a pessoa se lembrar de acender a luz."

*Alvo Dumbledore,
em Harry Potter e o Prisioneiro de Azkaban*

Resumo

MOURA, Maíra Martim de. **R-LASH: implementação e aplicação do modelo hidrológico em linguagem R**. 2023. 142f. Tese (Doutorado em Recursos Hídricos) - Programa de Pós-Graduação em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, Pelotas, 2023.

A crescente industrialização e urbanização, associadas às mudanças climáticas, têm impactado a distribuição espaço-temporal dos recursos hídricos e favorecido o aumento da imprevisibilidade dos processos hidrológicos. Visando uma melhor compreensão do funcionamento do balanço hídrico e da dinâmica dos inúmeros processos que controlam o movimento da água e seus prováveis impactos sobre a sua quantidade, diversos modelos hidrológicos vêm sendo desenvolvidos. Um dos modelos que tem se destacado em diversos trabalhos realizados no Brasil é o Lavras Simulation of Hydrology (LASH). A grande vantagem do LASH é o número reduzido de parâmetros para representação dos processos hidrológicos. Além disso, o modelo permite a utilização de bases de dados menos detalhadas, o que favorece sua utilização, principalmente em países em desenvolvimento. Apesar de possuir um pequeno número de parâmetros a serem otimizados e já ter apresentado bom desempenho em trabalhos localizados em diferentes regiões do Brasil, o LASH ainda necessita de estudos e aprimoramentos relacionados ao seu processamento, principalmente quanto às estratégias de calibração. O principal objetivo deste trabalho foi implementar o modelo hidrológico LASH em ambiente de programação aberto, utilizando linguagem de programação R, bem como avaliar sua implementação, eficiência e usabilidade para três bacias hidrográficas. A área de estudo compreendeu as bacias hidrográficas do rio Piratini (BHRP), do arroio Fragata (BHAF) e do arroio Pelotas (BHAP), localizadas no sul do Rio Grande do Sul. Na versão proposta, o modelo LASH, agora denominado R-LASH, teve sua rotina hidrológica adaptada para linguagem R e, além do algoritmo de calibração mono-objetivo SCE-UA, três algoritmos multiobjetivos (DREAM, MOPSO e NSGA II) foram acrescentados à rotina do modelo. Com base no proposto, foi possível a ampliação das funcionalidades do modelo LASH, principalmente pela padronização dos arquivos de entrada, realizada no módulo ArcLASH, e pela possibilidade de utilização de algoritmos multiobjetivos para calibração do modelo. A calibração do R-LASH para as bacias hidrográficas analisadas resultou em conjuntos de parâmetros do modelo adequados, os quais permitiram a simulação dos processos físicos de forma satisfatória.

Palavras-chave: módulo ArcLASH; algoritmo multiobjetivo; calibração automática; gestão de recursos hídricos.

Abstract

MOURA, Máira Martim de. **R-LASH: implementation and application of the hydrological model in R language**. 2023. 142f. Dissertation (Doctorate of Water Resources) - Water Resources Graduate Program, Center for Technological Development, Federal University of Pelotas, Pelotas, 2023.

Growing industrialization and urbanization, associated with climate change, have impacted the space-time distribution of water resources and favored the increase in the unpredictability of hydrological processes. Aiming at a better understanding of the functioning of the water balance and the dynamics of the numerous processes that control the movement of water and their probable impacts on its quantity, several hydrological models have been developed. One of the models that has stood out in several works carried out in Brazil is the Lavras Simulation of Hydrology (LASH). The great advantage of LASH is the reduced number of parameters for representing hydrological processes. In addition, the model allows the use of less detailed databases, which favors its use, especially in developing countries. Despite having a small number of parameters to be optimized and having already performed well in studies located in different regions of Brazil, LASH still needs improvements related to its processing, mainly regarding calibration strategies. The main objective of this work was to implement the LASH hydrological model in an open programming environment, using the R programming language, as well as to evaluate its implementation, efficiency, and usability for three watersheds. The study area comprised the watersheds of the Piratini River (BHRP), the Fragata River (BHAF), and the Pelotas River (BHAP), located in the south of Rio Grande do Sul. In the proposed version, the LASH model, now called R-LASH, had its hydrological routine adapted to the R language and, in addition to the SCE-UA mono-objective calibration algorithm, three multi-objective algorithms (DREAM, MOPSO, and NSGA II) were added to the model routine. Based on the proposal, it was possible to expand the functionalities of the LASH model, mainly by standardizing the input files, performed in the ArcLASH module, and by the possibility of using multiobjective algorithms for model calibration. The calibration of the R-LASH for the watersheds analyzed resulted in adequate sets of model parameters, which allowed the simulation of the physical processes in a satisfactory way.

Key-words: ArcLASH module; multiobjective algorithm; automatic calibration; water resources management.

Lista de Figuras

Figura 1 - Classificações dos modelos hidrológicos de acordo com diferentes aspectos.	22
Figura 2 – Representação das etapas que envolvem o processamento do código-fonte com linguagem compilada e linguagem interpretada.	23
Figura 3 – Principais diferenças entre linguagem compilada e linguagem interpretada.	23
Figura 4 – Aplicação dos algoritmos SCE-UA, MOCOM-UA e MOSCEM-UA, por grande área.	28
Figura 5 – Principais características das versões do modelo hidrológico LASH: discretização espacial, calibração e aplicação.	30
Figura 6 - Modelo hidrológico LASH da concepção e avaliação ao desenvolvimento da terceira versão.	31
Figura 7 - Localização das bacias hidrográficas nas quais o modelo LASH já foi aplicado. .	32
Figura 8 - Organograma representando os principais aprimoramentos do R-LASH.	33
Figura 9 - Comportamento do fator KS em função do armazenamento atual de água no solo e das equações 23 e 24.	39
Figura 10 – Detalhe da rotina SCE disponível em linguagem R.	47
Figura 11 – Exemplificação do funcionamento do algoritmo DREAM.	49
Figura 12 – Exemplificação do funcionamento do algoritmo MOPSO.	50
Figura 13 – Exemplificação do funcionamento do algoritmo NSGA-II.	51
Figura 14 – Representação de: (a) espaço das soluções factíveis, e (b) espaço das funções objetivo e a representação da fronteira de Pareto FP.	51
Figura 15 - Fluxograma ilustrando os processos, arquivos de entrada e informações de saída do módulo ArcLASH.	55
Figura 16 - Localização da bacia hidrográfica Mirim-São Gonçalo e das bacias hidrográficas do estudo.	59
Figura 17 - Localização das bacias hidrográficas e municípios de abrangência.	60
Figura 18 - Localização das estações de monitoramento selecionadas para o presente estudo.	61
Figura 19 - Modelo digital de elevação da região de estudo.	64
Figura 20 - Classes de solo, considerando até segundo nível categórico, encontradas na área de estudo.	65
Figura 21 – Localização dos transectos de solo de Aquino (2014) e Soares (2017), utilizados para apoio metodológico.	66
Figura 22 – Uso do solo, em 2003, nas bacias hidrográficas do estudo.	71
Figura 23 – Uso do solo, em 2018, nas bacias hidrográficas do estudo.	72
Figura 24 - Interface do módulo ArcLASH no software ArcGIS®.	75
Figura 25 – Organização das pastas de saída do módulo ArcLASH.	76
Figura 26 – Organização da pasta subwatershedsTxt.	76
Figura 27 – Modelo de arquivo de saída do módulo ArcLASH com informações de variáveis do uso do solo.	77
Figura 28 – Modelo de arquivo de saída do módulo ArcLASH com informações de variáveis do solo.	77
Figura 29 – Modelo de arquivo de saída do módulo ArcLASH com informações das sub-bacias.	78
Figura 30 – Sub-bacias da BHAF-PC resultantes da preparação da base de dados espaciais com o módulo ArcLASH.	79
Figura 31 – Sub-bacias da BHAP-PCF resultantes da preparação da base de dados espaciais com o módulo ArcLASH.	80

Figura 32 – Sub-bacias da BHRP-PO resultantes da preparação da base de dados espaciais com o módulo ArcLASH.....	80
Figura 33 – Estrutura de organização do R-LASH.	82
Figura 34 – Equacionamento dos escoamentos de base, subsuperficial e superficial, bem como a ascensão capilar.	82
Figura 35 – Equacionamento do cálculo da Evapotranspiração.....	83
Figura 36 – Equacionamento das estatísticas associados ao modelo, as quais são calculadas independentemente de serem ou não utilizadas como funções-objetivo.....	83
Figura 37 – Função para fazer leitura dos dados de saída do ArcLASH e conversão para formato de entrada no script LASH.R.	84
Figura 38 – Detalhe do <i>script</i> chamando FUNCOES.R e lendo os dados de entrada do modelo.	85
Figura 39 – Transformação dos dados lidos em vetores e inicialização da função LASH (rotina do modelo LASH).	86
Figura 40 – Loops realizados na série histórica e nas sub-bacias, na função LASH.	86
Figura 41 – Cálculo dos volumes e vazões e das estatísticas de desempenho, finalizando os cálculos da função LASH.....	87
Figura 42 – Detalhe do script de calibração, com as funções dos algoritmos selecionados implementadas.	88
Figura 43 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo SCE-UA para a BHAF-PC.	90
Figura 44 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo DREAM para a BHAF-PC.....	91
Figura 45 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo MOPSO para a BHAF-PC.....	91
Figura 46 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo NSGA II para a BHAF-PC.....	92
Figura 47 – Percentuais médios dos componentes do escoamento da BHAF-PC, a saber: QB – escoamento de base, QSS – escoamento subsuperficial e Qs – escoamento superficial.	94
Figura 48 – Vazões mínimas, médias e máximas anuais observadas e estimadas por meio dos algoritmos de otimização para a BHAF-PC.	96
Figura 49 – Curvas de permanência das vazões observadas e simuladas com o modelo LASH, utilizando os parâmetros estimados para a BHAF-PC.	98
Figura 50 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo SCE-UA para a BHAF-PCF.	100
Figura 51 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo DREAM para a BHAF-PCF.....	101
Figura 52 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo MOPSO para a BHAF-PCF.	101
Figura 53 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo NSGA-II para a BHAF-PCF.	102
Figura 54 – Percentuais médios dos componentes do escoamento da BHAF-PCF, a saber: QB – escoamento de base, QSS – escoamento subsuperficial e Qs – escoamento superficial.	104
Figura 55 – Vazões mínimas, médias e máximas anuais observadas e estimadas por meio dos algoritmos de otimização para a BHAF-PCF.....	105
Figura 56 – Curvas de permanência das vazões observadas e simuladas com o modelo LASH, utilizando os parâmetros estimados para a BHAF-PCF.	107
Figura 57 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo SCE-UA para a BHRP-PO.....	109

Figura 58 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo DREAM para a BHRP-PO.	109
Figura 59 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo MOPSO para a BHRP-PO.	110
Figura 60 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo NSGA-II para a BHRP-PO.	110
Figura 61 – Percentuais médios dos componentes do escoamento da BHRP-PO, a saber: QB – escoamento de base, QSS – escoamento sub-superficial e Qs – escoamento superficial.	113
Figura 62 – Vazões mínimas, médias e máximas anuais observadas e estimadas por meio dos algoritmos de otimização para a BHRP-PO.....	114
Figura 63 – Curvas de permanência das vazões observadas e simuladas com o modelo LASH, utilizando os parâmetros estimados para a BHRP-PO.....	116
Figura 64 – Valores de CNS e CNS – LOG obtidos a partir dos parâmetros do modelo LASH estimados nos estudos anteriores.....	121

Lista de Tabelas

Tabela 1 – Modelos hidrológicos implementados em linguagem de programação R, referências e repositórios.....	25
Tabela 2 - Limites mínimos e máximos dos parâmetros do modelo LASH.....	44
Tabela 3 - Equações para a estimativa do tempo de concentração das bacias hidrográficas, com base nos limiares de área de drenagem (A).....	56
Tabela 4 - Características das bacias hidrográficas utilizadas neste estudo.....	60
Tabela 5 – Estações de monitoramento utilizadas e seus respectivos períodos com dados disponíveis.....	62
Tabela 6 - Períodos utilizados para aquecimento, calibração e validação do modelo LASH nas bacias hidrográficas de estudo.....	63
Tabela 7 - Valores de umidade do solo no ponto de saturação (θ_s) e no ponto de murcha permanente (θ_{PMP}), e de profundidade do solo (Z_{SOLO}) empregados neste estudo, para cada classe de solo.....	67
Tabela 8 - Classes de solo, em percentual, para as bacias hidrográficas contempladas no estudo.....	68
Tabela 9 – Código e classe de uso do solo do Projeto MapBiomas e respectivos enquadramentos realizados para entrada das informações no modelo LASH.....	70
Tabela 10 - Classes de uso do solo, em percentual, para as bacias hidrográficas contempladas no estudo, para os mapeamentos de 2003, 2008, 2013 e 2018.....	70
Tabela 11 - Parâmetros relacionados às classes de uso do solo.....	73
Tabela 12 – Limiares utilizados para geração da rede de drenagem numérica e seus respectivos números de sub-bacias.....	78
Tabela 13 – Percentual de influência das estações pluviométricas para as bacias hidrográficas do estudo.....	81
Tabela 14 – Percentual de influência das estações meteorológicas para as bacias hidrográficas do estudo.....	81
Tabela 15 – Parâmetros do modelo LASH estimados para a BHAF-PC.....	89
Tabela 16 – Estatísticas de desempenho das aplicações realizadas na BHAF-PC.....	89
Tabela 17 – Vazões de referência estimadas para a BHAF-PC.....	97
Tabela 18 – Parâmetros do modelo LASH estimados para a BHAP-PCF.....	99
Tabela 19 – Estatísticas de desempenho das aplicações realizadas na BHAP-PCF.....	99
Tabela 20 – Vazões de referência estimadas para a BHAP-PCF.....	106
Tabela 21 – Parâmetros do modelo LASH estimados para a BHRP-PO.....	108
Tabela 22 – Estatísticas de desempenho das aplicações realizadas na BHRP-PO.....	108
Tabela 23 – Vazões de referência estimadas para a BHRP-PO.....	115
Tabela 24 – Estatísticas de desempenho obtidas com modelos hidrológicos aplicados às bacias hidrográficas utilizadas.....	119
Tabela 25 – Parâmetros do modelo LASH obtidos em estudos anteriores, para as bacias hidrográficas utilizadas.....	119

Lista de Tabelas

ANA	Agência Nacional de Águas e Saneamento Básico
AE	Algoritmos evolucionários
AG	Algoritmos Genéticos
ARIMA	<i>Auto Regressive Integrated Moving Average</i>
BHAF-PC	Bacia hidrográfica do arroio Fragata – Passo dos Carros
BHAP-PCF	Bacia hidrográfica do arroio Pelotas – Ponte Cordeiro de Farias
BHMSG	Bacia hidrográfica Mirim-São Gonçalo
BHRP-PO	Bacia hidrográfica do rio Piratini – Pedro Osório
CCE	<i>Competitive Complex Evolution</i>
CN	<i>Curve Number</i>
CRI	Capacidade do Reservatório de Interceptação
DE-MC	<i>Differential Evolution Markov Chain</i>
<i>DREAM</i>	<i>Differential Evolution Adaptive Metropolis</i>
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
<i>GR4J</i>	<i>Genie Rural 4-parameters Journalier</i>
<i>GR5J</i>	<i>Genie Rural 5-parameters Journalier</i>
<i>GR6J</i>	<i>Genie Rural 6-parameters Journalier</i>
<i>HBV model</i>	<i>Hydrologiska Byråns Vattenbalansavdelning model</i>
IAF	Índice de área foliar
IDE	<i>Integrated Development Environment</i>
INMET	Instituto Nacional de Meteorologia
KGE	<i>Kling-Gupta efficiency</i>
LAI	<i>Leaf Area Index</i>
LASH	<i>Lavras Simulation Hydrology</i>
LISEM	<i>Llmburg Soil Erosion Model</i>
MDE	Modelo digital de elevação
MGB	Modelo de Grandes Bacias
M-LASH	<i>Lavras Simulation Hydrology em Matlab</i>
<i>MOCOM-UA</i>	<i>Multi-Objective Complex Evolution</i>
MOPSO	<i>Multi-Objective Particle Swarm Optimization</i>
MOSCDE	<i>Multi-Objective Shuffled Complex Differential Evolution</i>
<i>MOSCEM</i>	<i>MultiObjective Shuffled Complex Evolution Metropolis</i>
<i>NSGA II</i>	<i>Elitist Non-dominated Sorted Genetic Algorithm II</i>
<i>PSO</i>	<i>Particle Swarm Optimization</i>
R-LASH	<i>Lavras Simulation Hydrology em R</i>
RMSE	<i>Root mean squared error</i>
SAC-SMA	<i>Sacramento Soil Moisture Accounting</i>
SCEM-UA	<i>Shuffled Complex Evolution Metropolis</i>
<i>SCE-UA</i>	<i>Shuffled Complex Evolution – University of Arizona</i>
SCS	<i>Soil Conservation Service</i>
SWAT	<i>Soil and Water Assessment Tool</i>
SYHDA	<i>System of Hydrological Data Acquisition and Analysis</i>
<i>TOPMODEL</i>	<i>Topography based Hydrological Model</i>

UFLA	Universidade Federal de Lavras
UFPel	Universidade Federal de Pelotas
URH	Unidade de Resposta Hidrológica
USGS	<i>United States Geological Survey</i>

Sumário

1 INTRODUÇÃO	16
1.1 Objetivo geral	18
1.1.1 Objetivos específicos	18
1.2 Hipóteses	18
2 REVISÃO DE LITERATURA	19
2.1 Ciclo hidrológico e bacia hidrográfica	19
2.2 Modelagem hidrológica	20
2.2.1 Classificação dos modelos hidrológicos	21
2.3 Linguagem de programação R	22
2.4 Algoritmos de otimização	26
2.5 Lavras Simulation of Hydrology	29
3 METODOLOGIA	33
3.1 Desenvolvimento do R-LASH	33
3.2 Equacionamento do modelo LASH	34
3.2.1 Balanço hídrico do solo	34
3.2.2 Interceptação e precipitação	34
3.2.3 Evapotranspiração	35
3.2.4 Ascensão capilar	39
3.2.5 Geração de escoamento superficial direto	40
3.2.6 Geração de escoamento subsuperficial	40
3.2.7 Geração de escoamento subterrâneo	41
3.2.8 Propagação nos reservatórios superficial, subsuperficial e subterrâneo	41
3.2.9 Propagação nos canais	43
3.2.10 Parametrização do modelo LASH	44
3.3 Adequação da rotina hidrológica para linguagem de código aberto	44
3.3.1 Algoritmos de calibração	45
3.3.2 Métricas de desempenho e funções objetivos	52
3.3.3 Avaliação de desempenho com o modelo LASH	53
3.4 Aprimoramento da ferramenta ArcLASH	54
3.5 Estudo de caso: Avaliação dos aprimoramentos	58
3.5.1 Base de dados temporais	61
3.5.2 Base de dados espaciais	63
4 RESULTADOS E DISCUSSÃO	74
4.1 Estrutura do módulo ArcLASH	74

4.1.1 Discretização espacial das bacias hidrográficas e tempo de processamento com o ArcLASH	78
4.2 Estrutura do modelo LASH em linguagem de programação R	82
4.2.1 <i>Script</i> Funções	82
4.2.2 <i>Script</i> R-LASH.....	85
4.2.3 <i>Script</i> Calibração.....	87
4.3 Calibração e validação das bacias hidrográficas.....	88
4.4 Discussão com a literatura	117
5 CONCLUSÕES.....	123
6 CONSIDERAÇÕES FINAIS	124
REFERÊNCIAS	126

1 INTRODUÇÃO

A água é um recurso natural indispensável à vida e essencial ao desenvolvimento econômico local, que vem tendo sua variabilidade espaço-temporal impactada pelas ações antrópicas e pelo aumento populacional, associados às mudanças climáticas. Essas associações têm favorecido o aumento da imprevisibilidade dos processos hidrológicos e culminado em inúmeros problemas relacionados à ocorrência de eventos extremos em bacias hidrográficas.

Com o objetivo de melhor compreender o funcionamento do balanço hídrico e a dinâmica dos inúmeros processos que controlam o movimento da água e prováveis impactos sobre a sua disponibilidade, diversos modelos hidrológicos foram desenvolvidos, como, por exemplo, o *Soil and Water Assessment Tool – SWAT* (ARNOLD et al., 1998), o Modelo de Grandes Bacias – MGB (COLLISCHONN, 2001) e o *Lavras Simulation Hydrology – LASH* (VIOLA, 2008).

Esses modelos podem ser empregados para as mais diversas finalidades, como previsões em sistemas de alertas às inundações (BAI et al., 2022; FAN et al., 2015; MARTINS; SILVA; PONS, 2019; ZHANG et al., 2017), dimensionamento de estruturas hidráulicas (AHN; JEONG; KIM, 2016; MISHRA; FROEBRICH; GASSMAN, 2007; PONTES et al., 2017) e avaliação do impacto do clima e das alterações no uso do solo (CARVALHO et al., 2022; FARISONI et al., 2019; LUCAS-BORJA et al., 2020; MELLO et al., 2021; OLIVEIRA et al., 2017; SANTOS et al., 2021). De acordo com Kumar (2015), devido à grande variabilidade espacial e temporal de características geofísicas e climáticas das bacias hidrográficas, os fenômenos envolvidos na transformação chuva-vazão são extremamente complexos, e suas simulações tornam-se mais desafiadoras quando os dados são espacial e/ou temporalmente limitados.

No Brasil, o monitoramento e o gerenciamento das informações hidrológicas são de responsabilidade da Agência Nacional de Águas e Saneamento Básico (ANA). Porém, a realidade brasileira é semelhante as dos demais países em desenvolvimento: poucos postos hidrológicos ou com séries de curta duração, acarretando uma rede de monitoramento precária, que contempla apenas médias e grandes bacias (BESKOW et al., 2013; GHUMMAN et al., 2011).

Diante deste contexto, um dos modelos que tem se destacado é o LASH que vem sendo desenvolvido desde 2008, resultado de uma parceria entre Brasil - Universidade Federal de Lavras (UFLA) e Universidade Federal de Pelotas (UFPel) – e Estados Unidos - Universidade de Purdue. De acordo com Mello et al. (2016), a grande vantagem do modelo é o fato de o mesmo ser compatível com a realidade de países em desenvolvimento, tanto em termos de processos hidrológicos quanto em termos de necessidade de bases de dados.

Ao longo dos últimos ano, o LASH vem recebendo diversos aprimoramentos computacionais, os quais permeiam, principalmente, a discretização espacial do modelo (concentrado, distribuído e semidistribuído), a linguagem de programação (Excel, Delphi, Matlab) e os algoritmos de calibração utilizados. Até este momento, o modelo LASH já possui quatro versões consolidadas: Viola (2008), Beskow (2009), Caldeira (2016) e Vargas (2021). Em sua versão atual, desenvolvida por Vargas (2021) e denominada M-LASH, o modelo é classificado como chuva-vazão de longo termo, semiconceitual e semidistribuído, com análise do balanço hídrico em sub-bacias hidrográficas.

Em conjunto com a terceira versão do modelo LASH (CALDEIRA, 2016), dois módulos foram desenvolvidos: o *System of Hydrological Data Acquisition and Analysis* (SYHDA) e o ArcLASH. O SYHDA (VARGAS et al., 2019) foi idealizado para o tratamento estatístico das séries temporais de precipitação e vazão, as quais são utilizadas para simulação e calibração do modelo, respectivamente. Atualmente, o SYHDA funciona como um software a parte do modelo LASH e possibilita uma série de análises estatísticas como, por exemplo, aplicação de testes não-paramétricos, análise de frequência local e regionalização de vazões. O módulo ArcLASH (CALDEIRA, 2016) foi desenvolvido para o tratamento e a padronização dos dados espaciais necessários para simulação hidrológica com o modelo LASH.

Apesar de apresentar um pequeno número de parâmetros a serem estimados e já ter apresentado bom desempenho em trabalhos localizados em diferentes regiões do país (BESKOW et al., 2011, 2016; CUNHA, 2021; MELLO et al., 2008; VARGAS, 2021; VIOLA et al., 2009, 2014, 2015), o LASH ainda necessita de estudos e aprimoramentos relacionados ao seu processamento, principalmente nas estratégias de calibração. Neste sentido, a implementação do modelo LASH em linguagens interpretadas como, por exemplo, Python, R e Matlab, é de grande vantagem, uma vez que permitem a atualização contínua do modelo e, também, a aplicação de

algoritmos de otimização mais robustos. Além disso, a interface do modelo até o momento encontra-se pouco amigável para ser utilizada pela comunidade geral, necessitando de adequação de sua linguagem para código aberto, o que facilitaria sua difusão e aplicação nos mais diversos setores da sociedade.

1.1 Objetivo geral

O objetivo deste estudo é implementar e avaliar o modelo hidrológico LASH em um ambiente de programação aberto, empregando técnicas do estado da arte para a calibração do modelo.

1.1.1 Objetivos específicos

Os objetivos específicos são:

- i) Implementar o modelo *Lavras Simulation of Hydrology* (LASH) na linguagem de programação R (R-LASH).
- ii) Investigar técnicas de otimização do estado da arte para a calibração do modelo hidrológico LASH, já disponíveis em linguagem R.
- iii) Aprimorar o módulo ArcLASH, em termos de padronização dos dados e de adaptação de sua rotina para atendimento às necessidades do R-LASH.
- iv) Avaliar a implementação, eficiência e usabilidade do modelo para as bacias hidrográficas do rio Piratini e dos arroios Fragata e Pelotas, localizadas no sul do Rio Grande do Sul.

1.2 Hipóteses

- i) A inserção do modelo em ambiente de programação R possibilita a utilização de algoritmos de otimização ainda não avaliados na rotina do modelo LASH.
- ii) O aprimoramento do módulo ArcLASH facilita a leitura dos dados espaciais na rotina do R-LASH, bem como traz novas possibilidades de representação dos processos físicos no modelo LASH.

2 REVISÃO DE LITERATURA

2.1 Ciclo hidrológico e bacia hidrográfica

A água é um recurso natural indispensável à manutenção das atividades humanas e ao progresso socioeconômico de uma região. A evolução humana e das cidades sempre teve relação com os rios e foi fundamentada na dinâmica e sazonalidade dos recursos hídricos (BAPTISTA; CARDOSO, 2013). Contudo, com a crescente expansão urbana e a explosão populacional decorrente do desenvolvimento industrial, inúmeros impactos ambientais vem surgindo e intensificando a ocorrência de eventos hidrológicos extremos e de suas consequências, tais como estiagens severas e inundações (KUMAR et al., 2018; SINGH; THAKUR; SINGH, 2013).

Estes cenários, de acordo com Prasad et al. (2015), justificam uma abordagem científica multidimensional para avaliar os recursos hídricos e sua distribuição, bem como para propor estratégias de gerenciamento sustentáveis. Neste contexto, se faz necessário o estudo e o conhecimento do ciclo hidrológico, ou seja, como ocorre a circulação da água entre a superfície terrestre e a atmosfera, em seus diferentes estados e ambientes do globo terrestre. Segundo Miranda, Oliveira e Silva (2010), essa circulação é impulsionada fundamentalmente pela radiação solar, associada à gravidade e à rotação da Terra. Dentre os vários componentes associados à dinâmica da água e de grande interesse para estudos de gestão, destacam-se o escoamento superficial direto, a precipitação, a evapotranspiração e a interceptação.

Devido às complexidades envolvidas no estudo dos componentes do ciclo hidrológico em escala global, se faz necessária a delimitação de uma região de estudo em escala regional/local. O modelo de gestão de recursos hídricos, instituído pela Lei 9.433 (BRASIL, 1997), estabelece a bacia hidrográfica como unidade de gestão territorial. A bacia hidrográfica é uma área de captação natural da água de precipitação que converge o escoamento para apenas um e único ponto de saída, funcionando como uma unidade de planejamento e gestão que proporciona o entendimento do solo, da água e da cobertura vegetal (PETSCH; MONTEIRO; BUENO, 2012; SREEDEVI et al., 2009).

2.2 Modelagem hidrológica

A compreensão sobre os processos hidrológicos é de fundamental importância em estudos hidroambientais, na gestão dos recursos hídricos e em projetos de obras hidráulicas. O tempo de residência da água em seus diferentes estados influencia na disponibilidade hídrica, na ocorrência de inundações e na dinâmica entre elementos, nutrientes e poluentes. De acordo com Moraes (2003), para obter conhecimento mais aprofundado acerca dessas inter-relações, tem-se utilizado a modelagem hidrológica como ferramenta para a quantificação dos fenômenos físicos envolvidos e previsão de cenários.

Devido às inúmeras complexidades envolvidas no entendimento das variáveis do ciclo hidrológico, diversos modelos hidrológicos foram e vem sendo desenvolvidos para tentar descrever o comportamento das mesmas e quantificá-las. Booij e Krol (2010) ressaltam que estes modelos vêm sendo extensivamente aplicados para o gerenciamento de recursos hídricos com diversos fins, como por exemplo, previsão de cheias (CLOKE; PAPPENBERGER, 2009), simulação de vazões de estiagens (ENGELAND; HISDAL, 2009; SMAKHTIN et al., 1998) e estudos de impactos climáticos (AKHTAR et al., 2008; STEELE-DUNNE et al., 2008; YU; WANG, 2009).

Estes modelos fazem uso da equação do balanço hídrico, tanto na escala global como na escala simplificada para a simulação da transformação chuva-vazão. Os modelos que utilizam a equação simplificada geralmente possuem um menor número de parâmetros calibráveis e uma base de dados mais simples, contudo, podem não ser tão representativos da área de estudo por simularem um número menor de processos físicos envolvidos. Os modelos que utilizam a equação geral, por sua vez, objetivam simular as interações que ocorrem na interface solo-vegetação-atmosfera, que não são diretamente consideradas nos modelos hidrológicos mais simplificados. Segundo Aubert, Loumagne e Oudin (2003), os modelos hidrológicos são muito sensíveis ao estado hídrico do solo, e a consideração e melhor representação dessa variável na bacia hidrográfica tende a aumentar a precisão do processo chuva-vazão e permitir um melhor controle da variação temporal dos modelos.

2.2.1 Classificação dos modelos hidrológicos

Os modelos hidrológicos podem ser classificados sob diferentes aspectos, como apresentado na Figura 1. De acordo com Almeida e Serra (2017), modelos estocásticos são aqueles nos quais uma ou mais variáveis envolvidas na modelagem têm um comportamento aleatório, possuindo distribuição de probabilidade, como por exemplo o *Auto Regressive Integrated Moving Average – ARIMA* (BOX; PIERCE, 1970). Já os modelos determinísticos são aqueles que produzem respostas idênticas para o mesmo conjunto de entradas, mesmo quando uma variável de entrada tiver caráter aleatório. Os modelos denominados chuva-vazão geralmente são do tipo determinístico, de modo que, a partir de dados de entrada, tais como os volumes precipitado e evaporado, condições iniciais de umidade do solo, cobertura vegetal, entre outros, possam ser fornecidas as séries de vazões.

Os modelos empíricos são aqueles cuja formulação não tem representação explícita dos processos físicos da bacia, enquanto os conceituais são baseados nas equações que descrevem o processo físico conceitual ou hipotético, não sendo necessariamente baseado no processo real (ALMEIDA; SERRA, 2017). Os modelos empíricos podem possuir uma característica regionalista, visto que suas equações são ajustadas para conjuntos de dados específicos.

Quanto à representação temporal dos dados de entrada, os modelos podem ser contínuos e discretos. Modelos contínuos são aqueles que contemplam longas séries de dados, de forma que captam os diferentes comportamentos do ciclo hidrológico. Modelos discretos são aqueles baseados em eventos, os quais tem por objetivo a análise de cheias e estiagem. Os modelos *Soil and Water Assessment Tool – SWAT* (ARNOLD et al., 1998) e o *Limburg Soil Erosion Model - LISEM* (DE ROO; WESSELING; RITSEMA, 1996) são exemplos de modelos contínuo e discreto, respectivamente.

Em relação à espacialização das informações, os modelos concentrados são aqueles que não consideram a variabilidade espacial das variáveis hidrológicas envolvidas no processo modelado. Na estrutura concentrada todas as variáveis de entrada e de saída são consideradas representativas de toda área de estudo e a principal variável é o tempo. Em modelos distribuídos, a variabilidade das variáveis hidrológicas no espaço é considerada. Existem diferentes formas de representação espacial das variáveis para a modelagem hidrológica, com destaque para a divisão da

bacia hidrográfica em grid de células, sub-bacias ou unidades de resposta hidrológica (URH). A modelagem distribuída prevalece frente à concentrada, entretanto, esta é altamente dependente de uma base de dados espaciais de qualidade. Exemplo de modelo que possibilita a representação da bacia hidrográfica de diferentes formas é o Modelo de Grandes Bacias – MGB (COLLISCHONN, 2001).

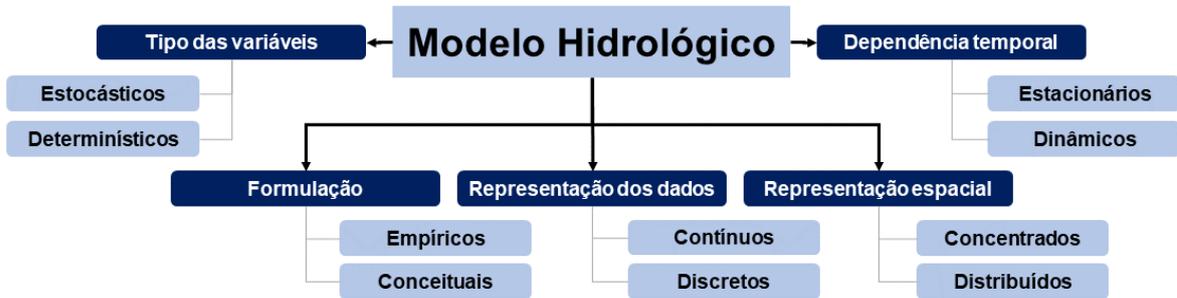


Figura 1 - Classificações dos modelos hidrológicos de acordo com diferentes aspectos.

2.3 Linguagem de programação R

De acordo com Gotardo (2015), linguagem de programação é um método padronizado que usamos para expressar as instruções de um programa a um computador, tais como quais dados usar, como estes dados serão tratados, armazenados e transmitidos, bem como quais ações devem ser tomadas em determinadas circunstâncias. Usualmente, uma linguagem de programação é composta por palavras e regras para formulação do código-fonte, o qual passa por processo de verificação e, então, é traduzido para linguagem de máquina, podendo ser executado pelo computador (SEBESTA, 2011).

As linguagens de programação podem ser classificadas como compiladas e interpretadas, de acordo com a forma de tradução do código-fonte para a linguagem de máquina. Segundo Paillard e Moreira (2017), as linguagens compiladas traduzem todo o código-fonte em linguagem de máquina para depois executar no computador. Por outro lado, nas linguagens interpretadas os trechos do código-fonte são traduzidos e tem sua execução imediata (Figura 2).

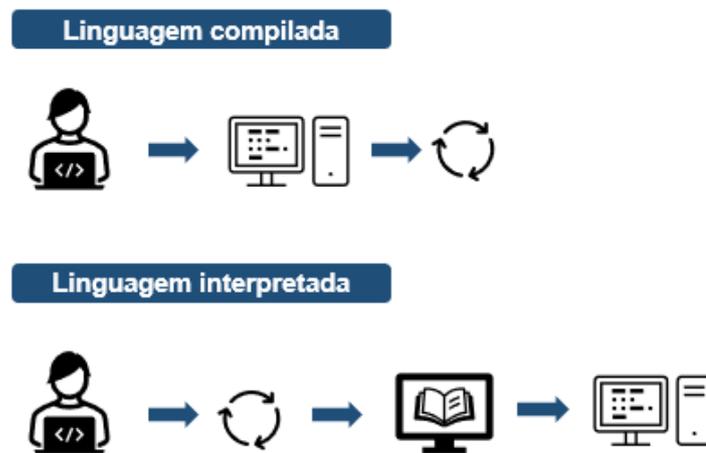


Figura 2 – Representação das etapas que envolvem o processamento do código-fonte com linguagem compilada e linguagem interpretada.

Na Figura 3 é apresentada uma síntese com as principais diferenças entre linguagens compilada e interpretada. Visto que nas linguagens interpretadas os trechos do código-fonte são traduzidos durante a execução, tem-se como consequência mais lentos. Em contrapartida, programas em linguagens interpretadas tendem a ser mais portáteis para outros ambientes computacionais, pois os interpretadores podem atuar como mediadores entre o código-fonte e o sistema operacional (PAILLARD; MOREIRA, 2017). Exemplos de linguagens compiladas são C, Fortran e Delphi, e de linguagens interpretadas, Python, Java, R e Matlab®.

	Linguagem compilada	Linguagem interpretada
Código-fonte	Implementações são tipicamente compiladores e não interpretadores.	Implementações executam instruções direta e livremente, sem antes compilar um programa em instruções em linguagem de máquina
Execução e depuração	Programas compilados são executados mais rapidamente	Os programas podem ser modificados enquanto o programa está em execução
	Os erros de compilação impedem a compilação do código.	Toda depuração ocorre em tempo de execução.
	Melhor desempenho.	Desempenho mais lento.

Figura 3 – Principais diferenças entre linguagem compilada e linguagem interpretada.

Quando as linguagens de programação possuem sintaxe voltada o entendimento humano, ou seja, interface de comandos intuitos e amigáveis, estas são denominadas de linguagens de alto nível (BALBINO et al., 2021). Com o crescimento do número de linguagens de programação de alto nível disponíveis no mercado, análises quanto à eficiência destas na resolução de problemas é de grande importância (MARTINS et al., 2020; NAMETALA; NUNES; AMARAL, 2018).

Martins et al. (2020) compararam as linguagens de programação C, Java e Python para verificar qual possui melhor desempenho nos quesitos tempo de execução, legibilidade, facilidade de escrita e número de linhas. De acordo com os autores, Python foi a linguagem mais adequada para algoritmos simples nos critérios avaliados, com exceção do tempo de execução.

Nametala, Nunes e Amaral (2018) realizaram análise comparativa de tempos de execução de um código em linguagem R, interpretado e compilado, em sistemas Windows e Linux. Os autores verificaram que a utilização do código compilado no sistema Linux obteve menor tempo de execução. De acordo com os autores, as diferenças observadas entre código compilado e interpretado, tanto em Windows quanto em Linux, mostrou-se pequena, ou seja, quando utilizado o mesmo sistema operacional, pode-se dizer que a compilação, apesar de útil, não é mais influente que a plataforma escolhida.

Apesar dos relatos de perda de performance com códigos interpretados, quando comparados com códigos compilados (MARTINS et al., 2020; NAMETALA; NUNES; AMARAL, 2018), as linguagens interpretadas possuem a vantagem de serem mais simples de depurar. Isso se deve ao fato de que com a interpretação a assimilação do código ocorre aos poucos, permitindo a visualização dos erros e a resolução destes mais facilmente.

De acordo com Schmidt-Walter et al. (2020), a integração de análises estatísticas complexas em modelos de transporte de solo, vegetação e atmosfera é tediosa e, por motivos de desempenho, os modelos são escritos principalmente em linguagens de programação compiláveis (C/C++ ou Fortran). Contudo, a implementação de modelos nestas linguagens exige extensas habilidades de programação e recursos de tempo para implementar extensões que os profissionais geralmente não possuem. Ao longo dos últimos anos, cada vez mais, tem-se realizado a implementação de modelos hidrológicos com linguagens interpretadas, proporcionando contato com interfaces e códigos mais amigáveis (COLLENTEUR;

VREMEC; BRUNETTI, 2020; MENDEZ; CALVO-VALVERDE, 2016; PARK et al., 2019; WI et al., 2017; ZANG et al., 2013).

Neste contexto, umas das linguagens que vem sendo amplamente utilizada é a linguagem R, desenvolvida pelos cientistas Ross Ihaka e Robert Gentleman, do departamento de Departamento de Estatística da Universidade de Auckland, na Nova Zelândia, e disponibilizada de forma gratuita desde 1993. Esta linguagem vem sendo utilizada para diversos fins, principalmente por ser desenvolvida em código aberto, o que permite sua aplicação por cientistas, estatísticos e cientistas de dados, como um meio conveniente para a análise exploratória de dados interativos.

Além da linguagem R, outras linguagens interpretadas como Matlab® e Python tem sido utilizadas para implementação de módulos e modelos hidrológicos. Metcalfe, Beven e Freer (2015), ao implementarem o modelo TOPMODEL em linguagem R, justificaram que a escolha do R frente às linguagens Python e MATLAB se deve ao fato de que estas apresentam funcionalidades espaciais relativamente básicas, exceto por meio da integração com softwares GIS.

Um das grandes vantagens da linguagem R é a de permitir rotinas com diferentes tipos de dados e, também, arquivos de banco de dados (ASTAGNEAU et al., 2021; BRENDEL; DYMOND; AGUILAR, 2019). Essa possibilidade facilita o manuseio das informações, o que tende a diminuir o tempo de processamento, uma vez que não há necessidade de realizar conversões dos tipos de dados. Neste mesmo contexto, há possibilidade de acoplar e executar códigos em outras linguagens de programação, como por exemplo, C, C++, Java e Fortran, nas rotinas de processamento (THYER et al., 2011).

Na Tabela 1 estão apresentados alguns modelos hidrológicos cujos equacionamentos foram implementados em linguagem de programação R. Em conjunto, são apresentados os pacotes, autores e repositórios dos modelos.

Tabela 1 – Modelos hidrológicos implementados em linguagem de programação R, referências e repositórios

Modelo	Referência	Disponibilidade em linguagem R		
		Pacote	Referência	Repositório
<i>Genie Rural 4 -parameters Journalier (GR4J)</i>	Perrin et al. (2003)			
<i>Genie Rural 5 -parameters Journalier (GR5J)</i>	Le Moine (2008)	<i>airGR</i>	Coron et al. (2023)	CRAN.R
<i>Genie Rural 6 -parameters Journalier (GR6J)</i>	Pushpalatha et al. (2011)			

Modelo	Referência	Disponibilidade em linguagem R		
		Pacote	Referência	Repositório
<i>Genie Rural 4 -parameters Journalier (GR4J)</i>	Perrin et al. (2003)	<i>hydromad</i>	Andrews; Croke; Jakeman (2011); Guillaume (2013)	GitHub
<i>Sacramento Soil Moisture Accounting (SAC-SMA)</i>	Burnash (1995)		<i>topmodel</i>	Buytaert (2012)
<i>Topography based Hydrological Model (TOPMODEL)</i>	Beven e Kirby (1979)	<i>dynatopmodel</i>	Metcalfe, Beven; Freer (2015)	GitHub
<i>Hydrologiska Byråns Vattenbalansavdelning model (HBV model)</i>	Bergström e Forsman (1973)	<i>TUWmodel</i>	Viglione; Parajka (2020)	CRAN.R
<i>Soil and Water Assessment Tool (SWAT)</i>	Arnold et al. (1998)	<i>SWATmodel</i>	Fuka et al. (2014)	GitHub
		<i>R-SWAT</i>	Nguyen et al. (2022)	GitHub

2.4 Algoritmos de otimização

Todo modelo hidrológico necessita de uma ou mais técnicas de otimização para a obtenção de seus parâmetros (calibração) pois, geralmente, estes não podem ser derivados de características medidas no campo. De acordo com Sorooshian e Gupta (1995), a calibração faz com que os parâmetros sejam selecionados e alterados de forma que o comportamento hidrológico observado seja mais próximo o possível do simulado pelo modelo.

Segundo Silva (2010), a escolha da técnica a ser utilizada depende da robustez do modelo, ou seja, da sensibilidade dos resultados do modelo às incertezas nos dados utilizados na configuração e calibração do modelo como, por exemplo, seu desempenho sob diferentes condições de calibração e validação. Além disso, a aplicação da técnica está altamente atrelada à capacidade de processamento dos computadores utilizados, bem como das linguagens de programação nas quais os modelos estão inseridos.

Cada vez mais, faz-se uso de algoritmos para calibração de modelos hidrológicos, os quais apresentam diferentes técnicas computacionais para definir as possíveis soluções do problema. Neste contexto, os algoritmos evolucionários (AE) tornaram-se a principal ferramenta para a análise de problemas multiobjetivo, principalmente os relacionados aos recursos hídricos (REED; NICHOLS; EARLS, 2013). Segundo Tang, Reed e Wagener (2006), a premissa é que, em se trabalhar com um conjunto de soluções simultâneas e não com apenas com um único valor ótimo, possibilita-se o uso dos AE como uma plataforma ideal para a otimização

multiobjetivo, principalmente para a calibração de parâmetros de modelos hidrológicos.

Os AE constituem uma família de métodos estocásticos de busca mono e multiobjetiva, baseados em processos de evolução natural. Os algoritmos de evolução diferencial, os algoritmos genéticos e os algoritmos de enxames de partículas compreendem os principais grupos de AE.

Dentre os inúmeros algoritmos evolutivos, em estudos envolvendo modelagem hidrológica, tem se destacado o *Shuffled Complex Evolution – University of Arizona* (SCE-UA) (DUAN; SOROOSHIAN; GUPTA, 1992). O SCE-UA é um algoritmo mono-objetivo baseado na combinação de técnicas de busca aleatória, algoritmos genéticos e otimização local, que opera com uma população de pontos que “evolui” em direção ao ótimo global através de sucessivas iterações e avaliações da função objetivo.

O bom desempenho do SCE-UA corroborou para o desenvolvimento de outros algoritmos, como por exemplo, o *Multi-Objective Complex Evolution* (MOCOM-UA) (YAPO; GUPTA; SOROOSHIAN, 1998), o *Shuffled Complex Evolution Metropolis* (SCEM-UA) (VRUGT et al., 2003a), o *MultiObjective Shuffled Complex Evolution Metropolis* (MOSCEM) (VRUGT et al., 2003b), o *Differential Evolution Adaptive Metropolis* (DREAM) (VRUGT et al., 2009) e o *Multi-Objective Shuffled Complex Differential Evolution* (MOSCDE) (GUO et al., 2013).

Naeini et al. (2019) elaboraram uma revisão de estudos que utilizaram o SCE-UA e derivações para calibração de modelos, ao longo das três últimas décadas. Na Figura 4 é apresentada a grande área de aplicação dos algoritmos. É possível observar o alto número de estudos com aplicação do algoritmo SCE-UA em estudos envolvendo recursos hídricos.

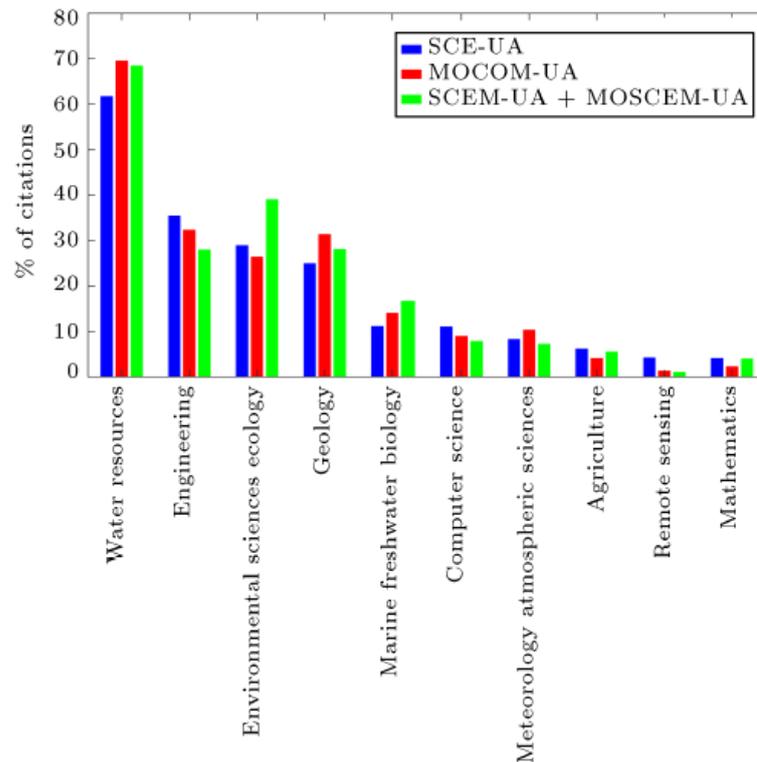


Figura 4 – Aplicação dos algoritmos SCE-UA, MOCOM-UA e MOSCEM-UA, por grande área.
Fonte: Naeini et al. (2019).

Outro grupo de algoritmos geralmente aplicados a modelos hidrológicos são os Algoritmos Genéticos (AG), os quais são bastante eficientes na busca de soluções ótimas de problemas. Os AG baseiam-se na teoria de evolução biológica e, embora possam parecer simplistas do ponto de vista biológico, estes algoritmos são suficientemente complexos para fornecer mecanismos de busca adaptativo poderosos e robustos.

Dentre os algoritmos genéticos disponíveis, destaca-se o *Elitist Non-dominated Sorted Genetic Algorithm II* (NSGA II) (DEB et al., 2002), o qual vindo sendo aplicado em diversos estudos para calibração de modelos hidrológicos (CONFESOR Jr.; WHITTAKER, 2007; SHAFII; DE SMEDT, 2009; ERCAN; GOODALL, 2016; GUTIERREZ, ADAMATTI; BRAVO, 2019).

Os algoritmos baseados na teoria de enxames de partículas simulam o comportamento social de bandos, no qual partículas como pássaros, insetos ou peixes fazem uso de suas experiências e da experiência do próprio bando para encontrarem o ninho ou alimento (NASCIMENTO; REIS JÚNIOR; MARTINS, 2009). O algoritmo *Particle Swarm Optimization* (PSO) (KENNEDY; EBERHART, 1995) é um algoritmo mono-objetivo, contudo, algumas versões multi-objetivo encontram-se disponíveis

(COELLO COELLO; LECHUGA, 2002; PARSOPOULOS; VRAHATIS, 2002; ALVAREZ-BENITEZ; EVERSON; FIELDSEND, 2005). O *Multi-Objective Particle Swarm Optimization* (MOPSO), versão multi-objetivo do PSO também é bastante aplicada na literatura, contudo, em muitos estudos é utilizada de modo comparativo a outros algoritmos, principalmente dos grupos apresentados anteriormente (e.g. SCE-UA, NSGA II) (WANG et al., 2010; HUANG; LEI; JIANG, 2012; BALAG; MOUSAVI, 2022).

2.5 Lavras Simulation of Hydrology

O *Lavras Simulation of Hydrology* (LASH) é um modelo hidrológico que vem sendo desenvolvido e aprimorado desde 2008, resultado de uma parceria entre as Universidades Federais de Pelotas e Lavras, e a Universidade de Purdue dos Estados Unidos. A concepção do modelo se deu com base na realidade dos países em desenvolvimento, tanto em termos de processos quanto em termos de indisponibilidade de dados (MELLO et al., 2016).

A primeira versão do LASH foi desenvolvida e apresentada por Viola (2008), como um modelo hidrológico semiconceitual, determinístico, de longo termo, concentrado e semidistribuído, baseado no método do CN Modificado (MISHRA *et al.*, 2006), no modelo MGB-IPH (COLLISCHONN, 2001) e no modelo de Muskingum-Cunge Linear (TUCCI, 2005), empregando o passo de simulação diário. Essa versão foi aplicada em duas bacias da região do alto rio Grande, em Minas Gerais. Os resultados obtidos foram promissores e o modelo foi capaz de simular de forma adequada as vazões diárias, inclusive em anos de El Niño e La Niña.

Posteriormente, Beskow (2009) realizou aprimoramentos computacionais e adaptações na rotina de calibração do modelo. Nesta versão, o modelo caracteriza-se como semiconceitual, determinístico, distribuído, de longo termo, fundamentado no método do CN Modificado (MISHRA et al., 2006) para estimativa do escoamento superficial direto, na equação de Brooks & Corey, para os escoamentos subsuperficial e de base, e modelo do Muskingum-Cunge Linear para propagação hidráulica na rede de drenagem. Essa versão foi inicialmente avaliada na bacia hidrográfica do ribeirão Jaguará (32 km²), a partir da qual foi possível verificar o potencial do modelo para a geração de séries de vazões máximas e mínimas e de curvas de permanência.

A terceira versão do modelo LASH foi realizada por Caldeira (2016), a partir da qual o modelo passou a ser classificado como de longo termo, semiconceitual e semidistribuído, com análise do balanço hídrico em sub-bacias hidrográficas. Essa versão foi idealizada a partir da adaptação do código de programação da segunda versão de células para sub-bacias. Além disso, foram implementados dois módulos auxiliares: o SYHDA e o ArcLASH, os quais fazem a preparação dos dados temporais e espaciais, respectivamente, necessários na rotina do modelo LASH.

A quarta versão do LASH, denominada de M-LASH, foi desenvolvida por Vargas (2021), em Matlab®. O M-LASH simula a rotina do modelo LASH na escala de sub-bacias e apresenta dois grandes avanços em termos de processamento, sendo eles: i. implementação do método da Onda Cinemática para propagação em canais; ii. acoplamento do algoritmo multiobjetivo AMALGAM (VRUGT; ROBINSON, 2007) na rotina de calibração do modelo. Nesta versão, pode ser implementada a paralelização do *script* de calibração, otimizando o tempo de calibração do modelo.

Na Figura 5 é apresentada uma síntese das principais diferenças entre as quatro versões do modelo LASH.

