

**VITOR CUNHA FONTES**

**EFEITOS DA EXPANSÃO AGRÍCOLA NA DISPONIBILIDADE HÍDRICA DO  
OESTE DA BAHIA VIA MODELAGEM HIDROLÓGICA**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Meteorologia Aplicada, para obtenção do título de *Doctor Scientiae*.

Orientador: Marcos Heil Costa

**VIÇOSA – MINAS GERAIS  
2022**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade  
Federal de Viçosa - Campus Viçosa**

T

F683e Fontes, Vitor Cunha, 1986-  
2022 Efeitos da expansão agrícola na disponibilidade hídrica do  
Oeste da Bahia via modelagem hidrológica / Vitor Cunha Fontes.  
– Viçosa, MG, 2022.

1 tese eletrônica (81 f.): il. (algumas color.).

Orientador: Marcos Heil Costa.

Tese (doutorado) - Universidade Federal de Viçosa,  
Departamento de Engenharia Agrícola, 2022.

Referências bibliográficas: f. 68-81.

DOI: <https://doi.org/10.47328/ufvbbt.2022.084>

Modo de acesso: World Wide Web.

1. Calibração. 2. Desmatamento. 3. Medidores de fluxo.  
4. Aquíferos. I. Costa, Marcos Heil, 1965-. II. Universidade  
Federal de Viçosa. Departamento de Engenharia Agrícola.  
Programa de Pós-Graduação em Meteorologia Aplicada.  
III. Título.

CDD 22. ed. 620.004

Bibliotecário(a) responsável: Renata de Fátima Alves CRB6/2578

**VITOR CUNHA FONTES**

**EFEITOS DA EXPANSÃO AGRÍCOLA NA DISPONIBILIDADE HÍDRICA DO  
OESTE DA BAHIA VIA MODELAGEM HIDROLÓGICA**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Meteorologia Aplicada, para obtenção do título de *Doctor Scientiae*.

APROVADA: 10 de dezembro de 2021.

Assentimento:



---

Vitor Cunha Fontes  
Autor



---

Marcos Heil Costa  
Orientador

*A minha esposa e meu filho.*

## **AGRADECIMENTOS**

A Universidade Federal de Viçosa (UFV) e ao Programa de Pós-Graduação em Meteorologia Aplicada, pela oportunidade.

Ao professor e orientador Marcos Heil Costa, pelos ensinamentos, confiança, paciência, preocupação e por ser exemplo de dedicação a pesquisa.

Ao meu pai Juarez, minha mãe Maria do Carmo e minha irmã Bárbara, pelo apoio incondicional.

A minha esposa Camila, pelo incentivo e força nos momentos difíceis, pelo apoio, por ser um exemplo de dedicação e trabalho.

Ao meu filho João Vítor, por ser a minha inspiração de vida.

A minha família, por todo o apoio.

Aos amigos do Grupo de Pesquisa em Interação Atmosfera-Biosfera da UFV, pela amizade e por toda a ajuda recebida.

Aos membros da banca examinadora, Prof. Everardo Chartuni Mantovani, Prof.<sup>a</sup> Gabrielle Ferreira Pires, Prof.<sup>a</sup> Hewlley Maria Acioli Imbuzeiro, Prof.<sup>a</sup> Lívia Cristina Pinto Dias e Prof. Marcos Heil Costa, pela disponibilidade e pelas sugestões para o enriquecimento deste trabalho.

Aos professores do Programa de Meteorologia Aplicada da UFV por se mostrarem acessíveis e dispostos a compartilhar o conhecimento.

Aos funcionários do Programa de Meteorologia Aplicada da UFV, em especial a servidora Graça Freitas, por se mostrarem sempre acessíveis, dispostos a ajudarem e por serem suporte para com os alunos.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa de estudo.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Enfim, a todos aqueles que contribuíram para a realização deste trabalho, o meu muito obrigado.

## RESUMO

FONTES, Vitor Cunha, D.Sc., Universidade Federal de Viçosa, dezembro de 2021. **Estudo dos efeitos da expansão agrícola do oeste da bahia via modelagem hidrológica.** Orientador: Marcos Heil Costa.