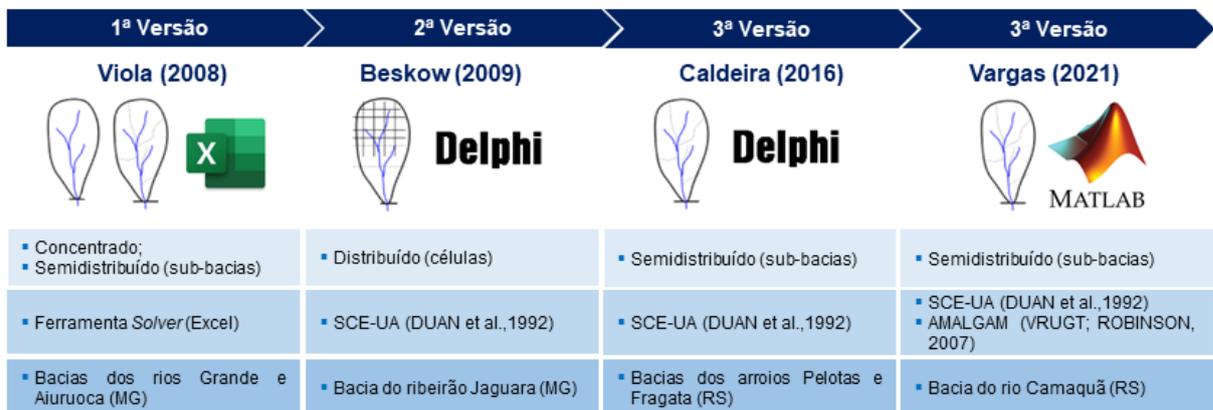


Figura 5 – Principais características das versões do modelo hidrológico LASH: discretização espacial, calibração e aplicação.

Além do nível de discretização espacial utilizado nas versões: concentrado e semidistribuído em sub-bacias (1ª versão), distribuído em células (2ª versão) e semidistribuído em sub-bacias (3ª e 4ª versões), o modelo LASH teve sua rotina de calibração aprimorada ao longo das versões. Inicialmente, o modelo era apresentado em planilha eletrônica, no formato Microsoft Office Excel, na qual a calibração dos parâmetros desconhecidos ou indiretamente mensuráveis era realizada de forma manual ou por meio da ferramenta *Solver*. Posteriormente, o modelo passou para

ambiente de programação Delphi®, no qual a calibração dos parâmetros é realizada pelo algoritmo *Shuffled Complex Evolution* (SCE-UA), desenvolvido por Duan, Sorooshian e Gupta (1992). Este método global de otimização de parâmetros executa a rotina de simulação hidrológica, compilando os bancos de dados espacial, de solo, de uso do solo e meteorológico, até convergir para um conjunto adequado de valores que representem os processos simulados. Atualmente, a versão M-LASH possibilita, além do SCE-UA, o uso do algoritmo AMALGAM para calibração do modelo, o qual é um dos algoritmos mais robustos em termos de otimização, visto que engloba em sua formulação diferentes técnicas de evolução.

Na Figura 6 é apresentada uma cronologia de evolução do modelo LASH, bem como as principais publicações realizadas com base em sua aplicação. As bacias hidrográficas nas quais o modelo LASH foi aplicado encontram-se localizadas na Figura 7.

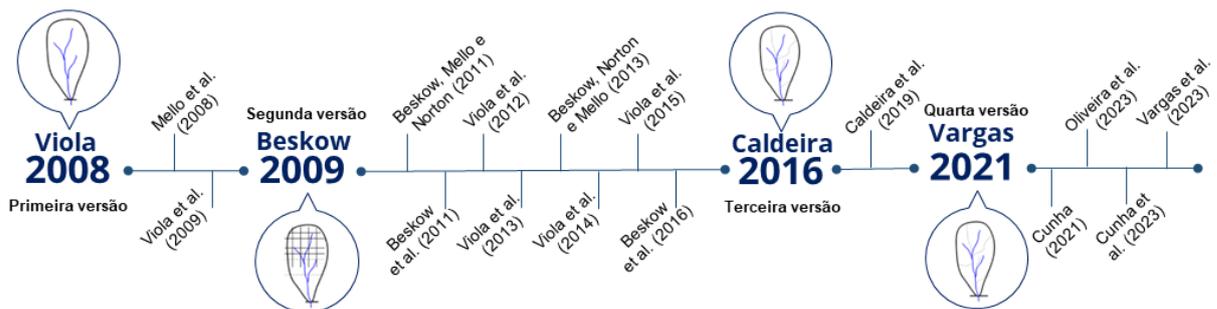


Figura 6 - Modelo hidrológico LASH da concepção e avaliação ao desenvolvimento da terceira versão.

Como é possível observar na Figura 6, diversos trabalhos vêm utilizando o modelo LASH ao longo dos últimos anos, nos quais, os autores têm realizado com sucesso a modelagem hidrológica em bacias hidrográficas brasileiras de diferentes tamanhos. Beskow et al. (2016) ressaltam que, com base nos resultados obtidos, que o modelo LASH pode ser empregado para gestão de recursos hídricos em bacias hidrográficas com uma base de dados limitada e sob condições similares de solo e uso do solo.

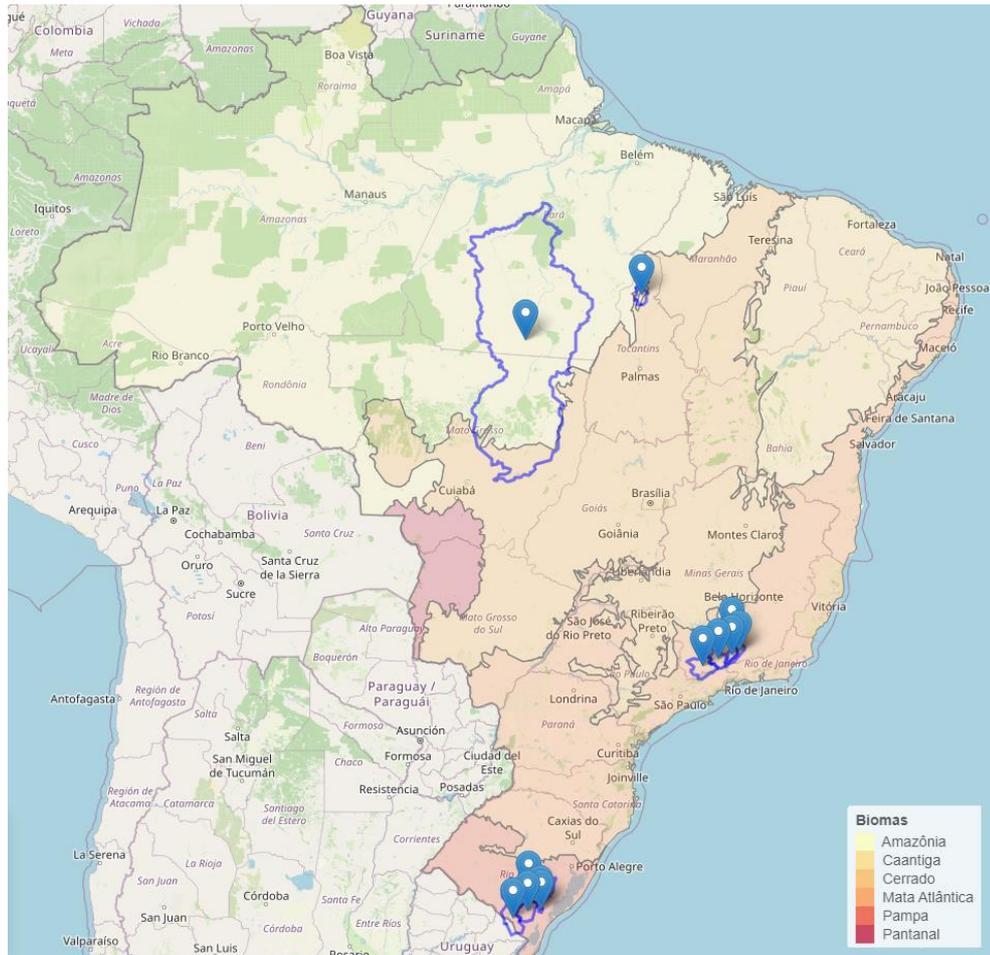


Figura 7 - Localização das bacias hidrográficas nas quais o modelo LASH já foi aplicado.
Fonte: Vargas (2021).

Conforme mencionado anteriormente, em conjunto com a terceira versão do modelo LASH, Caldeira (2016) desenvolveu a primeira versão do módulo ArcLASH. De acordo com Caldeira (2016), o ArcLASH foi idealizado seguindo o princípio da parcimônia, com intuito de identificar os mapas e informações que deveriam constituir a base de dados espacial do LASH e o menor número de entradas necessárias para que fosse possível estabelecê-la, levando em consideração as peculiaridades do modelo e a viabilidade das operações e da própria ferramenta.

O ArcLASH foi desenvolvido na forma de script, para ser executado através do ArcGIS® (ESRI, 2014). A linguagem de programação adotada foi Python, sendo empregados, especialmente, os códigos de programação disponíveis na biblioteca ArcPy.

3 METODOLOGIA

3.1 Desenvolvimento do R-LASH

Para implementação da rotina do modelo LASH em linguagem de programação R (R-LASH), bem como execução dos aprimoramentos propostos para esta versão, uma sequência lógica de etapas foi executada. Na Figura 8 é apresentado o organograma contemplando os principais aprimoramentos da versão R-LASH.

O desenvolvimento do R-LASH contemplou três diferentes momentos:

- i. ArcLASH – Linguagem Python: foram implementadas novas funcionalidades no módulo, principalmente em termos de processamento das bases de dados espaciais. Todos os arquivos de entrada e saída foram padronizados.
- ii. R-LASH – Linguagem R: inserção da rotina hidrológica do modelo LASH em linguagem R e busca na literatura de algoritmos multiobjetivos, já disponíveis em R, para compor o módulo de calibração do modelo.
- iii. R-LASH – Linguagem R: estudo de caso contemplando três bacias hidrográficas localizadas no sul do Rio Grande do Sul. Foram realizadas algumas análises comparativas entre algoritmos implementados no R-LASH e os resultados foram discutidos junto a literatura.

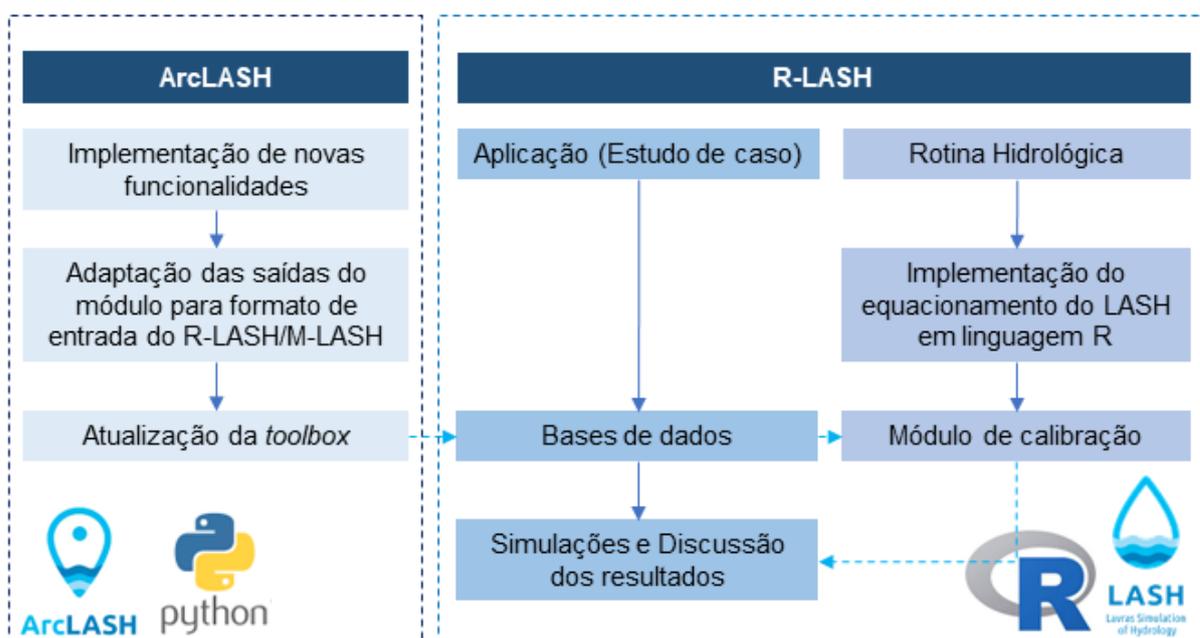


Figura 8 - Organograma representando os principais aprimoramentos do R-LASH.

3.2 Equacionamento do modelo LASH

3.2.1 Balanço hídrico do solo

O modelo LASH baseia-se na equação do balanço hídrico (Equação 1), independentemente do nível de discretização espacial utilizado (Caldeira et al., 2019). A variável dependente do modelo é o armazenamento atual de água no solo (A_t) e as independentes são: precipitação média (P) – descontada a interceptação, ascensão capilar (D_{CR}), evapotranspiração real (ET_R), escoamento de base (D_B), escoamento subsuperficial (D_{SS}), escoamento superficial direto (D_S) e armazenamento de água no solo no intervalo de tempo imediatamente anterior a t (A_{t-1}). Todas as variáveis são equacionadas como lâminas (mm) e o intervalo de tempo Δt utilizado é diário.

$$A_t = A_{t-1} + (P + D_{CR} - ET_R - D_B - D_{SS} - D_S) \cdot \Delta t \quad \text{Equação 1}$$

De acordo com Viola (2008), o A_t é uma variável de estado primordial em modelos de simulação hidrológica, pois atua diretamente na geração das lâminas de escoamento de base, subsuperficial e superficial direto, além de, exercer influência na evapotranspiração. Entretanto, a condição inicial de A_t é uma incerteza para a simulação hidrológica, pois não existem dados monitorados. Assim, foi adotado um valor inicial de 50% da capacidade de armazenamento de água no solo (A_m) média de cada sub-bacia hidrográfica, seguindo recomendações de Ribeiro Neto (2006).

Com exceção do A_{t-1} , cada componente da Equação 1 possui uma rotina hidrológica específica dentro do modelo LASH, as quais serão apresentadas a seguir.

3.2.2 Interceptação e precipitação

A interceptação consiste na retenção de uma parcela da precipitação, acima da superfície do solo e, geralmente, ocorre devido à vegetação. De acordo com Mello e Silva (2013), a estimativa da parcela de interceptação é bastante relevante, uma vez que a quantificação da evaporação da água é realizada com base nesta parcela (BESKOW, 2009).

Cada sub-bacia possui uma capacidade de armazenamento, denominada de Capacidade do Reservatório de Interceptação (CRI) (Equação 2). A CRI é calculada como

uma função linear do Índice de Área Foliar (IAF) (ZHOU et al., 2006; COLLISCHONN et al., 2007; MELLO et al., 2008).

$$CRI = \alpha \cdot IAF \quad \text{Equação 2}$$

Em que: α é a capacidade máxima de armazenamento de água por unidade de área das folhas, fixada em 0,2 mm (DICKINSON, 1984; WIGMOSTA; VAIL; LETTENMAIER, 1994).

Posteriormente ao cálculo do CRI, realiza-se o equacionamento da lâmina interceptada (LI_t , em mm) (Equação 3) e da precipitação (P , em mm) (Equação 4). O valor de LI_t varia de acordo com a precipitação total (P_T) ocorrida no intervalo de tempo t e a lâmina interceptada disponível no início do intervalo de tempo t (LI_{t-1}).

$$LI_t = \begin{cases} CRI, & LI_{t-1} = 0 \text{ e } P_T > CRI \text{ ou } LI_{t-1} + P_T > CRI \\ P_T, & LI_{t-1} = 0 \text{ e } P_T < CRI \\ LI_{t-1} + P_T, & LI_{t-1} \neq 0 \text{ e } LI_{t-1} + P_T < CRI \end{cases} \quad \text{Equação 3}$$

$$P = P_T - (LI_t - LI_{t-1}) \quad \text{Equação 4}$$

Em que: LI_t é a lâmina interceptada durante o intervalo de tempo t (mm), CRI é a capacidade do reservatório de interceptação (mm), LI_{t-1} é a lâmina no reservatório de interceptação no 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 modelo LASH estima o esvaziamento do reservatório de interceptação, descontando da lâmina armazenada (LI_t) a evapotranspiração potencial (ET_P).

3.2.3 Evapotranspiração

No modelo LASH, primeiramente é obtida a evapotranspiração da cultura (ET_C), por meio da equação de Penman-Monteith (Equação 5), que leva em consideração as características da cobertura do solo, como albedo, altura e resistência da superfície (VIOLA et al., 2015).

$$ET_C = \frac{0,408 \cdot \Delta \cdot (R_n - G) + \left(\frac{864000 \cdot \gamma \cdot \varepsilon}{T_{Kv} \cdot R \cdot r_a} \right) \cdot (e_s - e_a)}{\Delta + \gamma \cdot \left(1 + \frac{r_s}{r_a} \right)} \quad \text{Equação 5}$$

Em que: ET_C é a evapotranspiração da cultura (mm), Δ é a declividade da curva de pressão de saturação da água ($\text{kPa} \cdot ^\circ\text{C}^{-1}$), R_n é a radiação líquida ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$), G é o fluxo de energia para o solo ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$) - considerado nulo, γ é a constante psicrométrica ($\text{kPa} \cdot ^\circ\text{C}^{-1}$), ε é a razão do peso molecular do vapor d'água/ar seco - 0,622 (adimensional), T_{Kv} é a temperatura virtual (K), R é a constante de gás específico - 0,287 ($\text{kJ} \cdot \text{kg}^{-1} \cdot \text{K}^{-1}$), r_a é a resistência aerodinâmica ($\text{s} \cdot \text{m}^{-1}$), r_s é a resistência estomática ($\text{s} \cdot \text{m}^{-1}$), e_a é a pressão atual do vapor d'água (kPa) e, e_s é a pressão de saturação do vapor d'água (kPa).

$$\Delta = \frac{4098 \cdot \left[0,6108 \cdot \exp\left(\frac{17,27 \cdot T}{T + 237,3}\right) \right]}{(T + 237,3)^2} \quad \text{Equação 6}$$

$$T_{Kv} = 1,01 \cdot (T + 273) \quad \text{Equação 7}$$

Em que: Δ é a declividade da curva de pressão de saturação da água ($\text{kPa} \cdot ^\circ\text{C}^{-1}$) na temperatura do ar T ($^\circ\text{C}$) e, T_{Kv} é a temperatura virtual (K).

$$\gamma = 0,000665 \cdot P \quad \text{Equação 8}$$

$$P = 101,3 \cdot \left(\frac{293 - 0,0065 \cdot z}{293} \right)^{5,26} \quad \text{Equação 9}$$

Em que: γ é a constante psicrométrica ($\text{kPa} \cdot ^\circ\text{C}^{-1}$), P é a pressão atmosférica (kPa) e, z é a altitude (m).

$$R_n = R_{ns} - R_{nl} \quad \text{Equação 10}$$

$$R_{ns} = (1 - a) \cdot R_s \quad \text{Equação 11}$$

$$R_{nl} = \begin{cases} \sigma \cdot \left(\frac{T_{\text{máx,K}}^4 + T_{\text{mín,K}}^4}{2} \right) \cdot (0,34 - 0,14 \cdot \sqrt{e_a}) \\ \quad \cdot \left(1,35 \cdot \frac{R_s}{R_{s0}} - 0,35 \right), & R_s \leq R_{s0} \\ \sigma \cdot \left(\frac{T_{\text{máx,K}}^4 + T_{\text{mín,K}}^4}{2} \right) \cdot (0,34 - 0,14 \cdot \sqrt{e_a}), & R_s > R_{s0} \end{cases} \quad \text{Equação 12}$$

Em que: R_n é a radiação líquida ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$), 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 é a radiação solar ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$), σ é a constante de Stefan-Boltzmann ($4,903 \cdot 10^{-9} \text{ MJ} \cdot \text{K}^{-4} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$).

¹⁾, $T_{\text{máx,K}}$ é a temperatura máxima (K), $T_{\text{mín,K}}$ é a temperatura mínima (K), e_a é a pressão atual do vapor d'água (kPa), R_s é a radiação solar ($\text{MJ}\cdot\text{m}^{-2}\cdot\text{dia}^{-1}$) e, R_{so} é a radiação de ondas curtas que ocorre quando não há nuvens no céu, ($\text{MJ}\cdot\text{m}^{-2}\cdot\text{dia}^{-1}$).

$$e_a = e_s \cdot \frac{\text{UR}}{100} \quad \text{Equação 13}$$

$$e_s = \frac{\left[0,6108 \cdot \exp\left(\frac{17,27 \cdot T_{\text{mín}}}{T_{\text{mín}} + 237,3}\right)\right] + \left[0,6108 \cdot \exp\left(\frac{17,27 \cdot T_{\text{máx}}}{T_{\text{máx}} + 237,3}\right)\right]}{2} \quad \text{Equação 14}$$

Em que: e_a é a pressão atual do vapor d'água (kPa), e_s é a pressão de saturação do vapor d'água (kPa), UR é a umidade relativa (%), $T_{\text{mín}}$ é a temperatura mínima ($^{\circ}\text{C}$) e, $T_{\text{máx}}$ é a temperatura máxima ($^{\circ}\text{C}$).

$$R_{\text{so}} = [0,75 \cdot (0,00002 \cdot z)] \cdot R_a \quad \text{Equação 15}$$

$$R_a = \left(\frac{24 \cdot 60}{\pi}\right) \cdot G_{\text{sc}} \cdot d_r \cdot [\omega_s \cdot \sin(\varphi) \cdot \sin(\delta) + \cos(\varphi) \cdot \cos(\delta) \cdot \sin(\omega_s)] \quad \text{Equação 16}$$

$$d_r = 1 + 0,033 \cdot \cos\left(\frac{2\pi}{365} \cdot j\right) \quad \text{Equação 17}$$

$$\omega_s = \arccos(-\tan(\varphi) \cdot \tan(\delta)) \quad \text{Equação 18}$$

$$\delta = 0,409 \cdot \sin\left(\frac{2\pi}{365} \cdot j - 1,39\right) \quad \text{Equação 19}$$

Em que: R_{so} é a radiação de ondas curtas que ocorre quando não há nuvens no céu, ($\text{MJ}\cdot\text{m}^{-2}\cdot\text{dia}^{-1}$), R_a é a radiação que atinge o topo da atmosfera ($\text{MJ}\cdot\text{m}^{-2}\cdot\text{dia}^{-1}$), z é a altitude (m), 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 é 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.

$$r_a = \begin{cases} \left(\frac{6,25}{U_{10}} \cdot \left[\ln\left(\frac{10}{h/10}\right)\right]\right)^2, & h \leq 10\text{m} \\ \frac{94}{U_{10}}, & h \leq 10\text{m} \end{cases} \quad \text{Equação 20}$$

$$U_{10} = V_{\text{emp}} \cdot \frac{\ln\left(\frac{10}{h/10}\right)}{\ln\left(\frac{2}{h/10}\right)} \quad \text{Equação 21}$$

$$V_{\text{emp}} = \begin{cases} v, & h_{\text{estação}} = 2\text{m} \\ \frac{v}{4,87}, & h_{\text{estação}} \neq 2\text{m} \\ \frac{v}{\ln(67,8 \cdot h_{\text{estação}} - 5,42)}, & \end{cases} \quad \text{Equação 22}$$

Em que: r_a é a resistência aerodinâmica ($\text{s}\cdot\text{m}^{-1}$), h é a altura da vegetação (m), U_{10} é a velocidade do vento a 10 m da superfície ($\text{m}\cdot\text{s}^{-1}$), v_{emp} é a velocidade do vento empregada ($\text{m}\cdot\text{s}^{-1}$), v é a velocidade do vento média diária ($\text{m}\cdot\text{s}^{-1}$), $h_{\text{estação}}$ é a altura da estação meteorológica (m).

A ET_C é convertida em evapotranspiração real (ET_R) utilizando a metodologia abordada no modelo hidrológico NRM3 Streamflow (NOTTER et al., 2007). Quando não há condições ótimas de umidade ou nutrientes, a evapotranspiração real é menor ou no máximo igual à ET_C (Equação 23).

Viola et al. (2012) ressaltam que a relação entre a ET_C e a ET_R pode ser expressa pelo coeficiente de estresse hídrico (K_S), o qual considera que a evapotranspiração é reduzida exponencialmente abaixo do limite inferior de disponibilidade de água no solo (A_L), no qual o limiar mais baixo corresponde à disponibilidade de água no solo no ponto de murcha permanente (A_{pmp}). Shuttleworth (1993) sugeriu os valores de 10% e 50% para A_L e A_m , respectivamente.

O coeficiente K_S é determinado no LASH considerando um decaimento exponencial da relação entre ET_R e ET_C a partir de um armazenamento limite de água no solo (A_L), pela seguinte equação adaptada de Bernardo, Soares e Mantovani (2005):

O comportamento de K_S em função do armazenamento atual de água no solo (A_t) pode ser visualizado na Figura 9. No modelo LASH, A_{PMP} e A_L são considerados equivalentes à, respectivamente, 10 e 50% da capacidade de armazenamento de água no solo (A_M), seguindo critérios adotados por Shuttleworth (1993).

$$ET_R = ET_C \cdot K_S \quad \text{Equação 23}$$

$$K_S = \begin{cases} \frac{\ln(A_t - A_{\text{PMP}})}{\ln(A_L - A_{\text{PMP}})}, & A_t < A_L \\ 1, & A_t \geq A_L \end{cases} \quad \text{Equação 24}$$

Em que: ET_R (mm) e ET_C (mm) são a evapotranspiração real e de cultura, respectivamente, K_S é o coeficiente de umidade do solo (adimensional), A_t é o

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

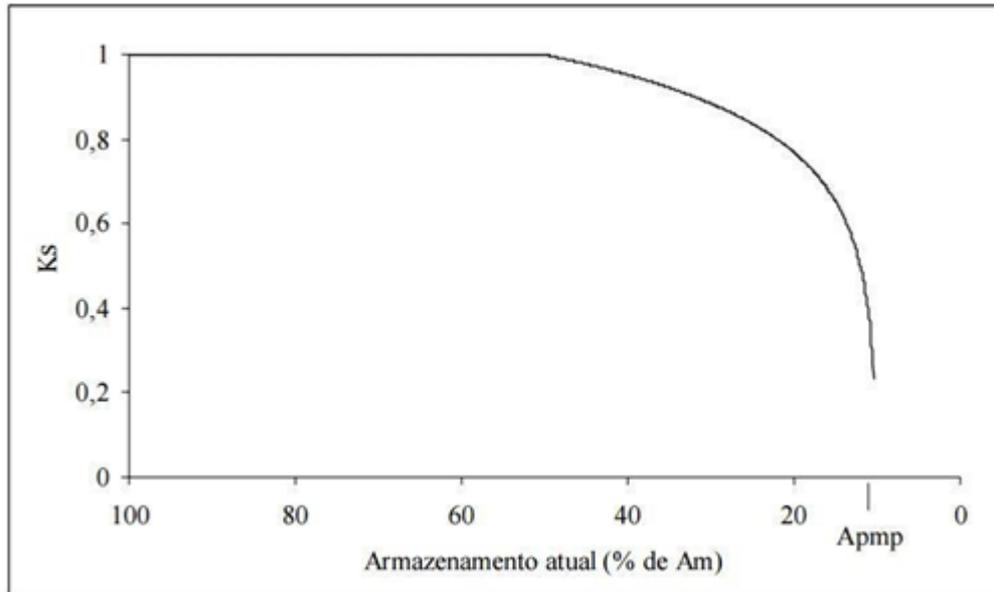


Figura 9 - Comportamento do fator KS em função do armazenamento atual de água no solo e das equações 23 e 24.

Fonte: Viola (2008)

3.2.4 Ascensão capilar

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 (DCR) 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 25 é utilizada.

$$D_{CR} = K_{CR} \cdot \frac{(A_{CR} - A_t)}{A_{CR}} \quad \text{Equação 25}$$

Em que: D_{CR} é a ascensão capilar (mm), K_{CR} é a constante, A_{CR} é o armazenamento limite para ocorrer ascensão capilar (mm) e, A_t é o armazenamento atual de água no solo (mm).

3.2.5 Geração de escoamento superficial direto

No modelo hidrológico LASH, a estimativa da parcela de escoamento superficial direto foi fundamentada no método Curva-Número (CN) (SCS, 1971), desenvolvido pelo *Soil Conservation Service* (SCS – atual *Natural Resources Conservation Services* do *United States Department of Agriculture*) e adaptado por Mishra et al. (2006), denominado de CN Modificado.

O método CN Modificado consiste em um aperfeiçoamento do método original, no sentido de melhor relacionar a abstração inicial (I_a) e o potencial de armazenamento de água no solo (S), considerando a umidade antecedente (M) como função da precipitação acumulada nos últimos 5 dias (P_5). A estimativa do escoamento superficial direto por este método se dá pelas seguintes equações:

$$D_{\text{SUP}} = \frac{(P_t - I_a) \cdot (P_t - I_a + M)}{P_t - I_a + M + S} \quad \text{Equação 26}$$

$$M = 0,5 \cdot (-(1 + \lambda) \cdot S) + \sqrt{(1 + \lambda)^2 \cdot S^2 + 4 \cdot P_5 \cdot S} \quad \text{Equação 27}$$

$$I_a = \frac{\lambda \cdot S^2}{S + M} \quad \text{Equação 28}$$

$$S = (\theta_s - \theta_A) \cdot h \quad \text{Equação 29}$$

$$S = A_m - A_t \quad \text{Equação 30}$$

Onde D_{SUP} 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 pelas equações (29 e 30) em função de A_m e A_t . Assim, λ é o coeficiente de abstração inicial, que de acordo com Mishra et al. (2006), pode variar de 0 a 0,5.

3.2.6 Geração de escoamento subsuperficial

A parcela de escoamento subsuperficial é estimada pelo modelo LASH seguindo o prescrito em Rawls et al. (1993). Desta forma, quando o armazenamento de água no solo no tempo t (A_t) for inferior ao limiar de armazenamento a partir do

qual ocorre geração de escoamento subsuperficial (A_{cc}), essa parcela será nula, contudo, se for superior, é estimada pela seguinte equação:

$$D_{SS} = K_{SS} \cdot \left(\frac{A_t - A_{cc}}{A_m - A_{cc}} \right)^{\left(3 + \frac{2}{Pr}\right)} \quad \text{se } A_t \geq A_{cc} \quad \text{Equação 31}$$

em que D_{SS} é o escoamento subsuperficial (mm), K_{SS} é a condutividade hidráulica do reservatório subsuperficial (mm.h^{-1}), calibrável, Pr é o índice de porosidade do solo, considerado fixo e igual a 0,4, A_{cc} representa o armazenamento de água no solo a partir do qual ocorre escoamento subsuperficial, considerado fixo e igual à 10% da capacidade de armazenamento de água no solo (A_m), como empregado por Collischonn (2001) e Ribeiro Neto (2006).

3.2.7 Geração de escoamento subterrâneo

A geração de escoamento subterrâneo, a qual é função da drenagem natural do aquífero superficial, é estimada no modelo hidrológico LASH com base em Rawls *et al.* (1993). Sendo assim, quando o armazenamento de água no solo no tempo t (A_t) for inferior ao limiar de armazenamento a partir do qual ocorre geração de escoamento subterrâneo (A_c), essa parcela será nula, no entanto, se superior, é estimada por:

$$D_B = K_B \cdot \left(\frac{A_t - A_c}{A_m - A_c} \right) \quad \text{se } A_t \geq A_c \quad \text{Equação 32}$$

em que D_B é o escoamento subterrâneo, em mm.dia^{-1} , K_B é a condutividade hidráulica do reservatório subterrâneo, calibrável, em mm.dia^{-1} , e A_c representa o armazenamento de água no solo a partir do qual ocorre escoamento subterrâneo, considerado fixo e igual à 1% da capacidade de armazenamento de água no solo (A_m).

3.2.8 Propagação nos reservatórios superficial, subsuperficial e subterrâneo

Uma vez quantificados D_{SUP} (Equação 26), D_{SS} (Equação 31) e D_B (Equação 32), o modelo converte cada componente do escoamento em vazão, empregando três reservatórios lineares em cada sub-bacia hidrográfica, a saber: o superficial, o subsuperficial e o subterrâneo (COLLISCHONN, 2001; TUCCI, 2005). Isto se faz

necessário para simular o retardamento dos diferentes componentes do escoamento nas sub-bacias hidrográficas, antes destes atingirem a rede de drenagem (VIOLA, 2011). De acordo com o autor, embora o método dos reservatórios lineares tenha uma abordagem simplificada do processo envolvido, sua aplicação tem proporcionado resultados satisfatórios, como observa-se em Beskow (2009), Mello et al. (2008) e Zhou et al. (2006).

A vazão de saída dos reservatórios lineares superficial, subsuperficial e subterrâneo é dada por:

$$Q_{SUP} = \frac{D_{SUP} \cdot A_{sb}}{C_{SUP} \cdot T_C} = \frac{V_{SUP}}{C_{SUP} \cdot t_c} \quad \text{Equação 33}$$

$$Q_{SS} = \frac{D_{SS} \cdot A_{sb}}{C_{SS} \cdot T_C} = \frac{V_{SS}}{C_{SS} \cdot t_c} \quad \text{Equação 34}$$

$$Q_B = \frac{D_B \cdot A_{sb}}{C_B} = \frac{V_B}{C_B} \quad \text{Equação 35}$$

Em que: Q_{SUP} , Q_{SS} e Q_B são as vazões de saída dos reservatórios superficial, subsuperficial e subterrâneo ($m^3 \cdot s^{-1}$), respectivamente, A_{sb} é a área de drenagem de cada da sub-bacia (m^2), V_{SUP} , V_{SS} e V_B representam o volume nos reservatórios superficial, subsuperficial e subterrânea (m^3), respectivamente, t_c representa o tempo de concentração (s), e C_{SUP} , C_{SS} e C_B são parâmetros de calibração da propagação dos reservatórios superficial, subsuperficial e de base, respectivamente.

Os parâmetros calibráveis C_{SUP} e C_{SS} são introduzidos devido às incertezas atreladas ao cálculo do tempo de concentração da sub-bacia hidrográfica. Quando analisada a parcela de escoamento subterrâneo, um parâmetro de mesmo propósito não é necessário, pois é possível analisar seu comportamento por meio de um período de recessão do hidrograma observado.

A vazão simulada a cada passo do modelo hidrológico, em cada sub-bacia hidrográfica, é, então, obtida pelo somatório das vazões de saída dos reservatórios superficial, subsuperficial e subterrâneo.

3.2.9 Propagação nos canais

De forma semelhante ao M-LASH (VARGAS, 2021), para a propagação nos canais foi adaptada e acoplada a função não-linear da Onda Cinemática de 1º ordem, resolvida de forma implícita, 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, 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 36).

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 36.

$$\frac{\Delta t}{\Delta x} Q_{i+1}^{j+1} + \alpha (Q_{i+1}^{j+1})^\beta = \frac{\Delta t}{\Delta x} Q_i^{j+1} + \alpha (Q_{i+1}^j)^\beta + \Delta t \left(\frac{q_{i+1}^{j+1} + q_{i+1}^j}{2} \right) \quad \text{Equação 36}$$

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

Visto que o intervalo de propagação nos trechos deve acompanhar o intervalo temporal de simulação do modelo LASH, a propagação nos canais foi implementada no R-LASH de forma condicional. Neste caso, a propagação somente será simulada se uma ou mais sub-bacias do objeto de estudo apresentaram tempo de concentração superior ao intervalo temporal (1 dia).

Ainda, cabe destacar que, entre os parâmetros da propagação, o coeficiente de rugosidade de Manning (n) pode ser otimizado, em conjunto com os demais parâmetros do modelo LASH, conforme sugerido no M-LASH.

3.2.10 Parametrização do modelo LASH

O modelo LASH possibilita a otimização de 7 parâmetros: λ - coeficiente de abstração inicial (adimensional); K_B - condutividade hidráulica do reservatório subterrâneo; K_{SS} - condutividade hidráulica do reservatório subsuperficial; K_{CR} - densidade de fluxo máxima para retorno por ascensão capilar; C_S - parâmetro do tempo de resposta do reservatório superficial; C_{SS} - parâmetro do tempo de resposta do reservatório subsuperficial; e, C_B - parâmetro do tempo de retardo do escoamento de base. Caso a propagação de canais seja utilizada, pode-se acrescentar à calibração do modelo o coeficiente de rugosidade de Manning (n).

Estes parâmetros foram definidos após a análise de sensibilidade do modelo realizada por Beskow, Mello e Norton (2011) e Viola et al. (2013). Os limites e unidades dos parâmetros encontram-se na Tabela 2.

Tabela 2 - Limites mínimos e máximos dos parâmetros do modelo LASH

Parâmetro	Unidade	Intervalo de valores	Referência
λ	adimensional	0 - 0,50	Mishra et al. (2006)
K_B	mm·dia ⁻¹	0 - 6	Beskow, Mello e Norton (2011)
K_{SS}	mm·dia ⁻¹	0 - 250	Caldeira (2016)
K_{CR}	mm·dia ⁻¹	0 - 5	Collischonn (2001)
C_S^*	adimensional	$C_S < C_{SS}$	Mello et al. (2008)
C_{SS}^*	adimensional	$C_S < C_{SS}$	Mello et al. (2008)
C_B	dias	-	-

*Parâmetros empíricos sem faixa específica de valores.

O K_{CR} tem relação direta com a possibilidade de retorno da água subterânea para a camada de solo. Visto a dificuldade de estimar este parâmetro a partir de um conjunto de dados, muitos modelos o desprezam. Collischonn (2001) ressalta que ao desprezar o K_{CR} , considera-se que toda a bacia hidrográfica simulada é área de recarga do aquífero, porém, existem casos em que algumas áreas da bacia podem ser claramente identificadas como regiões de descarga do aquífero.

3.3 Adequação da rotina hidrológica para linguagem de código aberto

A rotina do modelo LASH foi escrita em linguagem de programação R, utilizando o Ambiente de Desenvolvimento Integrado ou *Integrated Development Environment* (IDE) do RStudio (RSTUDIO TEAM, 2020). De acordo com Racine

(2012), o RStudio consiste em uma IDE que foi cuidadosamente pensada e que antecipa as necessidades dos usuários, possibilitando a simples utilização de R, e também, sua abordagem para criação e transferência de conhecimento.

A utilização da linguagem da programação em R vem sendo alavancada em diversas áreas de pesquisa, principalmente devido ao fato de que:

- i. R é uma linguagem de programação e um ambiente de software que sustenta uma grande variedade de técnicas computacionais, tais como modelagem linear e não linear, análise de séries temporais e testes estatísticos (SOETAERT; MEYSMAN, 2012);
- ii. o ambiente de software R possui um conjunto de funcionalidades que auxiliam na execução de várias tarefas de computação;
- iii. o R inclui uma instalação de manipulação e armazenamento de dados, um conjunto de operadores para cálculos em matrizes e matrizes, uma grande coleção de ferramentas para análise de dados e instalações gráficas para análise e exibição de dados.

Além disso, R é de código aberto e altamente extensível. Os usuários podem aprimorar o código base do R e também escrever extensões ou pacotes que adicionam funcionalidade à implementação básica (R Development Core Team). Outro fator que contribuiu para o sucesso do R é a existência da Rede de Arquivamento Compreensivo R (<http://CRAN.R-project.org/>), que é um repositório da Web único que arquiva uma ampla variedade de pacotes de extensão para R.

3.3.1 Algoritmos de calibração

O modelo LASH, em sua atual versão, utiliza como técnica de calibração o algoritmo *Shuffled Complex Evolution* (SCE-UA), desenvolvido por Duan, Sorooshian e Gupta (1992). Contudo, esta é uma técnica mono-objetiva, ou seja, possibilita a utilização de apenas uma função objetivo durante a calibração dos parâmetros do modelo. Booij e Krol (2010) ressaltam que, em modelos calibrados com apenas uma função objetivo, os resultados podem parecer satisfatórios, mas, geralmente, não representam bem algumas partes do hidrograma estimado, como por exemplo, vazões muito baixas.

Frente a esta limitação, algumas técnicas multiobjetivos foram implementadas e avaliadas na rotina de calibração do R-LASH. A principal característica destas

técnicas é a de não possuir, geralmente, uma única solução. De acordo com Araújo (2014), muitos problemas do mundo real apresentam um conjunto de objetivos a serem considerados que são, em grande maioria, conflitantes entre si. Ou seja, ao mudar de uma solução para outra, percebe-se a melhora em uma função objetivo em detrimento de pelo menos uma das outras funções objetivo. Ketabchi e Ataie-Ashtiani (2015) ressaltam que, cabe ao modelador saber identificar dentre as soluções aquelas que são eficientes para a resolução do problema.

Os algoritmos de calibração multiobjetivos, já disponíveis e implementados em linguagem R, incorporados neste estudo foram *DiffeRential Evolution Adaptive Metropolis* – DREAM (VRUGT et al., 2009), *Multi-objective Particle Swarm Optimization* – MOPSO (COELLO; LECHUGA, 2002) e *Non-dominated Sorting Genetic Algorithm II* - NSGA-2 (DEB et al., 2002), referentes aos pacotes *dream: DiffeRential Evolution Adaptive Metropolis* (GUILLAUME; ANDREWS, 2013), *MOPSOCD: Multi-objective Particle Swarm Optimization with Crowding Distance* (PROS NAVAL, 2013) e *nsga2R* (CHING-SHIH TSOU, 2022), respectivamente.

Estes algoritmos foram selecionados por: i) estarem implementados em linguagem R; e ii) possuírem formas de otimização/evolução diferenciadas.

3.3.1.1 Algoritmo SCE-UA

O algoritmo *Shuffled Complex Evolution – University of Arizona* (SCE-UA) é do tipo mono-objetivo e foi desenvolvido por Duan, Sorooshian e Gupta (1992). De acordo com Duan, Sorooshian e Gupta (1994), o SCE-UA é baseado em quatro conceitos, os quais combinados, tornam o algoritmo eficaz e robusto. São eles:

- 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
- iv. a combinação de complexos.

Segundo Duan, Sorooshian e Gupta (1992), o componente chave do SCE-UA é o algoritmo *Competitive Complex Evolution* (CCE), utilizado para evoluir cada complexo e que se baseia no esquema de pesquisa *Simplex downhill* do algoritmo Nelder-Mead (NELDER; MEAD, 1965).

As etapas de execução do SCE-UA, de acordo com Beskow (2009), são:

- i. criar aleatoriamente um complexo de pontos em todo espaço possível;
- ii. empregar a técnica de clusterização para tornar possível a busca na mais promissora das regiões identificadas no complexo inicial;
- iii. definir uma estratégia de complexo evolutivo sistemático (algoritmo CCE), essencial para fornecer robustez à busca e, de forma adicional, para o direcionamento de busca baseado na função-objetivo escolhida; e
- iv. incorporar um procedimento de evolução competitiva, 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 R por Felix Andrews, em 2009, e disponível no repositório CRAN (Figura 10).

```
## Translated from MATLAB to R
## and substantially revised by Felix Andrews <felix@nfrac.org>
## 2009-08-18

## Changed sampling scheme of parents from each complex;
## convergence criteria; memory efficiency; initial sampling; etc.

# Copyright (C) 2006 Brecht Donckels, BIOMATH, brecht.donckels@ugent.be
#
# This program is free software; you can redistribute it and/or
# modify it under the terms of the GNU General Public License
# as published by the Free Software Foundation; either version 2
# of the License, or (at your option) any later version.
#
# This program is distributed in the hope that it will be useful,
# but WITHOUT ANY WARRANTY; without even the implied warranty of
# MERCHANTABILITY or FITNESS FOR A PARTICULAR PURPOSE. See the
# GNU General Public License for more details.
#
# You should have received a copy of the GNU General Public License
# along with this program; if not, write to the Free Software
# Foundation, Inc., 59 Temple Place - Suite 330, Boston, MA 02111-1307,
# USA.

## Originally based on code by Qingyun Duan, 16 May 2005
## http://www.mathworks.com.au/matlabcentral/fileexchange/7671

## NOTE: keep this in sync with the help page!
sceDefaults <- function()
  list(ncomplex = 5,          ## number of complexes
       cce.iter = NA,        ## number of iteration in inner loop (CCE algorithm)
       fnscale = 1,          ## function scaling factor (set to -1 for maximisation)
       elitism = 1,          ## controls amount of weighting in sampling towards the better parameter sets
       initsample = "latin", ## sampling scheme for initial values -- "latin" or "random"
       reltol = 1e-5,        ## convergence threshold: relative improvement factor required in an SCE iteration
       tolsteps = 7,         ## number of iterations within reltol to confirm convergence
       maxit = 10000,        ## maximum number of iterations
       maxeval = Inf,        ## maximum number of function evaluations
       maxtime = Inf,        ## maximum duration of optimization in seconds
       returnpop = FALSE,    ## whether to return populations from all iterations
       trace = 0,            ## level of user feedback
       REPORT = 1)          ## number of iterations between reports when trace >= 1

SCEoptim <- function(FUN, par, ...,
                    lower = -Inf, upper = Inf,
                    control = list())
  {
```

Figura 10 – Detalhe da rotina SCE disponível em linguagem R.

3.3.1.2 Algoritmo DREAM

O Algoritmo *DiffeRential Evolution Adaptive Metropolis* (DREAM) foi apresentado por Vrugt et al. (2008, 2009) e consiste em uma adaptação do algoritmo *Shuffled Complex Evolution Metropolis* (SCEM-UA) (VRUGT et al., 2003a). O algoritmo simula múltiplas cadeias simultaneamente e efetua ajustes automáticos nas distribuições propostas durante a evolução dos passos da cadeia. Na Figura 11 é exemplificado o funcionamento do algoritmo DREAM, em termos de evolução em busca do ótimo global.

A base do algoritmo DREAM deriva do algoritmo *Differential Evolution Markov Chain* (DE-MC), proposto por ter Braak (2006). O método DE-MC consiste em um algoritmo genético com critério de seleção similar ao do algoritmo Metropolis. N diferentes cadeias são simuladas simultaneamente e as populações de parâmetros são armazenadas em uma matriz $N \times d$, em que d se refere à dimensão do problema (no caso, o número de parâmetros a ser estimado, neste caso igual a 7).

Através de um amostrador do tipo *Markov Chain Monte Carlo* (MCMC), o algoritmo DREAM realiza a convergência gradual de uma distribuição inicial proposta para uma distribuição estacionária dos parâmetros, por meio da assimilação de dados observados. Essa distribuição estacionária também pode ser denominada de distribuição a posteriori, visto que está condicionada a ocorrência dos dados observados assimilados.

Vrugt et al. (2009) destacam que, devido à simulação de N cadeias, as quais podem ser inicializadas em paralelo, o DREAM identifica um RMSE ótimo global de forma mais confiável do que SCE-UA e outros algoritmos de mesmo grupo, e requer menos simulações.

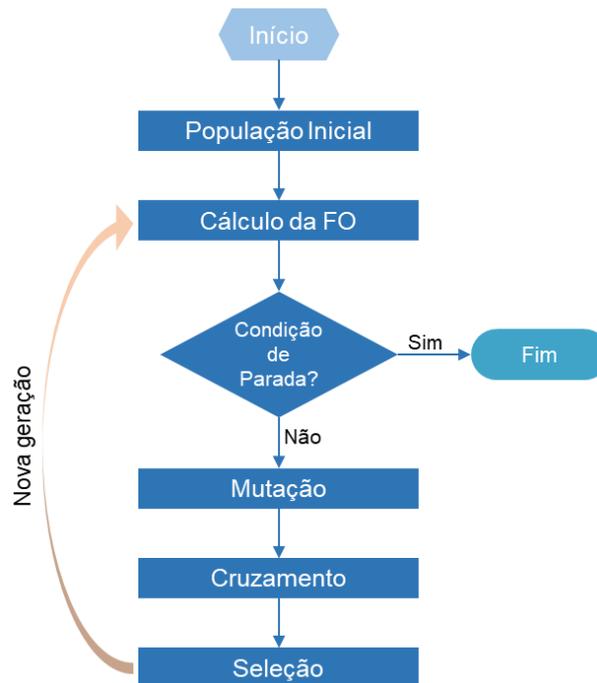


Figura 11 – Exemplificaç o do funcionamento do algoritmo DREAM.

3.3.1.3 Algoritmo MOPSO

O algoritmo de otimizaç o por enxame de part culas, ou *Particle Swarm Optimization* (PSO),   uma forma de resoluç o de problemas de otimizaç o que utiliza o conceito de populaç o e busca multi-dimensional. O algoritmo foi desenvolvido por Kennedy e Eberhart (1995), que tentavam simular o comportamento de um enxame de indiv duos em busca por alimento, como   observado por exemplo, no cardume de peixes e no voo dos p ssaros.

Posteriormente, o PSO foi estendido por Coello e Lechuga (2002) para resoluç o de problemas de otimizaç o multiobjetivo, sendo ent o denominado *Multi-Objective Particle Swarm Optimization* (MOPSO).

Basicamente, considera-se que uma populaç o, cujos indiv duos s o poss veis soluç es, “voa” no espaço de soluç es e, novas soluç es s o geradas a partir de iteraç es sociais entre as part culas. A posiç o   atualizada a cada iteraç o, considerando:

1. Velocidade anterior da part cula
2. Melhor posiç o individual – Melhor individual
3. Melhor posiç o do enxame (l der) – Melhor soluç o

Na Figura 12 é exemplificado o funcionamento do algoritmo MOPSO, em termos de evolução em busca do ótimo global.

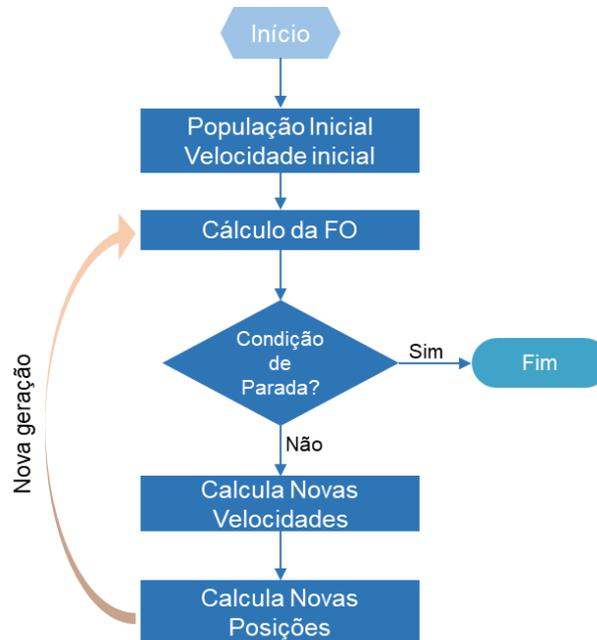


Figura 12 – Exemplificação do funcionamento do algoritmo MOPSO.

Assim como em outros métodos de otimização, o MOPSO trabalha com populações de soluções, ou seja, em uma mesma iteração, diversos pontos do espaço de busca são avaliados por meio de uma função de aptidão. Devido à sua robustez, este algoritmo eleva o esforço computacional durante a calibração de modelos, contudo, devido a maior sua maior capacidade de percorrer o espaço de busca, reduz a probabilidade de obtenção de ótimos locais.

3.3.1.4 Algoritmo NSGA-II

O NSGA-II (*Elitist Non-dominated Sorted Genetic Algorithm II*) é um algoritmo genético multiobjetivo proposto por Deb et al. (2002) como uma versão melhorada do NSGA (*Non-dominated Sorted Genetic Algorithm*) (SRINIVAS; DEB, 1994). No NSGA-II, o Ordenamento de Pareto (Figura 14) é feito de uma forma mais rápida (*Fast Non-dominated Sorting*), devido a forma como a busca pelo ótimo global é realizada (Figura 13):

- i. Geração de uma população formada por um conjunto aleatório de indivíduos, os quais podem ser vistos como possíveis soluções do problema;

- ii. Durante o processo evolutivo, esta população é avaliada, ou seja, é atribuída uma nota para cada indivíduo, refletindo sua habilidade de adaptação a determinado ambiente;
- iii. Parte dos indivíduos mais adaptados são mantidos, enquanto os outros são descartados (darwinismo).
- iv. Os indivíduos selecionados podem sofrer modificações em suas características fundamentais através de cruzamentos ou recombinação genética, gerando descendentes para a próxima geração.

Este processo de reprodução é repetido até que uma solução satisfatória seja encontrada.

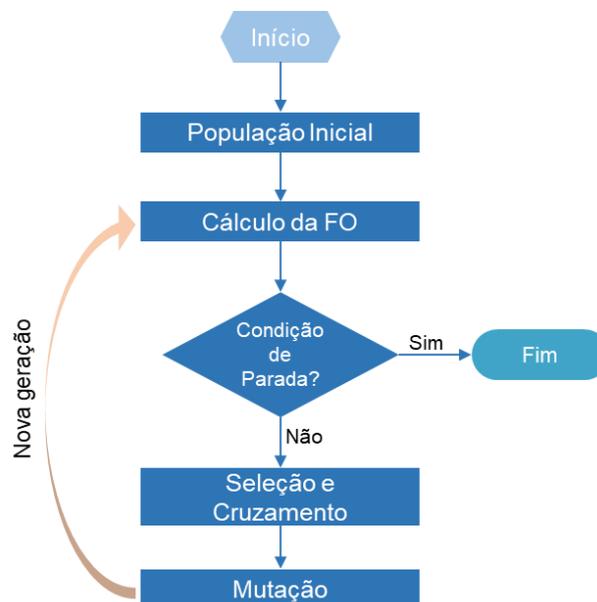


Figura 13 – Exemplificação do funcionamento do algoritmo NSGA-II.

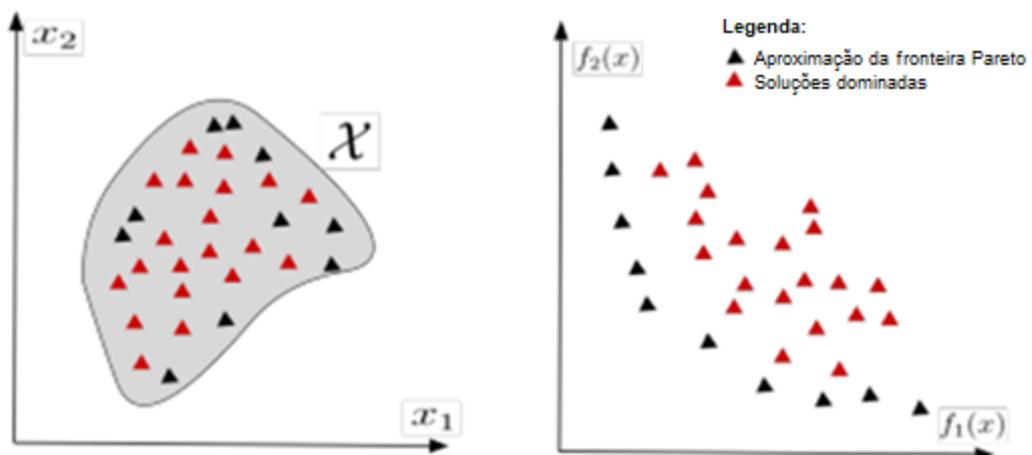


Figura 14 – Representação de: (a) espaço das soluções factíveis, e (b) espaço das funções objetivo e a representação da fronteira de Pareto FP.

3.3.2 Métricas de desempenho e funções objetivos

O desempenho do modelo foi avaliado pelas estatísticas *root mean squared error* (RMSE), coeficiente de Nash-Sutcliffe (C_{NS}) (NASH; SUTCLIFFE, 1970) e sua versão logaritmizada ($C_{NS,log}$), o percentual de viés (PBIAS) e o *Kling-Gupta efficiency* (KGE) (GUPTA et al., 2009), descritas pelas Equações 37 a 41, respectivamente.

$$RMSE = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (Q_{obs_t} - Q_{est_t})^2} \quad \text{Equação 37}$$

$$C_{NS} = 1 - \frac{\sum_{i=1}^N (Q_{obs_t} - Q_{est_t})^2}{\sum_{i=1}^N (Q_{obs_t} - \overline{Q_{obs}})^2} \quad \text{Equação 38}$$

$$C_{NS-LOG} = 1 - \frac{\sum_{i=1}^N (\log(Q_{obs_t}) - \log(Q_{est_t}))^2}{\sum_{i=1}^N (\log(Q_{obs_t}) - \overline{\log(Q_{obs})})^2} \quad \text{Equação 39}$$

$$P_{BIAS} = \frac{\sum_{i=1}^N (Q_{obs_t} - Q_{est_t})}{\sum_{i=1}^N (Q_{obs_t})} \cdot 100 \quad \text{Equação 40}$$

$$KGE = \sqrt{(r - 1)^2 + \left(\frac{\sigma_{est}}{\sigma_{obs}} - 1\right)^2 + \left(\frac{\mu_{est}}{\mu_{obs}} - 1\right)^2} \quad \text{Equação 41}$$

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; N é o número de ordenadas do hidrograma, r é a correlação linear entre as vazões observadas e estimadas, σ_{est} é o desvio padrão das vazões estimadas, σ_{obs} é o desvio padrão das vazões observadas, μ_{est} é a média das vazões estimadas e μ_{obs} é a média das vazões observadas.

O C_{NS} e o RMSE são estatísticas utilizadas para avaliar o comportamento do hidrograma ao longo do tempo e têm enfoque nas vazões elevadas. De acordo com Beskow (2009), o C_{NS-LOG} possibilita verificar a capacidade do modelo quanto às simulações das vazões de estiagem. Dessa forma, recomenda-se a utilização do C_{NS} e do C_{NS-LOG} para análises de resultados. Moriasi et al. (2015) destacam que uma das desvantagens do C_{NS} é a sua impossibilidade de identificar o viés do modelo, sendo o P_{BIAS} , empregado de forma complementar.

A estatística KGE é baseada na decomposição do C_{NS} e do Erro Quadrático Médio, e tem por principal característica a representação, em uma mesma métrica, da correlação, da tendência e da variabilidade relativa entre valores observados e simulados.

Em termos de classificações de valores para as estatísticas avaliadas, foram considerados:

- C_{NS} (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;
- P_{BIAS} (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
- RMSE (Singh *et al.*, 2005): em comparação com o desvio padrão (DP) dos dados observados. Podem ser considerados baixos valores de RMSE, aqueles menores que a metade do DP dos dados observados.

O C_{NS-LOG} e o KGE foram avaliados utilizando mesma classificação de valores proposta para o C_{NS} .

Para a calibração do modelo, utilizando os algoritmos multiobjetivos, foram selecionadas como função-objetivo o C_{NS} , C_{NS-LOG} e P_{BIAS} , todos com mesmo peso, pois juntos, permitem avaliar diferentes características do hidrograma de resposta.

3.3.3 Avaliação de desempenho com o modelo LASH

Para avaliação de desempenho com o modelo LASH costuma-se realizar o processo denominado *simple-test*, o qual consiste na subdivisão da série histórica em três partes: aquecimento, calibração e validação.

O período de aquecimento compreende uma parte da série da histórica para início da simulação hidrológica, e geralmente é composto de alguns meses de observações. Visto que, muitas considerações são feitas acerca das condições iniciais, principalmente em termos de umidade do solo, este período serve para que estas considerações sejam vencidas, uma vez que a camada de solo seja totalmente saturada durante este período inicial (GUIDOLIN, 2020). Cabe destacar que, apesar de ser processado em conjunto com a etapa de calibração, os dados deste período não são utilizados para compor as métricas de desempenho.

A calibração é realizada com uma parte da série histórica de interesse, a partir da qual serão otimizados os parâmetros do modelo, por meio de uma ou mais funções

objetivos. Nesta etapa, os parâmetros do modelo serão estimados de forma que as vazões simuladas se aproximem das vazões observadas.

Posteriormente à calibração, é realizada a validação do modelo. Faz-se uso de parte da série histórica, não utilizada na calibração, para verificação do modelo. As vazões do período de validação são simuladas a partir da aplicação dos parâmetros otimizados, e as métricas de desempenho são calculadas, para verificação da representatividade do modelo calibrado.

3.4 Aprimoramento da ferramenta ArcLASH

A preparação dos dados espaciais utilizados no modelo LASH é realizada no módulo ArcLASH, que consiste em um script em linguagem Python, utilizado no software de geoprocessamento ArcGIS® 10.1 (ESRI, 2014) como uma toolbox.

O ArcLASH foi idealizado por Caldeira (2016) e tem por objetivo a manipulação dos dados espaciais necessários para a simulação das informações hidrológicas. Visto que o modelo LASH tem sido ampliado e desenvolvido em outras linguagens de programação, a implementação de melhorias no ArcLASH se fez necessária.

Assim, foram realizadas adequações no módulo ArcLASH, com vistas ao processamento e, principalmente, em termos de exportação dos arquivos necessários para a modelagem hidrológica, de forma que estes fossem facilmente importáveis na rotina do modelo LASH. A seguir, são apresentados maiores detalhes acerca dos aprimoramentos realizados na ferramenta.

Os dados de entrada do módulo ArcLASH compreendem um modelo digital de elevação (MDE), um mapa de solos, um ou mais mapas de uso do solo, a rede de monitoramento de precipitação e a rede de monitoramento de dados meteorológicos. Além disso, faz-se necessário informar o limiar de hidrografia e as distâncias consideradas para abranger as estações de monitoramento na ponderação da área de influência.

O processamento das informações espaciais é dividido em três etapas (Figura 15): delimitação e caracterização das sub-bacias, processamentos das informações de solo e de uso do solo, e análise da área de influência das estações pluviométricas e meteorológicas.

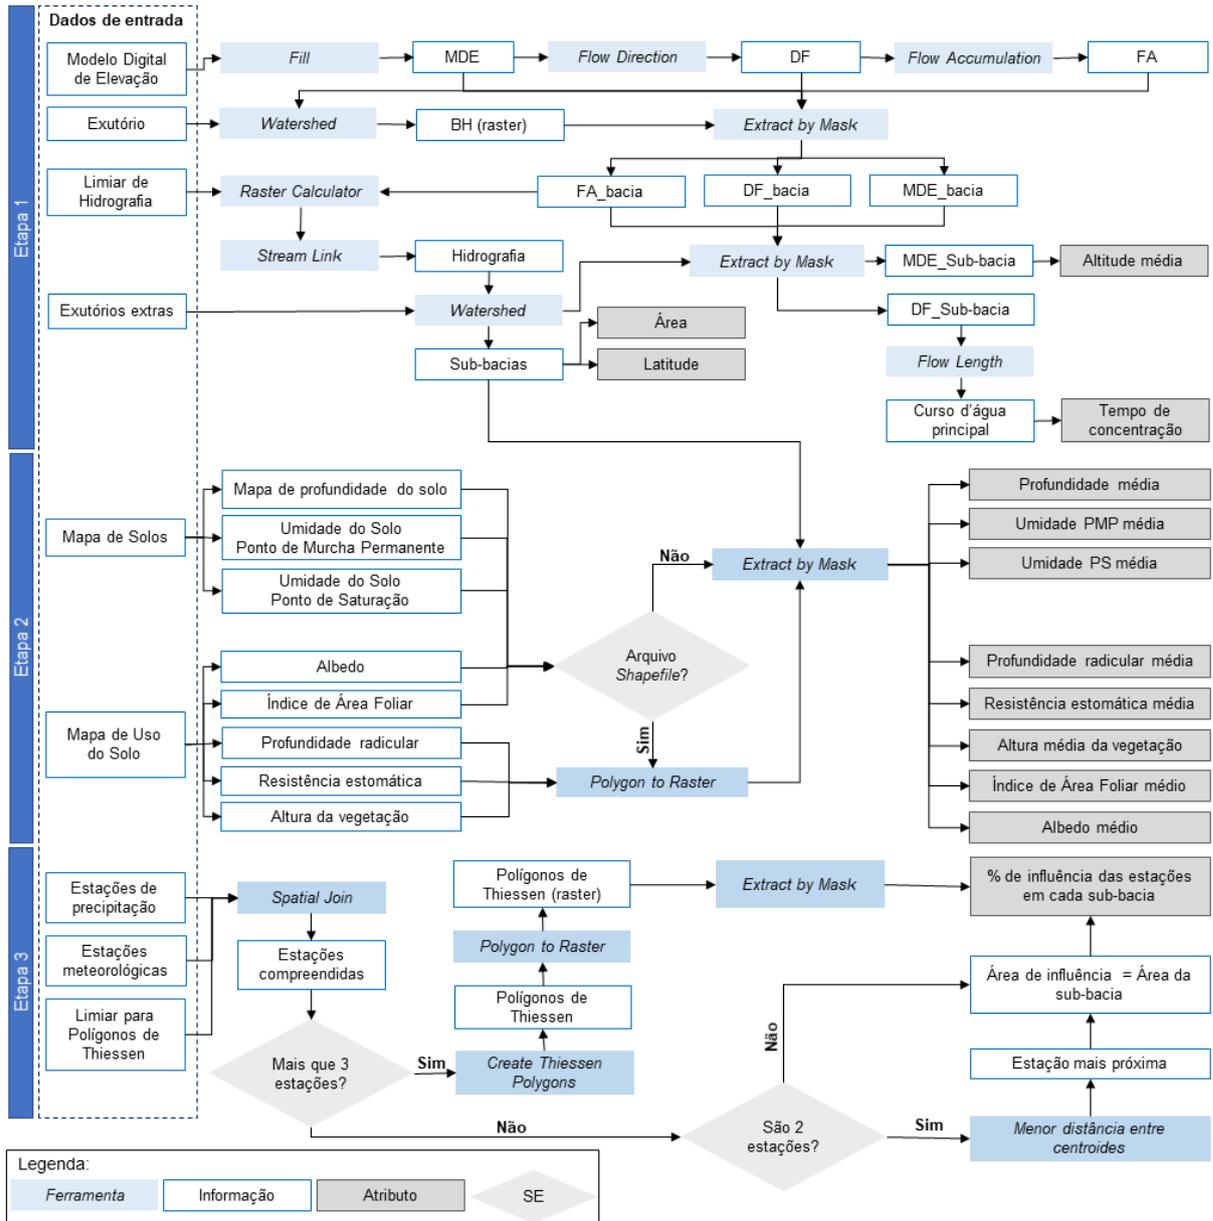


Figura 15 - Fluxograma ilustrando os processos, arquivos de entrada e informações de saída do módulo ArcLASH.

Na etapa de delimitação e caracterização das sub-bacias é realizado o processamento do MDE da área de interesse, em relação ao exutório previamente fornecido. Com base no limiar de drenagem (número de pixels) é realizada a subdivisão da bacia em sub-bacias. Foi acrescida ao ArcLASH, a possibilidade de inserção de exutórios extras, os quais consistem em pontos de interesse na bacia e que devem resultar em valores de vazão na simulação hidrológica (e.g. exutórios de sub-bacias importantes, estações de monitoramento, local estratégico para implementação de empreendimentos, outros). Caso estes exutórios extras sejam fornecidos, eles são considerados durante a subdivisão da bacia hidrográfica, para

que ao final do processo, consistam em um ponto localizado no exutório de uma sub-bacia.

Após a definição das sub-bacias e da hidrografia, as informações de área, latitude e altitude média são extraídas para cada sub-bacia delimitada. Nesta nova versão do módulo ArcLASH foi implementado o cálculo do tempo de concentração da bacia e das sub-bacias, o qual é utilizado no modelo LASH. Anteriormente, o tempo de concentração era definido por Kirpich e, se necessário, multiplicado por um fator de correção.

Visto que a aplicação do modelo LASH não é restrita em termos de escala de bacias hidrográficas, optou-se pela implementação de diferentes equações de tempo de concentração (t_c), conforme limiares de área apresentados na Tabela 3.

Tabela 3 - Equações para a estimativa do tempo de concentração das bacias hidrográficas, com base nos limiares de área de drenagem (A)

Limiar de área	Equação	Referência
$A \leq 0,5 \text{ km}^2$	Kirpich Equação 42	Kirpich (1940)
$0,5 < A \leq 20 \text{ km}^2$	Ven Te Chow Equação 43	Chow (1962)
$20 \text{ km}^2 < A \leq 200 \text{ km}^2$	Picking Equação 44	Mello e Silva (2013)
$A > 200 \text{ km}^2$	Giandotti Equação 45	Giandotti (1934)

$$t_c = 57 \cdot L^{1,155} \cdot H^{-0,385} \quad \text{Equação 42}$$

$$t_c = 52,64 \cdot \left(\frac{L}{\sqrt{S_o}} \right)^{0,64} \quad \text{Equação 43}$$

$$t_c = 51,79 \cdot \left(\frac{L^2}{\sqrt{S_o}} \right)^{0,333} \quad \text{Equação 44}$$

$$t_c = 60 \cdot \frac{1,5 \cdot L + 4 \cdot \sqrt{A}}{0,80 \cdot \sqrt{h}} \quad \text{Equação 45}$$

Em que, t_c é o tempo de concentração, em minutos; L é o comprimento do curso d'água principal, em km; H é o desnível entre a altitude do ponto inicial e final do curso d'água principal, em m; S_o é a declividade média do curso d'água principal, em m/km; A é a área de drenagem, em km^2 ; e h é o desnível entre a altitude média da bacia e a altitude final do curso d'água principal, em m.

Algumas observações devem ser feitas acerca das equações de t_c utilizadas. Para a Equação 45, foi realizada uma adaptação, de forma que o resultado final fosse obtido em minutos. Em todas as equações, o maior comprimento de fluxo percorrido

pela água, obtido via ferramenta “*Flow Length*”, foi adotado como curso d’água principal.

Na Etapa 2 é realizado o processamento das informações de solo e de uso do solo. Primeiramente, são extraídos os valores médios dos parâmetros relacionados às classes de solo das sub-bacias. Acerca das informações de solo, optou-se pela manutenção de dois formatos de entrada na ferramenta. O usuário pode fazer uso de um arquivo em formato *shapefile*, cujas colunas são padronizadas, ou arquivos em formato *raster* para a profundidade do solo e para as umidades de saturação e no ponto de murcha permanente. A utilização do arquivo em formato *shapefile* faz referência aos mapas de solo, nos quais, para cada classe de solo tem-se um conjunto de parâmetros relacionados. Os arquivos em formato *raster* são mais restritos aos locais em que as informações de solo estão espacializadas, geralmente, fruto de mapeamentos e estudos locais mais robustos.

Os mapas de usos do solo são processados de forma semelhante ao das classes de solo, entretanto, somente as variáveis IAF e albedo permitem a entrada em formato *raster*. Assim, ao selecionar os itens “Multiple IAF” e “Multiple Albedo”, o usuário pode fazer entrada de mapas em formato *raster* para estes atributos. Foi inserida nova funcionalidade nesta parte da ferramenta, que é a possibilidade de entrada de vários mapas de uso no processamento, permitindo ao usuário a representação das alterações de uso do solo observadas nos locais de interesse.

A terceira e última etapa do módulo ArcLASH tem por objetivo a análise da área de influência das estações pluviométricas e meteorológicas nas sub-bacias. Essa etapa tem grande relevância para a simulação hidrológica, visto que é dela que são determinadas as estações e dados a serem utilizados como entrada no modelo LASH, para cada sub-bacia.

A ponderação dos dados de precipitação e das variáveis meteorológicas, tais como umidade do ar, velocidade do vento, etc., são realizadas com base nos Polígonos de Thiessen (THIESSEN, 1911). Entretanto, quando o número de estações com dados disponíveis é inferior a 3, o módulo está organizado da seguinte forma: i) somente uma estação, a área de influência da estação é igual a área da sub-bacia; ii) duas estações, opta-se pela influência da que apresenta menor distância entre os centroides da sub-bacia com o da estação, ou seja, a área de influência da estação mais próxima é igual a área da sub-bacia. As áreas de influência, ao final do processamento, são convertidas em percentuais de influência.

A cada etapa de processamento, o módulo ArcLASH foi estruturado para exportar arquivos com os dados resumidos por sub-bacia. Estes arquivos foram padronizados para leitura das informações na rotina hidrológica do modelo LASH. Além dos arquivos com as informações necessárias para a modelagem hidrológica, ao final do processamento, uma pasta com as bases de dados espaciais resultantes é disponibilizada, para auxiliar na elaboração de mapas e figuras.

3.5 Estudo de caso: Avaliação dos aprimoramentos

Com base na Lei Nº 10.350 de 1994 que regulamenta o artigo 171 da Constituição Estadual, o Estado do Rio Grande do Sul é dividido em três grandes regiões hidrográficas: rio Uruguai, Guaíba e Litoral. Cada uma destas regiões é subdividida em bacias menores, conforme os cursos d'água de maior importância para cada região.

Uma das bacias de grande importância para o Estado é a bacia hidrográfica Mirim-São Gonçalo (BHMSG), que possui uma área de aproximadamente 62.250 km², da qual, 47% está localizada na parte sul do Rio Grande do Sul e 53% no Uruguai (CORADI et al., 2009). Na parte brasileira da Mirim-São Gonçalo (Figura 16) tem destaque o canal São Gonçalo, importante via navegável de 76 km de extensão, que liga a laguna dos Patos à lagoa Mirim.

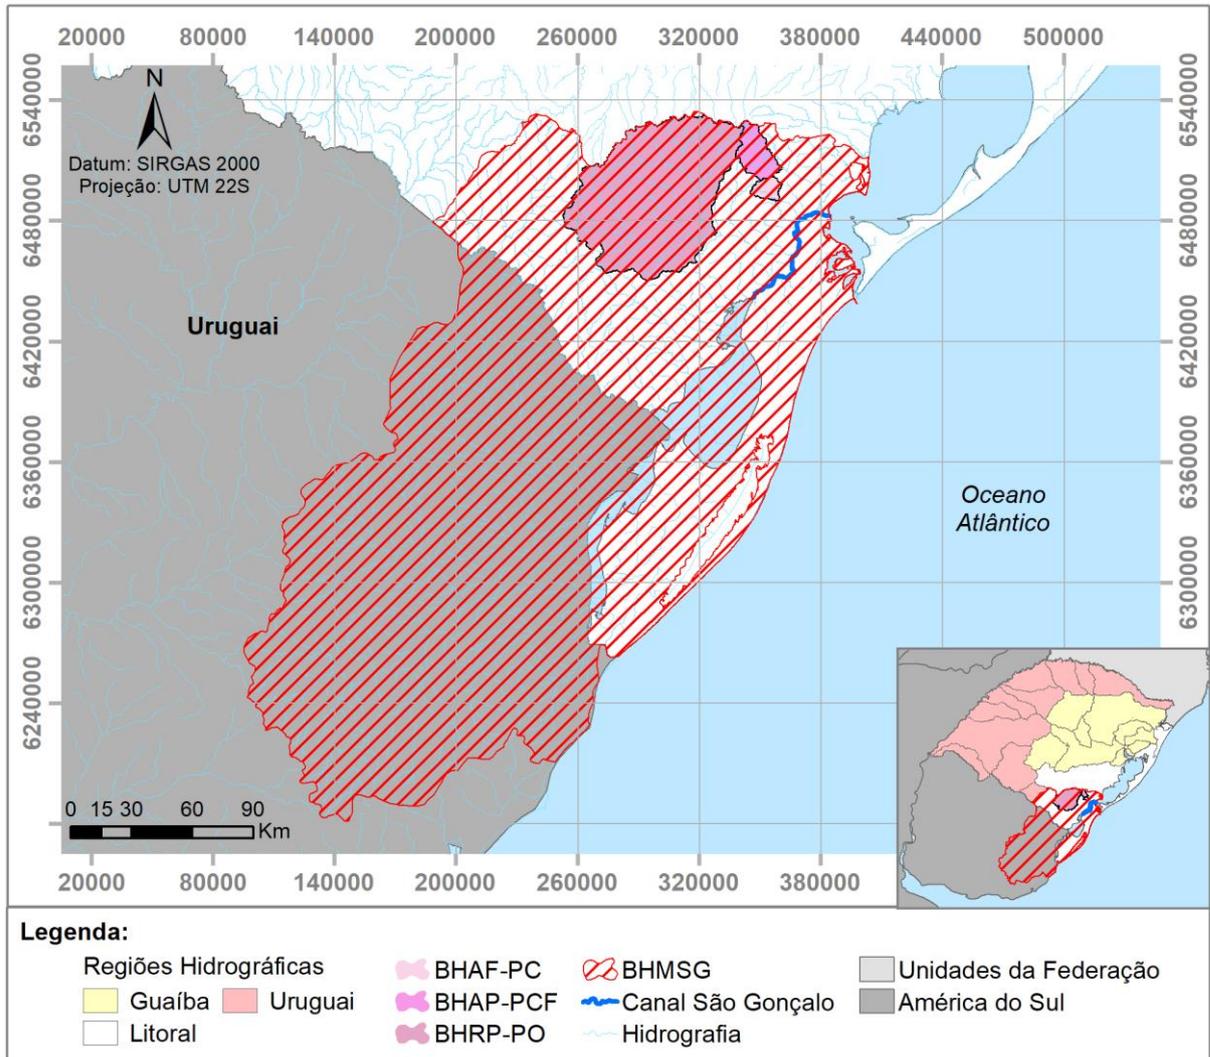


Figura 16 - Localização da bacia hidrográfica Mirim-São Gonçalo e das bacias hidrográficas do estudo.

O canal São Gonçalo apresenta diversos usos múltiplos, com destaque o abastecimento do município de Rio Grande desde a década de 80. Diferentes sub-bacias desaguam no canal, como por exemplo, a bacia hidrográfica do rio Piratini, que compreende 19% de toda região brasileira da Mirim-São Gonçalo, e as bacias hidrográficas dos arroios Fragata e Pelotas, as quais somam ~ 4% da parte brasileira da BHMSG.

Frente à importância dessas três bacias para o desenvolvimento da região sul do Estado, elas foram selecionadas para avaliação do modelo LASH. Juntas, essas bacias hidrográficas compreendem onze municípios (Figura 17) e suas delimitações, neste estudo, correspondem aos pontos de monitoramento com dados fluviométricos disponíveis.

Devido à disponibilidade de dados hidrológicos monitorados pela ANA nas seções de controle denominadas “Ponte Cordeiro de Farias”, “Passo dos Carros” e

“Pedro Osório”, estas bacias foram denominadas bacia hidrográfica do rio Piratini – Pedro Osório (BHRP-PO), do arroio Fragata – Passo dos Carros (Bhaf-PC) e do arroio Pelotas – Ponte Cordeiro de Farias (BHAP-PCF). As características básicas das bacias selecionadas são apresentadas na Tabela 4.

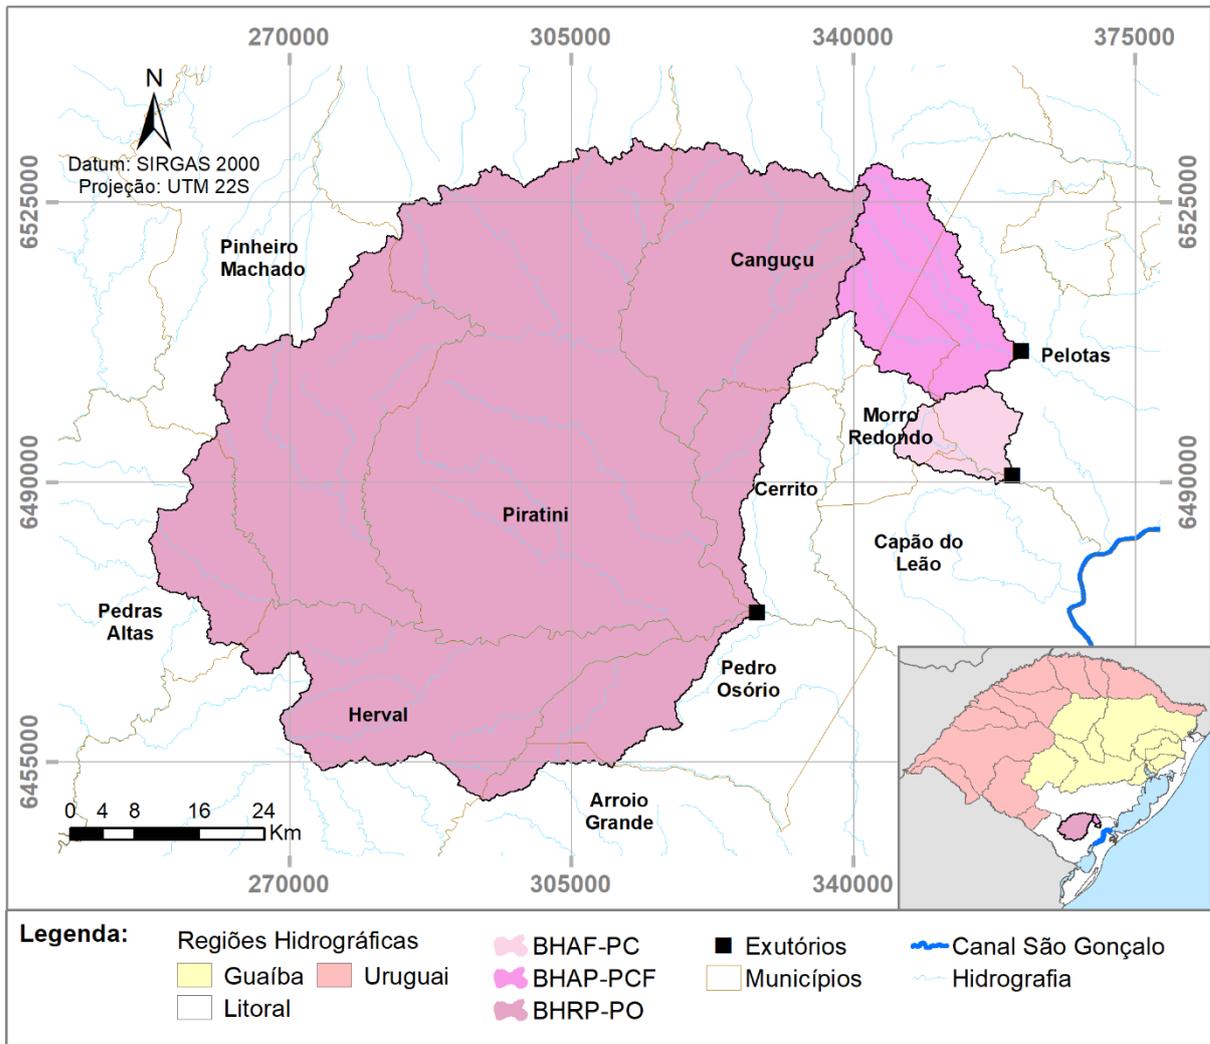


Figura 17 - Localização das bacias hidrográficas e municípios de abrangência.

Tabela 4 - Características das bacias hidrográficas utilizadas neste estudo

Bacia hidrográfica	Nome	Área drenagem total (km ²)	Características (delimitação deste estudo)		
			Área drenagem (km ²)	Perímetro (km)	Declividade média (%)
BHRP-PO	Bacia hidrográfica do rio Piratini – Pedro Osório	5.560,80	4.700,47	513,54	10,19
Bhaf-PC	Bacia hidrográfica do arroio Fragata – Passo dos Carros	216,36	125,05	73,38	10,12
BHAP-PCF	Bacia hidrográfica do arroio Pelotas – Ponte Cordeiro de Farias	903,07	369,13	145,14	11,99

3.5.1 Base de dados temporais

Para a realização da simulação hidrológica com o modelo LASH são necessários dados observados de precipitação e de algumas variáveis meteorológicas, sendo elas: temperatura, umidade relativa, radiação solar e velocidade do vento a 2 m. Os dados observados de vazão são necessários para a etapa de calibração do modelo.

Na Tabela 5 estão apresentadas as estações que compõem a rede de monitoramento hidrológico utilizada neste estudo. Essas estações estão espacializadas na Figura 18. As estações foram selecionadas segundo alguns critérios, tais como proximidade à área de estudo, disponibilidade de dados e coerência regional.

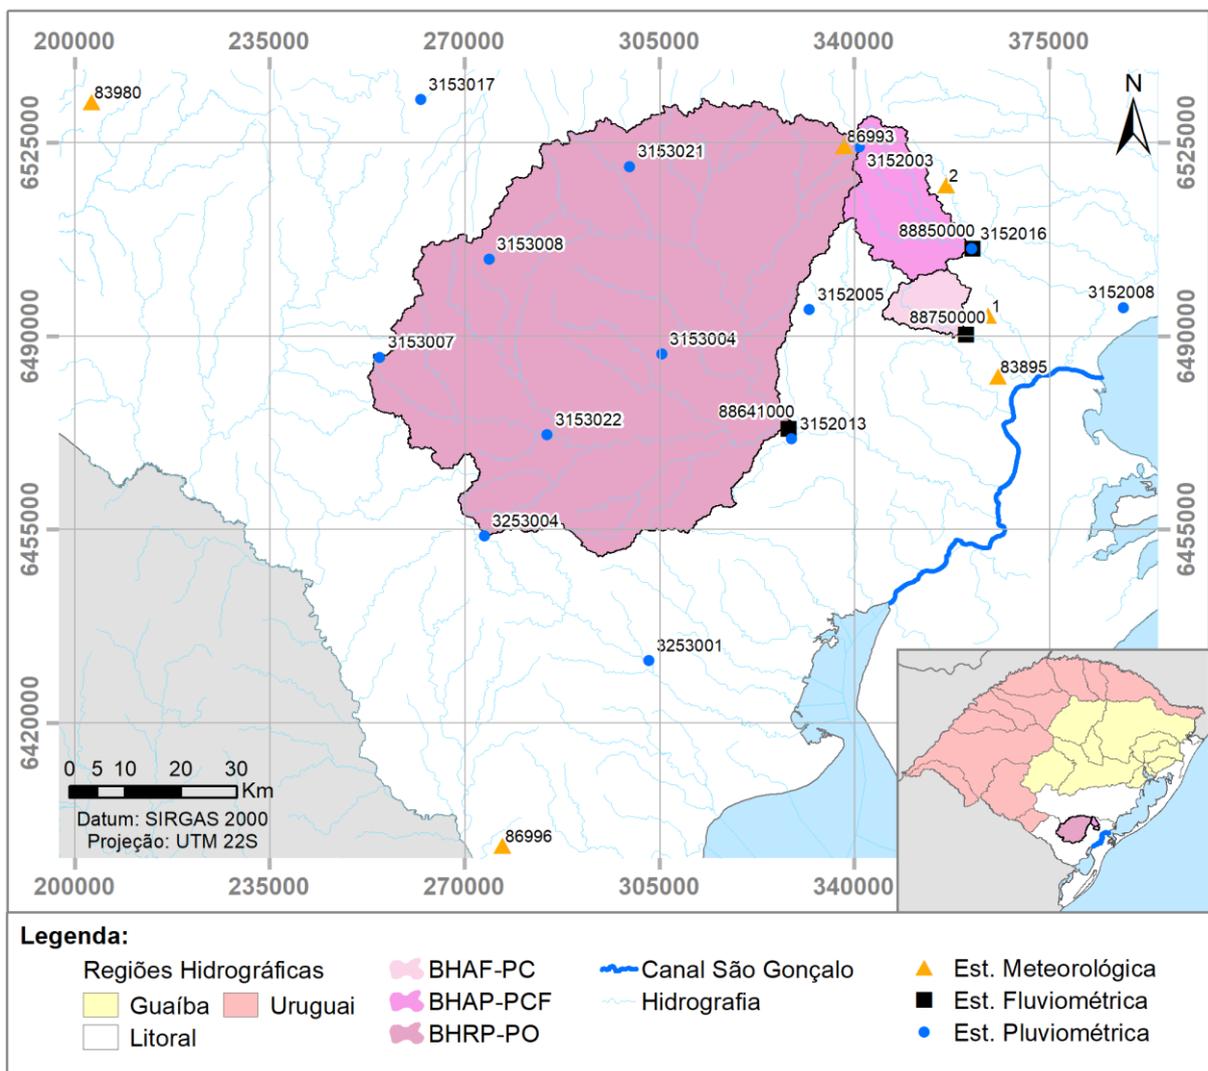


Figura 18 - Localização das estações de monitoramento selecionadas para o presente estudo.

Tabela 5 – Estações de monitoramento utilizadas e seus respectivos períodos com dados disponíveis

Tipo	Nome	Código	Responsável	Operadora	Latitude	Longitude	Altitude (m)	Município	Disponibilidade de dados	
Fluviométrica	Ponte Cordeiro de Farias	88850000	ANA	CPRM	-31,574	-52,463	40	Pelotas	08/1964	07/2022
	Passo dos Carros	88750000	ANA	CPRM	-31,714	-52,477	10	Pelotas	10/1964	10/2022
	Pedro Osório	88641000	ANA	CPRM	-31,863	-52,816	17	Pedro Osório	04/2000	10/2022
Pluviométrica	Canguçu	3152003	ANA	CPRM	-31,404	-52,673	400	Canguçu	01/1943	10/2022
	Vila Freire	3152005	ANA	CPRM	-31,669	-52,773	250	Cerrito	10/1976	10/2022
	Granja São Pedro	3152008	ANA	CPRM	-31,673	-52,178	3	Pelotas	01/1966	10/2022
	Pedro Osório	3152013	ANA	CPRM	-31,880	-52,810	27	Pedro Osório	03/1977	10/2022
	Ponte Cordeiro de Farias	3152016	ANA	CPRM	-31,574	-52,463	40	Pelotas	08/1964	10/2022
	Ferraria	3153004	ANA	CPRM	-31,738	-53,054	200	Piratini	09/1976	10/2022
	Passo da Capela	3153006	ANA	CPRM	-31,134	-53,054	120	Piratini	01/1977	10/2022
	Pedras Altas	3153007	ANA	CPRM	-31,733	-53,588	380	Pedras Altas	01/1966	07/2022
	Pinheiro Machado	3153008	ANA	CPRM	-31,578	-53,377	440	Pinheiro Machado	10/1965	10/2022
	Torrinhas	3153017	ANA	CPRM	-31,314	-53,499	420	Pinheiro Machado	09/1976	07/2022
	Estação Experimental de Piratini	3153021	ANA	CPRM	-31,431	-53,108	340	Piratini	09/1979	10/2022
	Cerro Chato	3153022	ANA	CPRM	-31,866	-53,274	100	Herval	04/2000	10/2022
	Arroio Grande	3253001	ANA	CPRM	-32,237	-53,090	3	Arroio Grande	12/1965	07/2022
Herval	3253004	ANA	CPRM	-32,029	-53,398	260	Herval	10/1965	10/2022	
Meteorológica	Estação Experimental Sede	1	EMBRAPA	EMBRAPA	-31,683	-52,433	57	Pelotas	01/1994*	12/2020**
	Estação Experimental Cascata	2	EMBRAPA	EMBRAPA	-31,470	-52,510	169	Pelotas	01/1994*	12/2018*
	Estação Agrometeorológica de Pelotas	83895	EMBRAPA	INMET	-31,783	-52,417	13	Pelotas	12/1925	12/2022
	Canguçu	86993	INMET	INMET	-31,403	-52,701	447	Canguçu	01/2007	12/2022
	Bagé	83980	INMET	INMET	-31,306	-54,119	246	Bagé	12/1911	12/2022
Jaguarão	86996	INMET	INMET	-32,535	-53,376	31	Jaguarão	01/2007	12/2022	

* Dados fornecidos pela Embrapa Clima Temperado; ** Série complementada por meio de boletins agrometeorológicos disponibilizados em meio digital.

Para compor a série utilizada, os dados passaram por análise de consistência, a fim de evitar que eles impactassem nas análises de calibração e validação. Os dados de vazão consistidos das estações selecionadas estão disponíveis até 2014 e passaram por análises locais e regionais no âmbito do projeto “Estudos de análise de consistência de dados fluviométricos de estações de monitoramento da ANA em operação nas bacias hidrográficas selecionadas”, apresentado em ANA (2020). Para o período de 2015 a 2020, os dados foram verificados em conjunto com os dados de precipitação. Quando da existência de pequenas falhas, estas foram preenchidas por interpolação e dados espúrios foram eliminados.

Os dados meteorológicos foram verificados em termos de magnitude e, coerência dos fenômenos meteorológicos observados na região em estudo. Quando identificados dados incoerentes estes foram eliminados e o preenchimento das informações faltantes ocorreu com base na estação mais próxima com dado disponível.

Os períodos estabelecidos para aquecimento, calibração e validação do modelo LASH, em cada uma das bacias hidrográficas, encontram-se na Tabela 6. Os períodos apresentados foram estabelecidos com base na disponibilidade de dados para simulação hidrológica.

Tabela 6 - Períodos utilizados para aquecimento, calibração e validação do modelo LASH nas bacias hidrográficas de estudo

Bacia hidrográfica	Número de anos	Aquecimento	Calibração	Validação
BHAF-PC	21	2000	2001 – 2010	2011- 2020
BHAP-PCF	21	2000	2001 – 2010	2011- 2020
BHRP-PO	21	2000	2001 – 2010	2011- 2020

3.5.2 Base de dados espaciais

A base de dados espaciais é composta por um modelo digital de elevação (MDE), mapas de classes de solo e mapas de uso do solo. Apesar de variarem no espaço, algumas destas informações variam, também, ao longo do tempo, como é o caso do uso do solo. Foi necessária a utilização de mais de um mapa para a extração das informações que compõem as séries históricas espaço-temporais utilizadas.

3.5.2.1 Relevo

Foram utilizadas quatro folhas do MDE SRTM, com resolução espacial de 30 m, para compor o MDE de toda a região em estudo. As folhas s32_w053, s32_w054, s33_w053 e s33_w054 foram obtidas no banco de dados do *United States Geological Survey* (USGS) e mosaicadas no software ArcGIS (ESRI, 2014).

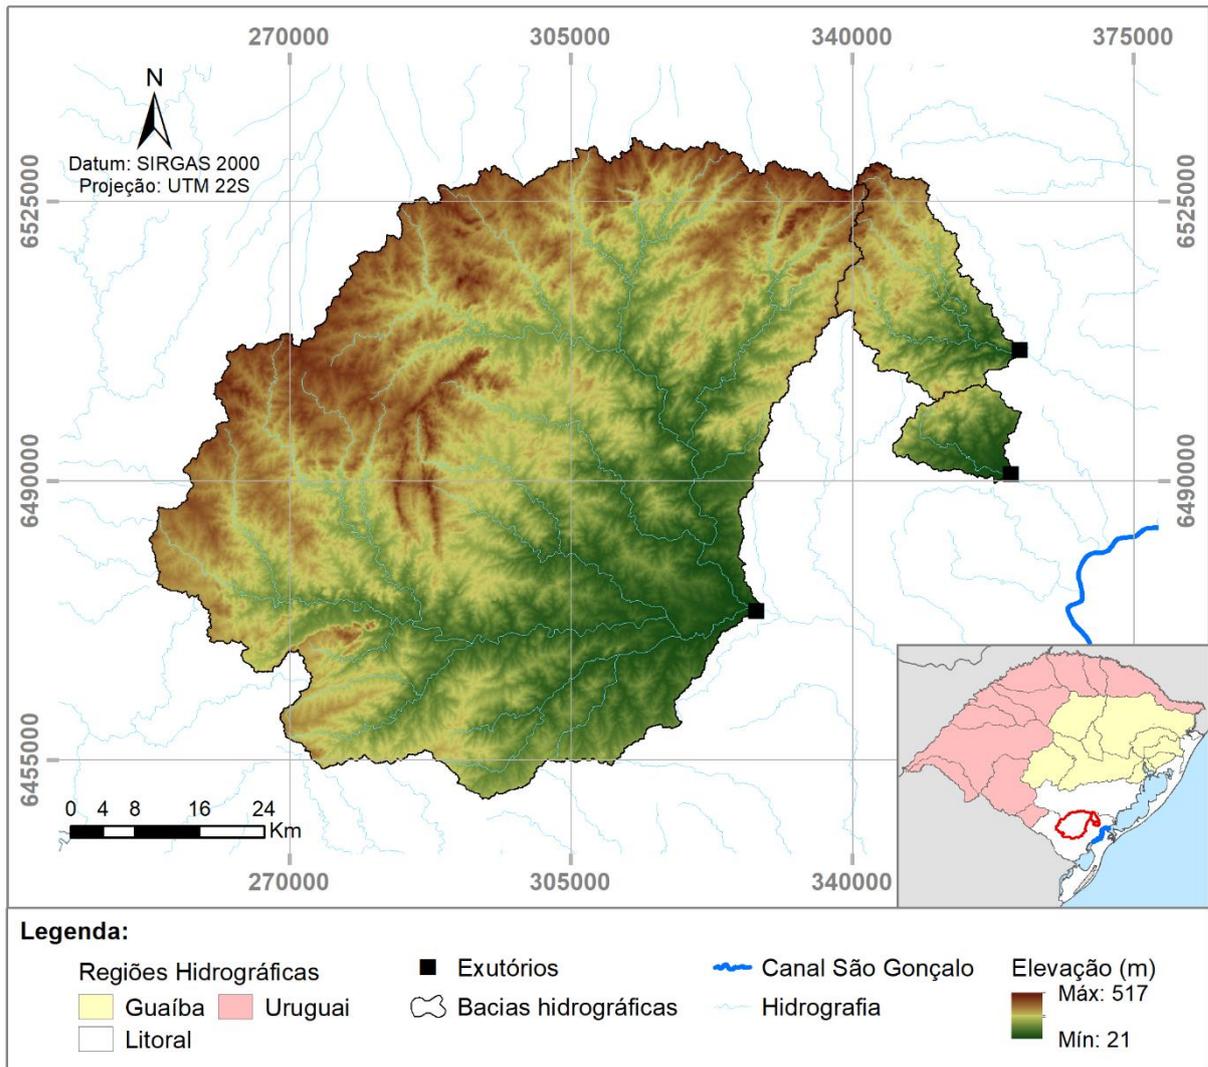


Figura 19 - Modelo digital de elevação da região de estudo.

3.5.2.2 Classes de solo

As informações referentes às classes de solo de cada bacia hidrográfica foram extraídas do mapa de solo intitulado “Solos e terras do planalto Sul-Rio-Grandense e planícies costeiras”, disponibilizado pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) e desenvolvido por Cunha, Silveira e Severo (2006).

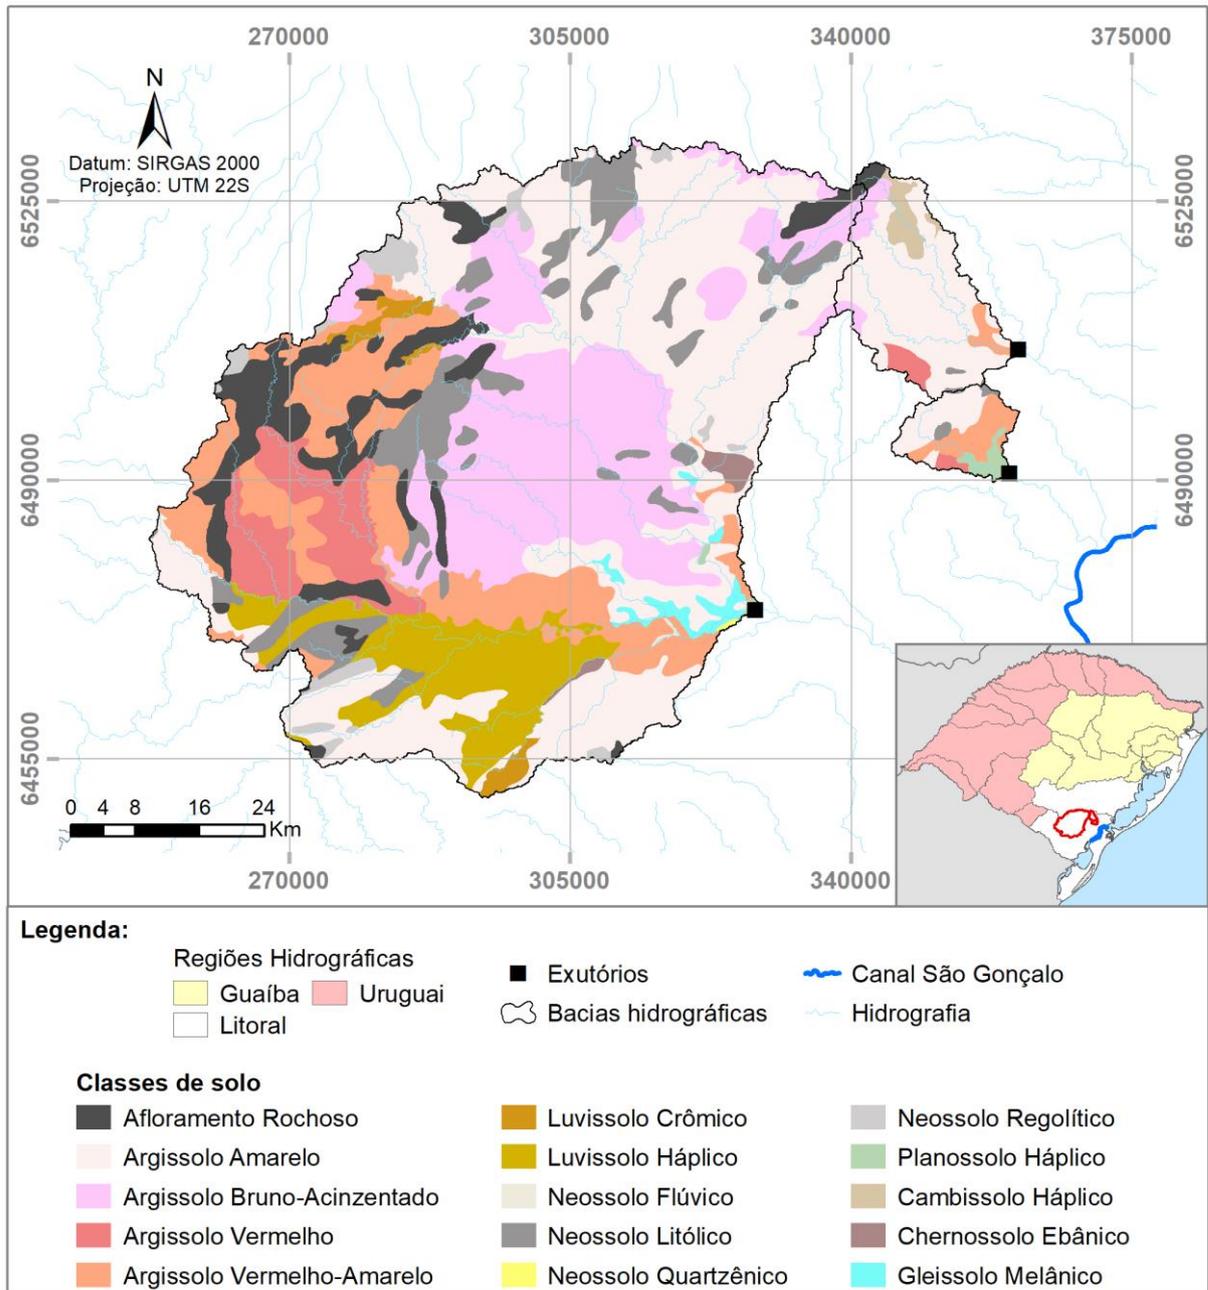


Figura 20 - Classes de solo, considerando até segundo nível categórico, encontradas na área de estudo.

Para cada classe de solo identificada são necessárias as informações de umidade do solo no ponto de saturação (θ_s) e no ponto de murcha permanente (θ_{PMP}), e a profundidade do solo (Z_{SOLO}). Estes valores estão apresentados na Tabela 7 e foram obtidos na literatura. Os trabalhos de Aquino (2014) e Soares (2017), desenvolvidos especialmente na área em estudo (Figura 21), também foram utilizados para complementar as informações.

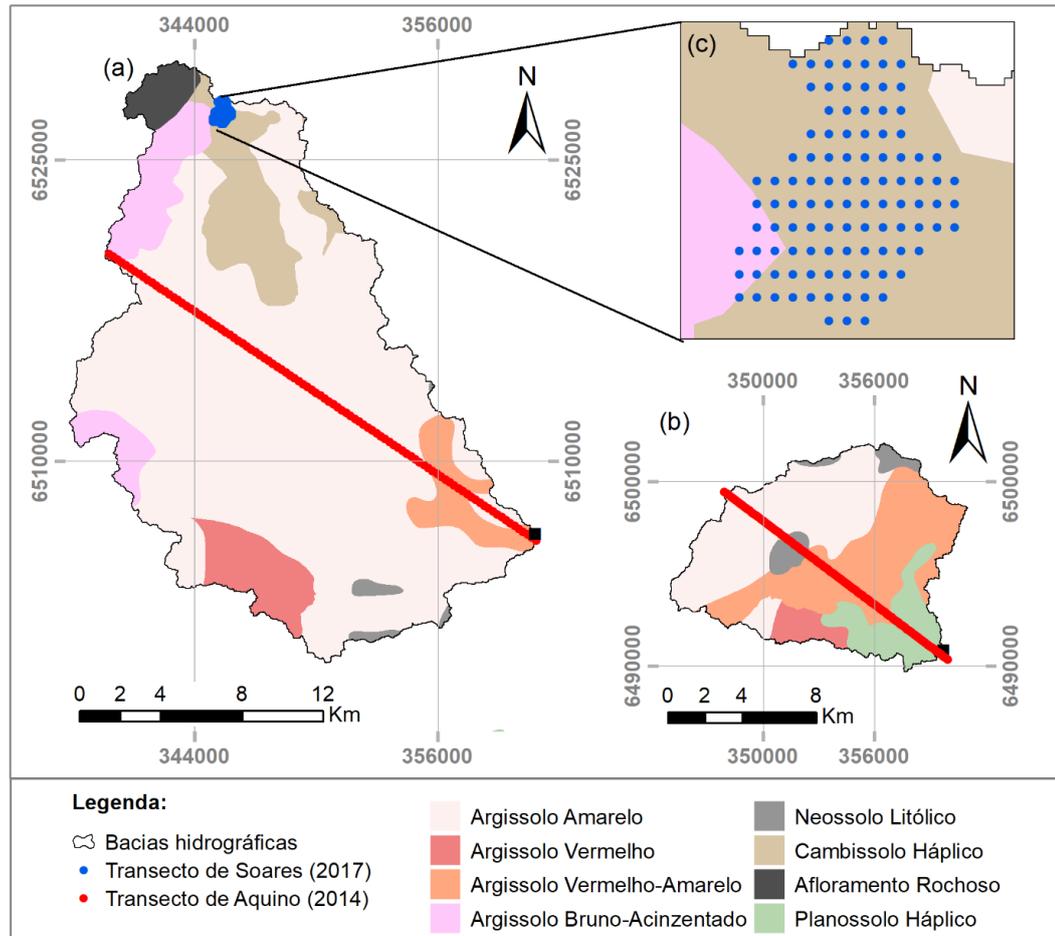


Figura 21 – Localização dos transectos de solo de Aquino (2014) e Soares (2017), utilizados para apoio metodológico.

Quanto à profundidade do solo, os valores empregados para cada classe (Tabela 7) foram definidos do seguinte modo:

- i) o mapa de solos apresentado na Figura 20 foi comparado, visualmente, aos mapas municipais de solos e unidades geomorfológicas elaborados pelo pesquisador Noel Gomes da Cunha, da EMBRAPA-CPACT, e colaboradores, a partir do reconhecimento dos solos da BHMSG realizado por Sombroek (1969);
- ii) para áreas representativas de cada classe de solo, buscou-se identificar a correspondência com os mapas de solos e de unidades geomorfológicas;
- iii) nos documentos que descrevem os mapas de solo e de unidades geomorfológicas, incluindo perfis representativos, buscou-se informações sobre a profundidade do solo;
- i) havendo mais de um perfil disponível para a classe de solo analisada, valores médios foram adotados.