O oeste da Bahia passou por uma grande expansão agrícola nos últimos anos e nessa região estão localizados alguns dos maiores produtores agrícolas do Brasil. Por conta disso, entre 1990 e 2015, 31% da vegetação natural da região foi convertida para regiões de pastagem e agricultura. Essa mudança de uso do solo pode ter afetado as vazões dos rios da região. O objetivo desse trabalho é avaliar a magnitude desse impacto. Esse tipo de análise pode ser feito por meio da modelagem. Primeiro foi necessário calibrar os modelos INLAND (*Integrated Model of Land Surface Processes*) e THMB (*Terrestrial Hydrology Model with Biogeochemistry*) para simularem a hidrologia da região. Foram calibrados um total de 19 parâmetros resultando numa simulação com um índice de eficiência de Kling-Gupta (KGE) de 0,83 para o período de calibração e de 0,80 para o período de validação. Depois foram simulados cenários sem desmatamento e sem aquífero. A diferença entre o cenário controle e o cenário sem desmatamento mostrou que a substituição da vegetação natural por áreas agrícolas e pastagens aumenta o volume do aquífero (diminuindo a evapotranspiração) e conseqüentemente a vazão (tanto a média quanto os valores mínimos e máximos). A diferença entre o cenário controle e o cenário sem aquífero mostrou que o aquífero ajuda a estabilizar a vazão mantendo valores mais altos de vazão mínima. Esses resultados, apesar de parecerem positivos, podem estar escondendo uma possível mudança climática que pode diminuir a precipitação da região e no levar no futuro a uma diminuição da vazão. Portanto, é preciso que os tomadores de decisão leve esse estudo como um alerta e passem a monitorar o uso do solo e os seus impactos na vazão para evitar possíveis futuros conflitos no uso da água.

Palavras-chave: Calibração. Desmatamento. Aquífero. Vazão.

## ABSTRACT

FONTES, Vitor Cunha, D.Sc., Universidade Federal de Viçosa, December, 2021. **Study of the effects of agricultural expansion in west bahia via hydrological modeling.** Adviser: Marcos Heil Costa.

The west of Bahia, a region where is located some of the largest agricultural producers in Brazil, has undergone a major agricultural expansion in recent years. As a result, between 1990 and 2015, 31% of the region's natural vegetation was converted to pasture and agricultural regions. This change in land use may have affected river flows in the region. The purpose of this work is, by computational modeling, to assess what type of impact is it. First, it was necessary to calibrate the INLAND (*Integrated Model of Land Surface Processes*) and THMB (*Terrestrial Hydrology Model with Biogeochemistry*) models to simulate the hydrology of the region. A total of 19 parameters were calibrated resulting in a simulation with a Kling-Gupta efficiency index (KGE) of 0.83 for the calibration period and 0.80 for the validation period. Then two scenarios were simulated, one without deforestation and another without aquifer. The no-deforestation scenario showed that deforestation increases the volume of the aquifer (decreasing evapotranspiration) and consequently the river flow. The no-aquifer scenario showed that the aquifer helps to stabilize the river flow by maintaining higher values of minimum flow. These results, despite appearing positive, may be hiding a possible climate change that could reduce precipitation in the region and lead to a decrease in flow in the future. Therefore, it is necessary that decision makers take this study as a warning and start to observe and analyze more the events in western Bahia.