Tabela 7 - Valores de umidade do solo no ponto de saturação (θ_s) e no ponto de murcha permanente (θ_{PMP}), e de profundidade do solo (Z_{SOLO}) empregados neste estudo, para cada classe de solo

Classe de solo	θ_s ($m^3 \cdot m^{-3}$)	θ_{PMP} ($m^3 \cdot m^{-3}$)	Referência	Z_{SOLO} (cm)	Referência
Afloramento rochoso	-	-	-	-	-
Argissolo Amarelo	0,458	0,179	Aquino (2014)	108	Cunha et al. (1997a); Cunha et al. (1997b); Cunha, Silveira e Severo (1996a)
Argissolo Bruno-Acinzentado	0,471	0,195	Aquino (2014)	124	Cunha et al. (1997b)
Argissolo Vermelho	0,459	0,192	Aquino (2014)	162	Cunha e Silveira (1996a)
Argissolo Vermelho-Amarelo	0,459	0,192	Aquino (2014)	146	Cunha e Silveira (1996b)
Cambissolo Háplico	0,427	0,100	Soares (2017)	70	Cunha et al. (1997a); Cunha et al. (1997b)
Chernossolo Ebânico	0,421	0,302	Otoni et al. (2018)	110	Cunha e Silveira (1996c)
Gleissolo Melânico	0,418	0,205	Otoni et al. (2018)	100	Cunha et al. (1997b)
Luvissolo Crômico	0,419	0,143	Silva (2008)	75	Cunha et al. (1998)
Luvissolo Háplico	0,419	0,143	Silva (2008)	117	Cunha, Silveira e Severo (1996a)
Neossolo Flúvico	0,425	0,221	Otoni et al. (2018)	130	Cunha, Silveira e Severo (1996b)
Neossolo Litólico	0,470	0,165	Aquino (2014)	30	Cunha et al. (1997b); Cunha, Silveira e Severo (1996a)
Neossolo Quartzarênico	0,444	0,097	Silva et al. (2006)	200	Cunha e Silveira (1996c)
Neossolo Regolítico	0,345	0,106	Otoni et al. (2018)	60	Cunha et al. (1997b)
Planossolo Háplico	0,405	0,175	Aquino (2014)	160	Cunha e Silveira (1996a); Cunha e Silveira (1996c)

Os percentuais de cada classe de solo, por bacia hidrográfica, encontram-se na Tabela 8. Os argissolos estão presentes em maioria nas três bacias hidrográficas, enquanto os Luvisolos e Neossolos aparecem em menores quantidades.

Em relação ao enquadramento hidrológico das classes presentes na área em estudo, observam-se solos das classes C e D, de acordo com Sartori, Lombardi Neto e Genovez (2005). De acordo com Mello e Silva (2013), solos do Grupo C são profundos a moderadamente profundos, possuem baixa permeabilidade superficial e baixa resistência à erosão. Os solos do Grupo D, por sua vez, são pouco profundos, apresentam camada de impedimento próximo ao horizonte A e alta vulnerabilidade à erosão.

Tabela 8 - Classes de solo, em percentual, para as bacias hidrográficas contempladas no estudo

Classe de solo	BHAF-PC	BHAP-PCF	BHRP-PO
Afloramento rochoso	-	2,03%	7,54%
Argissolo Amarelo	40,52%	72,50%	31,57%
Argissolo Bruno-Acinzentado	-	7,04%	21,58%
Argissolo Vermelho	4,81%	4,80%	5,21%
Argissolo Vermelho-Amarelo	35,76%	4,18%	13,17%
Cambissolo Háplico	-	8,65%	-
Chernossolo Ebânico	-	-	0,55%
Gleissolo Melânico	-	-	0,90%
Luvisolo Crômico	-	-	1,10%
Luvisolo Háplico	-	-	8,05%
Neossolo Flúvico	-	-	0,05%
Neossolo Litólico	5,07%	0,80%	8,30%
Neossolo Quartzarênico	-	-	0,04%
Neossolo Regolítico	-	-	1,86%
Planossolo Háplico	13,84%	-	0,08%

3.5.2.3 Uso do solo

Para obtenção dos mapas de uso do solo foram utilizadas imagens do Projeto de Mapeamento Anual do Uso e Cobertura da Terra no Brasil (MapBiomas, 2022). A Coleção de Série Anual de Mapas da Cobertura e Uso do Solo do Brasil (Coleção 7) contempla mapeamento completo do território brasileiro, elaborado por bioma, e classifica os diferentes usos do solo com base em imagens da série de satélites Landsat.

Para o bioma Pampa (HASENACK et al., 2022), a Coleção 7 contém mapas anuais de uso e cobertura do solo de 1985 a 2021, os quais foram produzidos a partir de uma sequência de procedimentos:

- i. Mosaicos Landsat anuais - usando valores medianos de pixels das cenas dentro de um período ótimo temporal;
- ii. Definição de um espaço de características – conjunto de métricas de sensoriamento remoto, incluindo bandas originais e índices usados como potenciais preditores de classe;
- iii. Amostras de treinamento - amostras de referência, usando a abordagem de amostras estáveis temporais;
- iv. Classificação de mosaicos Landsat com amostras de treinamento – usando o algoritmo *random forest*;
- v. Tratamento pós-classificação – uma série de filtros para remover ruídos e transições temporais improváveis;
- vi. Montagem do mapa final - integração das classes mapeadas com classes transversais adicionais; e
- vii. Validação - avaliação da precisão usando um conjunto de amostras independentes de validação plurianual.

Para melhor representação da hidrologia das bacias hidrográficas selecionadas, optou-se pela escolha de uma imagem de uso do solo a cada cinco anos de dados históricos, totalizando quatro imagens. Os anos escolhidos foram 2003 (2000 – 2005), 2008 (2006 – 2010), 2013 (2011 – 2015) e 2018 (2016 – 2020), os quais são intermediários de cada período.

De acordo com Siqueira et al. (2022), é consenso na literatura que o uso e ocupação do solo interferem diretamente no aumento ou diminuição de processos degradantes ao ambiente. Contudo, poucos são os estudos de modelagem hidrológica que representam as alterações de uso do solo durante as etapas de calibração e validação dos modelos. Geralmente, os estudos que abordam estas alterações provocam cenários com alterações de uso e avaliam os prováveis impactos desses cenários nas vazões simuladas, com base no modelo já calibrado.

As classes de uso do solo do Projeto MapBiomias estão apresentadas na Tabela 9. Posteriormente, essas classes foram enquadradas como floresta nativa, silvicultura, pastagem, campo nativo, agricultura, solo exposto ou água. Esse enquadramento foi realizado em vistas da disponibilidade dos parâmetros de entrada do modelo LASH, associados às classes de uso do solo.

Tabela 9 – Código e classe de uso do solo do Projeto MapBiomias e respectivos enquadramentos realizados para entrada das informações no modelo LASH

Código	Classe (MapBiomias)	Classe (Enquadramento)
3	Formação florestal	Floresta nativa
9	Silvicultura	Silvicultura
11	Campo alagado e área pantanosa	Campo nativo
12	Formação campestre	Campo nativo
21	Mosaico de usos - agropecuária	Pastagem
24	Área urbanizada	Solo exposto
25	Outras áreas não vegetadas	Solo exposto
29	Afloramento rochoso	Solo exposto
30	Mineração	Solo exposto
33	Rio, lago, oceano	Água
39	Soja	Agricultura
40	Arroz	Agricultura
41	Outras lavouras temporárias	Agricultura
49	Restinga arborizada	Campo nativo

Na Tabela 10 é apresentada uma síntese do uso do solo, com as porcentagens de cada classe, ao longo do tempo, nas bacias hidrográficas em estudo. Na Figura 22 e na Figura 23 estão apresentadas as classes de uso do solo na área de estudo, respectivamente para os anos de 2003 e 2018. É possível observar as mudanças no uso e ocupação do solo na região, principalmente em termos de aumento de Silvicultura e Agricultura.

Tabela 10 - Classes de uso do solo, em percentual, para as bacias hidrográficas contempladas no estudo, para os mapeamentos de 2003, 2008, 2013 e 2018

Bacia hidrográfica	Classe de uso do solo	2003	2008	2013	2018
BHAF-PC	Água	0,02%	0,03%	0,02%	0,03%
	Solo Exposto	0,15%	0,14%	0,32%	0,35%
	Mata nativa	36,16%	35,13%	36,19%	38,31%
	Silvicultura	7,35%	8,58%	8,78%	9,11%
	Pastagem	2,17%	1,34%	2,34%	1,73%
	Campo nativo	47,94%	48,08%	45,16%	40,06%
	Agricultura	6,20%	6,70%	7,18%	10,42%
BHAP-PCF	Água	0,01%	0,01%	0,01%	0,01%
	Solo Exposto	0,36%	0,36%	0,33%	0,34%
	Mata nativa	36,78%	35,32%	36,96%	38,41%
	Silvicultura	3,75%	4,70%	5,54%	6,17%
	Pastagem	3,97%	4,45%	4,82%	3,34%
	Campo nativo	43,33%	42,12%	37,40%	34,22%
	Agricultura	11,80%	13,03%	14,94%	17,51%
BHRP-PO	Água	0,09%	0,09%	0,09%	0,11%
	Solo Exposto	0,45%	0,42%	0,40%	0,40%
	Mata nativa	33,22%	29,85%	31,22%	32,18%
	Silvicultura	1,54%	3,62%	5,34%	5,55%
	Pastagem	1,18%	1,15%	2,92%	1,87%
	Campo nativo	61,59%	62,25%	54,88%	51,13%
	Agricultura	1,92%	2,62%	5,14%	8,77%

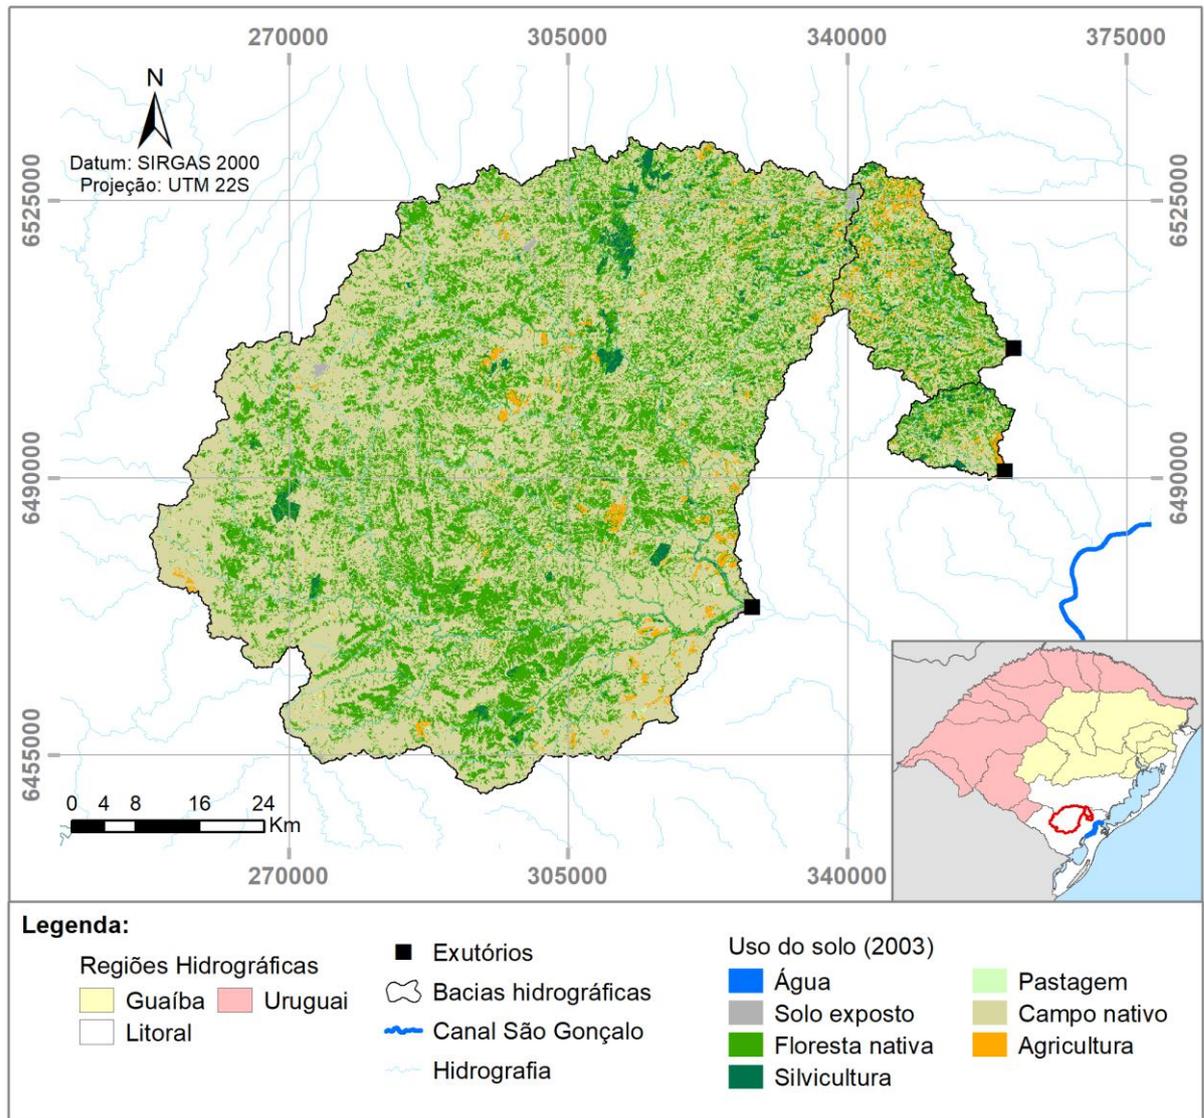


Figura 22 – Uso do solo, em 2003, nas bacias hidrográficas do estudo.

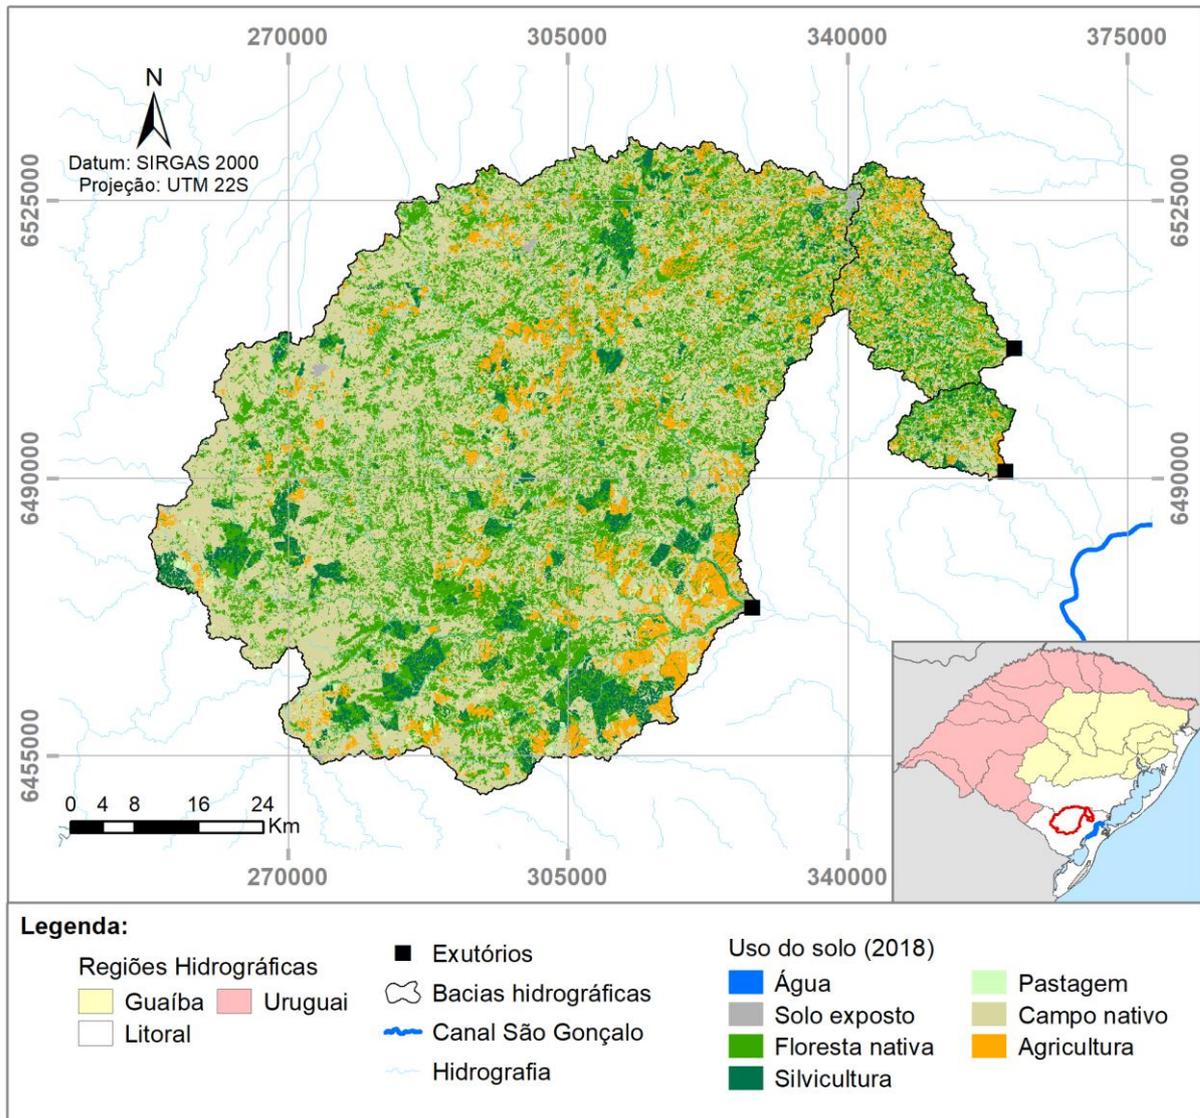


Figura 23 – Uso do solo, em 2018, nas bacias hidrográficas do estudo.

As classes de uso do solo foram atreladas a valores de índice de área foliar (IAF), albedo (α), altura da vegetação (h), resistência estomática (r_s) e profundidade do sistema radicular (P_{sr}). Esses valores são necessários para o cálculo de algumas variáveis do modelo LASH, e seus valores foram obtidos junto à literatura.

Para caracterização das estações, considerou-se: verão, de dezembro a fevereiro; outono, de março a maio; inverno, de junho a agosto; e primavera, de setembro a novembro. Os valores dos parâmetros e respectivas referências encontram-se na Tabela 11.

Tabela 11 - Parâmetros relacionados às classes de uso do solo

Variável	Classe de Uso do Solo	Estação do ano				Referência
		Verão	Outono	Inverno	Primavera	
Altura (m)	Campo Nativo	0,50	0,50	0,50	0,50	Barros (2016)
	Pastagem	0,50	0,50	0,50	0,50	Barros (2016)
	Agricultura	1,33	0,37	0,37	0,21	Barros (2016)
	Floresta Nativa	10,00	10,00	10,00	10,00	Collischonn (2001)
	Silvicultura	5,00	5,00	5,00	5,00	Collischonn (2001)
	Solo Exposto	0,05	0,05	0,05	0,05	Collischonn (2001)
	Corpos d'água	0,05	0,05	0,05	0,05	Collischonn (2001)
Resistência estomática (s·m ⁻¹)	Campo Nativo	65,0	65,0	65,0	65,0	Bathurst et al. (2011)
	Pastagem	60,0	70,0	80,0	80,0	Ruhoff et al. (2013)
	Agricultura	60,0	70,0	80,0	80,0	Ruhoff et al. (2013)
	Floresta Nativa	140,0	140,0	140,0	140,0	Andrew e Dymond (2007)
	Silvicultura	112,0	112,0	112,0	112,0	Andrew e Dymond (2007)
	Solo Exposto	545,3	545,3	545,3	545,3	Correia, Alvalá e Manzi (2004)
	Corpos d'água	0,0	0,0	0,0	0,0	Collischonn (2001)
Profundidade do sistema radicular (mm)	Campo Nativo	500	500	500	500	Allen et al. (1998)
	Pastagem	500	500	500	500	Allen et al. (1998)
	Agricultura	500	500	500	500	Allen et al. (1998)
	Floresta Nativa	2000	2000	2000	2000	Viola (2008)
	Silvicultura	1500	1500	1500	1500	Viola (2008)
	Solo Exposto	300	300	300	300	Mello et al. (2008)
	Corpos d'água	0	0	0	0	-
Índice de Área Foliar (m ² ·m ⁻²)	Campo Nativo	0,60	0,60	0,60	0,60	Hessel et al. (2003b)
	Pastagem	3,99	3,21	1,86	2,67	Fagundes et al. (2006)
	Agricultura	5,33	3,00	1,00	2,00	Ruhoff et al. (2013)
	Floresta Nativa	5,67	4,00	3,00	3,67	Ruhoff et al. (2013)
	Silvicultura	4,01	4,01	4,01	4,01	Berger et al. (2019)
	Solo Exposto	0,00	0,00	0,00	0,00	-
	Corpos d'água	0,00	0,00	0,00	0,00	-
Albedo	Campo Nativo	0,135	0,130	0,130	0,140	Giongo, Padovani e Vettorazzi (2009)
	Pastagem	0,160	0,150	0,155	0,160	Giongo, Padovani e Vettorazzi (2009)
	Agricultura	0,160	0,150	0,170	0,165	Giongo, Padovani e Vettorazzi (2009)
	Floresta Nativa	0,133	0,150	0,177	0,160	Miranda et al. (1996)
	Silvicultura	0,133	0,150	0,177	0,160	Miranda et al. (1996)
	Solo Exposto	0,150	0,153	0,173	0,160	Ruhoff et al. (2013)
	Corpos d'água	0,100	0,100	0,100	0,100	Ruhoff et al. (2013)

4 RESULTADOS E DISCUSSÃO

4.1 Estrutura do módulo ArcLASH

Na Figura 24 é apresentada a interface da versão atualizada para o módulo ArcLASH. Dentre as principais mudanças implementadas, pode-se destacar as possibilidades de:

- entrada de diferentes mapas de usos do solo;
- entrada de diferentes mapas de IAF (LAI - Leaf Area Index);
- entrada de diferentes mapas de albedo; e
- adicionar pontos de exutórios extras, para os quais se tem interesse em conhecer a hidrologia.

Além das melhorias realizadas à nível de programação e entrada de dados, os arquivos espaciais resultantes do processamento das sub-bacias também são fornecidos. Ao final do processamento com o módulo ArcLASH, é possível ter acesso a arquivos importantes, tanto para caracterização quanto para ilustração das áreas, como o MDE, declividade, sub-bacias e hidrografia. Os arquivos referentes às classes de solo e uso do solo, que foram espacializados para a área em estudo, também são fornecidos.

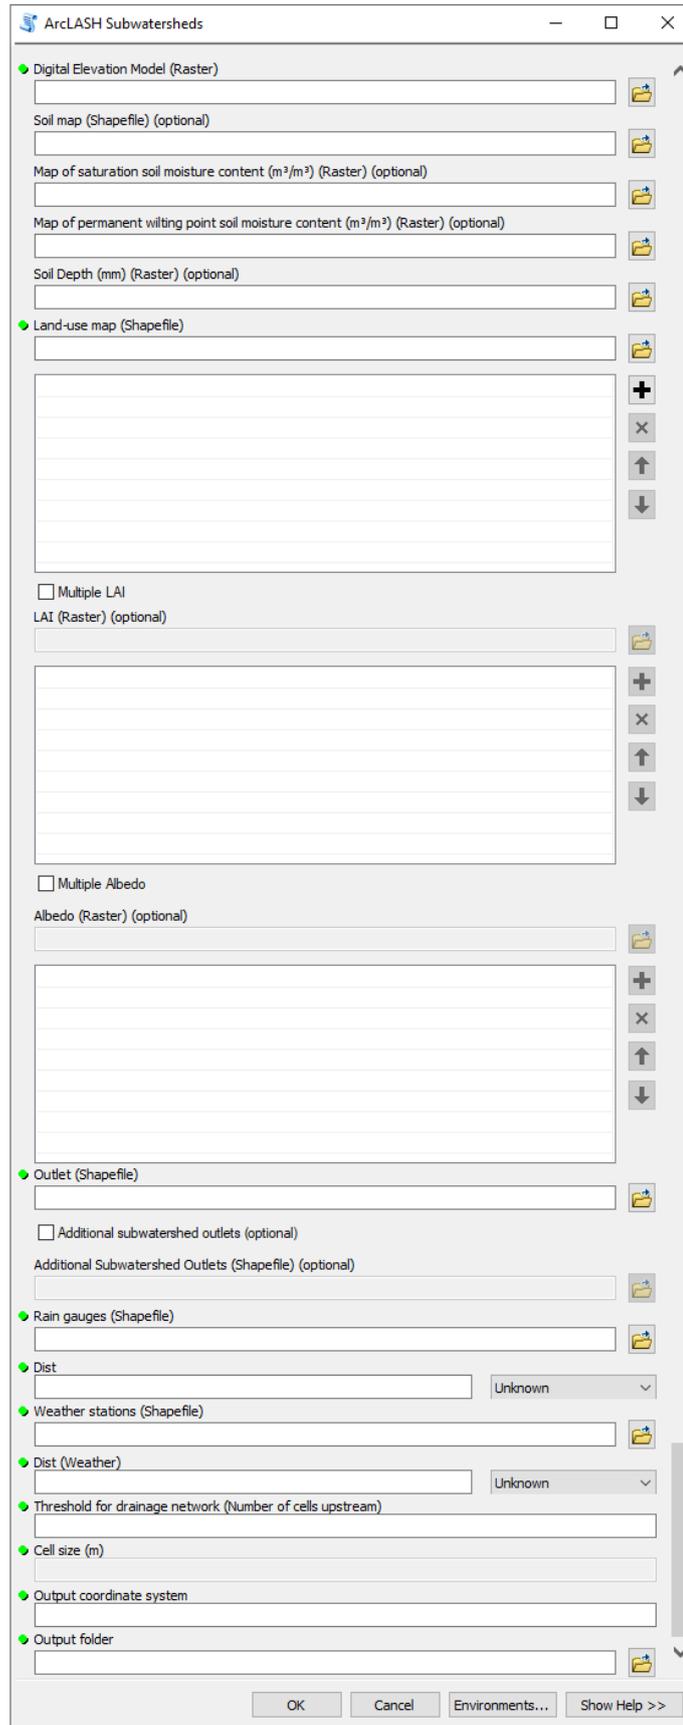


Figura 24 - Interface do módulo ArcLASH no software ArcGIS®.

Assim como a padronização das informações de entrada garantem o processo correto das informações no módulo ArcLASH, a padronização dos arquivos de saída, garantem a correta leitura dessas informações na rotina do modelo LASH em linguagem R e, também, o M-LASH (VARGAS, 2021).

Na Figura 25, é apresentada a organização dos arquivos de saída após processamento no módulo, a qual contempla três pastas: i) `subwatershedsTxt`, contempla os arquivos com informações processadas em formato `*.txt` para cada sub-bacia delimitada; ii) `watershedRasters`, contempla os arquivos digitais para o recorte da bacia hidrográfica em estudo; e iii) `watershedTxt`, contempla os arquivos com informações processadas em formato `*.txt` para a bacia hidrográfica de forma concentrada.

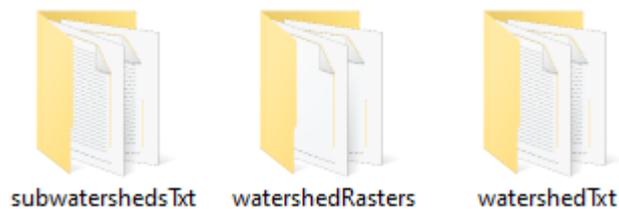


Figura 25 – Organização das pastas de saída do módulo ArcLASH.

Na Figura 26 é exemplificada a pasta de saída “`subwatershedsTxt`”. O modelo da Figura 27 exemplifica a saída dos valores médios de albedo, para uma bacia dividida em 43 sub-bacias. Neste exemplo, foram avaliadas 16 imagens diferentes de uso do solo diferentes, compreendendo o período de 2000 a 2020.

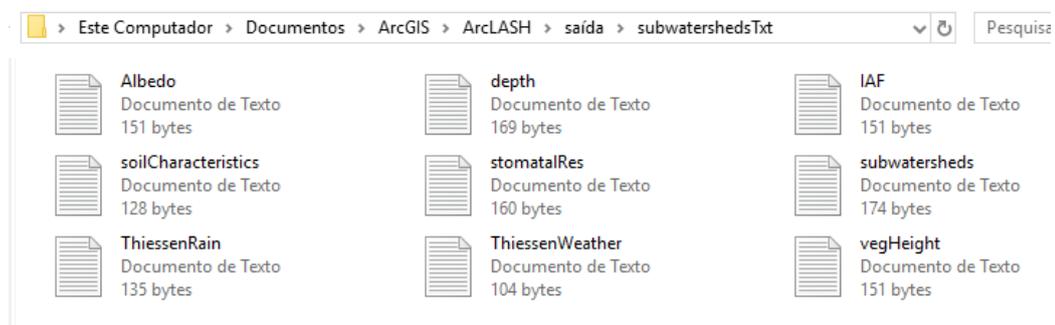
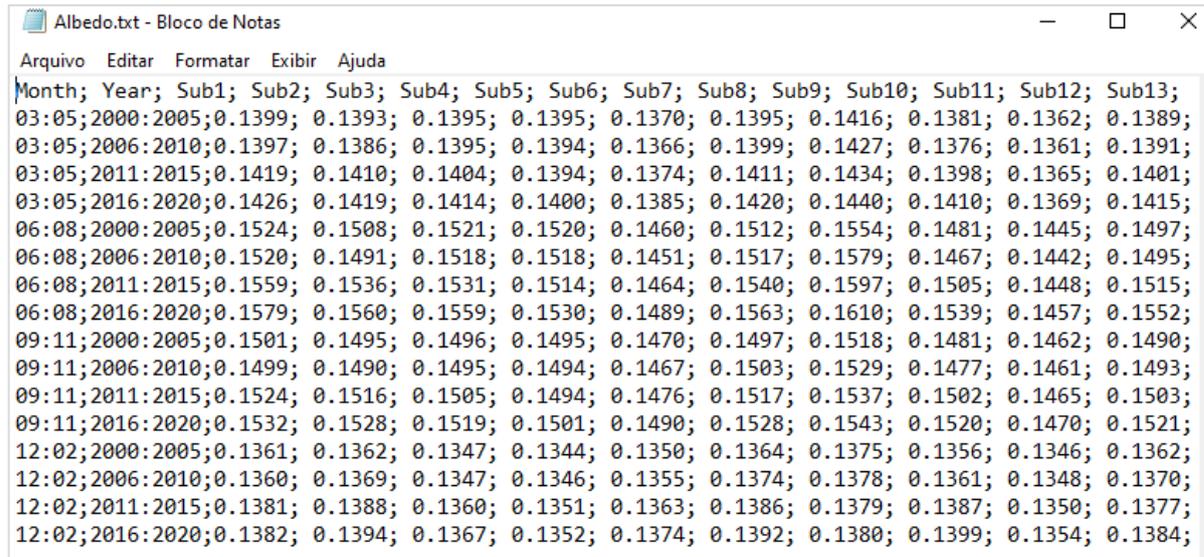


Figura 26 – Organização da pasta `subwatershedsTxt`.



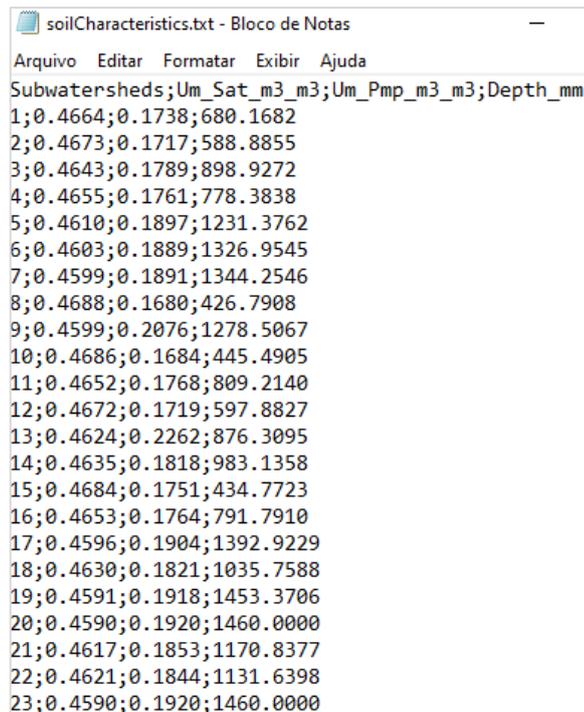
```

Month; Year; Sub1; Sub2; Sub3; Sub4; Sub5; Sub6; Sub7; Sub8; Sub9; Sub10; Sub11; Sub12; Sub13;
03:05;2000:2005;0.1399; 0.1393; 0.1395; 0.1395; 0.1370; 0.1395; 0.1416; 0.1381; 0.1362; 0.1389;
03:05;2006:2010;0.1397; 0.1386; 0.1395; 0.1394; 0.1366; 0.1399; 0.1427; 0.1376; 0.1361; 0.1391;
03:05;2011:2015;0.1419; 0.1410; 0.1404; 0.1394; 0.1374; 0.1411; 0.1434; 0.1398; 0.1365; 0.1401;
03:05;2016:2020;0.1426; 0.1419; 0.1414; 0.1400; 0.1385; 0.1420; 0.1440; 0.1410; 0.1369; 0.1415;
06:08;2000:2005;0.1524; 0.1508; 0.1521; 0.1520; 0.1460; 0.1512; 0.1554; 0.1481; 0.1445; 0.1497;
06:08;2006:2010;0.1520; 0.1491; 0.1518; 0.1518; 0.1451; 0.1517; 0.1579; 0.1467; 0.1442; 0.1495;
06:08;2011:2015;0.1559; 0.1536; 0.1531; 0.1514; 0.1464; 0.1540; 0.1597; 0.1505; 0.1448; 0.1515;
06:08;2016:2020;0.1579; 0.1560; 0.1559; 0.1530; 0.1489; 0.1563; 0.1610; 0.1539; 0.1457; 0.1552;
09:11;2000:2005;0.1501; 0.1495; 0.1496; 0.1495; 0.1470; 0.1497; 0.1518; 0.1481; 0.1462; 0.1490;
09:11;2006:2010;0.1499; 0.1490; 0.1495; 0.1494; 0.1467; 0.1503; 0.1529; 0.1477; 0.1461; 0.1493;
09:11;2011:2015;0.1524; 0.1516; 0.1505; 0.1494; 0.1476; 0.1517; 0.1537; 0.1502; 0.1465; 0.1503;
09:11;2016:2020;0.1532; 0.1528; 0.1519; 0.1501; 0.1490; 0.1528; 0.1543; 0.1520; 0.1470; 0.1521;
12:02;2000:2005;0.1361; 0.1362; 0.1347; 0.1344; 0.1350; 0.1364; 0.1375; 0.1356; 0.1346; 0.1362;
12:02;2006:2010;0.1360; 0.1369; 0.1347; 0.1346; 0.1355; 0.1374; 0.1378; 0.1361; 0.1348; 0.1370;
12:02;2011:2015;0.1381; 0.1388; 0.1360; 0.1351; 0.1363; 0.1386; 0.1379; 0.1387; 0.1350; 0.1377;
12:02;2016:2020;0.1382; 0.1394; 0.1367; 0.1352; 0.1374; 0.1392; 0.1380; 0.1399; 0.1354; 0.1384;

```

Figura 27 – Modelo de arquivo de saída do módulo ArcLASH com informações de variáveis do uso do solo.

Na Figura 28 e na Figura 29 são exemplificadas as saídas de solo e sub-bacias, para o mesmo exemplo anterior. No primeiro caso, são fornecidos valores médios dos parâmetros do solo, para cada sub-bacia. Para as sub-bacias, são fornecidas as características morfométricas calculadas no processo do ArcLASH, sendo elas: área de drenagem, latitude do centroide da sub-bacia, tempo de concentração e altitude média.

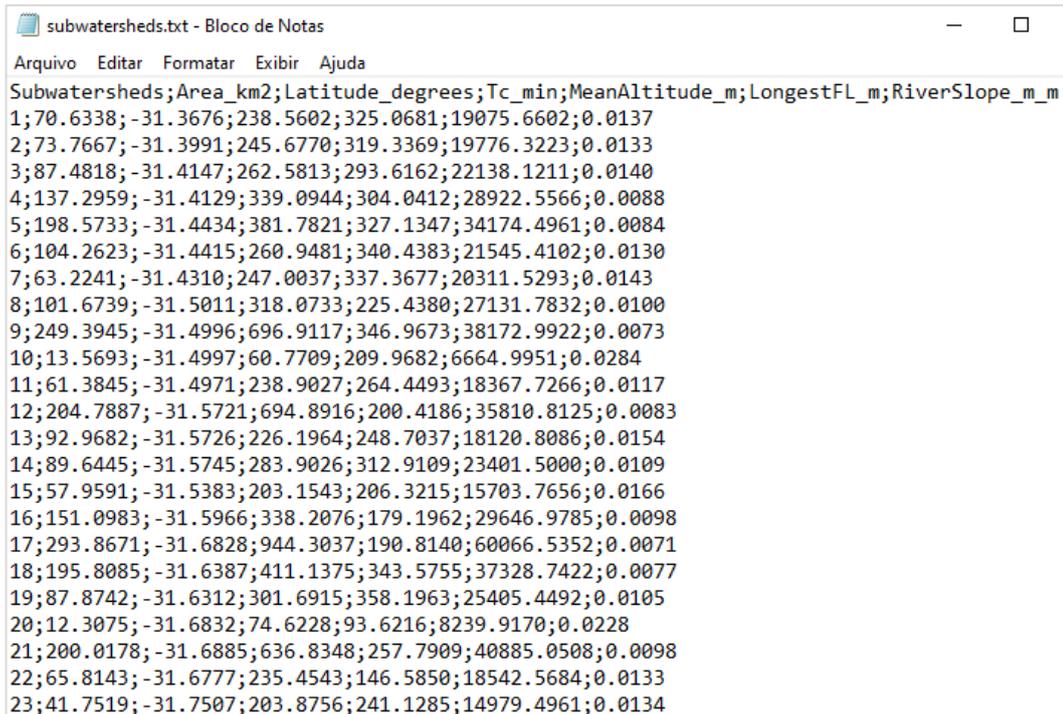


```

Subwatersheds;Um_Sat_m3_m3;Um_Pmp_m3_m3;Depth_mm
1;0.4664;0.1738;680.1682
2;0.4673;0.1717;588.8855
3;0.4643;0.1789;898.9272
4;0.4655;0.1761;778.3838
5;0.4610;0.1897;1231.3762
6;0.4603;0.1889;1326.9545
7;0.4599;0.1891;1344.2546
8;0.4688;0.1680;426.7908
9;0.4599;0.2076;1278.5067
10;0.4686;0.1684;445.4905
11;0.4652;0.1768;809.2140
12;0.4672;0.1719;597.8827
13;0.4624;0.2262;876.3095
14;0.4635;0.1818;983.1358
15;0.4684;0.1751;434.7723
16;0.4653;0.1764;791.7910
17;0.4596;0.1904;1392.9229
18;0.4630;0.1821;1035.7588
19;0.4591;0.1918;1453.3706
20;0.4590;0.1920;1460.0000
21;0.4617;0.1853;1170.8377
22;0.4621;0.1844;1131.6398
23;0.4590;0.1920;1460.0000

```

Figura 28 – Modelo de arquivo de saída do módulo ArcLASH com informações de variáveis do solo.



```

subwatersheds.txt - Bloco de Notas
Arquivo Editar Formatar Exibir Ajuda
Subwatersheds;Area_km2;Latitude_degrees;Tc_min;MeanAltitude_m;LongestFL_m;RiverSlope_m_m
1;70.6338;-31.3676;238.5602;325.0681;19075.6602;0.0137
2;73.7667;-31.3991;245.6770;319.3369;19776.3223;0.0133
3;87.4818;-31.4147;262.5813;293.6162;22138.1211;0.0140
4;137.2959;-31.4129;339.0944;304.0412;28922.5566;0.0088
5;198.5733;-31.4434;381.7821;327.1347;34174.4961;0.0084
6;104.2623;-31.4415;260.9481;340.4383;21545.4102;0.0130
7;63.2241;-31.4310;247.0037;337.3677;20311.5293;0.0143
8;101.6739;-31.5011;318.0733;225.4380;27131.7832;0.0100
9;249.3945;-31.4996;696.9117;346.9673;38172.9922;0.0073
10;13.5693;-31.4997;60.7709;209.9682;6664.9951;0.0284
11;61.3845;-31.4971;238.9027;264.4493;18367.7266;0.0117
12;204.7887;-31.5721;694.8916;200.4186;35810.8125;0.0083
13;92.9682;-31.5726;226.1964;248.7037;18120.8086;0.0154
14;89.6445;-31.5745;283.9026;312.9109;23401.5000;0.0109
15;57.9591;-31.5383;203.1543;206.3215;15703.7656;0.0166
16;151.0983;-31.5966;338.2076;179.1962;29646.9785;0.0098
17;293.8671;-31.6828;944.3037;190.8140;60066.5352;0.0071
18;195.8085;-31.6387;411.1375;343.5755;37328.7422;0.0077
19;87.8742;-31.6312;301.6915;358.1963;25405.4492;0.0105
20;12.3075;-31.6832;74.6228;93.6216;8239.9170;0.0228
21;200.0178;-31.6885;636.8348;257.7909;40885.0508;0.0098
22;65.8143;-31.6777;235.4543;146.5850;18542.5684;0.0133
23;41.7519;-31.7507;203.8756;241.1285;14979.4961;0.0134

```

Figura 29 – Modelo de arquivo de saída do módulo ArcLASH com informações das sub-bacias.

4.1.1 Discretização espacial das bacias hidrográficas e tempo de processamento com o ArcLASH

As bases de dados espaciais das bacias hidrográficas selecionadas para aplicação do R-LASH foram processadas no módulo ArcLASH. Para permitir algumas discussões e comparação acerca das versões do modelo LASH, optou-se pela utilização de mesmo limiar de drenagem numérica de Caldeira (2019). Na Tabela 12 estão apresentados os limiares utilizados e o respectivo número de sub-bacias.

Tabela 12 – Limiares utilizados para geração da rede de drenagem numérica e seus respectivos números de sub-bacias

Bacia Hidrográfica	Limiar de drenagem numérica*		Sub-bacias	Distâncias para Polígonos de Thiessen (m)
	Pixels	Hectares (ha)		
BHAF-PC	2.778	250	21	50.000
BHAP-PCF	8.334	750	31	50.000
BHRP-PO	66.667	6.000	43	150.000

* Limiar apresentado em Caldeira (2019).

Cabe destacar que, apesar de serem representadas as mesmas sub-bacias de Caldeira (2019) neste estudo, as demais informações que compõem a base de dados espaciais são distintas. Logo, os resultados do processamento das informações espaciais devem ser avaliados em conjunto com os resultados hidrológicos, não devendo ser diretamente comparados.

Da Figura 30 a Figura 32 encontram-se espacializadas as sub-bacias resultantes do processamento no módulo ArcLASH. Verifica-se que há variação nas formas e tamanhos das sub-bacias, as quais se devem à metodologia do software utilizado para delimitação e, também, ao limiar de drenagem utilizado. Essas sub-bacias, principalmente as com áreas de drenagem muito pequenas podem trazer dificuldades ao modelo, uma vez que apresentam respostas hidrológicas muito inferiores ao passo de tempo utilizado (diário).

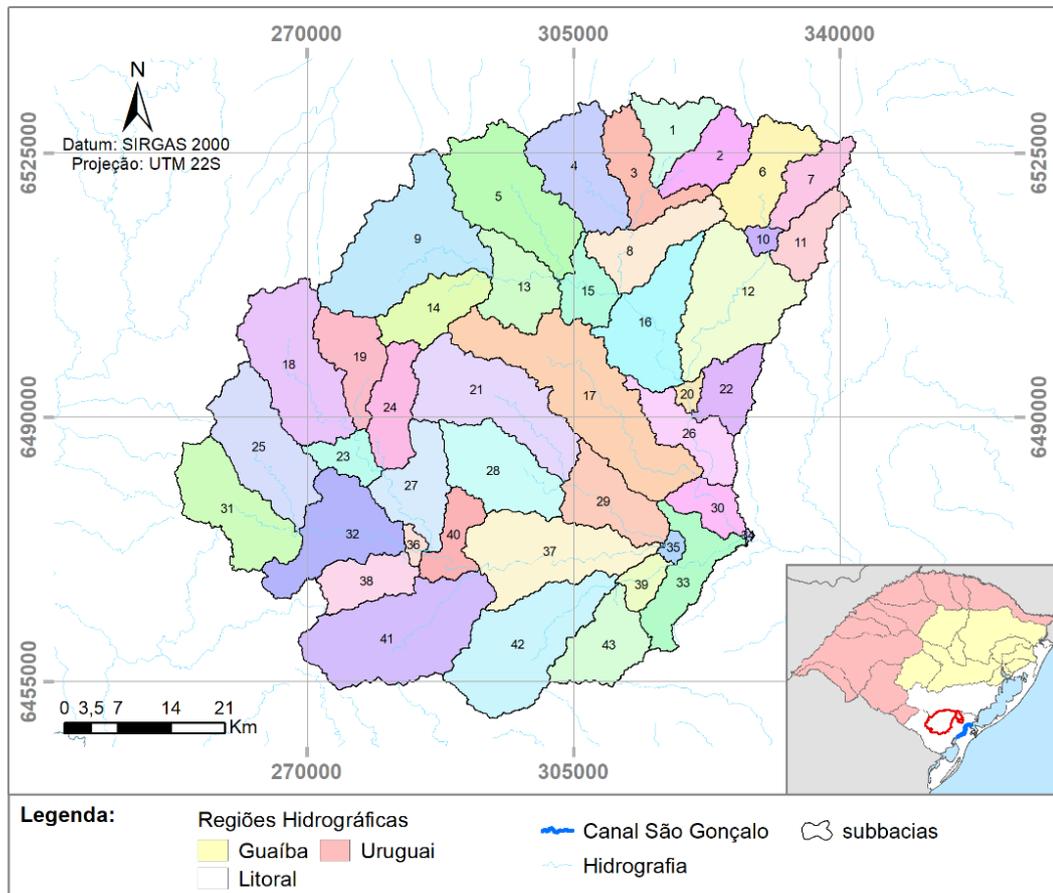


Figura 30 – Sub-bacias da BHAFC-PC resultantes da preparação da base de dados espaciais com o módulo ArcLASH.

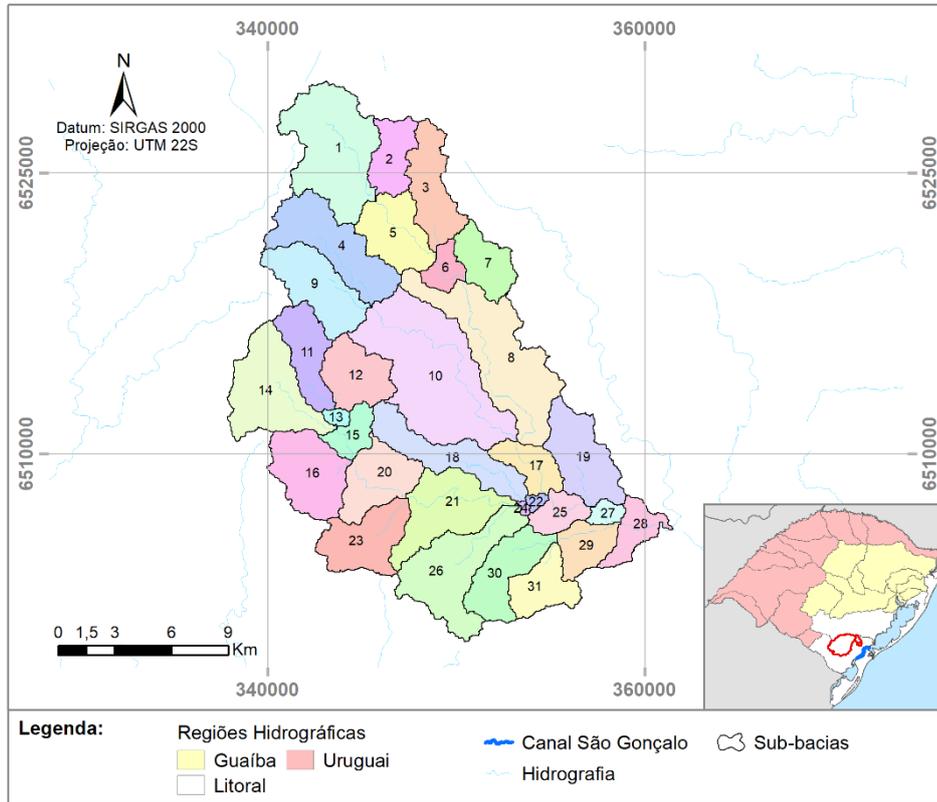


Figura 31 – Sub-bacias da BHAP-PCF resultantes da preparação da base de dados espaciais com o módulo ArcLASH.

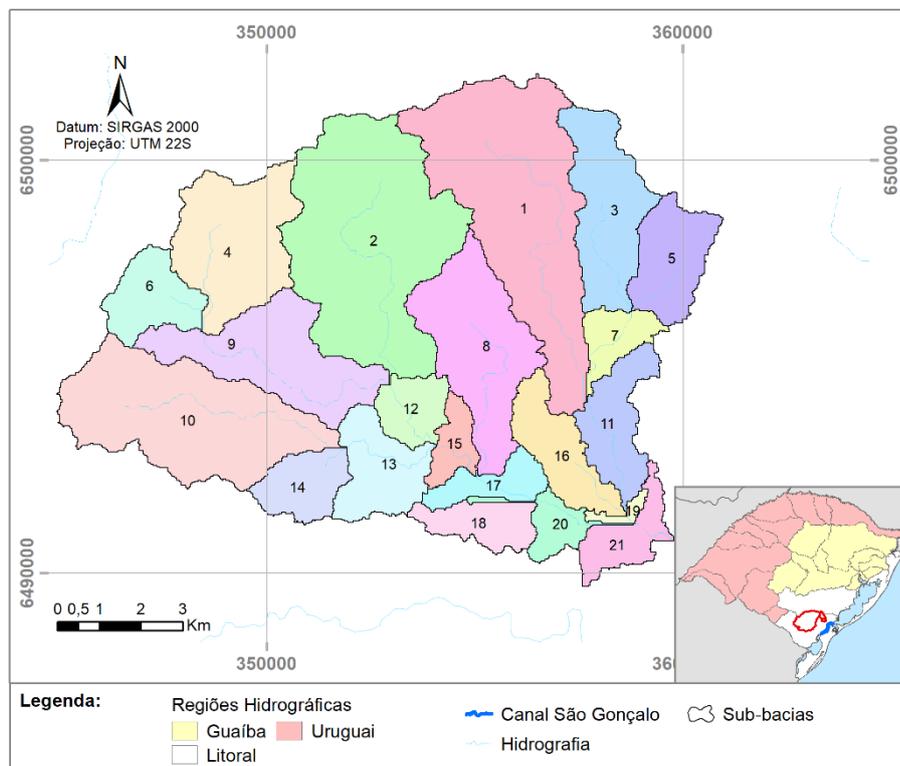


Figura 32 – Sub-bacias da BHRP-PO resultantes da preparação da base de dados espaciais com o módulo ArcLASH.

O processamento da base de dados espacial, considerando o número de sub-bacias apresentado na Tabela 12, e um total de 16 mapas de uso do solo, teve duração de:

- 47 minutos e 29 segundos, para a BHAF-PC (21 sub-bacias; 125,05 km²).
- 1 hora, 29 minutos e 59 segundos, para a BHAP-PCF (31 sub-bacias; 369,13 km²).
- 3 horas, 41 minutos e 40 segundos, para a BHRP-PO (43 sub-bacias; 4.700,47 km²).

Esse tempo de processamento está atrelado a um computador com memória RAM 8,00 GB e processador Intel(R) Core(TM) i7-1165G7 CPU @ 2.80GHz.

Na Tabela 13 e na Tabela 14 estão apresentadas as estações pluviométricas e meteorológicas, respectivamente, com influência nas bacias hidrográficas do estudo, bem como os percentuais de influência.

Tabela 13 – Percentual de influência das estações pluviométricas para as bacias hidrográficas do estudo

Código	Estação	BHAF-PC	BHAP-PCF	BHR-PO
1	Est. Experimental Sede	100,0	-	-
2	Est. Experimental Cascata	-	32,49	-
86993	Canguçu	-	1,50	7,91
3152003	Canguçu	-	38,19	0,26
3152005	Vila Freire	-	1,98	7,71
3152013	Pedro Osório	-	-	6,54
3152016	Ponte Cordeiro de Farias	-	25,84	-
3153004	Ferraria	-	-	17,85
3153007	Passo da Capela	-	-	6,89
3153008	Pedras Altas	-	-	13,40
3153021	Estação Experimental de Piratini	-	-	17,11
3153022	Cerro Chato	-	-	18,51
3253004	Herval	-	-	3,82

Tabela 14 – Percentual de influência das estações meteorológicas para as bacias hidrográficas do estudo

Código	Estação	BHAF-PC	BHAP-PCF	BHR-PO
1	Est. Experimental Sede	100,0	4,58	0,53
2	Est. Experimental Cascata	-	60,05	-
83895	Estação Agrometeorológica de Pelotas	-	-	13,83
86993	Canguçu	-	35,37	85,64

4.2 Estrutura do modelo LASH em linguagem de programação R

A estrutura do modelo LASH em R foi idealizada a partir de três scripts (Figura 33), a serem executados na seguinte ordem: Funções, LASH e Calibração. Esta divisão foi estabelecida de forma que os códigos não fiquem tão extensos e permitam a fácil atualização ao longo do desenvolvimento e aprimoramento do modelo.

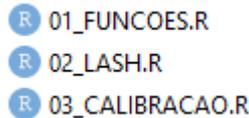


Figura 33 – Estrutura de organização do R-LASH.