Keywords: Calibration. Deforestation. Aquifer. Flow rate.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Dinâmica da água no solo simulada pelo modelo INLAND ( <i>Integrated Model of Land Surface Processes</i> ) .....	23
Figura 2 – Estrutura organizacional do Optis .....	30
Figura 3 – Representação do Sistema Aquífero Urucuia (SAU) .....	32
Figura 4 – (a) Território brasileiro com destaque a Região do oeste da Bahia, (b) Bacias que formam o Sistema Aquífero Urucuia (bacias do rio Grande, rio Correntes e rio Carinhanha), (c) Localização da estação fluvial automática 46543000 .....	33
Figura 5 – Série anual de precipitação (mm/dia) nas áreas de drenagem da estação 46543000, extraídas do mapa de precipitação produzido por Xavier et al. (2015), considerando o período de 1980 a 2015 .....	34
Figura 6 – Mudança de uso do solo no oeste da Bahia entre 1990 e 2015 .....	35
Figura 7 – Porcentagem da área de vegetação natural no período entre 1990 e 2015 para as áreas de drenagem da estação 46543000 .....	36
Figura 8 – Fluxograma da sequência de execução dos modelos INLAND ( <i>Integrated Model of Land Surface Processes</i> ) e THMB ( <i>Terrestrial Hydrology Model with Biogeochemistry</i> ) .....	37
Figura 9 – Fluxograma da sequência de execução dos modelos, utilizando uma configuração do INLAND ( <i>Integrated Model of Land Surface Processes</i> ) para cada classe de cobertura do solo.....	38
Figura 10 – Valores observados e simulados de vazão (m <sup>2</sup> /s) para as áreas de drenagem da estação 46543000, considerando o período entre 1992 a 2015 .....	47
Figura 11 – Curvas das funções de distribuição acumulada empírica (FDAE) da vazão simulada e observada no cenário padrão. Os pontos em vermelho representam o local onde a distância entre as curvas é máxima (reta tracejada). O valor-p do teste de Kolmogorov-Smirnov bilateral é também apresentado .....	49
Figura 12 – Gráfico de dispersão com linha de tendência linear do período de (a) calibração (de 1992 a 2007) e de (b) validação (de 2008 a 2015) .....	51
Figura 13 – Média anual de vazão (m <sup>3</sup> /s) simulada para os cenários padrão e sem desmatamento para a área de drenagem da estação 46543000, considerando o período entre 1992 a 2015.....	52

Figura 14 – Curvas das funções de distribuição acumulada empírica (FDAE) da vazão simulada nos cenários padrão e sem desmatamento. Os pontos em vermelho representam o local onde a distância entre as curvas é máxima (reta tracejada). O valor-p do teste de Kolmogorov-Smirnov unilateral a direita é também apresentado.....	53
Figura 15 – Gráfico de dispersão com plano de regressão entre a vazão e a drenagem profunda e o superficial considerando os valores simulados na presença de desmatamento .....	56
Figura 16 – Gráfico de dispersão com plano de regressão entre a vazão e a drenagem profunda e o superficial considerando os valores simulados na ausência de desmatamento .....	58
Figura 17 – Curvas das funções de distribuição acumulada empírica (FDAE) da drenagem profunda simulada considerando o cenário padrão e do cenário sem desmatamento. Os pontos em vermelho representam o local onde a distância entre as curvas é máxima. O valor-p do teste de Kolmogorov-Smirnov unilateral a direita é também apresentado .....	59
Figura 18 – Curvas das funções de distribuição acumulada empírica (FDAE) do escoamento superficial simulado considerando o cenário padrão e do cenário sem desmatamento. Os pontos em vermelho representam o local onde a distância entre as curvas é máxima. O valor-p do teste de Kolmogorov-Smirnov bilateral é também apresentado .....	60
Figura 19 – Média anual de vazão (m <sup>3</sup> /s) simulada para os cenários padrão e sem aquífero para a área de drenagem da estação 46543000, considerando o período entre 1992 a 2015 .....	62
Figura 20 – Curvas das funções de distribuição acumulada empírica (FDAE) da vazão simulada considerando o cenário padrão e o cenário sem aquífero. Os pontos em vermelho representam o local onde a distância entre as curvas é máxima. O valor-p do teste de Kolmogorov-Smirnov bilateral é também apresentado .....	63
Figura 21 – Gráfico de dispersão com plano de regressão entre a vazão e a drenagem profunda e o superficial considerando os valores simulados na ausência do aquífero.....	65
Figura 22 – Gráfico de dispersão com reta ajustada entre a vazão e a drenagem profunda considerando os valores simulados na ausência do aquífero .....	66