4.2.1 Script Funções

No *script* 01_FUNCOES.R, estão inseridas funções (equacionamentos) das variáveis envolvidas no modelo LASH, tais como escoamentos (Figura 34) e evapotranspiração (Figura 35), bem como as estatísticas de análises (Figura 36). Além disso, neste *script* encontram-se algumas funções de apoio, como a de conversão dos arquivos de saída do ArcLASH em formatos de entrada do modelo LASH (Figura 37).

```

Ds<-function(Lambda, P, P5, Am, At){
  S<-Am - At #mm
  S<-max(S,0)
  M<-0.5 * (-(1 + Lambda) * S + sqrt((((1 - Lambda)^2) * (S^2)) + (4 * P5 * S)))
  ifelse(M < 0, M <- 0, M <- M)
  Ia <- ifelse ((S == 0) & (M == 0),0,(Lambda * (S ^ 2)) / (S + M)) #mm
  Ds_result <- ((P - Ia) * (P - Ia + M)) / (P - Ia + M + S) #mm
  ifelse ((P==0) | (P < Ia), Ds_result <- 0, Ds_result <- Ds_result)
  return(Ds_result)
}

Dss <- function(kss, Am, At, Acc_perc, P5){
  Acc <- (Acc_perc/100) * Am #mm
  ifelse(At >= Acc, Dss_result <- kss * (((At - Acc)/(Am - Acc))^(3+(2/P5))), Dss_result <- 0)
  return(Dss_result)
}

Db <- function(kb, Am, At, Ac_perc){
  Ac <- (Ac_perc/100) * Am #mm
  ifelse(At >= Ac, Db_result <- kb * ((At - Ac)/(Am - Ac)), Db_result <- 0)
  return(Db_result)
}

Dcr <- function(Kcr, Am, At, Acr_perc){
  Acr <- (Acr_perc/100) * Am #mm
  ifelse(Acr > At, Dcr_result <- Kcr * ((Acr - At)/Acr), Dcr_result <- 0)
  return(Dcr_result)
}

```

Figura 34 – Equacionamento dos escoamentos de base, subsuperficial e superficial, bem como a ascensão capilar.

```

ETR <- function(data_analisada, lat_deg, altitude_media, tmin, tmax, UR_media, rad_solar, v_vento_2m, albedo, h_veg, res_est, Arm_t, Arm_L, Arm_pwp){
  ##### constantes #####
  gsc <- 0.082 #constante solar (MJ.m-2.min-1)
  const_sb <- 4.903*10^-9
  ratio_mol <- 0.622 # Ratio molecular weight of water vapor/dry air
  specific_gas_const <- 0.287 # specific gas constant (Kj.kg-1.K-1)

  ## a data tem que vir como string '2010-06-10' por exemplo.
  J <- yday(as.Date(data_analisada)) # Dia Juliano
  lat_rad <- lat_deg * (pi/180)
  dr <- 1+0.033*(cos((2*pi/365)*J)) # Distância relativa inversa Terra-Sol
  decl_solar <- 0.409*sin(((2*pi)/365)*J)-1.39 # Declinação solar (radianos)
  ws <- acos((-tan(lat_rad))*(tan(decl_solar))) # Ângulo horário ao nascer ou pôr do sol (radianos)
  Ra <- ((24*60)/pi)*gsc*dr*(ws*sin(lat_rad)*sin(decl_solar)+cos(lat_rad)*cos(decl_solar)*sin(ws)) # Radiação que atinge o topo da atmosfera (MJ.m-2.dia-1)
  Rso <- ((0.75+(0.00002*altitude_media))^Ra # Clear-sky solar radiation (MJ.m-2.dia-1)
  es <- ((0.6108*exp((17.27*tmin)/(tmin+237.3)))+(0.6108*exp((17.27*tmax)/(tmax+237.3))))/2 # Pressão de saturação do vapor d'água (kPa)
  ea <- es * (UR_media/100) # Pressão atual de vapor d'água (kPa)
  ifelse(rad_solar==Rso, Rnl <- (const_sb*(((tmax+273.15)^4)+((tmin+273.15)^4))/2)*(0.34-(0.14*sqrt(ea)))+(1.35*(rad_solar/Rso)-0.35)),
  Rnl <- (const_sb*(((tmax+273.15)^4)+((tmin+273.15)^4))/2)*(0.34-(0.14*sqrt(ea)))) # Radiação de ondas longas - Rnl (MJ.m-2.dia-1)
  Rns <- rad_solar*(1-albedo) # Radiação de ondas curtas (MJ.m-2.dia-1)
  Rn <- Rns - Rnl # Radiação líquida que incide na superfície (MJ.m-2.dia-1)
  tmed <- (tmin + tmax)/2 # Temperatura média diária (°C)
  Tkv <- 1.01 * tmed + 273.15 # Temperatura virtual (K)
  Delta <- (4098 * es)/((tmed + 237.3)^2) # Declividade da curva de pressão de saturação do vapor d'água (kPa.°C-1)
  v_vento_10m <- v_vento_2m * ((log(10/(h_veg/10)))/(log(2/(h_veg/10)))) # Velocidade do vento a 10m de altura (m.s-1)
  ifelse(h_veg<=10, res_aerod <- ((6.25/v_vento_10m)*(log(10/(h_veg/10)))^2)), res_aerod <- (94/v_vento_10m) # Resistência aerodinâmica (s.m-1)
  Patm <- 101.3*(((293-(0.0065*altitude_media))/293)^5.26) # Pressão atmosférica (kPa)
  const_psi cr <- 0.000665*Patm
  ETC <- (0.408*Delta*(Rn-0)+((86400*const_psi cr*ratio_mol)/(Tkv*res_aerod*specific_gas_const))*(es-ea))/(Delta+const_psi cr*(1+(res_est/res_aerod)))
  ifelse(Arm_t < Arm_L, ifelse(Arm_t < Arm_pwp, KS <- 0, KS <- log(Arm_t - Arm_pwp)/log(Arm_L - Arm_pwp)), KS <- 1) # Coeficiente de estress hídrico
  KS <- max(KS, 0)
  #KS <- 1
  ETR <- KS * ETC # Evapotranspiração real da cultura (mm.dia-1)
  return(ETR)
}

```

Figura 35 – Equacionamento do cálculo da Evapotranspiração.

```

### RMSE
rmse<-function(obs,est){
  sm<-(obs-est)^2
  sm<-as.numeric(na.exclude(sm))
  rm<-sqrt(sum(sm)/length(sm))
  return(rm)
}

### Cns
Cns<-function(obs,est){
  obs<-obs+est-est
  est<-est+obs-obs
  cns<-1-(sum((obs-est)^2, na.rm=T)/sum((obs-mean(obs, na.rm=T))^2, na.rm=T))
  return(cns)
}

### Cnslg
Cnslg<-function(obs,est){
  obs<-obs+est-est
  est<-est+obs-obs

  mdobs<-log10(mean(obs, na.rm=T))
  obs<-log10(obs)
  est<-log10(est)

  cns<-1-(sum((obs-est)^2, na.rm=T)/sum((obs-mdobs)^2, na.rm=T))
  return(cns)
}

### PBIAS
PBIAS<-function(obs,est){
  obs<-obs+est-est
  est<-est+obs-obs

  pbias<-(sum(obs-est, na.rm=T)/sum(obs, na.rm=T))*100

  return(pbias)
}

```

Figura 36 – Equacionamento das estatísticas associadas ao modelo, as quais são calculadas independentemente de serem ou não utilizadas como funções-objetivo.

```

### Ler dados
numberOfDays <- function(date) {
  m <- format(date, format="%m")
  while (format(date, format="%m") == m) {
    date <- date + 1
  }

  return(as.integer(format(date - 1, format="%d")))
}

ler_dados<-function(x){
  dados_ent<-read.csv(x, sep = ";", stringsAsFactors = F)
  {df_final<-NULL
  for(i in 1:length(dados_ent[,1])){
    anos<-as.numeric(unlist(strsplit(dados_ent$Year[i], split=":")))[1]:
      as.numeric(unlist(strsplit(dados_ent$Year[i], split=":")))[2]
    meses<-as.numeric(unlist(strsplit(dados_ent$Month[i], split=":")))[1]:
      as.numeric(unlist(strsplit(dados_ent$Month[i], split=":")))[2]

    d1<-length(dados_ent[,1])

    dd_unido<-NULL
    for(j in 1:length(meses)){
      m<-as.character(meses[j])
      ll<-length(unlist(strsplit(m, split = "")))
      if(ll==1){m<-paste0("0",m)}
      dd_unido<-c(dd_unido, paste0("01",m, anos))
    }

    dd_unido<-as.Date(dd_unido,format = "%d%m%Y")

    dias<-sapply(dd_unido,FUN=numberOfDays)

    datas<-NULL
    for(j in 1:length(dias)){
      datas<-c(datas,as.character(((dd_unido[j]-1)+1:dias[j])))
    }

    dados<-as.data.frame(matrix(NA, ncol=(d1-1),
                                nrow=length(datas)))
    dados[,1]<-datas

    for(j in 1:length(datas)){
      dados[j,2:(d1-1)]<-dados_ent[i,3:d1]
    }

    names(dados)<-c("data",names(dados_ent)[-c(1:2)])

    df_final<-rbind(df_final, dados)
    ord<-order(as.Date(df_final$data))
    df_final<-df_final[ord,]
  }
}

return(df_final)

```

Figura 37 – Função para fazer leitura dos dados de saída do ArcLASH e conversão para formato de entrada no script LASH.R.

4.2.2 Script R-LASH

No *script* R-LASH são contemplados os cálculos do modelo LASH e iterações dos processos hidrológicos nas sub-bacias.

Os primeiros processos executados neste script são a leitura das funções dispostas no script FUNCOES.R e dos dados espaciais e temporais, já discretizados por sub-bacia (Figura 38).

Posteriormente, são elaborados os vetores necessários aos cálculos e lidas algumas informações de controle muito importantes para o modelo, tais como o tempo de simulação e número de sub-bacias (Figura 39).

Posteriormente, tem-se início a rotina do modelo LASH, a qual está implementada como função. No caso da rotina preparada para a calibração, é informado o vetor posição com os parâmetros do modelo (Figura 39), e estes são variáveis a serem estimadas a partir dos *loops* e otimização das funções objetivos. Caso o modelo já esteja calibrado, este vetor recebe inicialmente os valores estimados e a rotina é processada para leitura das vazões de saída.

```
#### FUNÇÕES DO MODELO LASH ####
source("C:/Users/marti/Downloads/FUNCOES.R")

#### DADOS DE ENTRADA ####

dados_Q_obs <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_vazao.txt", sep=";")
dados_chuva <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_chuva_diaria.txt", sep=";")
dados_temp_min <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_temperatura_min.txt", sep=";")
dados_temp_max <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_temperatura_max.txt", sep=";")
dados_UR <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_umidade_relativa.txt", sep=";")
dados_VV <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_velocidade_vento.txt", sep=";")
dados_RS <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_radiacao_solar.txt", sep=";")
dados_subbacias <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_subbacias.txt", sep=";")
dados_solos_subbacias <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_solos.txt", sep=";")
dados_uso_IAF <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_uso_iaf.txt", sep=";")
dados_uso_h <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_uso_h_veg.txt", sep=";")
dados_uso_albedo <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_uso_albedo.txt", sep=";")
dados_uso_resist_est <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_uso_resist_est.txt", sep=";")
dados_uso_prof_sist_rad <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_uso_prof_sist_rad.txt", sep=";")
propagacao <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_trechos.txt", sep=";")
contribuintes <- read.csv("C:/Users/marti/Downloads/Dados_entrada/dados_vazoes_subbacias.txt", sep=";")
```

Figura 38 – Detalhe do *script* chamando FUNCOES.R e lendo os dados de entrada do modelo.

```
##### Transformando em vetores necessários #####
Numero_subbacias <- length(dados_subbacias$Subbacias)
Area_subbacias <- dados_subbacias$Area_km2
Latitude_subbacias <- dados_subbacias$Latitude_graus
tc_subbacias <- dados_subbacias$tc_min
alt_subbacias <- dados_subbacias$altitude_m
Umidade_saturacao_subbacias <- dados_solos_subbacias$Um_Sat_m3_m3
Umidade_PMP_subbacias <- dados_solos_subbacias$Um_PMP_m3_m3
profundidade_solo_subbacias <- dados_solos_subbacias$Prof_mm

Tempo_inicio_simulacao <- 1 # está setado para começar no primeiro dia
Tempo_fim_simulacao <- length(dados_chuva$data) # está setado para ir até o último dia do arquivo
Intervalo_simulacao <- 1440 #minutos

hidrograma_obs <- dados_Q_obs[Tempo_inicio_simulacao:Tempo_fim_simulacao, 2]

##### Constantes usadas para calibração #####
Pr <- 0.4
PercAm_At <- 50# % de At
PercAm_AL <- 50 # % de At
PercAm_Apmp <- 10 # % de At
PercAm_AC <- 1 # % de At
PercAm_Acc <- 10 # % de At
PercAm_Acr <- 10 # % de At

LASH <- function(x){
  Lambda <- x[1]
  Kss <- x[2]
  Kb <- x[3]
  Kcr <- x[4]
  Cs <- x[5]
  Css <- x[6]
  Cb <- x[7]

  # ##### Parâmetros de calibração #####
  Lambda <- rep(x = Lambda, times = 23)
  Kss <- rep(x = Kss, times = 23)
  Kb <- rep(x = Kb, times = 23)
  Kcr <- rep(x = Kcr, times = 23)
  Cs <- rep(x = Cs, times = 23)
  Css <- rep(x = Css, times = 23)
  Cb <- rep(x = Cb, times = 23)
}
```

Figura 39 – Transformação dos dados lidos em vetores e inicialização da função LASH (rotina do modelo LASH).

```
##### Loops na série histórica e nas sub-bacias #####
for (t in Tempo_inicio_simulacao:Tempo_fim_simulacao)
{Qt [t, 1] <- dados_chuva[t, 1]
data_sim <- dados_chuva[t, 1]
for (sb in 1:Numero_subbacias) {
ABH <- Area_subbacias[sb]
Latitude <- Latitude_subbacias [sb]
Altitude <- alt_subbacias [sb]
tc <- tc_subbacias[sb]
chuva <- dados_chuva [t, (sb + 1)]
ifelse (t <= 6, P5 <- sum(dados_chuva[1:(t-1), (sb + 1)]), P5 <- sum(dados_chuva[(t-5):(t-1), (sb + 1)]))
temp_min <- dados_temp_min[t, (sb + 1)]
temp_max <- dados_temp_max[t, (sb + 1)]
UR <- dados_UR [t, (sb + 1)]
VV <- dados_VV [t, (sb + 1)]
RS <- dados_RS [t, (sb + 1)]
teta_sat <- Umidade_saturacao_subbacias [sb]
teta_PMP <- Umidade_PMP_subbacias [sb]
prof_solo <- profundidade_solo_subbacias [sb]
IAF <- dados_uso_IAF [t, (sb + 1)]
altura_veg <- dados_uso_h [t, (sb + 1)]
alb <- dados_uso_albedo [t, (sb + 1)]
resistencia_estomatal <- dados_uso_resist_est [t, (sb + 1)]
prof_sist_rad <- dados_uso_prof_sist_rad [t, (sb + 1)]
ifelse(prof_sist_rad > prof_solo, prof_controle <- prof_solo, prof_controle <- prof_sist_rad)
Am <- (teta_sat - teta_PMP) * prof_controle
AL <- (PercAm_AL/100) * Am
Apwp <- (PercAm_Apmp/100) * Am
LI_ant <- Arm_Interc [sb]

ET_real <- ETr(data_sim, Latitude, Altitude, temp_min, temp_max, UR, RS, VV, alb, altura_veg, resistencia_estomatal, At[sb], AL, Apwp)

### interceptação
LI_ant <- Arm_Interc [sb]
CRI <- 0.2 * IAF
LIT <- ifelse((LI_ant + chuva) > CRI, CRI, (LI_ant + chuva))
chuva <- chuva - (LIT - LI_ant)
Evap_int <- min (ETp(data_sim, Latitude, Altitude, temp_min, temp_max, UR, RS, VV, alb, altura_veg, 0), LIT)
Arm_Interc[sb] <- LIT - Evap_int

Dsup <- Ds (Lambda, chuva, P5, Am, At[sb])
Dsubsup <- Dss (Kss, Am, At[sb], PercAm_Acc, Pr)
Dsub <- Db (Kb, Am, At[sb], PercAm_AC)
Dcap <- Dcr (Kcr, Am, At[sb], PercAm_Acr)
AT [sb] <- At [sb] + chuva - (Dsup + Dsubsup + Dsub) + Dcap - ET_real
}
```

Figura 40 – Loops realizados na série histórica e nas sub-bacias, na função LASH.

```
##### cálculo de volumes e de vazões por sub-bacia hidrográfica #####
Vs[sb] <- Vs[sb] + (Dsup * ABH * 1000)
Qs <- Vs[sb]/(Cs * tc * 60)
Vs [sb] <- Vs[sb]-(Qs * Intervalo_simulacao * 60)
ifelse (Vs[sb] > 0, Vs[sb]<- Vs[sb], Vs[sb] <- 0)

Vss [sb] <- Vss[sb] + (Dsubsup * ABH * 1000)
Qss <- Vss[sb]/(Ccss * tc * 60)
Vss [sb] <- Vss[sb]-(Qss * Intervalo_simulacao * 60)
ifelse (Vss[sb] > 0, Vss[sb]<- Vss[sb], Vss[sb]<- 0)

Vb [sb] <- Vb[sb] + (Dsub * ABH * 1000)
Qb <- Vb[sb]/(Cb * 24 * 60 * 60)
Vb [sb] <- Vb[sb]-(Qb * Intervalo_simulacao * 60)
ifelse (Vb[sb] > 0, Vb[sb]<- Vb[sb], Vb[sb]<- 0)

Qsup_sb [t, (sb + 1)] <- Qs
Qsubsup_sb [t, (sb + 1)] <- Qss
Qesbase_sb [t, (sb + 1)] <- Qb
Qt [t, (sb + 1)] <- Qs + Qss + Qb
}

Qt[t,(Numero_subbacias + 2)]<- sum(Qt[t,2:(Numero_subbacias+1)])
Qsup_sb[t,(Numero_subbacias + 2)]<- sum(Qsup_sb[t,2:(Numero_subbacias+1)])
Qsubsup_sb[t,(Numero_subbacias + 2)]<- sum(Qsubsup_sb[t,2:(Numero_subbacias+1)])
Qesbase_sb[t,(Numero_subbacias + 2)]<- sum(Qesbase_sb[t,2:(Numero_subbacias+1)])
}

missingvalue <- hidrograma_obs[1]

estatistica<-list()
estatistica[[1]] <- rmse(hidrograma_obs[1:Tempo_fim_simulacao], Qt[1:Tempo_fim_simulacao,45],missingvalue)
estatistica[[2]] <- Cns(hidrograma_obs[1:Tempo_fim_simulacao], Qt[1:Tempo_fim_simulacao,45],missingvalue)
estatistica[[3]] <- Cnslg(hidrograma_obs[1:Tempo_fim_simulacao], Qt[1:Tempo_fim_simulacao,45],missingvalue)
estatistica[[4]] <- PBIAS(hidrograma_obs[1:Tempo_fim_simulacao], Qt[1:Tempo_fim_simulacao,45],missingvalue)

names(estatistica)<-c("RMSE", "Cns", "Cnslg", "PBIAS")
estatistica
return (estatistica)
```

Figura 41 – Cálculo dos volumes e vazões e das estatísticas de desempenho, finalizando os cálculos da função LASH.

4.2.3 Script Calibração

Para a calibração do R-LASH foi elaborado um terceiro script, o qual chama a função LASH e faz a leitura dos valores limites mínimos e máximos inferidos para a estimativa dos parâmetros e atendimento das funções objetivos.

As funções dos algoritmos de calibração foram implementadas conforme recomendações dos autores e, os valores de inicialização foram alterados conforme literatura e análise de sensibilidade e convergência ao longo dos testes realizados.

```

library("mopsocd")
library("nsga2R")
library("dream")
library("DEoptim")

Minimos <- c('Lambda'=0, 'Kss'=0.1, 'Kb'=0.1, 'Kcr'=0.1, 'Cs'=1, 'Css'=5, 'Cb'=20)
Maximos <- c('Lambda'=0.2, 'Kss'=250, 'Kb'=6, 'Kcr'=5, 'Cs'=100, 'Css'=1000, 'Cb'=100)

mopso <- mopsocd(fn=LASH,
  varcnt = 7,
  fncnt = 2,
  lowerbound = Minimos,
  upperbound = Maximos,
  opt = 1,
  popsize = 100,
  maxgen = 100,
  archivesize = 250,
  verbosity = 1,
  pMut = 0.5,
  w = 0.4,
  c1 = 1.0,
  c2 = 1.0)

nsga <- nsga2R(fn=LASH,
  varNo=7,
  objDim = 2,
  lowerBounds = Minimos,
  upperBounds = Maximos,
  popSize = 100,
  tourSize = 2,
  generations = 20,
  cprob = 0.7,
  XoverDistIdx = 5,
  mprob = 0.2,
  MuDistIdx = 10)

dream <- dreamCalibrate(FUN = LASH,
  pars = list(Lambda=c(Minimos["Lambda"],Maximos["Lambda"]),
    Kss=c(Minimos["Kss"],Maximos["Kss"]),
    Kb=c(Minimos["Kb"],Maximos["Kb"]),
    Kcr=c(Minimos["Kcr"],Maximos["Kcr"]),
    Cs=c(Minimos["Cs"],Maximos["Cs"]),
    Css=c(Minimos["Css"],Maximos["Css"]),
    Cb=c(Minimos["Cb"],Maximos["Cb"])),
  obs = dados_Q_obs,
  lik.fun = calc.rmse,
  lik.control = NULL)

```

Figura 42 – Detalhe do script de calibração, com as funções dos algoritmos selecionados implementadas.

4.3 Calibração e validação das bacias hidrográficas

Os principais resultados obtidos na etapa de calibração e validação do R-LASH, utilizando os algoritmos de otimização SCE-UA, DREAM, MOPSO e NSGA II estão apresentados a seguir. A calibração dos parâmetros foi realizada de forma concentrada, ou seja, os valores dos parâmetros do modelo são os mesmos para cada uma das sub-bacias.

Os conjuntos de parâmetros para as bacias hidrográficas foram selecionados com base nas estatísticas de desempenho, em conjunto com a representação da curva de permanência.

Na Tabela 15 estão apresentados os parâmetros estimados a partir dos diferentes algoritmos de otimização para a BHAF. As estatísticas de desempenho resultantes da aplicação dos parâmetros estimados no modelo encontram-se na Tabela 16.

Tabela 15 – Parâmetros do modelo LASH estimados para a BHAF-PC

Parâmetro	Unidade	SCE-UA	DREAM	MOPSO	NSGA II
λ	adimensional	0,011	0,020	0,011	0,010
K_{SS}	mm·dia ⁻¹	8,244	1,229	6,151	0,520
K_B	mm·dia ⁻¹	0,544	1,128	0,711	0,781
K_{CR}	mm·dia ⁻¹	1,704	2,565	3,983	0,488
C_S	adimensional	79,608	78,233	66,484	47,852
C_{SS}	adimensional	406,174	295,080	411,485	102,625
C_B	dias	41,762	19,112	55,101	20,434

Tabela 16 – Estatísticas de desempenho das aplicações realizadas na BHAF-PC

Algoritmo	Calibração					Validação				
	C_{NS}	$C_{NS,LOG}$	P_{BIAS} (%)	RMSE (m ³ /s)	KGE	C_{NS}	$C_{NS,LOG}$	P_{BIAS} (%)	RMSE (m ³ /s)	KGE
SCE-UA	0,50	0,71	29,12	4,69	0,34	0,60	0,77	-2,93	3,65	0,55
DREAM	0,50	0,78	27,06	4,68	0,36	0,61	0,76	-4,66	3,61	0,56
MOPSO	0,50	0,74	27,78	4,65	0,44	0,63	0,76	-3,68	3,50	0,63
NSGA II	0,48	0,71	27,70	4,78	0,53	0,62	0,79	-3,15	3,54	0,79

As estatísticas de desempenho do período de calibração indicam que o modelo obteve desempenho satisfatório para representação das vazões máximas, e desempenho muito bom para as vazões mínimas. Para o período de validação, há melhora nos valores das estatísticas, uma vez que o desempenho do modelo para representação das vazões máximas passa a ser classificado como bom. Caldeira (2019) obtiveram $C_{NS} > 0,70$ para a calibração da BHAF-PC, de 1995 a 2000. Contudo, para o período de 2001 a 2008 (validação), o C_{NS} caiu para 0,54. Os valores obtidos pelos autores para o período de validação corroboram com os obtidos para o período de calibração, que engloba dados de 2001 a 2010.

Os valores de P_{BIAS} para o período de calibração não foram satisfatórios, contudo, para o período de validação, todos enquadram-se como muito bom. Os resultados do RMSE tiveram comportamento semelhante.

Apesar de a série histórica da estação fluviométrica selecionada não apresentar tendência, ou seja, indicativo de mudanças no comportamento das vazões, para a BHAF-PC observa-se que há pequena diversidade de respostas no período de

calibração, principalmente nos três primeiros anos (2001 a 2003). As mudanças no uso do solo e nos hietogramas da região não são suficientes para justificar as diferenças observadas (vazões mais elevadas). Por se tratar de uma bacia hidrográfica pequena, o monitoramento em escala diária prejudica as análises, uma vez que a resposta aos eventos de chuva observados tendem a ocorrer em um intervalo inferior ao diário. Associado a isso, tem-se a baixa disponibilidade espacial de dados climatológicos. No entanto, Beskow et al. (2011) relatam que a calibração de modelos hidrológicos em escala diária pode ter maior dificuldade na estimativa das vazões de pico em bacias hidrográficas com tempo de concentração inferior a um dia, as quais são sensíveis a eventos de precipitação de curta duração.

Da Figura 43 a Figura 46 são apresentados os hidrogramas observados e estimados a partir dos algoritmos SCE-UA, DREAM, MOPSO e NSGA, respectivamente.

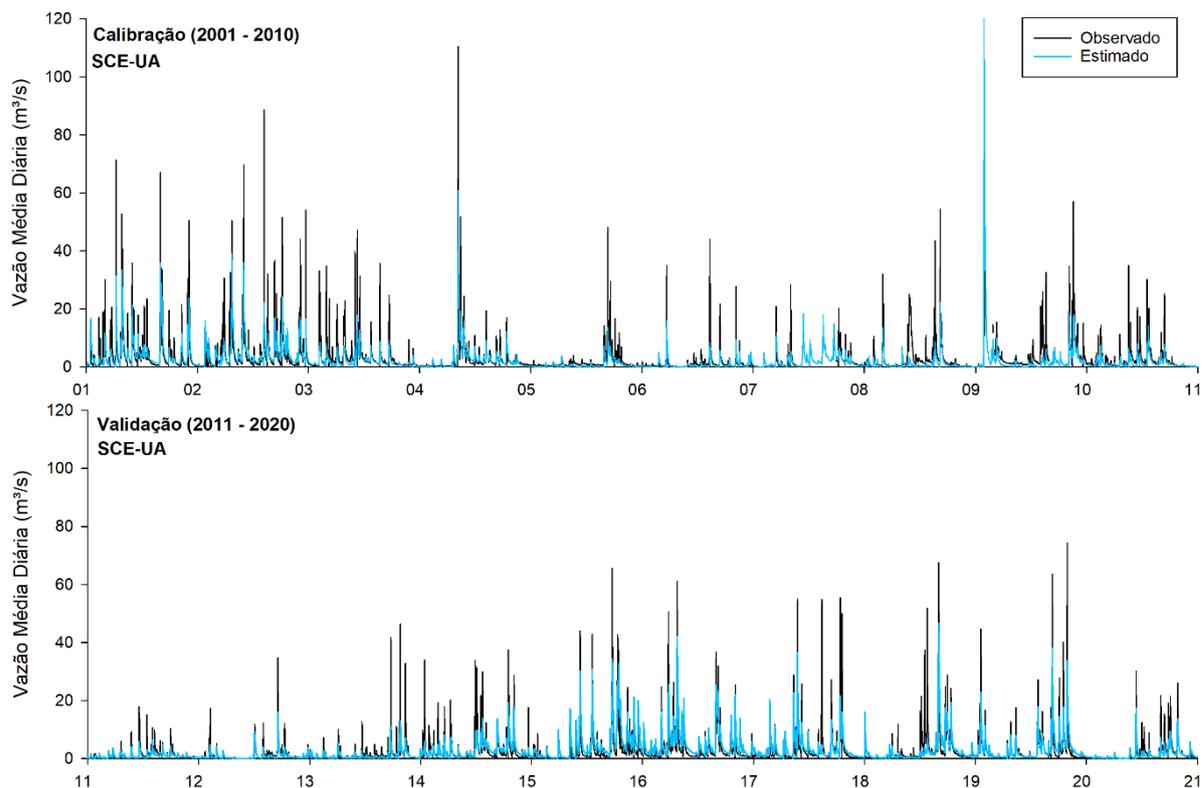


Figura 43 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo SCE-UA para a BHAFC-PC.

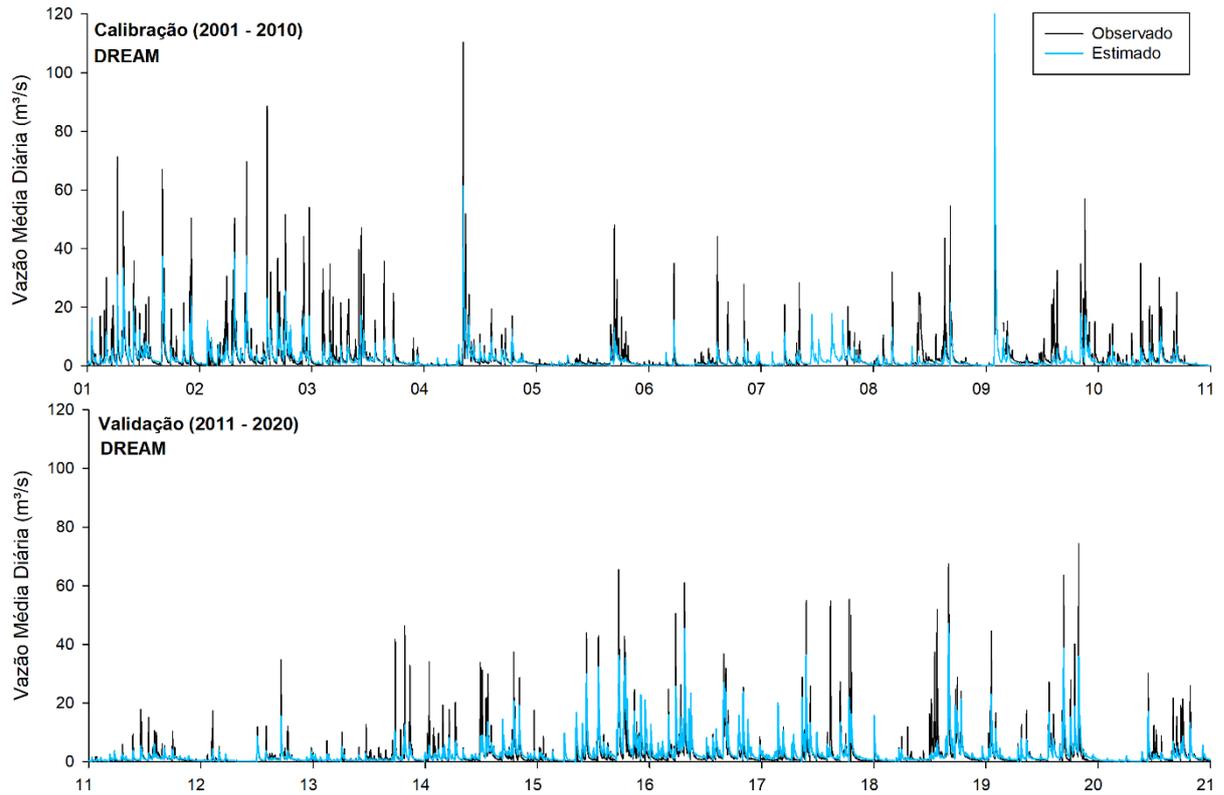


Figura 44 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo DREAM para a BAHF-PC.

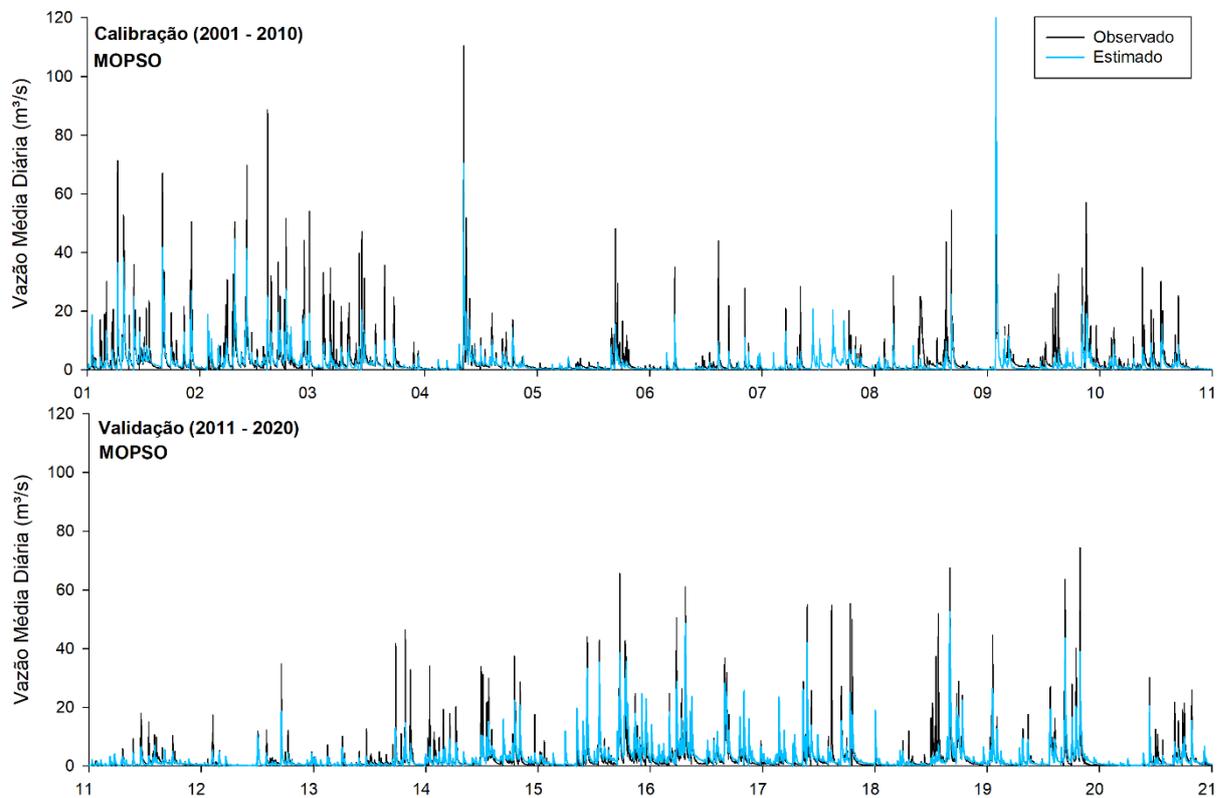


Figura 45 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo MOPSO para a BAHF-PC.

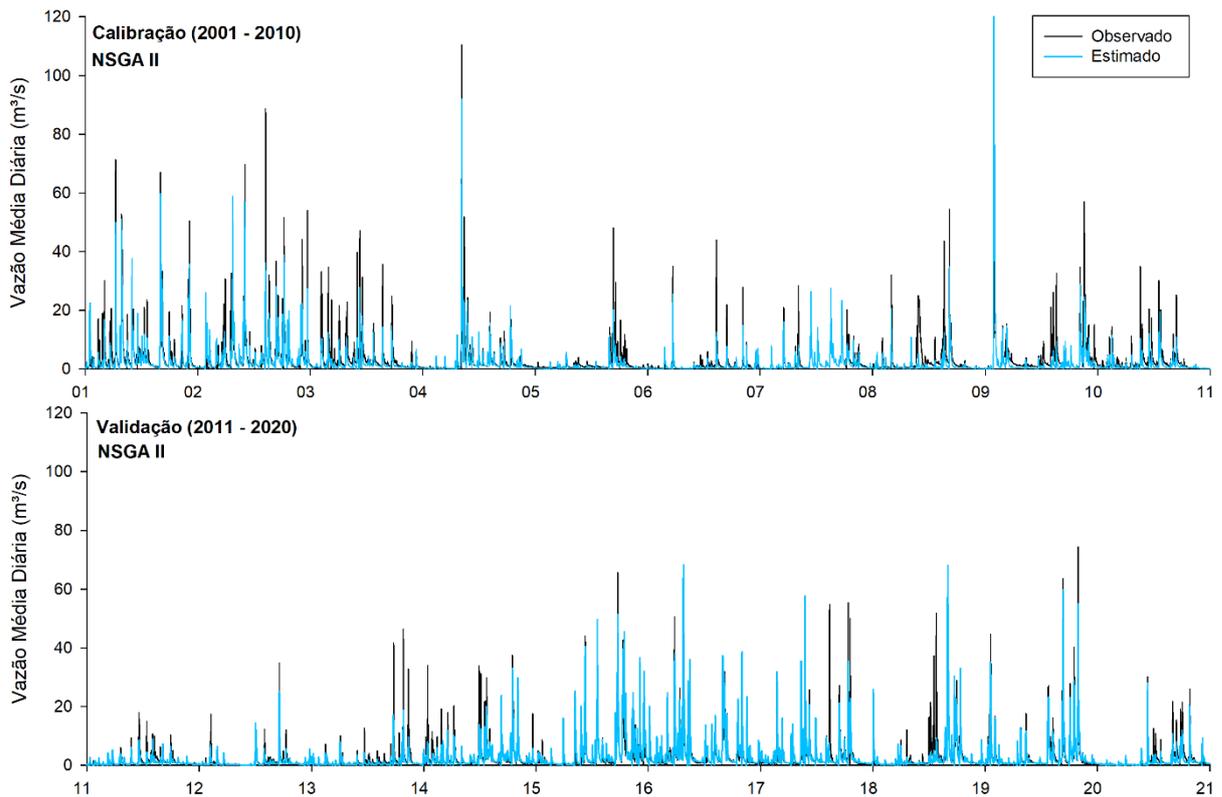


Figura 46 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo NSGA II para a BHAF-PC.

A BHAF-PC apresentou grandes variações nos valores estimados para os parâmetros a partir dos diferentes algoritmos (Tabela 15). O parâmetro λ está diretamente relacionado às perdas no processo de conversão da precipitação em ESD. Para a BHAF-PC, os algoritmos apresentaram valores muito próximos ($\sim 0,011$), com exceção do algoritmo DREAM, que resultou em λ igual a 0,020.

Tendo em vista que os parâmetros K_B e K_{SS} estão ligeiramente associados ao tipo de solo, variações nos seus valores são esperadas para diferentes bacias hidrográficas. Por apresentar $\sim 81\%$ de solos argilosos em seu território e terreno suave-ondulado, a BHAF-PC apresenta valores baixos de K_{SS} , os quais corroboram com valores obtidos por Caldeira (2016) e Caldeira (2019), quando utilizados os algoritmos SCE-UA e MOPSO. Aquino (2014) encontrou um valor médio de K_{SAT} de $18 \text{ mm}\cdot\text{dia}^{-1}$ para a BHAF-PC, sendo este, o valor máximo de K_{SS} quando o solo se encontra saturado (REICHARDT, 1990). Logo, observa-se que os valores de K_{SS} obtidos com o R-LASH apresentam sentido hidrológico.

De acordo com Caldeira (2019), o valor de K_{CR} indica a máxima densidade de fluxo por ascensão capilar que a bacia apresentará em condições de umidade do solo propícias à sua ocorrência. Esse parâmetro apresentou grande variação de valores

em relação à sua amplitude (0 a $5 \text{ mm}\cdot\text{dia}^{-1}$), entre os algoritmos. Visto que os solos presentes na BHAF-PC possuem predominância de textura argilosa, há maior quantidade de microporos, ou seja, maiores os valores de K_{CR} . Assim, os valores obtidos com o MOPSO estariam mais próximos ao esperado.

Os valores calibrados de C_S a partir do SCE-UA e do DREAM para a BHAF-PC foram próximos e destoaram dos obtidos com o MOPSO e o NSGA II. Os valores do C_{SS} apresentaram variação entre os algoritmos, contudo, as diferenças são aceitáveis dada a magnitude do intervalo escolhido para esse parâmetro ($50 - 50.000$). O NSGA, de maneira geral, resultou nos menores valores para os parâmetros C_S , C_{SS} e C_B , o que representa um esvaziamento mais rápido dos reservatórios. Efeito visível desses tempos menores pode ser observado na Figura 46, na qual os hidrogramas obtidos com os parâmetros apresentam enchimento e esvaziamento muito rápido dos reservatórios, originando vários picos nos hidrogramas que não são verificados no hidrograma observado, e nem nos hidrogramas derivados dos demais algoritmos.

O C_B está relacionado ao período de recessão do hidrograma e, de acordo com Horn (2016), tem seu desenho definido pelo escoamento de base, contemplando as vazões com permanência acima de 50%. Dessa forma, os maiores valores de $C_{NS,LOG}$ seriam um bom indicativo para os parâmetros C_B mais adequados. Neste caso, os algoritmos MOPSO (55,101 dias) foi o com melhor desempenho, corroborando com os valores obtidos por Caldeira (2019) e Vargas et al. (2023).

Na Figura 47 encontram-se as composições do escoamento obtidas para a BHAF-PC, a partir da aplicação dos parâmetros apresentados na Tabela 15 no R-LASH. Avaliando as composições médias anuais do escoamento, verificam-se padrões diferentes, os quais são resultantes das diferenças nos valores dos parâmetros do modelo LASH calibrados pelos algoritmos em análise.

De modo geral, a distribuição entre escoamento de base, subsuperficial e superficial do SCE-UA e do MOPSO são semelhantes, o que é plausível, uma vez que os parâmetros do modelo obtidos a partir desses algoritmos foram próximos. Os algoritmos DREAM e NSGA II resultaram em parâmetros do modelo LASH distintos, entretanto, na aplicação deles, a composição do escoamento foi semelhante.

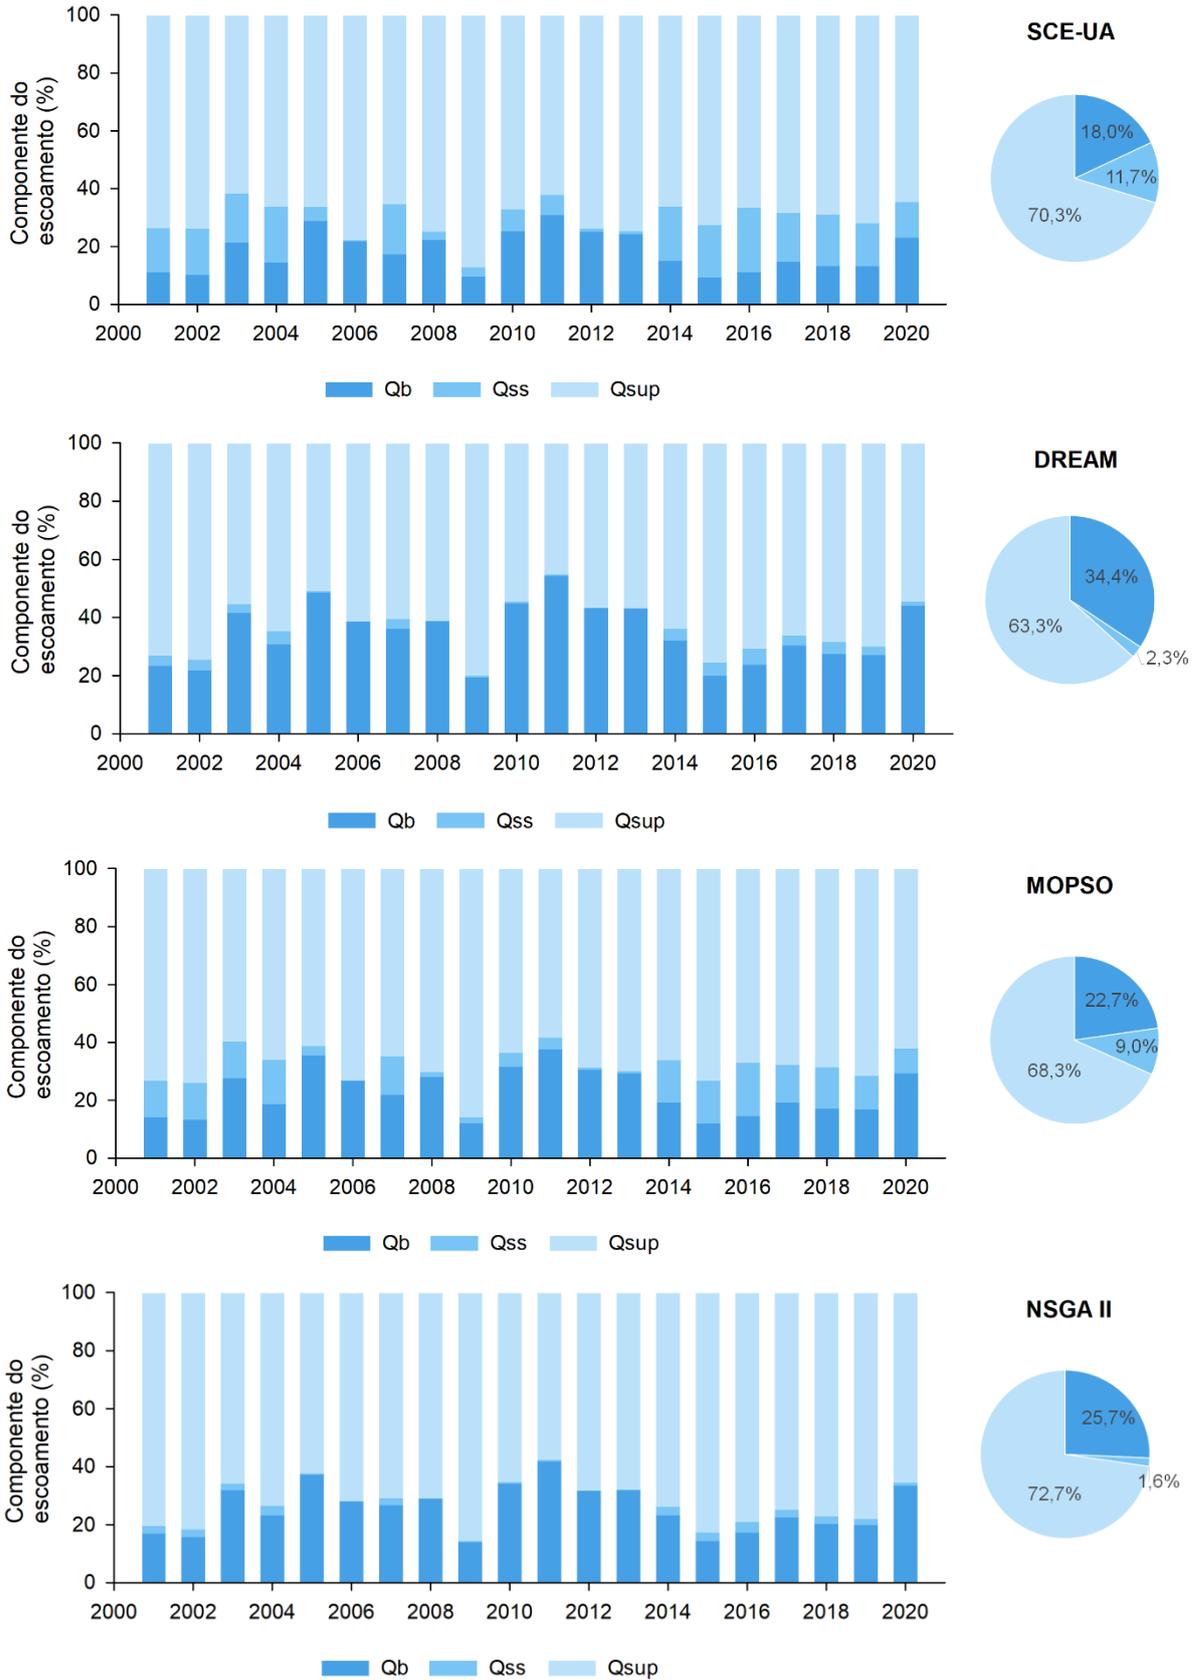


Figura 47 – Percentuais médios dos componentes do escoamento da BHAF-PC, a saber: QB – escoamento de base, QSS – escoamento subsuperficial e Qs – escoamento superficial.

A maior diferença na composição do escoamento é verificada entre superficial e subsuperficial. Nas simulações com os parâmetros derivados da aplicação dos algoritmos SCE-UA e MOPSO, o escoamento subsuperficial é em média, 10% do total, ao passo que, com a aplicação do DREAM e do NSGA II, essa porcentagem cai para ~2%.

Caldeira (2016) obteve composição média do escoamento de 22,73% (Q_B), 10,56% (Q_{SS}) e 66,71% (Q_S) para a BHAF-PC. Utilizando o algoritmo SCE-UA, Caldeira (2019) obteve 11,5% (Q_B), 10,3% (Q_{SS}) e 78,2% (Q_S), ao passo que, para a mesma base de dados, utilizando o algoritmo AMALGAM, Vargas et al. (2023) obtiveram composição de 8,8% (Q_B), 21,5% (Q_{SS}) e 69,7% (Q_S). Os percentuais obtidos com o MOPSO se assemelham aos de Caldeira (2016) e Vargas et al. (2023).

Na Figura 48 estão apresentadas as vazões mínimas, médias e máximas anuais, observadas e estimadas, para a BHAF-PC. Pode-se observar que as vazões obtidas a partir dos diferentes algoritmos de otimização permitiram representar as vazões mínimas de forma satisfatória e, em geral, subestimaram as vazões médias e máximas. Resultados semelhantes para a BHAF-PC foram observados por Caldeira (2016), utilizando o algoritmo SCE-UA e período de análise de 1994 a 2005.

O NSGA II foi o que permitiu a melhor representação das vazões máximas, enquanto os resultados com os demais algoritmos foram inferiores e não apresentam diferenças significativas entre si. Entretanto, vale destacar que os quatro algoritmos utilizados resultaram em vazões máximas subestimadas, com exceção do evento de 2009, que não foi bem representado por nenhum algoritmo.

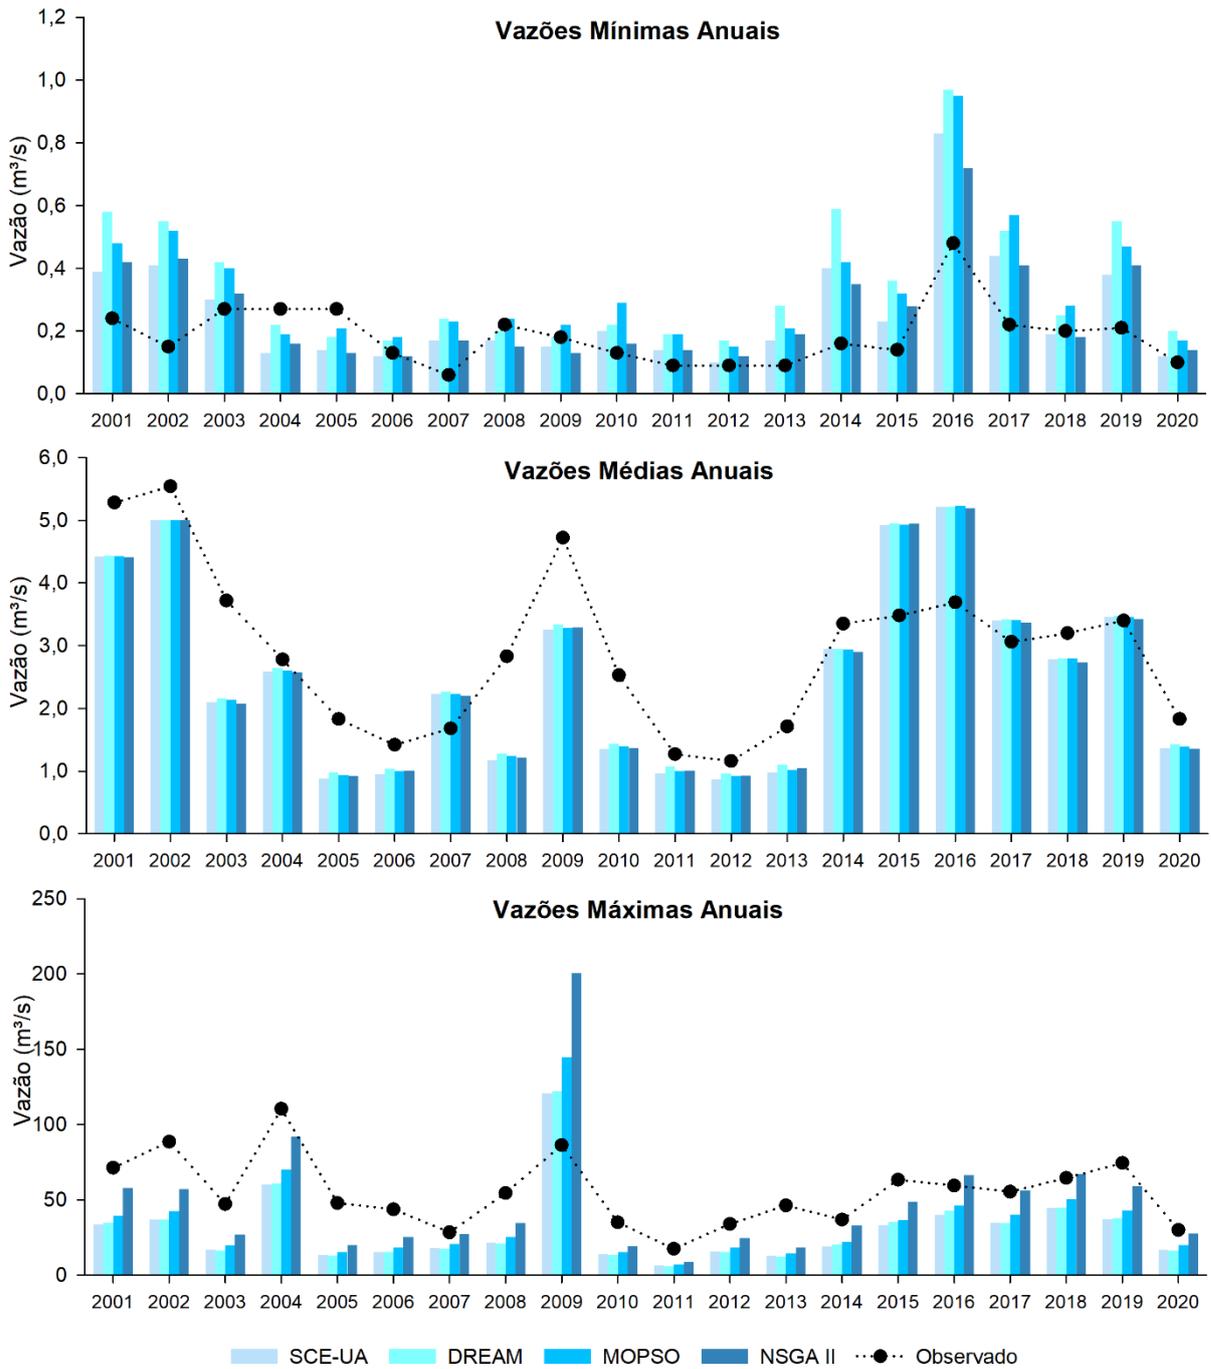


Figura 48 – Vazões mínimas, médias e máximas anuais observadas e estimadas por meio dos algoritmos de otimização para a BHAF-PC.

Na Tabela 17 estão apresentadas as vazões de referência estimadas para a BHAF-PC e os erros relativos em relação aos dados observados. As curvas de permanência estão apresentadas na Figura 49.

Tabela 17 – Vazões de referência estimadas para a BHAF-PC

Vazão de referência	Q _{OBS}	SCE-UA		DREAM		MOPSO		NSGA II	
		Q _{SIMULADA}	ER (%)						
Q _{10%}	6,561	5,958	-9%	5,776	-12%	5,826	-11%	5,757	-12%
Q _{20%}	3,161	3,467	10%	3,283	4%	3,262	3%	2,771	-12%
Q _{30%}	2,083	2,314	11%	2,238	7%	2,200	6%	1,708	-18%
Q _{40%}	1,441	1,655	15%	1,676	16%	1,591	10%	1,208	-16%
Q _{50%}	1,094	1,134	4%	1,278	17%	1,120	2%	0,930	-15%
Q _{60%}	0,811	0,797	-2%	0,985	21%	0,806	-1%	0,714	-12%
Q _{70%}	0,597	0,561	-6%	0,758	27%	0,609	2%	0,557	-7%
Q _{80%}	0,428	0,393	-8%	0,565	32%	0,446	4%	0,409	-5%
Q _{90%}	0,267	0,271	2%	0,386	44%	0,330	24%	0,284	6%
Q _{95%}	0,168	0,212	26%	0,283	68%	0,266	58%	0,207	23%

O algoritmo MOPSO foi o que resultou na melhor representação da curva de permanência das vazões. O algoritmo SCE-UA também teve bom desempenho, ao passo que, os algoritmos DREAM e NSGA II derivaram curvas com desvios constantes e mais acentuados. As vazões de referências obtidas foram superiores àquelas obtidas por Caldeira (2016) e Caldeira (2019) para a BHAF-PC, mesmo com as estatísticas de desempenho inferiores. Essa constatação permite inferir que, apesar de o modelo não conseguir representar adequadamente todos os picos do hidrograma observado, as vazões mínimas e médias foram melhor representadas.

Frente a todas as premissas do modelo e respostas hidrológicas avaliadas, entende-se que o MOPSO e o SCE-UA permitiram a melhor representação das vazões para a BHAF-PC. Apesar da boa representação das vazões mínimas e dos valores obtidos para as estatísticas de desempenho, o NSGA II resultou em parâmetros do modelo cujos sentidos físicos não condizem com o esperado para a região. O DREAM apresentou desempenho intermediário.

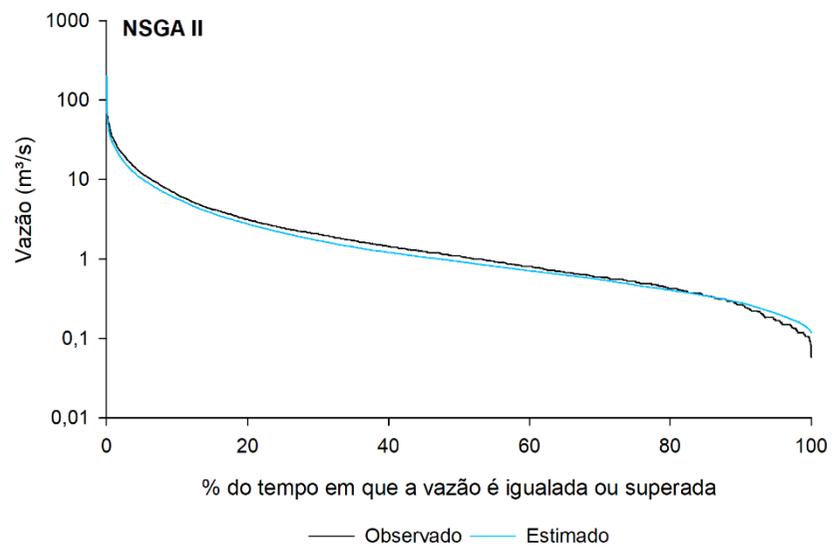
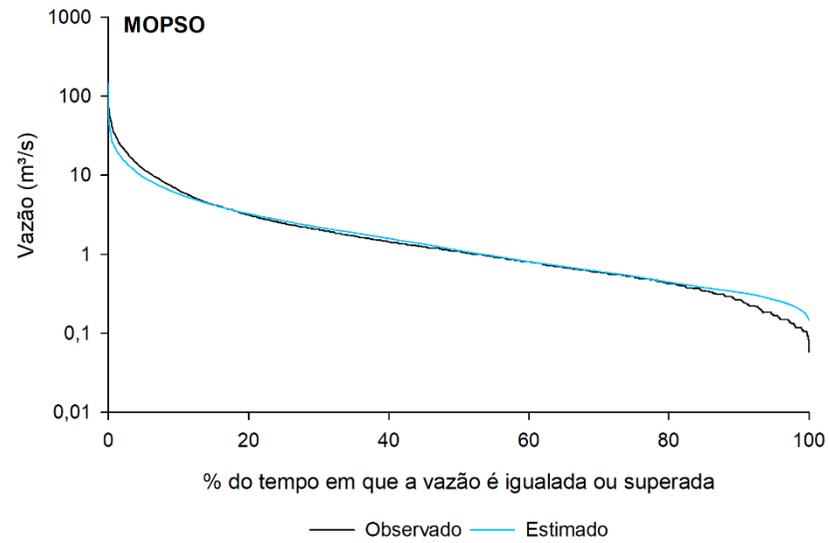
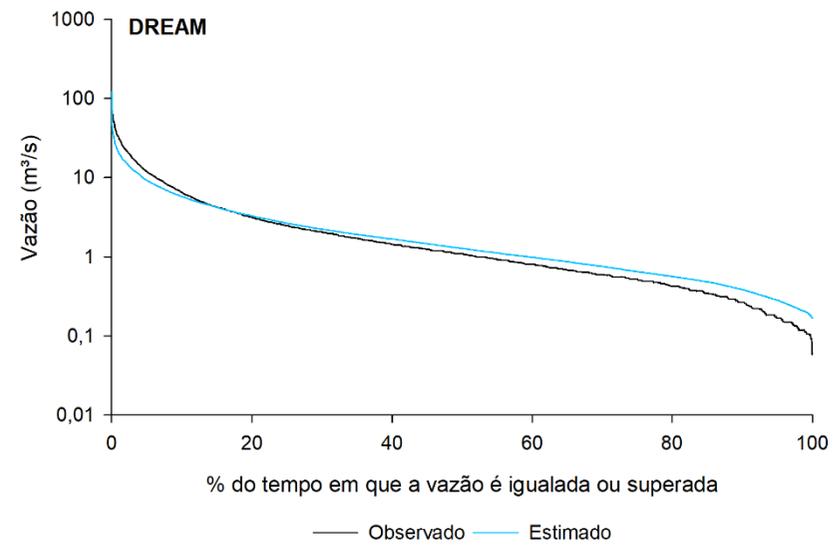
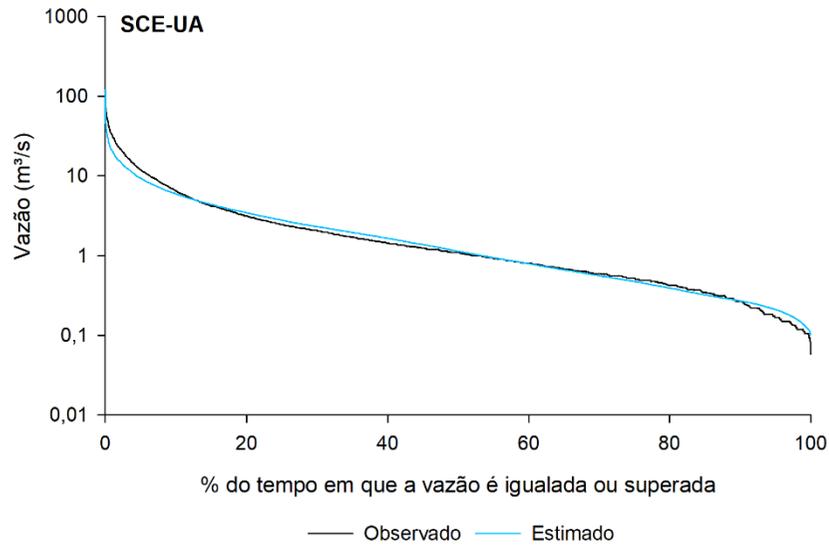


Figura 49 – Curvas de permanência das vazões observadas e simuladas com o modelo LASH, utilizando os parâmetros estimados para a BHAF-PC.

Na Tabela 18 estão apresentados os parâmetros estimados a partir dos diferentes algoritmos de otimização para a BHAP-PCF. As estatísticas de desempenho resultantes da aplicação dos parâmetros estimados no modelo encontram-se na Tabela 19.

Tabela 18 – Parâmetros do modelo LASH estimados para a BHAP-PCF

Parâmetro	Unidade	SCE-UA	DREAM	MOPSO	NSGA II
λ	adimensional	0,021	0,022	0,015	0,012
K_{SS}	mm·dia ⁻¹	173,143	159,574	59,147	167,970
K_B	mm·dia ⁻¹	1,895	1,866	2,238	1,764
K_{CR}	mm·dia ⁻¹	3,319	3,302	3,167	3,334
C_S	adimensional	12,035	14,208	14,850	15,694
C_{SS}	adimensional	226,564	241,572	216,000	337,918
C_B	dias	45,529	44,353	48,010	47,078

Tabela 19 – Estatísticas de desempenho das aplicações realizadas na BHAP-PCF

Algoritmo	Calibração					Validação				
	C_{NS}	$C_{NS,LOG}$	P_{BIAS} (%)	RMSE (m ³ /s)	KGE	C_{NS}	$C_{NS,LOG}$	P_{BIAS} (%)	RMSE (m ³ /s)	KGE
SCE-UA	0,40	0,63	18,71	16,17	0,62	0,57	0,72	-10,42	10,46	0,77
DREAM	0,46	0,64	24,67	15,27	0,52	0,62	0,74	-2,52	9,79	0,75
MOPSO	0,48	0,67	23,09	15,07	0,52	0,62	0,72	-3,52	9,85	0,74
NSGA II	0,49	0,64	25,74	14,98	0,47	0,63	0,74	-0,32	9,75	0,70

As estatísticas de desempenho do período de calibração indicam que o modelo obteve desempenho insatisfatório para representação das vazões máximas, e desempenho muito bom para as vazões mínimas. Para o período de validação, há melhora nos valores das estatísticas, uma vez que o desempenho do modelo para representação das vazões máximas passa a ser classificado como bom. Caldeira (2019) obtiveram $C_{NS} > 0,70$ para a calibração da BHAP-PCF, de 1995 a 2000. Contudo, para o período de 2001 a 2008 (validação), o C_{NS} caiu para 0,64. Os valores obtidos pelos autores para o período de validação corroboram com os obtidos para o período de calibração, que engloba dados de 2001 a 2010.

Os valores de P_{BIAS} para o período de calibração não foram satisfatórios, contudo, para o período de validação, enquadram-se como muito bom. Os resultados do RMSE tiveram comportamento semelhante.

Semelhante ao observado para a BHAF-PCF, observa-se que há pequena diversidade de respostas no período de calibração, principalmente nos três primeiros anos (2001 a 2003).

Da Figura 50 a Figura 53 são apresentados os hidrogramas observados e estimados a partir dos algoritmos SCE-UA, DREAM, MOPSO e NSGA, respectivamente.

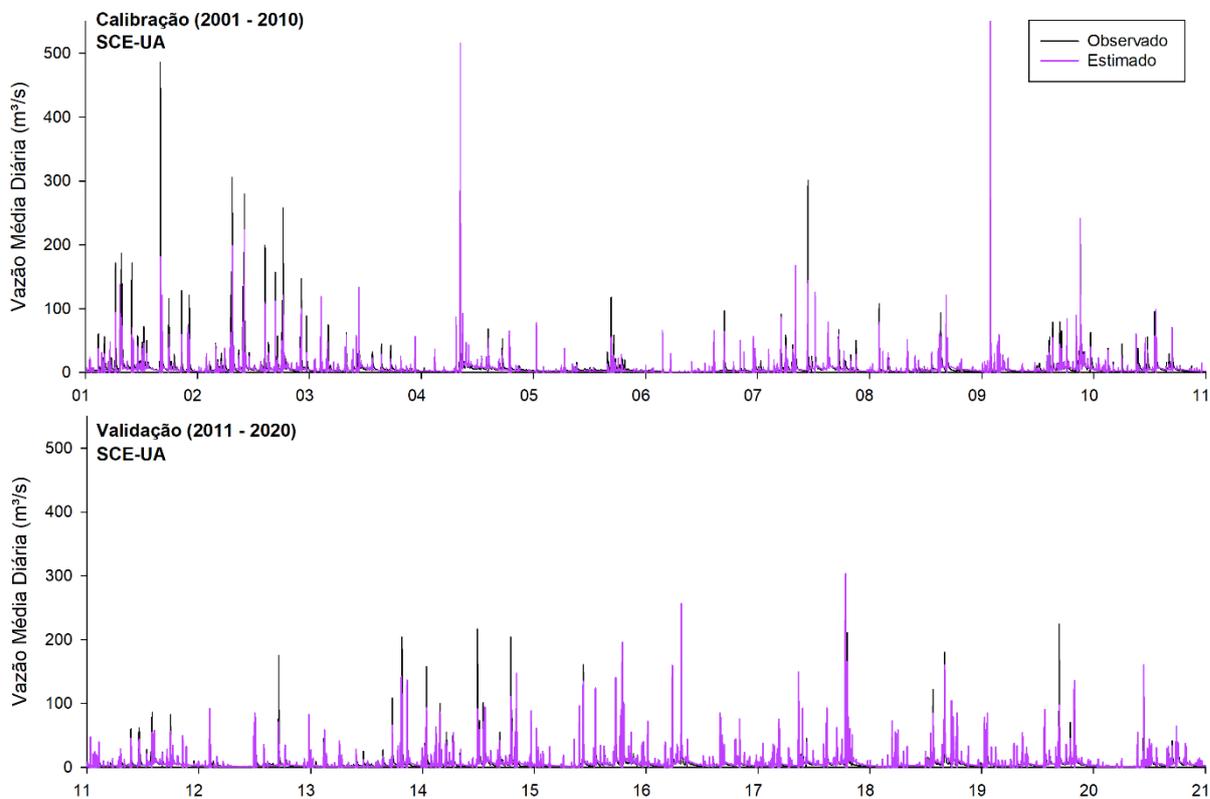


Figura 50 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo SCE-UA para a BHAP-PCF.

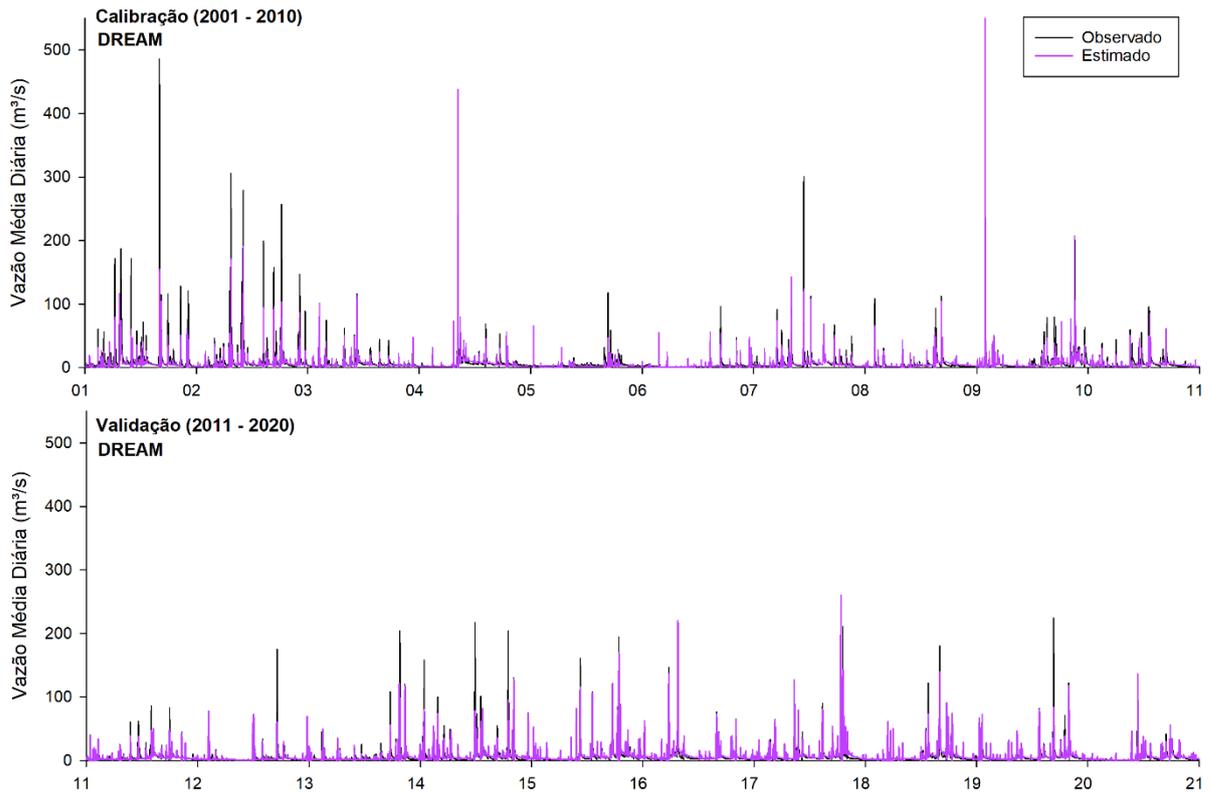


Figura 51 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo DREAM para a BHAP-PCF.

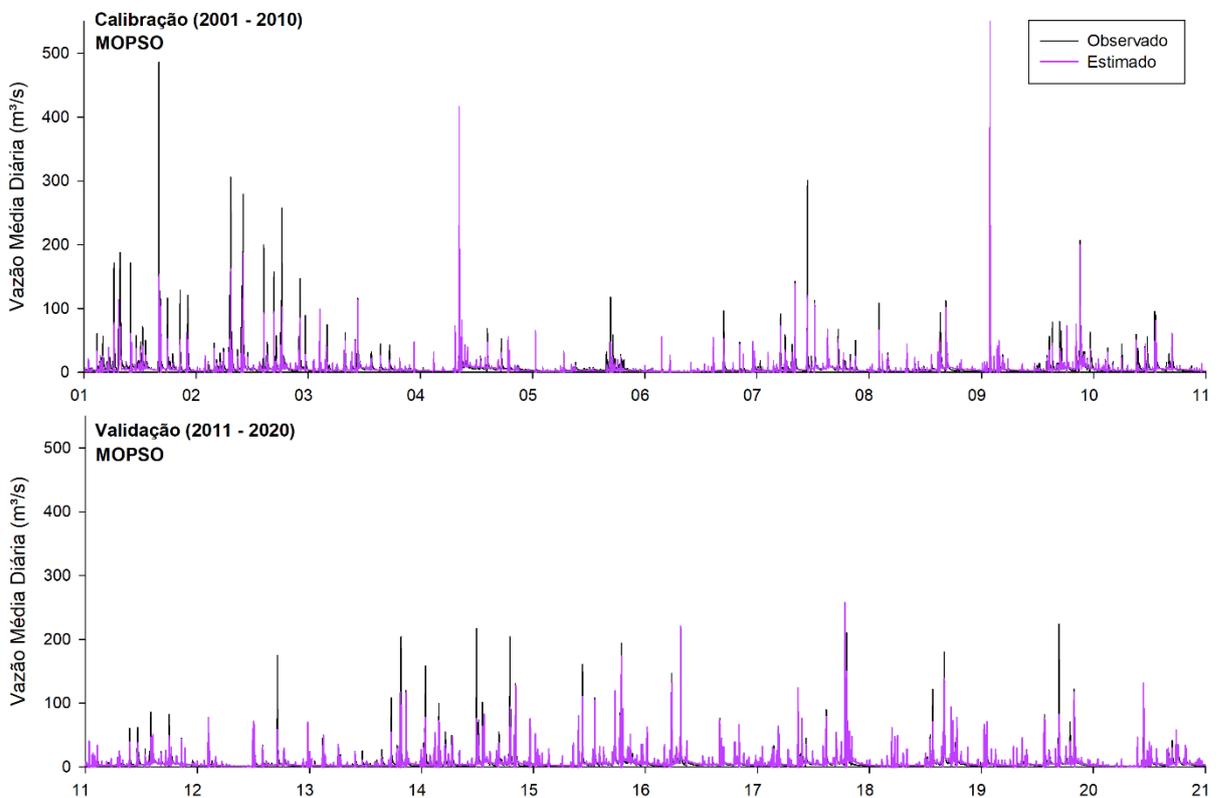


Figura 52 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo MOPSO para a BHAP-PCF.

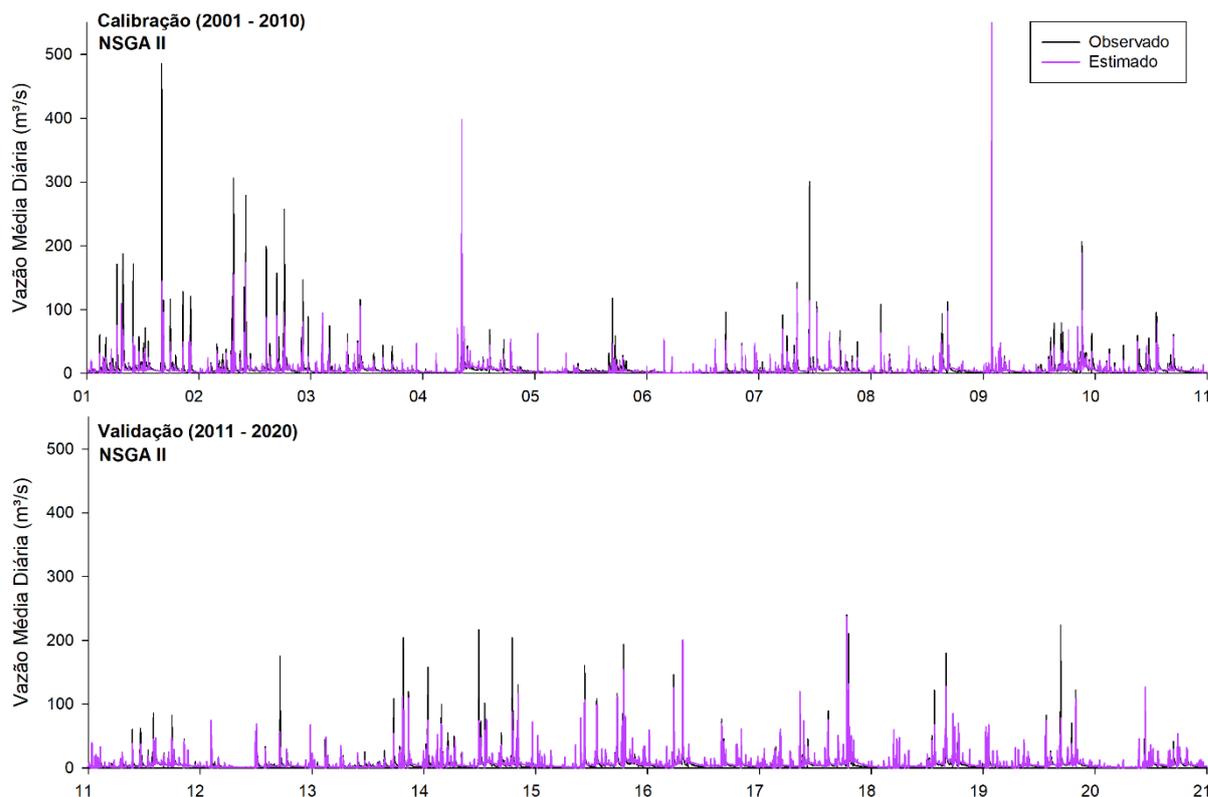


Figura 53 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo NSGA-II para a BHAP-PCF.

A BHAP-PCF foi a bacia que apresentou as menores variações nos valores estimados para os parâmetros a partir dos diferentes algoritmos (Tabela 18). Os valores de λ obtidos pelos algoritmos SCE-UA e DREAM foram de $\sim 0,020$, ao passo que, os valores do MOPSO e do NSGA II foram menores e iguais a 0,015 e 0,012, respectivamente. Nesse sentido, os dois primeiros algoritmos tendem a ter mais perdas iniciais anteriormente à geração do ESD, corroborando com o valor de λ obtido por Caldeira (2016).

Tendo em vista que os parâmetros K_B e K_{SS} estão ligeiramente associados ao tipo de solo, variações nos seus valores são esperadas para diferentes bacias hidrográficas. Por apresentar $\sim 73\%$ de solos argilosos do tipo C em seu território, a BHAP-PCF apresenta valores baixos de K_{SS} , os quais corroboram com valores obtidos por Caldeira (2016), com exceção do algoritmo MOPSO. De acordo com Caldeira (2016), os valores obtidos para K_{SS} mais elevados indicam infiltração superior, tendo potencial para geração de ESD acima da média.

O valor de K_{CR} apresentou pouca variação de valores em relação à sua amplitude (0 a $5 \text{ mm} \cdot \text{dia}^{-1}$) entre os algoritmos. Visto que os solos presentes na BHAP-PCF possuem predominância de textura argilosa, há maior quantidade de microporos,

ou seja, maiores os valores de K_{CR} . Assim, os valores obtidos estão próximos ao esperado e corroboram com os obtidos por Caldeira (2016) e Caldeira (2019) para a BHAP-PCF.

Os valores calibrados de C_S e foram próximos entre si, com média igual a 14,90. Os valores do C_{SS} apresentaram variação entre os algoritmos, contudo, as diferenças são aceitáveis dada a magnitude do intervalo escolhido para esse parâmetro (50 - 50.000). O NSGA, em geral, resultou nos maiores valores para os parâmetros C_S , C_{SS} e C_B , o que representa um esvaziamento mais lento dos reservatórios. O C_B variou de 44,35 dias (DREAM) a 48,010 (MOPSO), corroborando com o estudo de Caldeira (2016), no qual obteve-se C_B igual a 44,34 dias.

Na Figura 54 encontram-se as composições do escoamento obtidas para a BHAP-PCF, a partir da aplicação dos parâmetros apresentados na Tabela 18 no R-LASH. Avaliando as composições médias anuais do escoamento, verificam-se padrões semelhantes entre os algoritmos SCE-UA, DREAM e NSGA II, ao passo que, estes destoam do MOPSO. Essas diferenças são resultantes das magnitudes observadas para os valores dos parâmetros do modelo LASH, principalmente o K_{SS} e o K_B , os quais apresentaram valores destoantes com o MOPSO.

Nas simulações com os parâmetros derivados da aplicação dos algoritmos SCE-UA, DREAM e NSGA II, o escoamento médio é de 49,5% (Q_B), 14,8% (Q_{SS}) e 35,7% (Q_S). Com a aplicação do MOPSO, essa distribuição é igual a 42,7% (Q_B), 8,4% (Q_{SS}) e 48,9% (Q_S). Caldeira (2016) obteve composição média do escoamento de 35,78% (Q_B), 12,10% (Q_{SS}) e 52,12% (Q_S) para a BHAP-PCF. Os resultados obtidos pelo autor são intermediários aos observados, contudo, é importante destacar que os estudos utilizam base de dados diferentes para a calibração do modelo LASH.

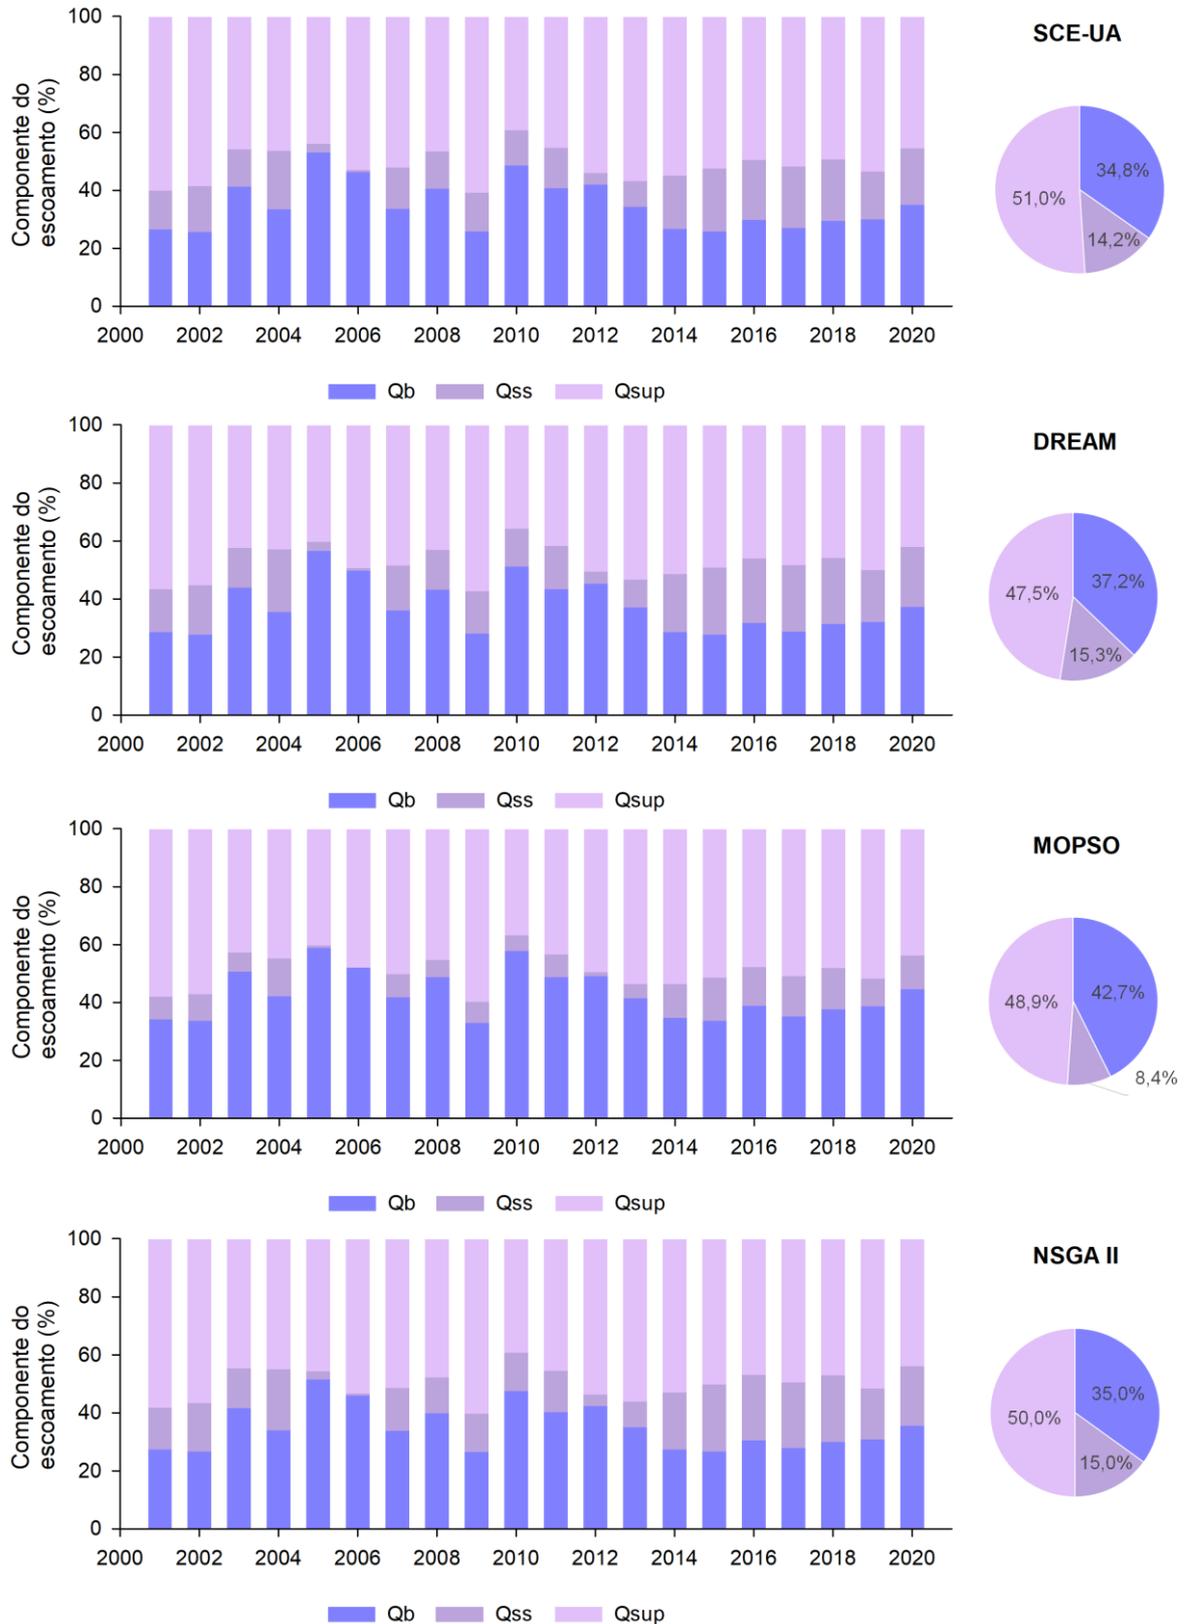


Figura 54 – Percentuais médios dos componentes do escoamento da BHAP-PCF, a saber: QB – escoamento de base, QSS – escoamento subsuperficial e Qs – escoamento superficial.

Na Figura 55 estão apresentadas as vazões mínimas, médias e máximas anuais, observadas e estimadas, para a BHAP-PCF. Pode-se observar que as vazões

obtidas a partir dos diferentes algoritmos de otimização permitiram representar as vazões médias de forma satisfatória e, em geral, superestimaram as vazões mínimas e subestimaram as máximas. Resultados semelhantes para a BHAP-PCF foram observados por Caldeira (2016), utilizando o algoritmo SCE-UA e período de análise de 1994 a 2005.

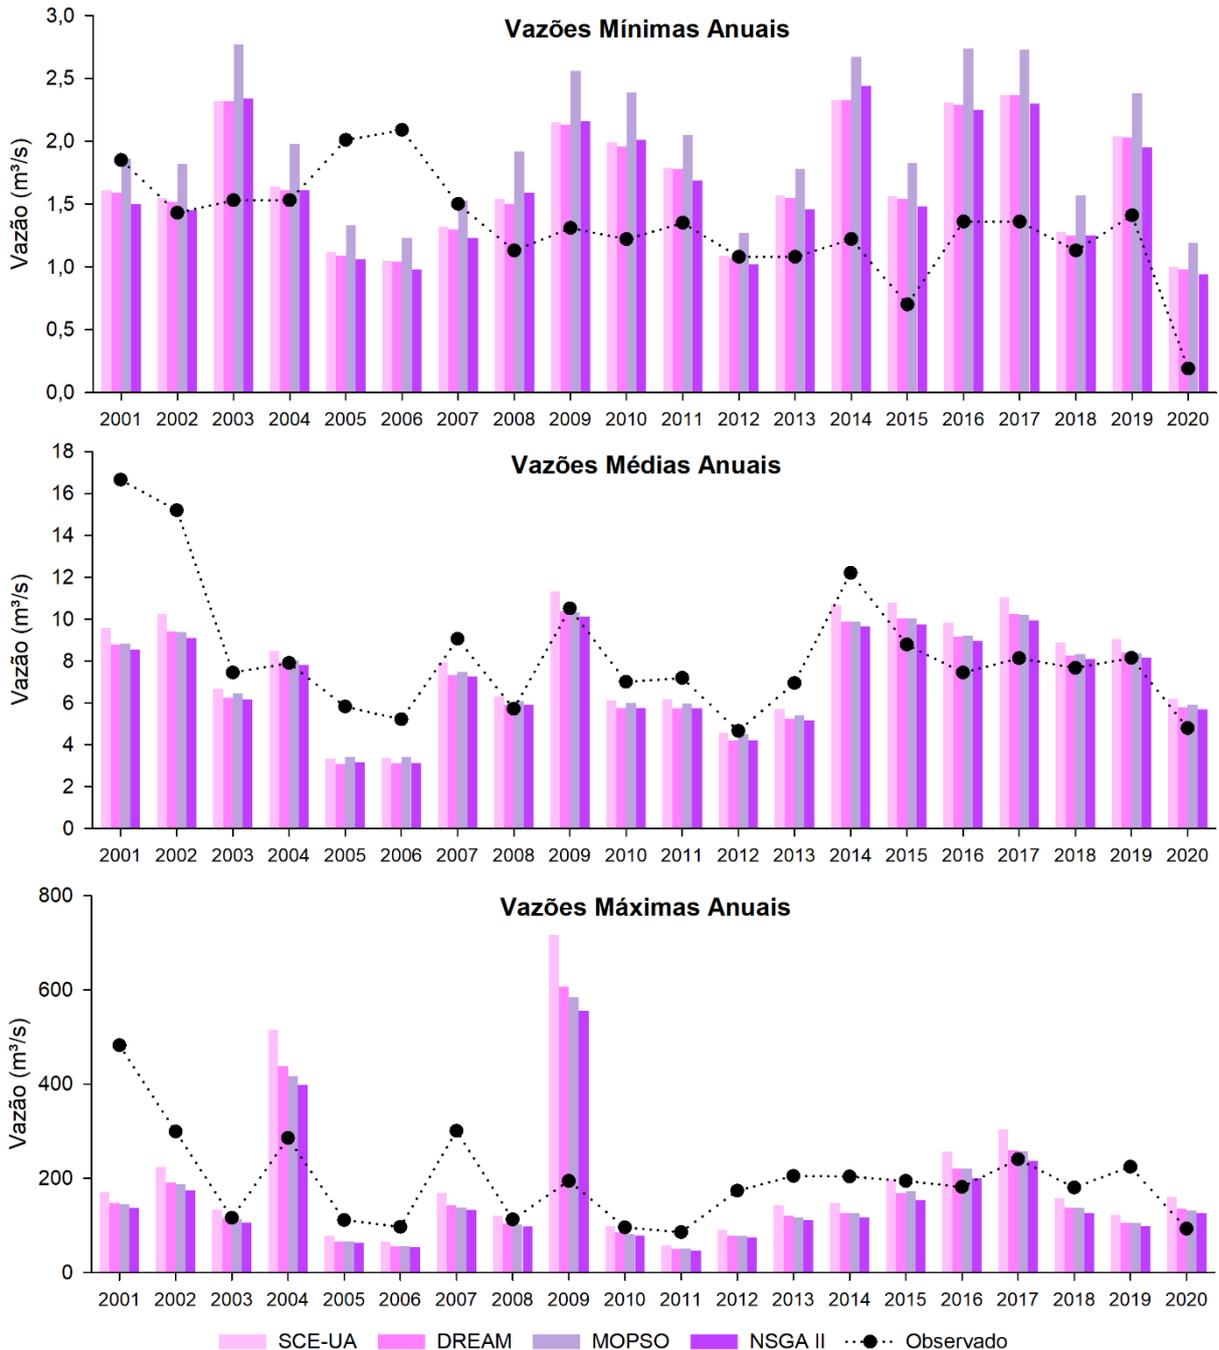


Figura 55 – Vazões mínimas, médias e máximas anuais observadas e estimadas por meio dos algoritmos de otimização para a BHAP-PCF.

As menores vazões mínimas foram estimadas a partir dos parâmetros estimados com o NSGA II. Para as vazões média, não são verificadas diferenças significativas entre os resultados obtidos a partir dos diferentes algoritmos. O SCE-UA foi o que permitiu a melhor representação das vazões máximas, enquanto os resultados com os demais algoritmos foram inferiores e não apresentam diferenças significativas entre si. Entretanto, vale destacar que os quatro algoritmos utilizados resultaram em vazões máximas subestimadas, com exceção dos eventos de 2004 e 2009, que não foram bem representados por nenhum algoritmo.

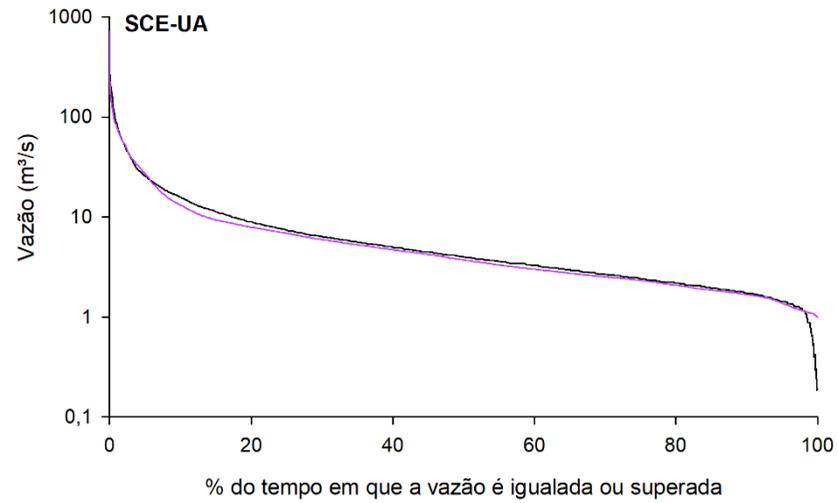
Na Tabela 20 estão apresentadas as vazões de referência estimadas para a BHAP-PCF e os erros relativos em relação aos dados observados. As curvas de permanência estão apresentadas na Figura 56.

Tabela 20 – Vazões de referência estimadas para a BHAP-PCF

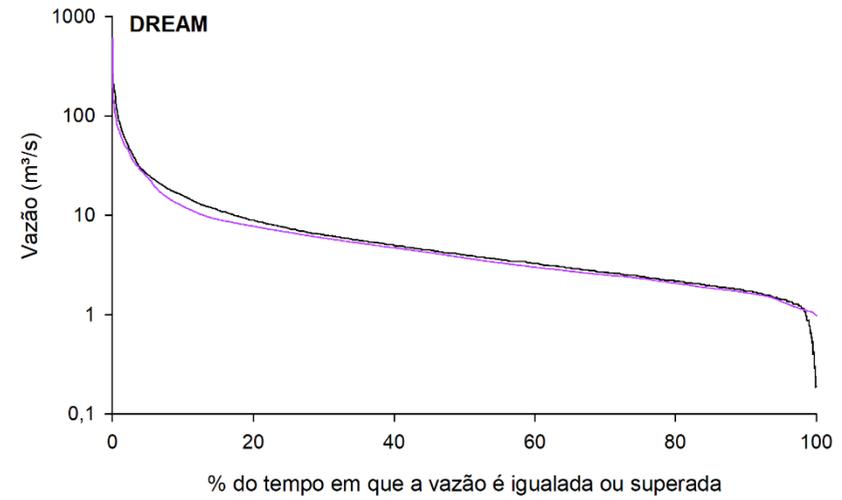
Vazão de referência	Q _{OBS}	SCE-UA		DREAM		MOPSO		NSGA II	
		Q _{SIMULADA}	ER (%)						
Q _{10%}	15,76	13,14	-17%	12,32	-22%	12,26	-22%	12,34	-22%
Q _{20%}	8,97	7,88	-12%	7,78	-13%	7,36	-18%	7,61	-15%
Q _{30%}	6,39	5,93	-7%	5,90	-8%	5,71	-11%	5,87	-8%
Q _{40%}	5,00	4,71	-6%	4,72	-6%	4,78	-4%	4,77	-5%
Q _{50%}	3,99	3,72	-7%	3,73	-7%	4,03	1%	3,85	-3%
Q _{60%}	3,29	3,01	-9%	3,00	-9%	3,34	2%	3,06	-7%
Q _{70%}	2,66	2,52	-5%	2,52	-5%	2,86	8%	2,52	-5%
Q _{80%}	2,18	2,08	-4%	2,07	-5%	2,39	10%	2,08	-5%
Q _{90%}	1,73	1,67	-3%	1,66	-4%	1,96	14%	1,63	-6%
Q _{95%}	1,43	1,38	-4%	1,37	-4%	1,66	16%	1,37	-4%

Os algoritmos SCE-UA foi o que resultou na melhor representação da curva de permanência das vazões. Os algoritmos NSGA II e DREAM também tiveram bom desempenho, ao passo que, o algoritmo MOPSO derivou curva com desvios constantes e mais acentuados, principalmente nos valores mínimos.

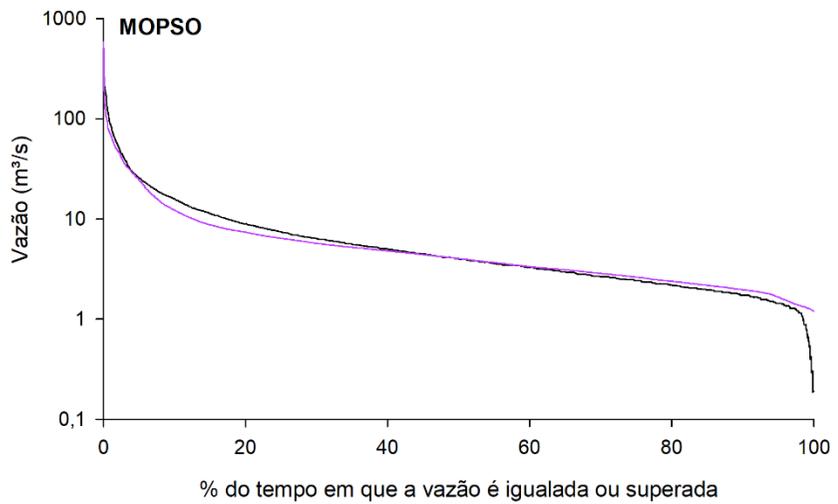
Frente a todas as premissas do modelo e respostas hidrológicas avaliadas, entende-se que o NSGA II e o SCE-UA permitiram a melhor representação das vazões para a BHAP-PCF. O MOPSO foi o algoritmo que resultou em parâmetros do modelo destoantes, apresentando desvios acentuados nas vazões mínimas. O DREAM apresentou desempenho intermediário.



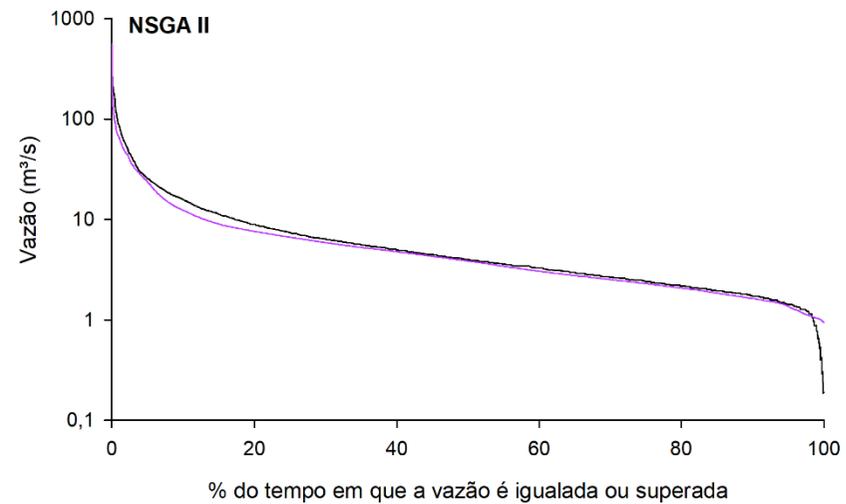
— Observado — Estimado



— Observado — Estimado



— Observado — Estimado



— Observado — Estimado

Figura 56 – Curvas de permanência das vazões observadas e simuladas com o modelo LASH, utilizando os parâmetros estimados para a BHAP-PCF.

Na Tabela 21 estão apresentados os parâmetros estimados a partir dos diferentes algoritmos de otimização para a BHRP-PO. As estatísticas de desempenho resultantes da aplicação dos parâmetros estimados no modelo encontram-se na Tabela 22.

Tabela 21 – Parâmetros do modelo LASH estimados para a BHRP-PO

Parâmetro	Unidade	SCE-UA	DREAM	MOPSO	NSGA II
λ	adimensional	0,126	0,087	0,038	0,044
K_{SS}	mm·dia ⁻¹	73,657	164,910	231,265	244,494
K_B	mm·dia ⁻¹	0,644	0,613	0,554	0,729
K_{CR}	mm·dia ⁻¹	3,322	3,450	4,178	0,517
C_S	adimensional	9,835	6,993	7,784	5,206
C_{SS}	adimensional	38,664	14,299	12,647	9,400
C_B	dias	53,082	45,400	33,527	20,149

Tabela 22 – Estatísticas de desempenho das aplicações realizadas na BHRP-PO

Algoritmo	Calibração					Validação				
	C_{NS}	$C_{NS,LOG}$	P_{BIAS} (%)	RMSE (m ³ /s)	KGE	C_{NS}	$C_{NS,LOG}$	P_{BIAS} (%)	RMSE (m ³ /s)	KGE
SCE-UA	0,66	0,85	14,98	136,65	0,29	0,69	0,84	-9,92	100,52	0,53
DREAM	0,73	0,84	11,89	121,23	0,59	0,75	0,86	-14,03	90,65	0,76
MOPSO	0,74	0,82	9,17	119,78	0,61	0,75	0,85	-17,14	90,52	0,76
NSGA II	0,72	0,80	6,01	123,87	0,77	0,69	0,83	-20,90	100,11	0,77

As estatísticas de desempenho do período de calibração indicam que o modelo obteve desempenho muito bom para representação das vazões máximas e mínimas. Para o período de validação, há melhora nos valores das estatísticas. Os resultados obtidos foram superiores aos obtidos por Caldeira (2019) e Vargas et al. (2023) para a BHRP-PO, os quais obtiveram C_{NS} igual a 0,69.

Os valores de P_{BIAS} para o período de calibração foram classificados como muito bom, para os algoritmos MOPSO e NSGA II, e como bom para os algoritmos SCE-UA e DREAM. No período de validação há uma pior nos valores, contudo, todos são, ao menos, satisfatórios. Os resultados do RMSE tiveram comportamento semelhante.

Da Figura 57 a Figura 60 são apresentados os hidrogramas observados e estimados a partir dos algoritmos SCE-UA, DREAM, MOPSO e NSGA, respectivamente.

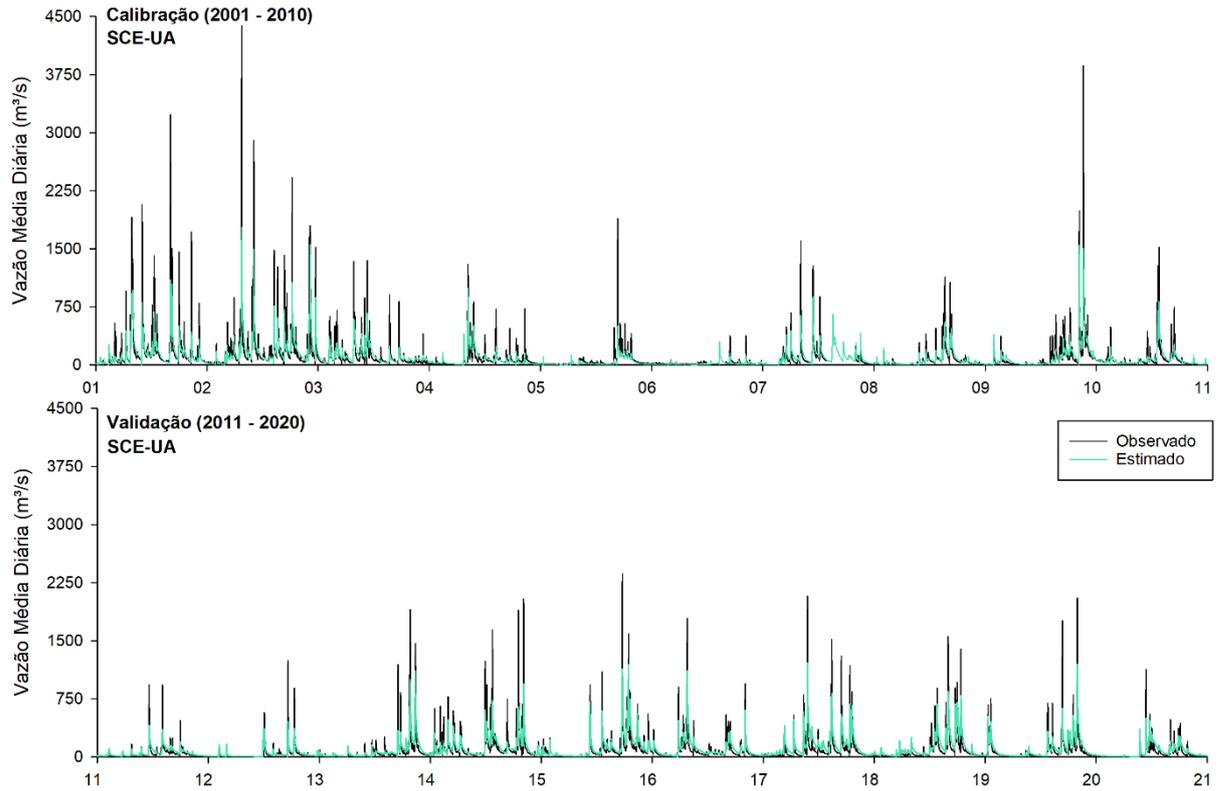


Figura 57 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo SCE-UA para a BHRP-PO.

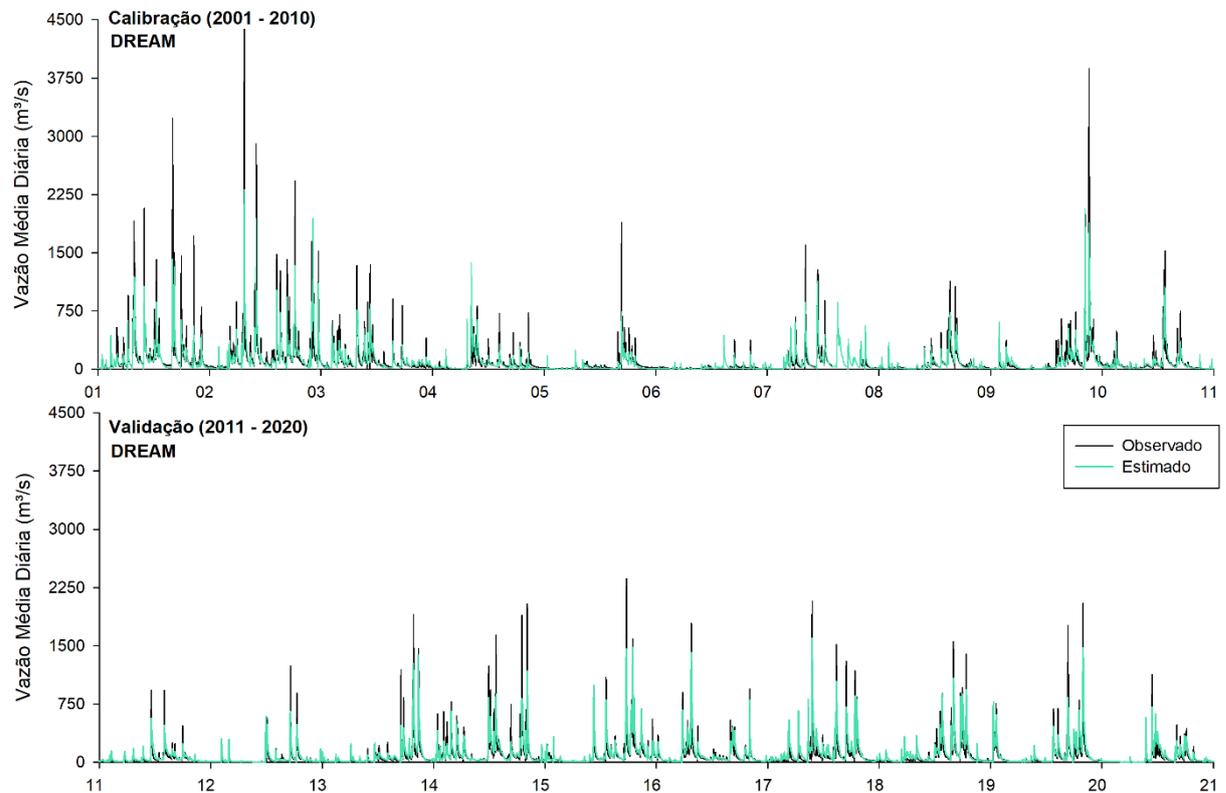


Figura 58 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo DREAM para a BHRP-PO.

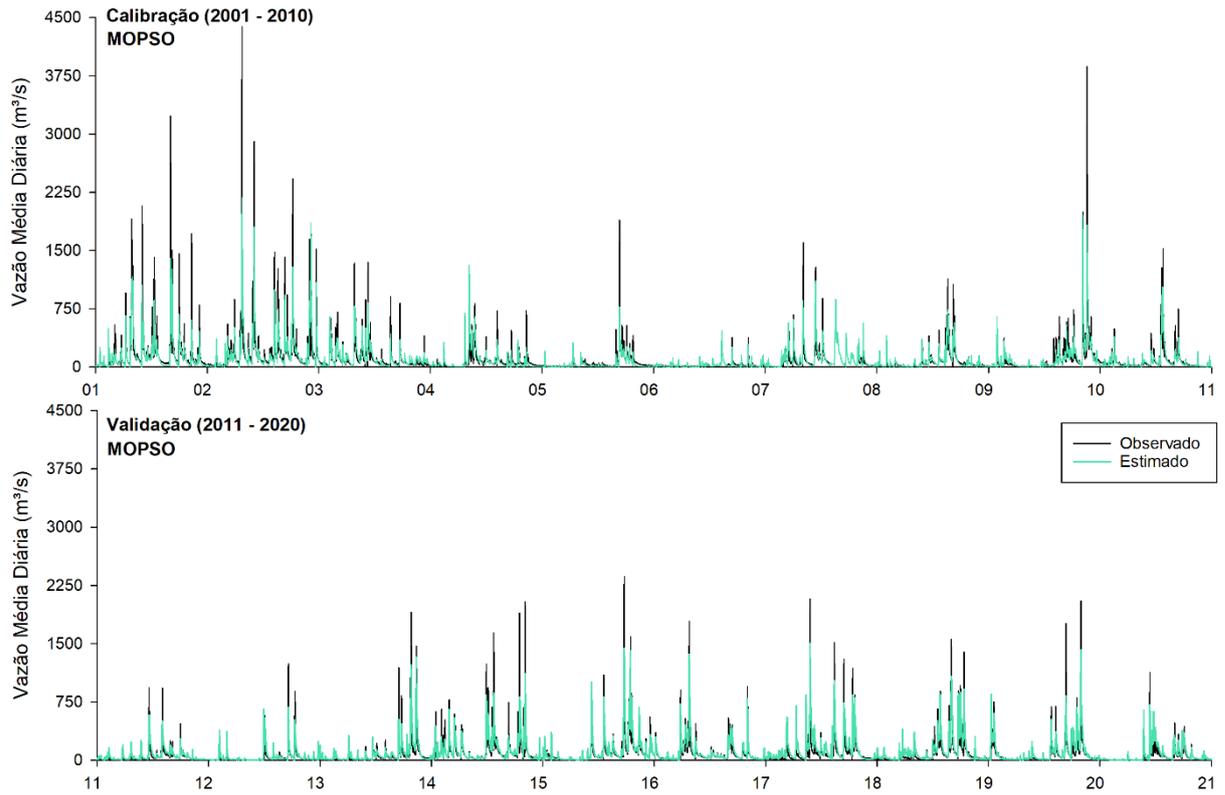


Figura 59 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo MOPSO para a BHRP-PO.

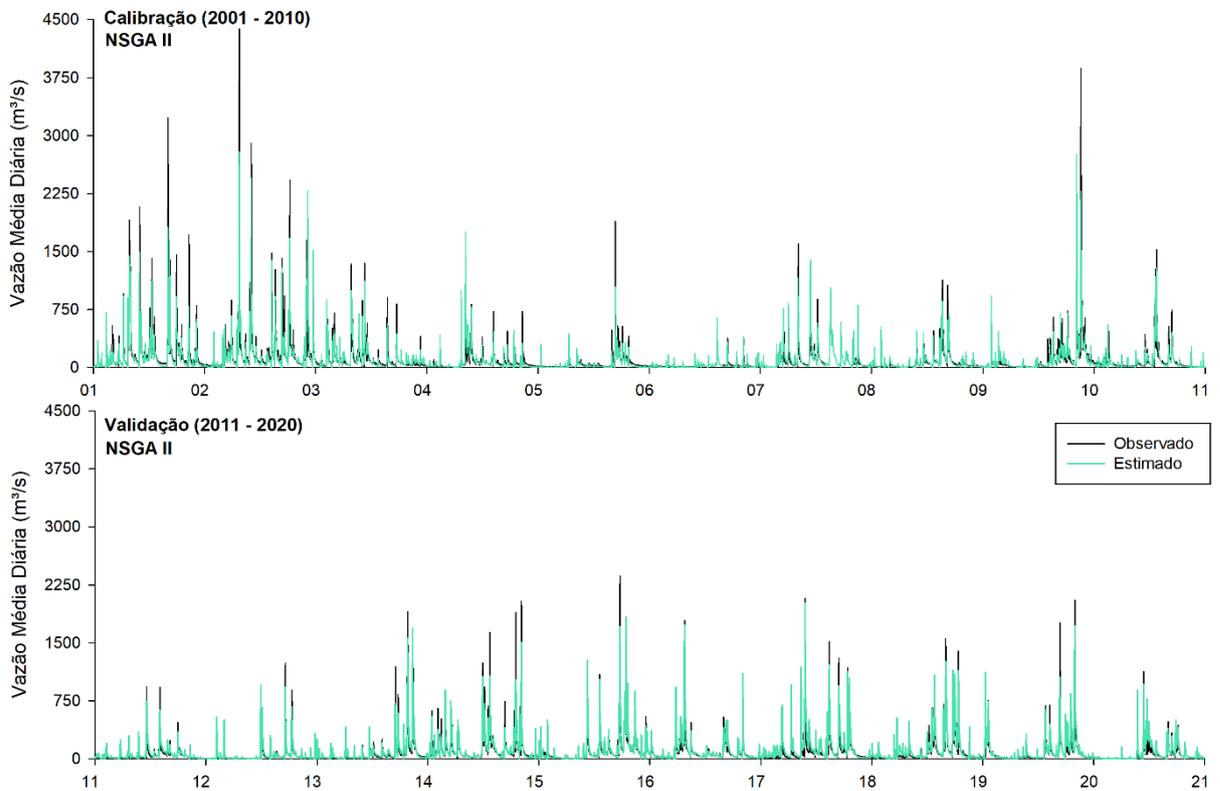


Figura 60 – Hidrogramas observado e simulado com o modelo LASH, utilizando os parâmetros estimados com o algoritmo NSGA-II para a BHRP-PO.

A BHRP-PO apresentou grandes variações nos valores estimados para os parâmetros a partir dos diferentes algoritmos (Tabela 21). O parâmetro λ apresentou valores distintos entre os algoritmos, variando de 0,038 (MOPSO) a 0,126 (SCE-UA). O λ igual a 0,038 corrobora com o valor obtido por Vargas et al. (2023) para a BHRP-PO, ao passo que, o valor obtido com o DREAM (0,087) corrobora com o valor de Caldeira (2019).

Tendo em vista que os parâmetros K_B e K_{SS} estão ligeiramente associados ao tipo de solo, variações nos seus valores são esperadas para diferentes bacias hidrográficas. Por apresentar ~50% de solos argilosos em seu território, a BHRP-PO apresenta valores médios de K_{SS} , os quais corroboram com valores obtidos por Caldeira (2019) e Vargas et al. (2023), quando utilizado o algoritmo SCE-UA ($K_{SS} = 73,657$). Para os demais algoritmos, os valores de K_{SS} são superiores, variando de 164,910 (DREAM) a 244,494 (NSGA II). Essas diferenças podem estar associadas à distribuição dos solos em relação às áreas das sub-bacias, uma vez que, o modelo LASH simula o balanço com base nos valores médios dos parâmetros.

Os valores de K_{CR} apresentaram grande variação em relação à sua amplitude (0 a 5 mm·dia⁻¹), variando de 0,517 mm·dia⁻¹ (NSGA II) a 4,178 mm·dia⁻¹ (MOPSO). Visto que os solos presentes na BHRP-PO possuem predominância de textura argilosa, há maior quantidade de microporos, ou seja, maiores os valores de K_{CR} . Assim, os valores obtidos com o MOPSO estariam mais próximos ao esperado e, os valores obtidos com o NSGA II, mais destoantes.

Os valores calibrados de C_S e C_{SS} a partir do MOPSO e do DREAM para a BHRP-PO foram próximos e destoaram dos obtidos com o SCE e o NSGA II. Em relação às demais bacias, os valores obtidos foram menores, simulando um esvaziamento do reservatório mais rápido. O NSGA II, de maneira geral, resultou nos menores valores para os parâmetros C_S , C_{SS} e C_B , o que representa um esvaziamento mais rápido dos reservatórios. Efeito visível desses tempos menores pode ser observado na Figura 60, na qual os hidrogramas obtidos com os parâmetros apresentam enchimento e esvaziamento muito rápido dos reservatórios, originando vários picos nos hidrogramas que não são verificados no hidrograma observado, e nem nos hidrogramas derivados dos demais algoritmos.

Os valores de C_B variaram de 20,149 dias (NSGA II) a 53,082 dias (SCE-UA). O C_B igual a 45,4 dias (DREAM) corrobora com o obtido por Caldeira (2019) para a BHRP-PO. Vargas et al. (2023), utilizando mesma base de dados, obteve C_B igual a

36,100, o qual encontra-se próximo do C_B obtido a partir do MOPSO. Os melhores valores de $C_{NS,LOG}$ foram obtidos com o DREAM e o MOPSO, sendo muito próximos. Logo, os valores obtidos com os algoritmos trazem um bom indicativo do intervalo de valores representativos de C_B .

Na Figura 61 encontram-se as composições do escoamento obtidas para a BHRP-PO, a partir da aplicação dos parâmetros apresentados na Tabela 21 no R-LASH. Avaliando as composições médias anuais do escoamento, verificam-se padrões diferentes, os quais são resultantes das diferenças nos valores dos parâmetros do modelo LASH calibrados pelos algoritmos em análise.

De modo geral, a distribuição entre escoamento de base, subsuperficial e superficial do SCE-UA e do DREAM são semelhantes entre si, o que ocorre também para as distribuições de MOPSO e NSGA II. Apesar de ambos os pares de algoritmos resultarem em parâmetros do modelo LASH distintos, a partir da aplicação deles, a composição do escoamento foi semelhante.

Nas simulações com os parâmetros derivados da aplicação dos algoritmos SCE-UA e DREAM, o escoamento médio é de 18,50% (Q_B), 43,90% (Q_{SS}) e 37,60% (Q_S). Com a aplicação do MOPSO e do DREAM, essa distribuição média é igual a 15,2% (Q_B), 36,5% (Q_{SS}) e 48,3% (Q_S).

As principais diferenças observadas em relação à literatura são na geração do Q_{SS} . Caldeira (2019), a partir do SCE-UA obteve-se a composição do escoamento em 18,6% (Q_B), 21,2% (Q_{SS}) e 60,2% (Q_S) para a BHRP-PO. Para as mesmas condicionantes de entrada, Vargas et al. (2023) utilizando o algoritmo AMALGAM, obteve 32,2% (Q_B), 6,6% (Q_{SS}) e 61,2% (Q_S). Apesar de haver grande diferença no componente de escoamento superficial direto entre os estudos de Caldeira (2019) e Vargas et al. (2023), verifica-se que o escoamento de base é quase o dobro, o que reflete diretamente no armazenamento de água na bacia em períodos mais secos.

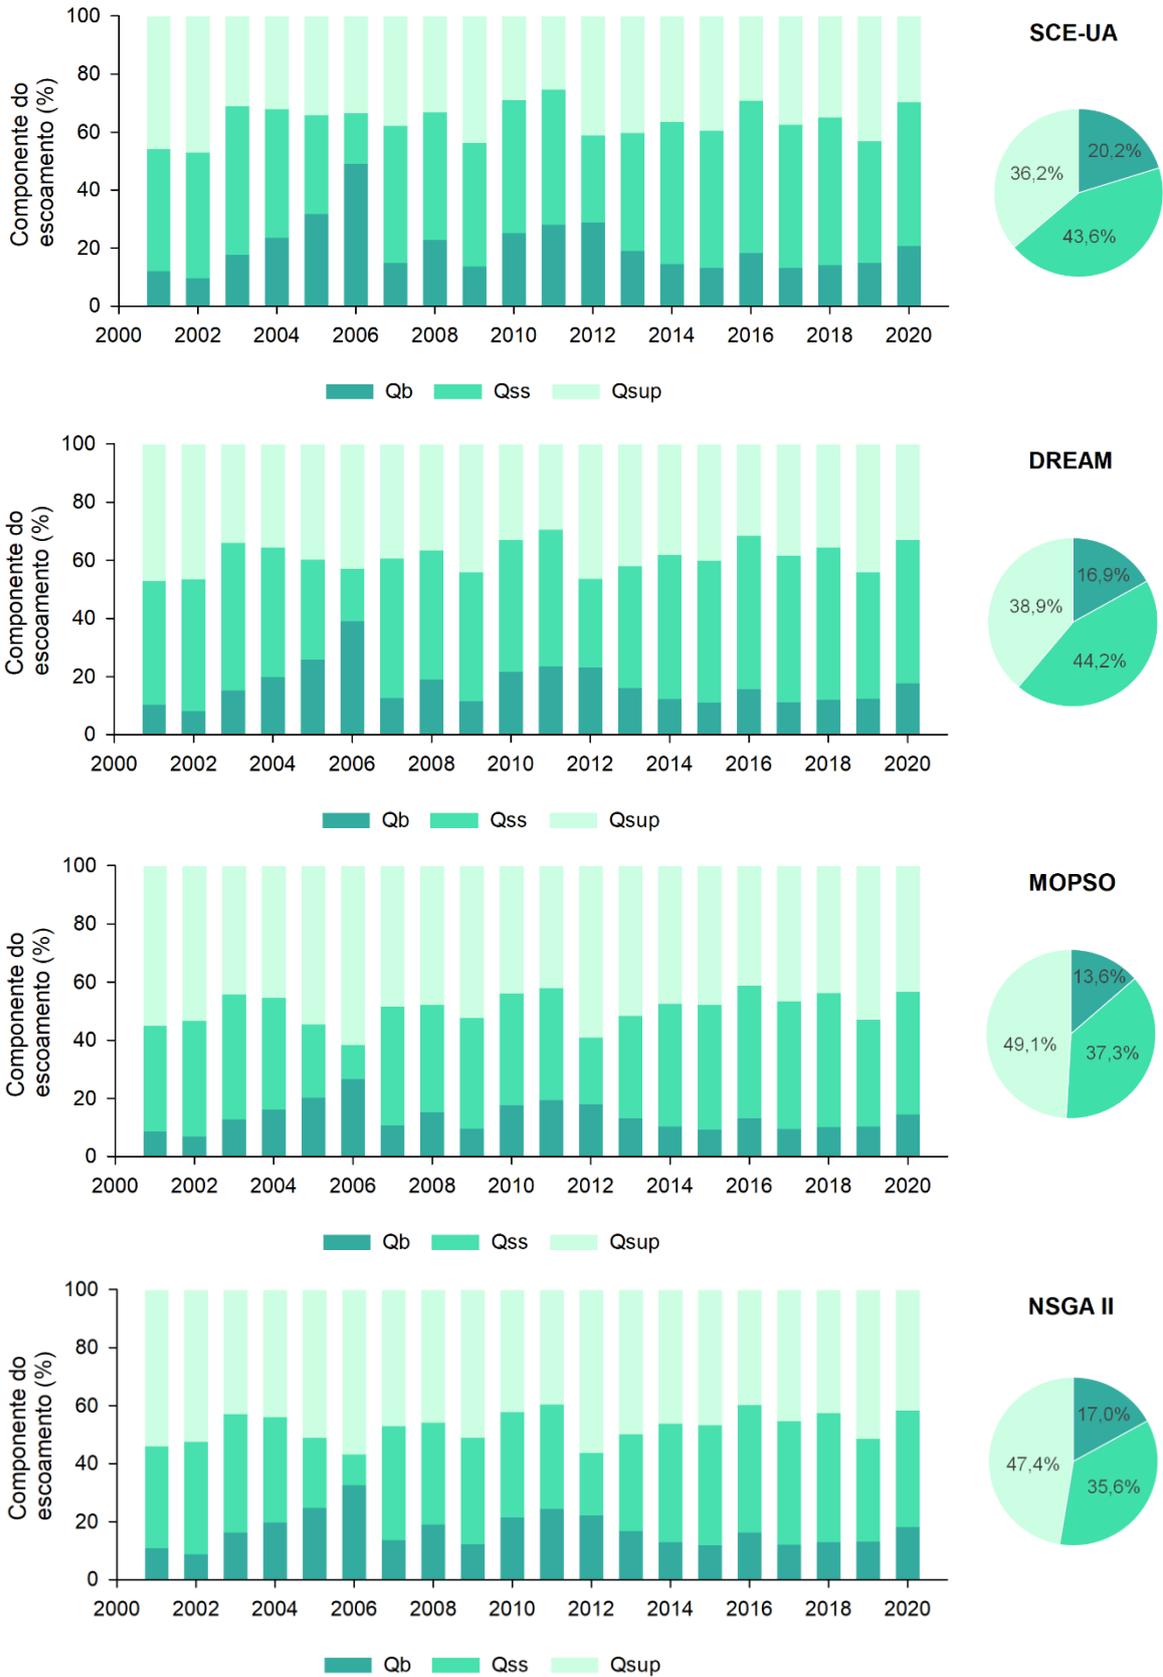


Figura 61 – Percentuais médios dos componentes do escoamento da BHRP-PO, a saber: QB – escoamento de base, QSS – escoamento sub-superficial e Qs – escoamento superficial.

Na Figura 62 estão apresentadas as vazões mínimas, médias e máximas anuais, observadas e estimadas, para a BHRP-PO.

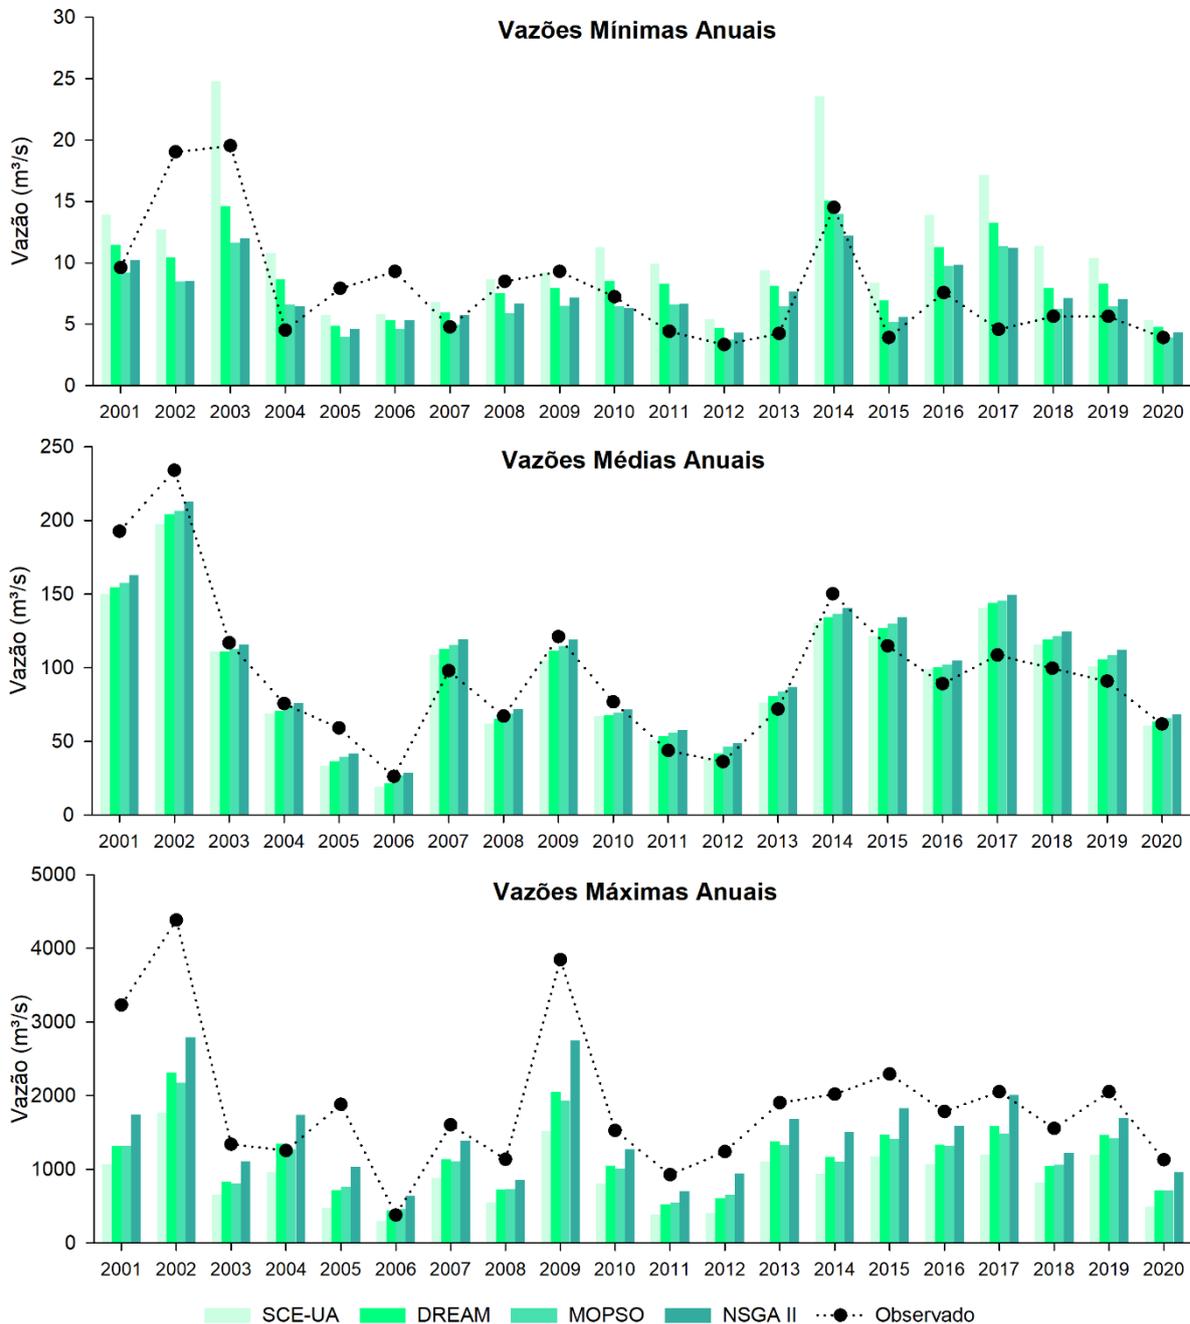


Figura 62 – Vazões mínimas, médias e máximas anuais observadas e estimadas por meio dos algoritmos de otimização para a BHRP-PO.

Pode-se observar que as vazões obtidas a partir dos diferentes algoritmos de otimização permitiram representar as vazões médias de forma satisfatória. Os menores valores foram obtidos a partir do SCE-UA e do DREAM, ao passo que, os maiores valores médios foram verificados a partir do NSGA II. Resultados

semelhantes para a BHRP-PO foram observados por Caldeira (2019), utilizando o algoritmo SCE-UA e período de análise de 2007 a 2016.

Em relação às vazões mínimas, observa-se que para o período de calibração os algoritmos apresentaram tendência de subestimativa dos valores. Para o período de validação, verifica-se melhor representação dos valores mínimos.

O NSGA II foi o que permitiu a melhor representação das vazões máximas, enquanto o SCE-UA apresentou os valores mais divergentes. Entretanto, vale destacar que os quatro algoritmos utilizados resultaram em vazões máximas subestimadas.

Na Tabela 23 estão apresentadas as vazões de referência estimadas para a BHRP-PO e os erros relativos em relação aos dados observados. As curvas de permanência estão apresentadas na Figura 63.

Tabela 23 – Vazões de referência estimadas para a BHRP-PO

Vazão de referência	Q _{OBS}	SCE-UA		DREAM		MOPSO		NSGA II	
		Q _{SIMULADA}	ER (%)						
Q _{10%}	204,93	220,33	8%	237,81	16%	249,42	22%	248,77	21%
Q _{20%}	108,59	135,44	25%	131,99	22%	136,95	26%	132,03	22%
Q _{30%}	72,19	92,90	29%	85,44	18%	87,47	21%	82,95	15%
Q _{40%}	52,61	67,25	28%	58,25	11%	58,97	12%	55,44	5%
Q _{50%}	39,49	49,23	25%	38,88	-2%	40,33	2%	38,21	-3%
Q _{60%}	28,91	33,79	17%	27,10	-6%	27,75	-4%	26,66	-8%
Q _{70%}	20,57	23,05	12%	18,48	-10%	18,69	-9%	18,89	-8%
Q _{80%}	14,36	15,60	9%	13,16	-8%	12,66	-12%	13,41	-7%
Q _{90%}	9,61	11,23	17%	9,43	-2%	8,49	-12%	8,95	-7%
Q _{95%}	6,77	8,49	25%	7,30	8%	6,43	-5%	6,79	0%

O algoritmo DREAM foi o que resultou na melhor representação da curva de permanência das vazões. O algoritmo MOPSO também teve bom desempenho, ao passo que, os algoritmos SCE-UA e NSGA II derivaram curvas com desvios constantes e mais acentuados.

Frente a todas as premissas do modelo e respostas hidrológicas avaliadas, entende-se que o MOPSO e o DREAM permitiram a melhor representação das vazões para a BHRP-PO. Apesar da boa representação das vazões mínimas e dos valores obtidos para as estatísticas de desempenho, o NSGA II resultou em parâmetros do modelo cujos sentidos físicos não condizem com o esperado para a região. O SCE-UA apresentou desempenho intermediário.

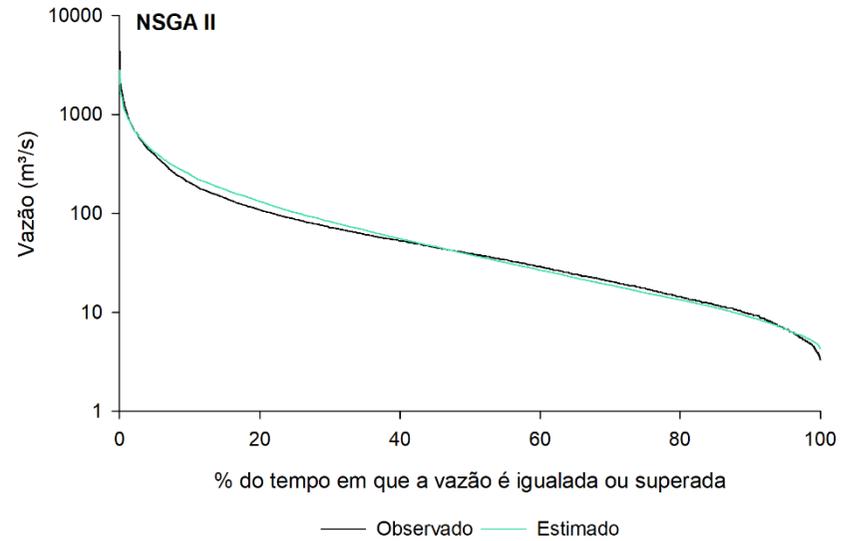
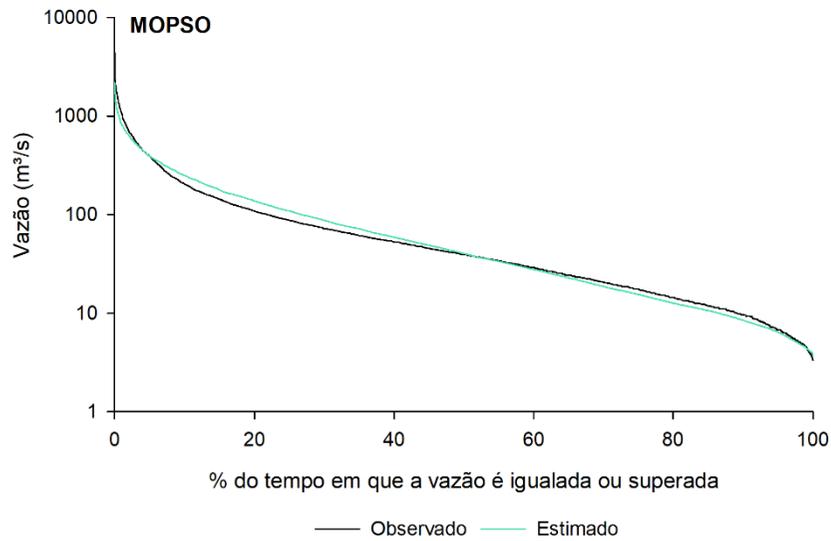
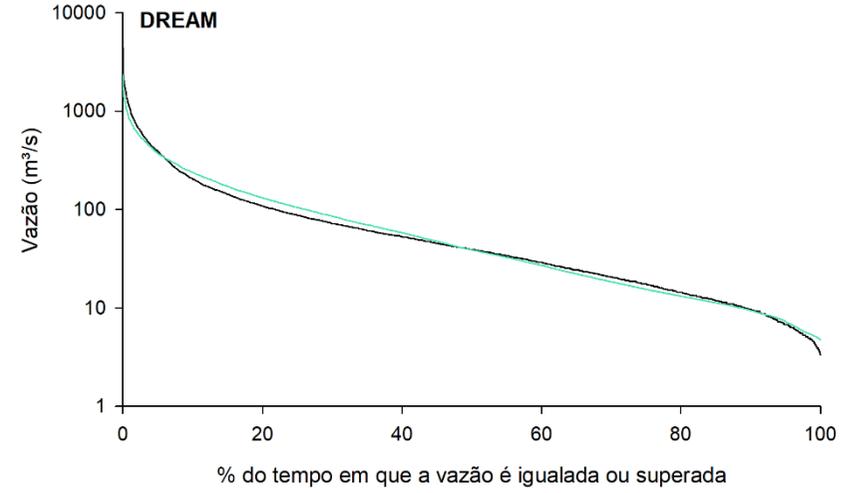
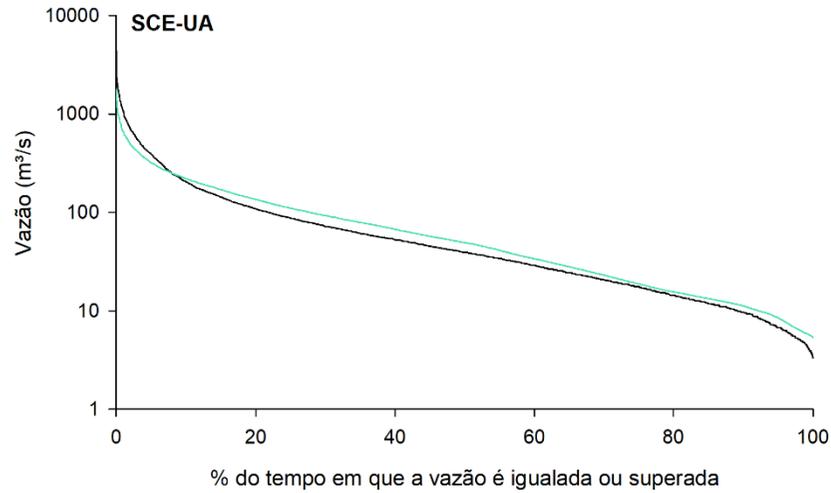


Figura 63 – Curvas de permanência das vazões observadas e simuladas com o modelo LASH, utilizando os parâmetros estimados para a BHRP-PO.

4.4 Discussão com a literatura

Na Tabela 24 é apresentada uma síntese das estatísticas de desempenho obtidas por meio da aplicação de modelos hidrológicos de longo termo nas bacias hidrográficas em estudo. Todos os trabalhos selecionados utilizaram as mesmas estações de controle fluviométrico para as análises, contudo, com recortes temporais e algoritmos e/ou processo de calibração distintos.

Caldeira (2016) aplicou a terceira versão do LASH – semidistribuída em sub-bacias – na BHAF-PC e na BHAP-PCF, considerando dados de 1994 a 2008. Na calibração, o autor obteve valores de C_{NS} enquadrados como muito bom para ambas as bacias, com pequena piora nos valores para o período de validação. De forma contrária ao observado no presente estudo, os valores de C_{NS} foram superiores aos de $C_{NS,LOG}$, o que se deve à escolha do C_{NS} como função-objetivo do algoritmo SCE-UA. Nesse caso, há uma melhora na representação das vazões de pico, contudo, verifica-se piora na representação das vazões mínimas.

Caldeira (2019) e Steinmetz (2020) aplicaram, respectivamente, o modelo LASH e o modelo SWAT, na base de dados de 1994 a 2005, para a BHAF-PC e a BHAP-PCF, e de 2008 a 2016 para a BHRP-PO. Os autores realizaram a calibração e validação dos modelos para posterior aplicação de cenários de projeções climáticas. Os resultados obtidos podem ser observados na Tabela 24, a partir dos quais pode-se identificar superioridade do modelo LASH em relação ao SWAT para as simulações realizadas nas bases de dados elaboradas pelos autores. Ambas as análises utilizaram algoritmos mono-objetivos e o C_{NS} como função objetivo, entretanto, o processo de representação espacial dos modelos é diferentes: sub-bacias no LASH, e sub-bacias e HRUs no SWAT. Além disso, no LASH foram estimados apenas sete parâmetros, ao passo que, no SWAT foi necessário o ajuste de 20 parâmetros. Os resultados obtidos para a BHRP-PO foram inferiores ao do presente estudo e, foram superiores para a BHAF-PC e a BHAP-PCF.

Possa et al. (2022) e Boeira et al. (2023) aplicaram o modelo MGB para simulação hidrológica na BHMSG e, entre as seções de controle utilizadas, estão as três estações fluviométricas deste estudo. Possa et al. (2022) utilizaram dados de janeiro/1990 a dezembro/2015, enquanto Boeira et al. (2023) consideraram dados de 01/04/2000 a 31/12/2020, para a BHRP-PO, e de 01/01/1980 a 31/12/2020 para a BHAF-PC e a BHAP-PCF. O grande diferencial destes trabalhos foi a consideração

do efeito dos ventos na simulação hidrológica, contudo, mesmo com a representação mais detalhada das condicionantes ambientais locais, alguns resultados obtidos pelos autores foram inferiores aos desse estudo, principalmente na BHRP-PO. Para as BHAP-PC e a BHAP-PCF os resultados obtidos pelos autores foram próximos aos do presente estudo, com valores de C_{NS} e P_{BIAS} satisfatórios. Cabe destacar que, dos trabalhos disponíveis, estes são os únicos que utilizam dados mais recentes, especialmente entre 2010 e 2020.

Vargas et al. (2023) aplicaram o M-LASH em quatro bacias hidrográficas, sendo duas delas a BHAF-PC e a BHRP-PO. Os autores utilizaram a mesma base de dados de Caldeira et al. (2016) para a BHAF-PC e de Caldeira (2019) para a BHRP-PO, em conjunto com o algoritmo AMALGAM. Os valores de C_{NS} obtidos na calibração e validação foram classificados como muito bom para a BHRP-PO, e respectivamente como muito bom e insatisfatório para a BHAF-PC. Os valores de P_{BIAS} obtidos pelos autores foram classificados como muito bom a bom.

Importante mencionar que nenhum dos trabalhos avaliados fizeram uso de mais de uma imagem/classificação de uso do solo na base de dados utilizada. Conforme apresentado anteriormente, as bacias em estudo vem passando por alterações na sua paisagem, com destaque para o aumento de áreas com cultivos agrícolas e silvicultura. Lucas (2017) realizou um mapeamento das mudanças na cobertura da terra na BHRP, o qual compreendeu os anos de 1994 a 2015 e apontou uma redução de 12,9% nas áreas de mata nativa, acréscimo de 4,5% nas áreas de campo e pastagem e de 3,5% nas áreas com silvicultura. Haja vista as mudanças percentuais entre as classes de uso do solo, principalmente nas últimas duas décadas, a representação dessas variações espacial e temporalmente trazem à modelagem maior representação dos processos.

Considerando apenas os estudos que utilizaram o modelo LASH (CALDEIRA, 2016; CALDEIRA, 2019; VARGAS et al., 2023), verifica-se grande variação nos parâmetros estimados (Tabela 25), inclusive entre aqueles que utilizaram a mesma base de dados.

Tabela 24 – Estatísticas de desempenho obtidas com modelos hidrológicos aplicados às bacias hidrográficas utilizadas

-	Estudo	Modelo Hidrológico	Calibração	Recorte temporal	Calibração			Validação		
					C_{NS}	$C_{NS,LOG}$	P_{BIAS} (%)	C_{NS}	$C_{NS,LOG}$	P_{BIAS} (%)
BHAF-PC	Caldeira (2016)	LASH	SCE-UA	01/94 - 12/08	0,73	0,66	-	0,53	0,75	-
	Caldeira (2019)	LASH	SCE-UA	01/94 - 12/05	0,73	0,67	-	0,52	0,76	-
	Steinmetz (2020)	SWAT	SUFI-2	01/94 - 12/05	0,58	0,35	-22,00	0,61	0,40	-17,10
	Possa et al. (2022)	MGB	Manual	01/90 - 12/15	0,42 a 0,58	0,57 a 0,65	-10 a 10	-	-	-
	Boeira et al. (2023)	MGB	Manual	01/80 - 12/20	0,519	0,673	-3,411	-	-	-
	Vargas et al. (2023)	M-LASH	AMALGAM	01/94 - 12/08	0,71	0,63	1,85	0,38	0,71	2,45
BHAP-PCF	Caldeira (2016)	LASH	SCE-UA	01/94 - 12/08	0,65	0,64	-	0,70	0,75	-
	Caldeira (2019)	LASH	SCE-UA	01/94 - 12/05	0,73	0,58	-	0,64	0,70	-
	Steinmetz (2020)	SWAT	SUFI-2	01/94 - 12/05	0,70	0,52	4,20	0,61	0,50	-20,35
	Possa et al. (2022)	MGB	Manual	01/90 - 12/15	0,42 a 0,58	0,25 a 0,45	10 a 27	-	-	-
	Boeira et al. (2023)	MGB	Manual	01/80 - 12/20	0,506	0,528	1,936	-	-	-
BHRP-PO	Caldeira (2019)	LASH	SCE-UA	01/07 - 12/16	0,69	0,78	21,67	0,72	0,82	-0,22
	Steinmetz (2020)	SWAT	SUFI-2	01/07 - 12/16	0,55	0,86	-13,26	0,72	0,81	-32,38
	Possa et al. (2022)	MGB	Manual	01/90 - 12/15	0,42 a 0,58	0,65 a 0,70	10 a 27	-	-	-
	Boeira et al. (2023)	MGB	Manual	04/00 - 12/20	0,531	0,527	14,374	-	-	-
	Vargas et al. (2023)	M-LASH	AMALGAM	01/07 - 12/16	0,69	0,62	-0,11	0,76	0,60	-10,58

Tabela 25 – Parâmetros do modelo LASH obtidos em estudos anteriores, para as bacias hidrográficas utilizadas

Estudo	λ	K_{CR}	K_{SS}	K_B	C_S	C_{SS}	C_B
BHAF-PC							
Caldeira (2016)	0,115	2,021	5,261	0,634	46,558	165,444	57,543
Caldeira (2019)	0,130	2,020	4,390	0,790	40,390	68,180	32,400
Vargas et al. (2023)	0,030	0,220	127,820	0,460	28,900	666,190	66,100
BHAP-PCF							
Caldeira (2016)	0,024	2,927	137,489	1,866	28,658	241,114	44,336
Caldeira (2019)	0,090	2,250	95,240	1,360	24,520	1534,360	68,180
BHRP-PO							
Caldeira (2019)	0,090	2,550	77,080	0,650	11,630	40,640	43,480
Vargas et al. (2023)	0,030	1,830	81,060	1,660	11,400	120,220	36,100

Em relação aos conjuntos de parâmetros obtidos pelos autores, para a BHAF-PC, verifica-se que os valores estimados no presente estudo apresentam divergência, principalmente nos parâmetros λ , K_{CR} e C_B (Tabela 15, Tabela 25). É importante destacar que, entre os estudos realizados na bacia, há também divergência nos valores dos parâmetros.

Os resultados obtidos para a BHAP-PCF (Tabela 15, Tabela 18) apresentam semelhança com os de Caldeira (2016) e divergem dos obtidos por Caldeira (2019). Neste contexto, ressalta-se os recortes temporais utilizados pelos autores, os quais abrangem, no primeiro estudo, um período maior e mais próximo do utilizado (1994 a 2008). Os estudos apresentam outras diferenças importantes, como o número de sub-bacias, igual a 43 (CALDEIRA, 2016) e 21 (CALDEIRA, 2019), mapa de solos e de uso do solo utilizados.

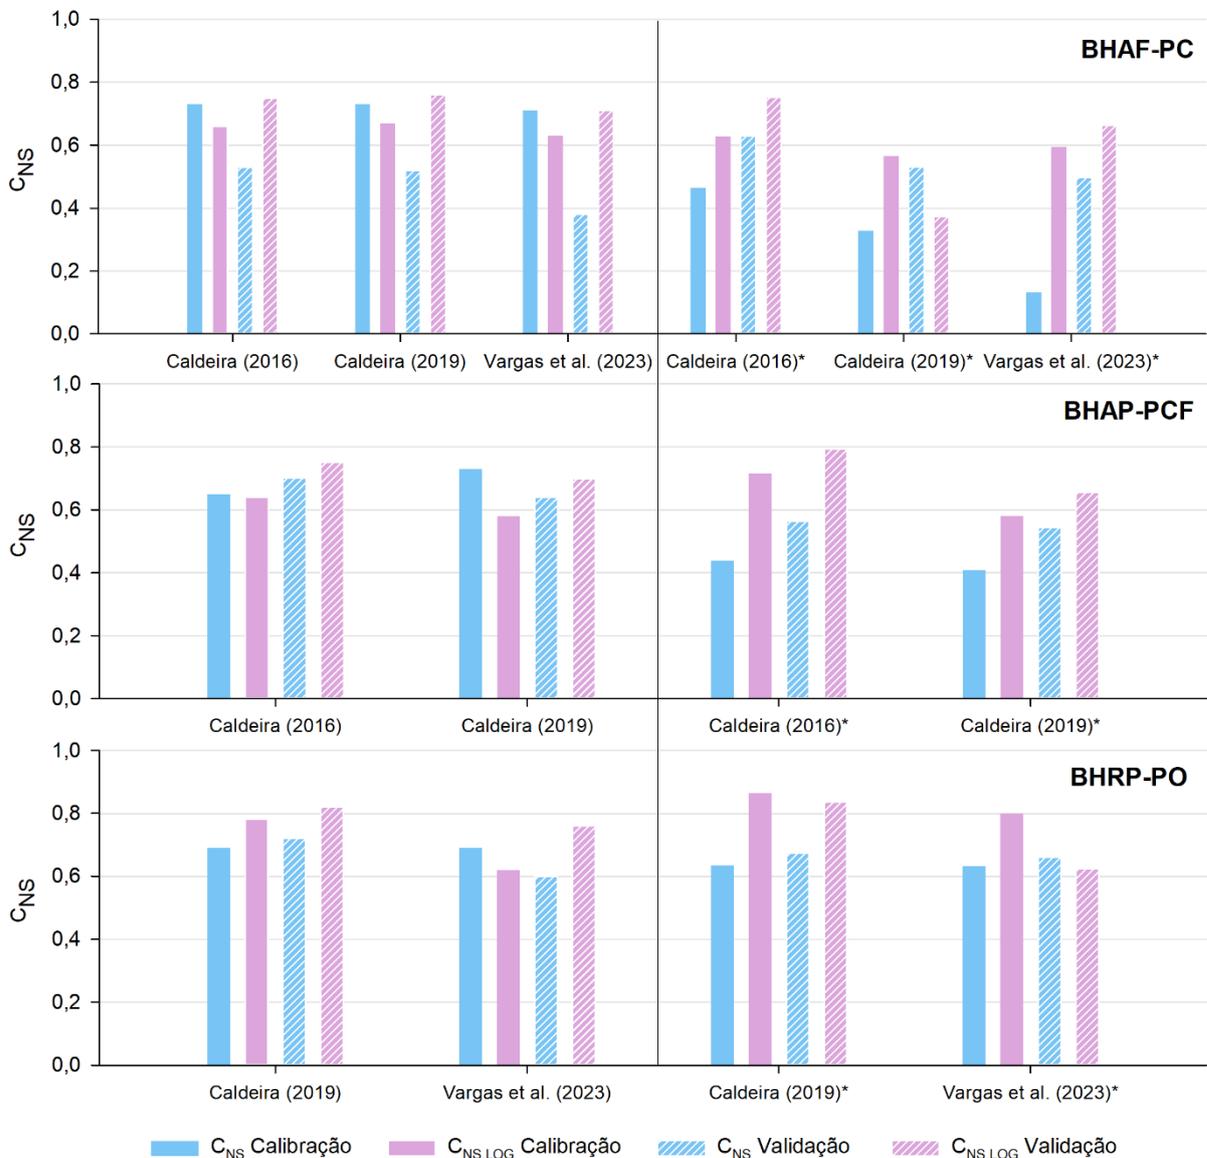
Para a BHAF-PC e a BHAP-PCF, observa-se que o melhor desempenho do modelo LASH foi no estudo de Caldeira (2016). Esse estudo apresenta algumas particularidades importantes, tais como: i. o uso de um recorte temporal consolidado, sem eventos atípicos de grandes magnitudes (seca severa e/ou enchente), como o evento observado em 2009, por exemplo; ii. um número mais elevado de sub-bacias - 23 (BHAF-PC) e 43 (BHAP-PCF); e iii. mapa de uso de solo anterior às grandes mudanças observadas na paisagem ao longo dos últimos anos. Neste contexto, entende-se que o modelo tem apresentado bom desempenho nos últimos estudos, uma vez que, mesmo com as alterações na paisagem, tem permitido estimar as vazões e, principalmente as curvas de permanência, de forma satisfatória.

Os parâmetros estimados para a BHRP-PO (Tabela 15, Tabela 21) apresentam valores divergentes aos obtidos por Caldeira (2019) e Vargas et al. (2023). Entretanto, vale destacar que ambos os estudos utilizaram a mesma base de dados e apresentaram parâmetros divergentes frente à calibração com diferentes algoritmos – SCE-UA e AMALGAM, respectivamente. O desempenho do R-LASH foi superior aos estudos anteriores, o que pode ter relação com o maior detalhamento do uso do solo na modelagem, sendo a BHRP-PO, entre as três bacias hidrográficas, a que mais apresentou mudanças ao longo dos últimos anos.

Conforme mencionado anteriormente, os parâmetros estimados no âmbito da calibração do modelo estão diretamente relacionados às condicionantes de entrada. Exemplo disso é observado quando da aplicação dos parâmetros estimados nos

trabalhos anteriores (Tabela 25) em conjunto com a base de dados elaborada no presente estudo (Figura 64).

É possível observar que há redução nos valores de C_{NS} , para todas as bacias hidrográficas. Caldeira (2016), Caldeira (2019) e Vargas (2023) obtiveram $C_{NS} > 0,70$ para a BHAF-PC e $C_{NS} > 0,65$ para a BHAP-PCF e a BHRP-PO, ou seja, desempenho entre bom e muito bom. Contudo, ao aplicar os parâmetros estimados pelos autores, obteve-se C_{NS} inferior a 0,50 para a BHAF-PC e a BHAP-PCF. Para a BHRP-PO, houve menor variação nos valores de C_{NS} aplicados à base de dados desse estudo. Em relação ao C_{NS-LOG} , há pequena redução nos valores da BHAF-PC e aumento dos valores da BHAP-PCF e BHRP-PO.



* Resultados obtidos a partir da aplicação dos parâmetros estimados pelos autores na base de dados deste estudo.

Figura 64 – Valores de C_{NS} e C_{NS-LOG} obtidos a partir dos parâmetros do modelo LASH estimados nos estudos anteriores.

Em trabalhos aplicando o modelo LASH em bacias hidrográficas de maior porte, tem-se observado desempenho superior aos obtidos para as bacias hidrográficas analisadas. Vargas et al. (2023) aplicaram o M-LASH na bacia hidrográfica do rio Camaquã, com área de 15.571 km² (59 sub-bacias: 0,23 km² a 1.088,00 km²), e obtiveram valores de C_{NS} e de C_{NS-LOG} superiores a 0,70, bem como $|P_{BIAS}| < 10\%$, utilizando os algoritmos SCE-UA e AMALGAM, tanto para o período de calibração quanto de validação.

Cunha et al. (2023) avaliaram o desempenho do M-LASH na bacia hidrográfica do rio Xingu, com exutório na estação de Altamira, totalizando uma área de drenagem de 448.022,80 km² (91 sub-bacias: 264 km² a 15.869,30 km²). Os autores consideraram o período de 1996 a 2000 para calibração, e de 2001 a 2005 para validação. As estatísticas de desempenho do modelo para o período de calibração foram excelentes, sendo C_{NS} igual a 0,93 e C_{NS-LOG} de 0,96 ($P_{BIAS} = 0,42\%$), as quais caíram para C_{NS} igual a 0,85 e C_{NS-LOG} de 0,66 ($P_{BIAS} = 16,06\%$). Importante mencionar que, apesar da redução dos valores das estatísticas, os resultados para o período de calibração são elevados.

Tanto no trabalho de Vargas et al. (2023) quanto de Cunha et al. (2023) observa-se que as sub-bacias definidas apresentam área de drenagem superior às das sub-bacias deste estudo: BHAF-PC (21 sub-bacias: 0,45 km² a 19,23 km²); BHAP-PCF (31 sub-bacias: 0,36 km³ a 39,38 km²) e BHRP-PO (43 sub-bacias: 1,51 km² a 293,87 km²). Além disso, em ambos os estudos o método de propagação em rios ser utilizado no modelo LASH, visto que o tempo de resposta médio das sub-bacias é superior ao passo de tempo diário.

5 CONCLUSÕES

O modelo LASH foi adaptado para a linguagem R, passando a ser denominado R-LASH. Dentre as principais vantagens do R-LASH, verifica-se: i. disponibilidade do modelo e de todo seu ferramental em código de linguagem aberta; e ii. acoplamento de algoritmos multiobjetivos que ainda não haviam sido avaliados à rotina do modelo.

As melhorias implementadas no código do módulo ArcLASH facilitam o tratamento das informações espaciais necessárias no modelo LASH, bem como garantem padronização na organização dos dados. Apesar de a etapa de atualização do módulo ArcLASH ter ocorrido em conjunto com o desenvolvimento do R-LASH, destaca-se que o mesmo é destinado à preparação das bases de entrada do modelo de forma genérica e, pode ser utilizado com outras versões do modelo LASH, como por exemplo o M-LASH.

A construção de uma base de dados mais dinâmica, em termos de variação dos usos do solo, permitiu a representação dos processos hidrológicos de maneira adequada. Os testes realizados nas bacias hidrográficas selecionadas apresentaram bom resultados e tendem a ser ampliados, principalmente em termos de análise dos parâmetros iniciais de cada algoritmo implementado no módulo de calibração.

Neste contexto, pode-se concluir que os resultados da implementação do R-LASH facilitam a atualização e ampliação do *script*, em um código de fácil manuseio, sendo este o grande gargalo da implementação do modelo LASH em linguagem interpretada.

6 CONSIDERAÇÕES FINAIS

O R-LASH consolida-se como ferramenta potencializadora para divulgação e aplicação do modelo LASH em diferentes locais e esferas da sociedade. Os bons resultados de calibração e validação em bacias hidrográficas distintas fazem do LASH um candidato à solução de diversos problemas e de gargalos técnico-científicos, tais como: composição de sistemas de controle e previsão de cheias, previsão de vazões para o setor elétrico, modelagem de vazões com representação da dinâmica espaço-temporal dos usos do solo, entre outros.

Frente aos resultados apresentados, compreende-se que o R-LASH deve passar para a fase de testes e aplicações mais complexos, com análises envolvendo os parâmetros de inicialização dos algoritmos e mais etapas de comparação entre as bacias hidrográficas e entre os algoritmos.

Acerca do módulo ArcLASH, são elencadas como potenciais melhorias:

- i. Disponibilização de uma versão para processamento no software QGIS, em código aberto e que possibilitaria a utilização de ferramentas e pacotes em linguagem Python diferentes do ArcPy.
- ii. Acoplamento de uma interface que possibilitasse a interação do usuário com a ferramenta, principalmente na etapa de subdivisão da bacia hidrográfica (e.g. ArcSWAT).
- iii. Implementação de ferramentas e processamento de informações dos canais de propagação a serem definidos no modelo.
- iv. Implementar a elaboração de Unidades de Resposta Hidrológica para aplicação no modelo em versão semidistribuída por HRU.

Cabe destacar que a proposta do ArcLASH, até o presente momento, não é servir de interface gráfica para o modelo LASH, e sim como um módulo para preparação da base de dados espaciais. As potenciais melhorias foram propostas no intuito de permitir a interação do usuário com o módulo durante a definição dos limiares de divisão, etapa anterior ao processamento mais robusto realizado pela ferramenta.

Em relação ao processamento de informações a serem utilizadas no módulo de propagação do modelo LASH, faz-se necessárias algumas investigações técnicas

para verificais ferramentas disponíveis. A implementação do módulo em ambiente aberto (QGIS) ampliará as possibilidades acerca da inserção desta etapa de tratamento de dados no módulo ArcLASH.

Sobre o R-LASH, propõe-se como potenciais melhorias:

- i. Estudo de alternativas de paralelização do módulo de calibração, para otimização do tempo de processamento, semelhante ao idealizado por Vargas (2021) no M-LASH.
- ii. Investigação dos parâmetros-ótimos de inicialização dos algoritmos, permitindo a manutenção destes no código do R-LASH e promovendo otimização do modelo em termos de calibração.
- iii. Acoplamento de diferentes métodos de propagação em canais no modelo, possibilitando contornar as limitações inerentes aos modelos teóricos disponíveis na literatura.
- iv. Adaptação da rotina para simulação em HRUs.

Sabe-se que a inserção do modelo LASH em linguagem de código aberto, como R por exemplo, facilita a atualização do código e implementação de ferramentas e pacotes que vão sendo disponibilizados. Desta forma, entende-se que vencida a etapa de implementação do R-LASH, tem início a etapa de aprimoramentos, os quais podem compreender inicialmente as potenciais melhorias elencadas, bem como pontos de atenção que venham a ser identificados com a aplicação do modelo em diferentes bacias hidrográficas.

REFERÊNCIAS

AHN, S. R.; JEONG, J. H.; KIM, S. J. Assessing drought threats to agricultural water supplies under climate change by combining the SWAT and MODSIM models for the Geum River basin, South Korea. **Hydrological Sciences Journal**, v. 61, n. 15, p. 2740-2753, 2016. DOI: <https://doi.org/10.1080/02626667.2015.1112905>

AKHTAR, M.; AHMAD, N.; BOOIJ, M. J. The impact of climate change on the water resources of Hindukush-Karakorum-Himalaya region under different glacier coverage scenarios. **Journal of Hydrology**, v. 355, p. 148–163, 2008. DOI: <https://doi.org/10.1016/j.jhydrol.2008.03.015>

ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. Crop evapotranspiration - Guidelines for computing crop water requirements - FAO **Irrigation and drainage paper 56**. Rome: FAO, 1998. 300 p.

ALMEIDA, L.; SERRA, J. C. V. Modelos hidrológicos, tipos e aplicações mais utilizadas. **Revista da FAE**, v. 20, n. 1, p. 129- 137, 2017.

ALVAREZ-BENITEZ, J. E.; EVERSON, R. M.; FIELDSEND, J. E. A MOPSO algorithm based exclusively on pareto dominance concepts. In: **Evolutionary Multi-Criterion Optimization: Third International Conference**, Guanajuato, Mexico, March 9-11, 2005. Proceedings 3. Springer Berlin Heidelberg, p. 459-473, 2005.

ANA – AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO. **Estudos de análise de consistência de dados fluviométricos de estações de Monitoramento da ANA em operação nas bacias hidrográficas selecionadas**. Agência Nacional de Águas e Saneamento Básico. Brasília: ANA, 2020. 64 p.

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: <https://doi.org/10.1016/j.envsoft.2006.10.006>

ANDREWS, F. T.; CROKE, B. F. W.; JAKEMAN, A. J. An open software environment for hydrological model assessment and development. **Environmental Modelling & Software**, v. 26, n. 10, p. 1171-1185, 2011. DOI: <https://doi.org/10.1016/j.envsoft.2011.04.006>

AQUINO, L. S. **Modelagem hidrológica na região sul do Rio Grande do Sul utilizando os modelos SWAT e LASH**. Tese (Doutorado em Agronomia). Universidade Federal de Pelotas. Pelotas, p. 101. 2014.

ARAÚJO, A. S. **Calibração multiobjetivo de modelos hidrológico e de superfície atmosférico**. 121f. 2014. Tese (Doutorado do Curso de Pós-Graduação em Computação Aplicada). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 121f. 2014.

ARNOLD, J. G.; SRINIVASAN, R.; MUTTIAH, R. S.; WILLIAMS, J. R. Large area hydrologic modeling and assessment part I: model development. **Journal of the**

American Water Resources Association, v. 34, n. 1, p. 73–89, 1998. DOI: <https://doi.org/10.1111/j.1752-1688.1998.tb05961.x>

ASTAGNEAU, P. C.; THIREL, G.; DELAIGUE, O.; GUILLAUME, J. H.; PARAJKA, J.; BRAUER, C. C.; VIGLIONE, A.; BUYTAERT, W.; BEVEN, K. J. Hydrology modelling R packages—a unified analysis of models and practicalities from a user perspective. **Hydrology and Earth System Sciences**, v. 25, n. 7, p. 3937-3973, 2021. DOI: <https://doi.org/10.5194/hess-25-3937-2021>

AUBERT, D.; LOUMAGNE, C.; OUDIN, L. Sequential assimilation of soil moisture and streamflow data in a conceptual rainfall–runoff model. **Journal of Hydrology**, v. 280, p. 145–161, 2003. DOI: [https://doi.org/10.1016/S0022-1694\(03\)00229-4](https://doi.org/10.1016/S0022-1694(03)00229-4)

BAI, J.; MU, R.; YAN, B.; GUO, J. Application of Soil Moisture Data Assimilation in Flood Forecasting of Xun River in Hanjiang River Basin. **Water**, v. 14, n. 24, p. 4061, 2022. DOI: <https://doi.org/10.3390/w14244061>

BALAG, H. N. K.; MOUSAVI, S. Optimizing Low Impact Development (LID) Methods in Urban Runoff Quantitative and Qualitative Control with Considering the Effects of Climate Change Using Multi-Objective Optimization Algorithms. **Irrigation and Water Engineering**, v. 13, n. 1, p. 440-464, 2022.

BALBINO, R. O.; KALINKE, M. A.; ZATTI, E. A.; MATTOS, S. G.; LOSS, T.; MOTTA, M. S. Programação Intuitiva: em Busca de Compreensões Intuitive Programming: in Search of Understandings. **Perspectivas da Educação Matemática**, v. 14, n. 36, p. 1-22, 2021.

BAPTISTA, M.; CARDOSO, A. Rios e cidades: uma longa e sinuosa história... **Revista UFMG**, v. 20, n.2, p. 124-153, 2013. DOI: <https://doi.org/10.35699/2316-770X.2013.2693>

BARROS, C. A. P. **Dinâmica dos escoamentos na modelagem da produção de sedimentos em uma pequena bacia rural**. 2016. 197 f. Tese (Doutorado em Agronomia) - Universidade Federal de Santa Maria, Santa Maria, 2016.

BATHURST, J. C.; BIRKINSHAW, S. J.; CISNEROS, F.; FALLAS, J.; IROUMÉ, A.; ITURRASPE, R.; NOVILLO, M. G.; URCIUOLO, A.; ALVARADO, A.; COELLO, C.; HUBER, A.; MIRANDA, M.; RAMIREZ, M.; SARANDÓN, R. 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: <https://doi.org/10.1016/j.jhydrol.2010.09.001>

BERGER, R.; SILVA, J. A. A. D.; FERREIRA, R. L. C.; CANDEIAS, A. L. B.; RUBILAR, R. 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: <https://doi.org/10.5902/1980509816942>

BERGSTRÖM S, FORSMAN A. Development of a conceptual deterministic rainfall-runoff model. *Nordic Hydrology*, v. 4, n. 3, p. 147– 170, 1973.

BERNARDO, S.; SOARES, A. A.; MANTOVANI, E. C. **Manual de irrigação**. 7^a. ed. Viçosa: UFV, 2005. 596 p. ISBN 8572692428.

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

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

BESKOW, S.; MELLO, C. R.; NORTON, L. D.; DA SILVA, A. M. Performance of a distributed semi-conceptual hydrological model under tropical watershed conditions. **Catena**, v.86, n. 3, p. 160–171, 2011. DOI: <https://doi.org/10.1016/j.catena.2011.03.010>

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, n. 2, p. 341–363, 2013. DOI: <https://doi.org/10.1007/s11269-012-0189-8>

BESKOW, S.; TIMM, L. C.; TAVARES, V. E. Q.; CALDEIRA, T. L.; AQUINO, L. S. 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, n. 14, p. 2567-2578, 2016. DOI: <https://doi.org/10.1080/02626667.2015.1133912>

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: <https://doi.org/10.1080/02626667909491834>

BOEIRA, L. S.; COLLARES, G. L.; SANTOS, G. B.; POSSA, T. M.; TERRA, V. S. S. Influence of Multiple Water Uses on an Important Cross-border Watershed in South America. **Research Square**, p. 01-17, 2023. DOI: <https://doi.org/10.21203/rs.3.rs-2511403/v1>

BOOIJ, M. J.; KROL, M. S. Balance between calibration objectives in a conceptual hydrological model. **Hydrological Sciences Journal**, v. 55, n. 6, p. 1017–1032, 2010. DOI: <https://doi.org/10.1080/02626667.2010.505892>

BOX, G. E. P.; PIERCE, D. A. Distribution of Residual Autocorrelations in Autoregressive-Integrated Moving Average Time Series Models. **Journal of the American Statistical Association**, v. 65, n. 332, p. 1509-1526, 1970. DOI: <https://doi.org/10.2307/2284333>

BRASIL. **Política Nacional de Recursos Hídricos**. Lei Nº 9.433, de 8 de janeiro de 1997.

BRENDEL, C. E.; DYMOND, R. L.; AGUILAR, M. F. An interactive web app for retrieval, visualization, and analysis of hydrologic and meteorological time series data.

Environmental Modelling & Software, v. 117, p. 14-28, 2019. DOI: <https://doi.org/10.1016/j.envsoft.2019.03.003>

BURNASH, R. J. C. The NWS River Forecast System: catchment modeling. In: SINGH, V. P. (Ed.). *Computer models of watershed hydrology*. Highlands Ranch, Colorado: Water Resources Publications, 1995. p. 311-366.

BUYTAERT, W. **topmodel: Implementation of the Hydrological Model TOPMODEL in R**. 2012. Disponível em <<https://cran.r-project.org/web/packages/topmodel/index.html>>. Acesso em 24 de março de 2023.

CALDEIRA, T. L. **Aprimoramento computacional do modelo Lavras Simulation of Hydrology (LASH): aplicação em duas bacias do Rio Grande do Sul**. 2016. 213f. Dissertação (Mestrado em Recursos Hídricos) – Programa de Pós-Graduação em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, Pelotas, 2016.

CALDEIRA, T. L.; MELLO, C. R.; BESKOW, S.; TIMM, L. C.; VIOLA, M. R. LASH hydrological model: An analysis focused on spatial discretization. **Catena**, v. 173, p. 183–193, 2019. DOI: <https://doi.org/10.1016/j.catena.2018.10.009>

CARVALHO, V. S. O.; CUNHA, Z. A.; ALVARENGA, L. A.; BESKOW, S.; MELLO, C. R.; MARTINS, M. A.; OLIVEIRA, C. M. M. Assessment of land use changes in the Verde River basin using two hydrological models. **Journal of South American Earth Sciences**, v. 118, p. 103954, 2022. DOI: <https://doi.org/10.1016/j.jsames.2022.103954>

CHING-SHIH TSOU. **nsga2R: Elitist Non-Dominated Sorting Genetic Algorithm**. 2022. Disponível em <<https://cran.r-project.org/package=nsga2R>>. Acesso em 23 de março de 2023.

CHOW, V. T. Hydrologic determination of waterway areas for the design of drainage structures in small drainage basins. **Engineering Experiment Station Bulletin n.462**. Urbana, Ill.:University of Illinois College of Engineering, 104 p., 1962.

CLOKE, H. L.; PAPPENBERGER, F. Ensemble flood forecasting: A review. **Journal of Hydrology**, v. 375, n. 3–4, p. 613-626, 2009. DOI: <https://doi.org/10.1016/j.jhydrol.2009.06.005>

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. IEEE, v. 2, p. 1051-1056, 2002.

COLLENTEUR, R.; VREMEC, M.; BRUNETTI, G. Interfacing FORTAN Code with Python: an example for the Hydrus-1D model, **EGU General Assembly**, EGU2020-15377, 2020. DOI: <https://doi.org/10.5194/egusphere-egu2020-15377>

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

COLLISCHONN, W.; ALLASIA, D.; DA SILVA, B. C.; TUCCI, C. E. The MGB-IPH model for large-scale rainfall—runoff modelling. **Hydrological Sciences Journal**, v. 52, n. 5, p. 878-895, 2007. DOI: <https://doi.org/10.1623/hysj.52.5.878>

CONFESOR JR., R. B.; WHITTAKER, G. W. Automatic Calibration of Hydrologic Models With Multi-Objective Evolutionary Algorithm and Pareto Optimization. **Journal of the American Water Resources Association**, v. 43, n. 4, p. 981-989, 2007. DOI: <https://doi.org/10.1111/j.1752-1688.2007.00080.x>

CORADI, P. C.; PEREIRA-RAMIREZ, O.; FIA, R.; MATOS, A. T. Qualidade de água superficial da Bacia Hidrográfica da Lagoa Mirim. **Revista de Ciências Ambientais**, v. 3, p. 53-64, 2009.

CORON, L.; DELAIGUE, O.; THIREL, G.; DORCHIES, D.; PERRIN, C.; MICHEL, C.; ANDRÉASSIAN, V.; BOURGIN, F.; BRIGODE, P.; LE MOINE, N.; MATHEVET, T.; MOUELHI, S.; OUDIN, L.; PUSHPALATHA, R.; VALÉRY, A. **airGR: Suite of GR Hydrological Models for Precipitation-Runoff Modelling**, 2023. Disponível em <<https://cran.r-project.org/package=airGR>>. Acesso em 27 de março de 2023.

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.

CUNHA, N. G.; SILVEIRA, R. J. C. **Estudo dos solos do município de Capão do Leão**. Pelotas: EMBRAPA/CPACT, 1996a. 54 p.

CUNHA, N. G.; SILVEIRA, R. J. C. **Estudo dos solos do município de Pelotas**. Pelotas: EMBRAPA/CPACT, 1996b. 50 p.

CUNHA, N. G.; SILVEIRA, R. J. C. **Geomorfologia, Solos e Capacidade de Uso das Terras do município de Pedro Osório**. Pelotas: EMBRAPA/CPACT, 1996c. 54 p.

CUNHA, N. G.; SILVEIRA, R. J. C.; SEVERO, C. R. S. **Estudo dos solos do município de Herval**. Pelotas: EMBRAPA/CPACT, 1996a. 45 p.

CUNHA, N. G.; SILVEIRA, R. J. C.; SEVERO, C. R. S. **Estudo dos solos do município de Arroio Grande**. Pelotas: EMBRAPA/CPACT, 1996b. 105 p.

CUNHA, N. G.; SILVEIRA, R. J. C.; SEVERO, C. R. S.; NUNES, M. L.; SOARES, M. J.; COSTA, C. N. **Estudo dos solos do município de Canguçu**. Pelotas: EMBRAPA-CPACT, 1997a. 86 p.

CUNHA, N. G.; SILVEIRA, R. J. C.; SEVERO, C. R. S.; NUNES, M. L.; COSTA, F. A.; SOARES, M. J.; COSTA, C. N. **Estudo dos solos do município de Piratini**. Pelotas: EMBRAPA/CPACT, 1997b. 91 p.

CUNHA, N. G.; SILVEIRA, R. J. C.; SEVERO, C. R. S.; SOARES, M. J.; SANTOS, C. N.; FONTOURA JÚNIOR, E. R.; VIEIRA, C. R. S. **Estudo dos solos do município de Pinheiro Machado**. Pelotas: EMBRAPA/CPACT, 1998. 80 p.

CUNHA, N.G.; SILVEIRA, R.J.C.; SEVERO, C.R.S. **Solos e terras do planalto Sul-Rio-Grandense e planícies costeiras**. Pelotas: Embrapa Clima Temperado, 2006. 42 p. (Embrapa Clima Temperado. Circular técnica, 55).

CUNHA, Z. A. **Simulação hidrológica na bacia hidrográfica do Rio Xingu**. 2021. 129f. Dissertação (Mestrado em Recursos Hídricos) - Programa de Pós-Graduação em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, Pelotas, 2021.

ZANDRA A. CUNHA, Z. A. MELLO, C. R.; BESKOW, S.; VARGAS, M. M.; GUZMAN, J. A.; MOURA, M. M. A Modeling Approach for Analyzing the Hydrological Impacts of the Agribusiness Land-Use Scenarios in an Amazon Basin. **Land**, v. 12, p. 1422, 2023. DOI: <https://doi.org/10.3390/land12071422>

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: [https://doi.org/10.1002/\(SICI\)1099-1085\(199608\)10:8%3C1107::AID-HYP415%3E3.0.CO;2-4](https://doi.org/10.1002/(SICI)1099-1085(199608)10:8%3C1107::AID-HYP415%3E3.0.CO;2-4)

DEB, K.; PRATAP, A.; AGARWAL, S.; MEYARIVAN, T. A. M. T. A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II. **IEEE Transactions on Evolutionary Computation**, v. 6, n. 2, p. 182-197, 2002. DOI: <https://doi.org/10.1109/4235.996017>

DICKINSON, R. E. Modeling evapotranspiration for three-dimensional global climate models. In: **Climate processes and climate sensitivity**. Washington: AGU, v. 29, p. 58-72, 1984 (Moogr. Series: AGU).

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: <https://doi.org/10.1029/91WR02985>

DUAN, Q.; SOROOSHIAN, S.; GUPTA, V. K. 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: [https://doi.org/10.1016/0022-1694\(94\)90057-4](https://doi.org/10.1016/0022-1694(94)90057-4)

ENGELAND, K.; HISDAL, H. A Comparison of Low Flow Estimates in Ungauged Catchments Using Regional Regression and the HBV-Model. **Water Resources Management**, v. 23, n. 12, p. 2567-2586, 2009. DOI: <https://doi.org/10.1007/s11269-008-9397-7>

ERCAN, M. B.; GOODALL, J. L. Design and implementation of a general software library for using NSGA-II with SWAT for multi-objective model calibration. **Environmental Modelling & Software**, v. 84, p. 112-120, 2016. DOI: <https://doi.org/10.1016/j.envsoft.2016.06.017>

ESRI, ArcGIS DESKTOP 10.1. Redlands, CA: **Environmental Systems Research Institute**, Inc. (Esri), 2014. CD-ROM.

FAGUNDES, J. L.; FONSECA, D. M. D.; MISTURA, C.; MORAIS, R. V. D.; VITOR, C. M. T.; GOMIDE, J. A.; NASCIMENTO JR, D.; CASAGRANDE, D. R.; COSTA, L. T. D. Características morfológicas 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. DOI: <https://doi.org/10.1590/S1516-35982006000100003>

FAN, F. M.; COLLISCHONN, W.; QUIROZ, K. J.; SORRIBAS, M. V.; BUARQUE, D. C.; SIQUEIRA, V. A. Flood forecasting on the Tocantins River using ensemble rainfall forecasts and real-time satellite rainfall estimates. **Journal of Flood Risk Management**, v. 9, n. 3, p. 278-288, 2016. DOI: <https://doi.org/10.1111/jfr3.12177>

FARINOSI, F.; ARIAS, M. E.; LEE, E.; LONGO, M.; PEREIRA, F. F.; LIVINO, A.; MOORCROFT, P. R.; BRISCOE, J. Future climate and land use change impacts on river flows in the Tapajós Basin in the Brazilian Amazon. **Earth's Future**, v. 7, n. 8, p. 993-1017, 2019. DOI: <https://doi.org/10.1029/2019EF001198>

FUKA, D. R.; WALTER, M. T.; MACALISTER, C.; STEENHUIS, T. S.; EASTON, Z. M. SWAT model: A Multi-Operating System, Multi-Platform SWAT Model Package in R. **Journal of the American Water Resources Association**, v. 50, n. 5, p. 1349-1353, 2014. DOI: <https://doi.org/10.1111/jawr.12170>

GHUMMAN, A. R.; AHMAD, M. M.; HASHMI, H. N.; KAMAL, M. A. Regionalization of Hydrologic Parameters of Nash Mode. **Water Resources**, v. 38, n. 6, 2011, p. 735–744, 2011. DOI: <https://doi.org/10.1134/S0097807811060030>

GIANDOTTI, M. Previsione delle piene e delle magre dei corsi d'acqua. **Memorie e Studi Idrografici**, v. 8, p. 107–117, 1934.

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.

GOTARDO, R. A. **Linguagem de programação I**. Rio de Janeiro: SESES, 2015. 200 p. ISBN: 978-85-5548-155-0

GUIDOLIN, T. G. S. F. **Avaliação do período de aquecimento, calibração e validação do modelo SWAT na bacia hidrográfica do arroio Taboão (RS)**. Trabalho de conclusão de curso (Graduação) - Universidade Federal do Rio Grande do Sul, Instituto de Pesquisas Hidráulicas, Curso de Engenharia Hídrica, Porto Alegre, 2020.

GUILLAUME, J. **Hydromad: Hydrological Model Assessment and Development**. 2013. Disponível em <<https://hydromad.catchment.org/#sacramento>>. Acesso em 26 de março de 2023.

GUO, J.; ZHOU, J.; ZOU, Q.; LIU, Y.; SONG, L. A novel multi-objective shuffled complex differential evolution algorithm with application to hydrological model parameter optimization. **Water resources management**, v. 27, p. 2923-2946, 2013. DOI: <https://doi.org/10.1007/s11269-013-0324-1>

GUPTA, H. V.; KLING, H.; YILMAZ, K. K.; MARTINEZ, G. F. Decomposition of the mean squared error and nse performance criteria: implications for improving hydrological modelling. **Journal of Hydrology**, V. 377, N. 1-2, P. 80–91, 2009. DOI: <https://doi.org/10.1016/j.jhydrol.2009.08.003>

GUTIERREZ, J. C. T.; ADAMATTI, D. S.; BRAVO, J. M. A new stopping criterion for multi-objective evolutionary algorithms: application in the calibration of a hydrologic model. **Computational Geosciences**, v. 23, p. 1219-1235, 2019. DOI: <https://doi.org/10.1007/s10596-019-09870-3>

HASENACK, H. **Pampa – Appendix**. 2022. Disponível em <https://mapbiomas.org/colecoes-mapbiomas-1?cama_set_language=pt-BR>. Acesso em: 23 de dezembro de 2022.

HESSEL, R.; MESSING, I.; LIDING, C.; RITSEMA, C.; STOLTE, J. Soil erosion simulations of land use scenarios for a small Loess Plateau catchment. **Catena**, v. 54, n. 1-2, p. 289-302, 2003. DOI: [https://doi.org/10.1016/S0341-8162\(03\)00070-5](https://doi.org/10.1016/S0341-8162(03)00070-5)

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.

HUANG, XIAOMIN; LEI, XIAOHUI; JIANG, YUNZHONG. Comparison of three multi-objective optimization algorithms for hydrological model. In: **Computational Intelligence and Intelligent Systems: 6th International Symposium**, ISICA 2012, Wuhan, China, October 27-28, 2012. Proceedings. Springer Berlin Heidelberg, p. 209-216, 2012.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: **Proceedings of ICNN'95-international conference on neural networks**. IEEE, v. 4, p. 1942-1948, 1995.

KETABCHI, H.; ATAIE-ASHTIANI, B. Evolutionary algorithms for the optimal management of coastal groundwater: A comparative study toward future challenges. **Journal of Hydrology**, v. 520, p. 193–213, 2015. DOI: <https://doi.org/10.1016/j.jhydrol.2014.11.043>

KIRPICH, Z. P. Time of concentration of small agricultural watersheds. **Civil Engineering**, v. 10, n. 6, p. 362-, 1940.

KOUCHI, D. H.; ESMALI, K.; FARIDHOSSEINI, A.; SANAEINEJAD, S. H.; KHALILI, D.; ABBASPOUR, K. C. Sensitivity of calibrated parameters and water resource estimates on different objective functions and optimization algorithms. **Water**, v. 9, n. 6, p. 384, 2017. DOI: <https://doi.org/10.3390/w9060384>

KUMAR, A. Geomorphologic Instantaneous Unit Hydrograph Based Hydrologic Response Models for Ungauged Hilly Watersheds in India. **Water Resources**

Management, v. 29, p. 863–883, 2015. DOI: <https://doi.org/10.1007/s11269-014-0848-z>

KUMAR, B.; VENKATESH, M.; TRIPHATI, A.; ANSHUMALI. A GIS-based approach in drainage morphometric analysis of Rihand River Basin, Central India. **Sustainable Water Resources Management**, 2018. DOI: <https://doi.org/10.1007/s40899-017-0118-3>

LE MOINE, N. Le bassin versant de surface vu par le souterrain: une voie d'amélioration des performances et du réalisme des modèles pluie-débit. Ph.D. thesis - Université Pierre et Marie Curie, Paris, 2008. Disponível em: <https://webgr.irstea.fr/wp-content/uploads/2012/07/2008-LE_MOINE-THESE.pdf>. Acesso em 26 de abril de 2023.

LUCAS, L. M. **Mudanças ambientais na cobertura da terra e no sistema fluvial: bacia hidrográfica do rio Piratini, RS**. 2017. 306f. Tese (Doutorado em Geografia) – Universidade Federal Fluminense, Niterói, 2017.

LUCAS-BORJA, M. E.; CARRÀ, B. G.; NUNES, J. P.; BERNARD-JANNIN, L.; ZEMA, D. A.; ZIMBONE, S. M. Impacts of land-use and climate changes on surface runoff in a tropical forest watershed (Brazil). **Hydrological Sciences Journal**, v. 65, n. 11, p. 1956-1973, 2020. DOI: <https://doi.org/10.1080/02626667.2020.1787417>

MAPBIOMAS. **Coleção da Série Anual de Mapas da Cobertura e Uso do Solo do Brasil**. Disponível em <https://mapbiomas.org/colecoes-mapbiomas-1?cama_set_language=pt-BR>. Acesso em: 23 de dezembro de 2022.

MARTINS, C. M. S.; SILVA, B. C.; PONS, N. A. D. Estimativa de cheias em bacias hidrográficas com base em previsões de precipitação por conjunto. **Revista Brasileira de Geografia Física**, v. 12, n. 5, p. 1713-1729, 2019.

MARTINS, N.; LUIZ VIDAL, E.; TALLINE SILVA DE CRISTO, N.; VIEIRA DE MELLO, A. Comparativo de linguagens de programação. Anais do Salão Internacional de Ensino, Pesquisa e Extensão, v. 8, n. 2, 2020.

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

MELLO, C. R.; NORTON, L. D.; PINTO, L. C.; BESKOW, S.; CURI, N. Agricultural watershed modeling: a review for hydrology and soil erosion processes. **Ciência e Agrotecnologia**, v. 40, n. 1, p. 7-25, 2016. DOI: <http://dx.doi.org/10.1590/S1413-70542016000100001>

MELLO, C. R.; VIEIRA, N. P.; GUZMAN, J. A.; VIOLA, M. R.; BESKOW, S.; ALVARENGA, L. A. Climate change impacts on water resources of the largest hydropower plant reservoir in Southeast Brazil. **Water**, v. 13, n. 11, p. 1560, 2021. DOI: <https://doi.org/10.3390/w13111560>

MELLO, C. R.; VIOLA, M. R.; NORTON, L. D.; SILVA, A. M.; WEIMAR, F. A. Development and application of a simple hydrologic model simulation for a Brazilian

headwater basin. **Catena**, v. 75, n. 3, p. 235-247, 2008. DOI: <https://doi.org/10.1016/j.catena.2008.07.002>

MENDEZ, M.; CALVO-VALVERDE, L. Development of the HBV-TEC hydrological model. **Procedia Engineering**, v. 154, p. 1116-1123, 2016. DOI: <https://doi.org/10.1016/j.proeng.2016.07.521>

METCALFE, P.; BEVEN, K.; FREER, J. Dynamic TOPMODEL: A new implementation in R and its sensitivity to time and space steps. **Environmental Modelling & Software**, v. 72, p. 155-172, 2015. DOI: <http://dx.doi.org/10.1016/j.envsoft.2015.06.010>

MIRANDA, A.; MIRANDA, H.; GRACE, J.; MEIR, P.; LLOYD, J. 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.

MIRANDA, R. A. C.; OLIVEIRA, M. V. S.; SILVA, D. F. D. Ciclo hidrológico planetário: abordagens e Conceitos. *Geo UERJ*, v. 1, n. 21, p. 109-119, 2010.

MISHRA, A.; FROEBRICH, J.; GASSMAN, P. W. Evaluation of the SWAT model for assessing sediment control structures in a small watershed in India. **Transactions of the ASABE**, v. 50, n. 2, p. 469-477, 2007.

MISHRA, S. K.; SAHU, R. K.; ELDHO, T. I.; JAIN, M. K. An Improved I a S Relation Incorporating Antecedent Moisture in SCS-CN Methodology. **Water Resources Management**, v. 20, n. 5, p. 643-660, 2006. DOI: <https://doi.org/10.1007/s11269-005-9000-4>

MORAES, J. M. Propriedades físicas dos solos na parametrização de um modelo hidrológico. **Revista Brasileira de Recursos Hídricos**, v. 8, n. 1, p. 61-70, 2003.

MORIASI, D. N.; ARNOLD, J. G.; VAN LIEW, M. W.; BINGNER, R. L.; HARMEL, R. D.; VEITH, T. L. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. **Transactions of the ASABE**, v. 50, n. 3, p. 885-900, 2007.

NAEINI, M. R.; ANALUI, B.; GUPTA, H. V.; DUAN, Q.; SOROOSHIAN, S. 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: <https://doi.org/10.24200/sci.2019.21500>

NAMETALA, C. L.; NUNES, G.; AMARAL, P. Análise comparativa de tempos de execução de código R interpretado e compilado em Sistemas Windows e Linux. **Revista do Seminário Internacional de Estatística com R**, v. 3, n. 1, p. 1-13, 2018.

NASCIMENTO, L. S. V.; REIS JÚNIOR, D. S.; MARTINS, E. S. P. R. Avaliação do algoritmo evolutivo MOPSO na calibração multiobjetivo do modelo SMAP no estado do Ceará. **Revista Brasileira de Recursos Hídricos**, v.14, n.1., p. 85-97, 2009.

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: [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/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: <https://doi.org/10.1093/comjnl/7.4.308>

NGUYEN, T. V.; DIETRICH, J.; DANG, D. T.; TRAN, D. A.; DOAN, B. V.; SARRAZIN, F. J.; ABBASPOUR, K.; SRINIVASAN, R. An interactive graphical interface tool for parameter calibration, sensitivity analysis, uncertainty analysis, and visualization for the Soil and Water Assessment Tool. **Environmental Modelling & Software**, v. 156, p. 105497, 2022. DOI: <https://doi.org/10.1016/j.envsoft.2022.105497>

NOTTER, B.; MACMILLAN, L.; VIVIROLI, D.; WEINGARTNER, R.; LINIGER, H. P. Impacts of environmental change on water resources in th Mt. Kenya Region. **Journal of Hydrology**, v. 343, p. 266-278, 2007. DOI: <https://doi.org/10.1016/j.jhydrol.2007.06.022>

OLIVEIRA, C. M. M.; ALVARENGA, L. A.; BESKOW, S.; CUNHA, Z. A.; VARGAS, M. M.; MELO, P. A.; TOMASELLA, J.; SANTOS, A. C. N.; CARVALHO, V. S.; SILVA, V. O. Hydrological Model Performance in the Verde River Basin, Minas Gerais, Brazil. **Resources**, v. 12, n. 8, p. 87, 2023. DOI: <https://doi.org/10.3390/resources12080087>

OLIVEIRA, V. A.; MELLO, C. R.; VIOLA, M. R.; SRINIVASAN, R. Assessment of climate change impacts on streamflow and hydropower potential in the headwater region of the Grande river basin, Southeastern Brazil. **International Journal of Climatology**, v. 37, n. 15, p. 5005-5023, 2017. DOI: <https://doi.org/10.1002/joc.5138>

OTTONI, M. V.; OTTONI FILHO, T. B.; SCHAAP, M.; LOPES-ASSAD, M. L. R. C.; ROTUNNO FILHO, O. C. Hydrophysical database for Brazilian soils (HYBRAS) and pedotransfer functions for water retention. **Vadose Zone Journal**, v.17, n.1, 170095, 2018. <https://doi.org/10.2136/vzj2017.05.0095>

PAILLARD, G. A. L.; MOREIRA, L. O. O impacto dos paradigmas e linguagens de programação no ensino intermediário da programação de computadores. **Revista Tecnologias na Educação**, v. 19, p. 1-17, 2017.

PAIVA, R. **Método de propagação baseado na Onda Cinemática**. 2007.

PARK, S.; NIELSEN, A.; BAILEY, R. T.; TROLLE, D.; BIEGER, K. A QGIS-based graphical user interface for application and evaluation of SWAT-MODFLOW models. **Environmental Modelling & Software**, v. 111, p. 493-497, 2019. DOI: <https://doi.org/10.1016/j.envsoft.2018.10.017>

PARSOPOULOS, K. E.; VRAHATIS, M. N. Multi-objective particles swarm optimization approaches. In: **Multi-objective optimization in computational intelligence: Theory and practice**. IGI global, p. 20-42, 2008.

PERRIN, C.; MICHEL, C.; ANDRÉASSIAN, V. Improvement of a parsimonious model for streamflow simulation. **Journal of Hydrology**, v. 279, n. 1-4, p. 275-289, 2003. DOI: [https://doi.org/10.1016/S0022-1694\(03\)00225-7](https://doi.org/10.1016/S0022-1694(03)00225-7)

PETSCH, C.; MONTEIRO, J. B.; BUENO, M. B. Análise comparativa da acuracidade da rede de drenagem gerada automaticamente e extraída de carta topográfica: Estudo de caso no Município de Ponta Grossa – PR. **Revista Geonorte**, v. 2, n. 4, p.1195–1205, 2012.

PONTES, P. R. M.; FAN, F. M.; FLEISCHMANN, A. S.; DE PAIVA, R. C. D.; BUARQUE, D. C.; SIQUEIRA, V. A.; JARDIM, P. F.; SORRIBAS, M. V.; COLLISCHONN, W. MGB-IPH model for hydrological and hydraulic simulation of large floodplain river systems coupled with open source GIS. **Environmental Modelling & Software**, v. 94, p. 1-20, 2017. DOI: <https://doi.org/10.1016/j.envsoft.2017.03.029>

POSSA, T. M.; COLLARES, G. L.; BOEIRA, L. S.; JARDIM, P. F.; FAN, F. M.; TERRA, V. S. S. Fully coupled hydrological–hydrodynamic modeling of a basin–river–lake transboundary system in Southern South America. **Journal of Hydroinformatics**, v. 24, n. 1, p. 93-112, 2022. DOI: <https://doi.org/10.2166/hydro.2021.096>

PRASAD, P. R.; REDDY, N. L. K.; PRASAD, N. V. B. S. S.; RAJU, D. N. Integrated water resources assessment and management in a small watershed – a geomorphic approach. **Hydrology Research**, v. 46, n. 2, p. 180-191, 2015. DOI: <https://doi.org/10.2166/nh.2013.105>

PROS NAVAL. **MOPSOCD: Multi-objective Particle Swarm Optimization with Crowding Distance**. 2023. Disponível em <<https://cran.r-project.org/package=mopsocd>>. Acesso em 27 de março de 2023.

PUSHPALATHA, R.; PERRIN, C.; LE MOINE, N.; MATHEVET, T.; ANDRÉASSIAN, V. A downward structural sensitivity analysis of hydrological models to improve low-flow simulation. **Journal of Hydrology**, v. 411, n. 1-2, p. 66-76, 2011. DOI: <https://doi.org/10.1016/j.jhydrol.2011.09.034>

RACINE, J. S. RStudio: a platform-independent IDE for R and Sweave. **Journal of Applied Econometrics**, v. 27, p. 167-172, 2012.

RAWLS, W. J.; AHUJA, L. R.; BRAKENSIE, D. L.; SHIRMOHAMMADI, A. 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.

REED, H. M.; NICHOLS, J. M.; EARLS, C. J. A modified differential evolution algorithm for damage identification in submerged shell structures. **Mechanical Systems and Signal Processing**, v. 39, n. 1-2, p. 396–408, 2013. DOI: <https://doi.org/10.1016/j.ymssp.2013.02.018>

REICHARDT, K. **A água em sistemas agrícolas**. São Paulo: Manole, 1990. 188p.

RIBEIRO NETO, A. **Simulação hidrológica na Amazônia: Rio Madeira**. Tese (Doutorado em Ciências em Engenharia Civil). Universidade Federal do Rio de Janeiro. Rio de Janeiro, p. 178. 2006.

RSTUDIO TEAM. **RStudio: Integrated Development for R**. RStudio, Inc., Boston, MA. 2020. Disponível em: < <http://www.rstudio.com/>>.

RUHOFF, A. L.; PAZ, A. R. D.; ARAGAO, L. E.; MU, Q.; MALHI, Y.; COLLISCHONN, W.; ROCHA, H. R.; RUNNING, S. W. 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: <https://doi.org/10.1080/02626667.2013.837578>

SANTOS, J. Y. G.; MONTENEGRO, S. M. G. L.; DA SILVA, R. M.; SANTOS, C. A. G.; QUINN, N. W.; DANTAS, A. P. X.; NETO, A. R. Modeling the impacts of future LULC and climate change on runoff and sediment yield in a strategic basin in the Caatinga/Atlantic forest ecotone of Brazil. **Catena**, v. 203, p. 105308, 2021. DOI: <https://doi.org/10.1016/j.catena.2021.105308>

SARTORI, A.; LOMBARDI NETO, F.; 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.

SCHMIDT-WALTER, P.; TROTSIUK, V.; MEUSBURGER, K.; ZACIOS, M.; MEESENBURG, H. Advancing simulations of water fluxes, soil moisture and drought stress by using the LWF-Brook90 hydrological model in R. **Agricultural and Forest Meteorology**, v. 291, p. 108023, 2020. DOI: <https://doi.org/10.1016/j.agrformet.2020.108023>

SEBESTA, R. W. **Conceitos de linguagens de programação**. 9ª ed. Porto Alegre: Bookman, 2011. 795f. ISBN 978-85-7780-862-5

SHAFII, M.; DE SMEDT, F. Multi-objective calibration of a distributed hydrological model (WetSpa) using a genetic algorithm. **Hydrology and Earth System Sciences**, v. 13, n. 11, p. 2137-2149, 2009. DOI: <https://doi.org/10.5194/hess-13-2137-2009>

SHUTTLEWORTH, W. J. Evaporation. In: MAIDMENT, D. R. **Handbook of hydrology**. New York: McGraw-Hill, 1993. p. 1-53. ISBN 0070397325.

SILVA, E. M.; LIMA, J. E. F. W.; AZEVEDO, J. A.; RODRIGUES, L. N. Valores de tensão na determinação da curva de retenção de água de solos do Cerrado. **Pesquisa Agropecuária Brasileira**, v. 41, n. 2, p. 323-330, 2006.

SILVA, G. L. D. **Qualidade física de um Luvissole cultivado com sistemas agroflorestais e convencional no semi-árido cearense**. Dissertação (Mestrado em Agronomia). Universidade Federal do Ceará. Fortaleza, p. 68. 2008.

SILVA, L. R. S. **Análise de incertezas e avaliação dos fatores influentes no desempenho de modelos de simulação de bacias hidrográficas**. Tese (Doutorado em Tecnologia Ambiental e Recursos Hídricos). Universidade de Brasília. Brasília, p. 241, 2010.

SINGH, J.; KNAPP, H. V.; ARNOLD, J. G.; DEMISSIE, M. 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: <https://doi.org/10.1111/j.1752-1688.2005.tb03740.x>

SINGH, P; THAKUR, J. K.; SINGH, U. C. Morphometric analysis of Morar River Basin, Madhya Pradesh, India, using remote sensing and GIS techniques. **Environmental Earth Sciences**, v. 68, n. 7, p. 1967–1977, 2013. DOI: <https://doi.org/10.1007/s12665-012-1884-8>

SIQUEIRA, P. C.; PONS, N. A. D.; DA SILVA, B. C.; JUNIOR, P. S. Aplicação do Modelo Hidrológico MGB-IPH para Simulação de Cenários de Uso do Solo na Bacia do Rio Sapucaí (MG). **Revista Brasileira de Geografia Física**, v. 15, n. 05, p. 2414-2429, 2022.

SMAKHTIN, V. Y.; SAMI, K; HUGHES, D. A. Evaluating the performance of a deterministic daily rainfall–runoff model in a low-flow context. **Hydrological Processes**, v. 12, p. 797–811, 1998. DOI: [https://doi.org/10.1002/\(SICI\)1099-1085\(19980430\)12:5%3C797::AID-HYP632%3E3.0.CO;2-S](https://doi.org/10.1002/(SICI)1099-1085(19980430)12:5%3C797::AID-HYP632%3E3.0.CO;2-S)

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.

SOETAERT, K.; MEYSMAN, F. Reactive transport in aquatic ecosystems: Rapid model prototyping in the open source software R. **Environmental Modelling & Software**, v. 32, p. 49-60, 2012. DOI: <https://doi.org/10.1016/j.envsoft.2011.08.011>

SOIL CONSERVATION SERVICE - SCS. **National Engineering Handbook**. Washington: Soil Conservation Service/USDA, 1971.

SOMBROEK, W. G. **Soil studies in the Merin lagoon basin**. Treinta y Tres: CLM/PNUD/FAO, v. 1, 1969. 325 p.

SOROOSHIAN, S.; GUPTA, V. K. **Model calibration**. In: SINGH, V. J. Computer models of watershed hydrology. Highlands Ranch: Water Resources Publications, 1995. Cap. 2. ISBN 10: 1-887201-74-2.

SREEDEVI, P. D.; OWAIS, S.; KHAN, H. H.; AHMED, S. Morphometric Analysis of a Watershed of South India Using SRTM Data and GIS. **Journal Geological Society of India**, v. 73, p.543-552, 2009. DOI: <https://doi.org/10.1007/s12594-009-0038-4>

SRINIVAS, N.; DEB, K. Multiobjective optimization using nondominated sorting in genetic algorithms. **Evolutionary Computation**, v. 2, n. 3, p. 221-248, 1994. DOI: <https://doi.org/10.1162/evco.1994.2.3.221>

STEELE-DUNNE, S.; LYNCH, P.; MCGRATH, R.; SEMMLER, T.; WANG, S. Y.; HANAFIN, J.; NOLAN, P. The impacts of climate change on hydrology in Ireland. **Journal of Hydrology**, v. 356, p. 28–45, 2008. DOI: <https://doi.org/10.1016/j.jhydrol.2008.03.025>

STEINMETZ, A. A. **Impacto das mudanças climáticas sobre as vazões em bacias hidrográficas do Pampa brasileiro**. 2020. 163f. Tese (Doutorado em Recursos Hídricos) – Programa de Pós-Graduação em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, Pelotas, 2020.

TANG, Y.; REED, P.; WAGENER, T. How effective and efficient are multiobjective evolutionary algorithms at hydrologic model calibration?. **Hydrology and Earth System Sciences**, v. 10, n. 2, p. 289-307, 2006. DOI: <https://doi.org/10.5194/hess-10-289-2006>

TER BRAAK, C. J. F. A Markov Chain Monte Carlo version of the genetic algorithm Differential Evolution: easy Bayesian computing for real parameter spaces. **Statistics and Computing**, v. 16, p. 239-249, 2006. DOI: <https://doi.org/10.1007/s11222-006-8769-1>

THIESSEN, A.; ALTER, J. C. Precipitation averages for large areas. Climatological Data For July, 1911. **Monthly Weather Review**, v. 39, n. 10, p. 1082-1084, 1911.

THYER, M.; LEONARD, M.; KAVETSKI, D.; NEED, S.; RENARD, B. The open source RFortran library for accessing R from Fortran, with applications in environmental modelling. **Environmental Modelling & Software**, v. 26, n. 2, p. 219-234, 2011. DOI: <https://doi.org/10.1016/j.envsoft.2010.05.007>

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

VARGAS, M. M. **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.

VARGAS, M. M.; BESKOW, S.; MELLO, C. R.; MOURA, M. M.; CUNHA, Z. A.; BESKOW, T. L. C.; TIMM, L. C. M-LASH: Hydrological and computational enhancements of the LASH model. **Environmental Modelling and Software**, v. 167, p. 105774, 2023. DOI: <https://doi.org/10.1016/j.envsoft.2023.105774>

VARGAS, M. M.; BESKOW, S.; CALDEIRA, T. L.; CORRÊA, L. L.; CUNHA, Z. A. SYHDA – System of Hydrological Data Acquisition and Analysis. **Revista Brasileira de Recursos Hídricos**, v. 24, e11, 2019.

VIGLIONE, A.; PARAJKA, J. TUWmodel: Lumped/Semi-Distributed Hydrological Model for Education Purposes. Disponível em <<https://cran.r-project.org/web/packages/TUWmodel/index.html>>. Acesso em 24 de março de 2023.

VIOLA, M. R. **Simulação hidrológica na cabeceira da Bacia Hidrográfica do Rio Grande de cenários de usos do solo e mudanças climáticas A1B**. Tese (Doutorado em Recursos Hídricos em Sistemas Agrícolas). Universidade Federal de Lavras. Lavras, p. 286. 2011.

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

VIOLA, M. R.; DE MELLO, C. R.; BESKOW, S.; NORTON, L. D. Applicability of the LASH Model for hydrological simulation of the Grand River Basin, Brazil. **Journal of Hydrologic Engineering**, v. 18, n. 12, p. 1639-1652, 2013.

VIOLA, M. R.; DE MELLO, C. R.; CHOU, S. C.; YANAGI, S. N.; GOMES, J. L. Assessing climate change impacts on Upper Grande River basin hydrology, Southeast Brazil. **International Journal of Climatology**, v. 30, n. 6, p. 1665-1679, 2015. DOI: <https://doi.org/10.1002/joc.4038>

VIOLA, M. R.; MELLO, C. D.; ACERBI JÚNIOR, F. W.; SILVA, A. D. Modelagem hidrológica na bacia hidrográfica do rio Aiuruoca, MG. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, n. 5, p. 581-590, 2009. DOI: <https://doi.org/10.1590/S1415-43662009000500011>

VIOLA, M. R.; MELLO, C. R.; BESKOW, S.; NORTON, L. D. Impacts of land-use changes on the hydrology of the Grande river basin headwaters, Southeastern, Brazil. **Water Resources Management**, v. 28, n. 13, p. 4537 - 4550, 2014. DOI: <https://doi.org/10.1007/s11269-014-0749-1>

VIOLA, M. R.; MELLO, C. R.; GIONGO, M.; BESKOW, S.; SANTOS, A. F. Modelagem hidrológica em uma sub-bacia hidrográfica do baixo rio Araguaia, TO. **Journal of Biotechnology and Biodiversity**, v. 3, n. 3, p. 38-47, 2012. DOI: <https://doi.org/10.20873/jbb.uft.cemaf.v3n3.viola>

VRUGT, J. A.; GUPTA, H. V.; BASTIDAS, L. A.; BOUTEN, W.; SOROOSHIAN, S. Effective and efficient algorithm for multiobjective optimization of hydrologic models. **Water resources research**, v. 39, n. 8, 2003b. DOI: <https://doi.org/10.1029/2002WR001746>

VRUGT, J. A.; GUPTA, H. V.; BOUTEN, W.; SOROOSHIAN, S. A Shuffled Complex Evolution Metropolis algorithm for optimization and uncertainty assessment of hydrologic model parameters. **Water Resources Research**, v. 39, n. 8, p. 2003a. DOI: <https://doi.org/10.1029/2002WR001642>

VRUGT, J. A.; TER BRAAK, C. J. F.; DIKS, C. G. H.; ROBINSON, B. A.; HYMAN, J. M.; HIGDON, D. Accelerating Markov chain Monte Carlo simulation by differential evolution with self-adaptive randomized subspace sampling. **International journal of nonlinear sciences and numerical simulation**, v. 10, n. 3, p. 273-290, 2009. DOI: <https://doi.org/10.1515/IJNSNS.2009.10.3.273>

VRUGT, J. A.; TER BRAAK, C. J.; CLARK, M. P.; HYMAN, J. M.; ROBINSON, B. A. 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: <https://doi.org/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: <https://doi.org/10.1073/pnas.0610471104>

WANG, Y.; LEI, X.; JIANG, Y.; WANG, H. Performance comparison of three multi-objective optimization algorithms on calibration of hydrological model. In: **2010 Sixth International Conference on Natural Computation**. IEEE, 2010. p. 2798-2803.

WI, S.; RAY, P.; DEMARIA, E. M.; STEINSCHNEIDER, S.; BROWN, C. A user-friendly software package for VIC hydrologic model development. **Environmental Modelling & Software**, v. 98, p. 35-53, 2017. DOI: <https://doi.org/10.1016/j.envsoft.2017.09.006>

WIGMOSTA, M. S.; VAIL, L. W.; LETTENMAIER, D. P. A distributed hydrology-vegetation model for complex terrain. **Water Resources Research**, v. 30, n. 6, p. 1665-1679, 1994. DOI: <https://doi.org/10.1029/94WR00436>

YAPO, P. O.; GUPTA, H. V.; SOROOSHIAN, S. Multi-objective global optimization for hydrologic models. **Journal of Hydrology**, v. 204, n. 1 - 4, p. 83 - 97, 1998. DOI: [https://doi.org/10.1016/S0022-1694\(97\)00107-8](https://doi.org/10.1016/S0022-1694(97)00107-8)

YU, P. S.; WANG, Y. C. Impact of climate change on hydrological processes over a basin scale in northern Taiwan. **Hydrological Processes**, v. 23, p. 3556–3568, 2009. DOI: <https://doi.org/10.1002/hyp.7456>

ZHANG, X.; BEESON, P.; LINK, R.; MANOWITZ, D.; IZAURRALDE, R. C.; SADEGHI, A.; THOMSON, A. M.; SAHAJPAL, R.; SRINIVASAN, R.; ARNOLD, J. G. Efficient multi-objective calibration of a computationally intensive hydrologic model with parallel computing software in Python. **Environmental Modelling & Software**, v. 46, p. 208-218, 2013. DOI: <https://doi.org/10.1016/j.envsoft.2013.03.013>

ZHANG, Y.; HOU, J.; GU, J.; HUANG, C.; LI, X. SWAT-based hydrological data assimilation system (SWAT-HDAS): Description and case application to river basin-scale hydrological predictions. **Journal of Advances in Modeling Earth Systems**, v. 9, n. 8, p. 2863-2882, 2017. DOI: <https://doi.org/10.1002/2017MS001144>

ZHOU, M. C.; ISHIDAIRA, H.; HAPUARACHCHI, H. P.; MAGOME, J.; KIEM, A. S.; TAKEUCHI, K. Estimating potential evapotranspiration using Shuttleworth-Wallace model and NOAA-AVHRR NDVI data to feed a distributed hydrological model over the Mekong River basin. **Journal of Hydrology**, v. 327, n. 1/2, p. 151-173, 2006. DOI: <https://doi.org/10.1016/j.jhydrol.2005.11.013>