## LISTA DE TABELAS

Tabela 1 – Descrição dos dezesseis tipos funcionais de plantas .....	21
Tabela 2 – Precipitação média (mm/dia) nas áreas de drenagem da estação 46543000 considerando o período de 1980 a 2015 .....	35
Tabela 3 – Porcentagem da área de drenagem da estação 46543000 com floresta, cerrado, pastagem e agricultura nos anos de 1990, 2007 e 2015 .....	36
Tabela 4 – Descrição dos parâmetros calibrados dos modelos INLAND ( <i>Integrated Model of Land Surface Processes</i> ) e THMB ( <i>Terrestrial Hydrology Model with Biogeochemistry</i> ) .....	38
Tabela 5 – Solução ótima para os parâmetros dos modelos INLAND ( <i>Integrated Model of Land Surface Processes</i> ) e THMB ( <i>Terrestrial Hydrology Model with Biogeochemistry</i> ) encontrada pelo processo de calibração via Optis .....	44
Tabela 6 – Medidas estatísticas descritivas dos valores simulados e observados nos períodos de calibração e validação para a estação 46453000 .....	48
Tabela 7 – Características dos valores observados e simulados de vazão (m <sup>3</sup> /s) para as áreas de drenagem da estação 46543000, considerando o período de calibração e validação .....	50
Tabela 8 – Medidas estatísticas descritivas dos valores simulados da vazão considerando o cenário padrão e o cenário sem desmatamento para a estação 46453000 .....	54
Tabela 9 – Valores médios de drenagem profunda (m <sup>3</sup> /s) e escoamento superficial (m <sup>3</sup> /s) para a área de drenagem da estação 46543000, considerando o período entre 1992 a 2015 .....	59
Tabela 10 – Medidas estatísticas descritivas dos valores simulados da vazão considerando o cenário padrão e o cenário sem aquífero para a estação 46453000.....	61

## SUMÁRIO

1 INTRODUÇÃO .....	13
1.1 OBJETIVO .....	14
1.1.1 OBJETIVOS ESPECÍFICOS.....	14
2 REVISÃO DE LITERATURA.....	15
2.1 EFEITOS CLIMÁTICOS DA MUDANÇA NO USO DO SOLO .....	15
2.2 MODELAGEM HIDROLÓGICA .....	17
2.2.1 INLAND .....	20
2.2.2 THMB .....	23
2.3 CALIBRAÇÃO .....	25
2.3.1 Optis .....	29
3 MATERIAL E MÉTODOS.....	32
3.1 AQUÍFERO URUCUIA .....	32
3.2 DADOS CLIMÁTICOS .....	34
3.3 DADOS DE USO DO SOLO .....	35
3.4 MODELOS HIDROLÓGICOS.....	36
3.4.1 Acoplamento INLAND e THMB .....	37
3.5 EXPERIMENTO NUMÉRICO.....	41
3.6 AVALIAÇÃO DO IMPACTO DO DESMATAMENTO NA VAZÃO.....	41
3.7 AVALIAÇÃO DA CONTRIBUIÇÃO DO AQUÍFERO PARA A REGULAÇÃO DA VAZÃO.....	42

4 RESULTADOS E DISCUSSÃO.....	43
4.1. CALIBRAÇÃO .....	43
4.2 AVALIAÇÃO DO IMPACTO DO DESMATAMENTO NA VAZÃO .....	51
4.3 AVALIAÇÃO DA CONTRIBUIÇÃO DO AQUÍFERO PARA A REGULAÇÃO DA VAZÃO .....	61
5 CONCLUSÃO.....	67
6 REFERÊNCIAS .....	68

## 1 INTRODUÇÃO

O oeste baiano vem sendo considerado o maior polo agrícola e principal produtor de grãos do Nordeste brasileiro (CONAB, 2020). Nesta região, a área plantada total aumentou de, aproximadamente, 2,1 milhões de hectare em 2013 para, aproximadamente, 2,5 milhões em 2020 (um aumento de 19%) (Associação de Agricultores e Irrigantes da Bahia – AIBA, 2020). A cultura da soja é predominante, nesta área, e sua produção foi de 3,3 milhões de toneladas para 6 milhões de toneladas nesse mesmo período. Segundo a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA, 2020), a produção brasileira total desse grão em 2020 foi de 125 milhões de toneladas, ou seja, o oeste da Bahia é responsável por, aproximadamente, 5% de toda a produção brasileira.

Essa expansão começou em meados da década de 1980 (Batistella e Valladares, 2009) e este crescimento rápido foi impulsionado pela abundante disponibilidade hídrica da região devido à presença do aquífero Urucuia (bacias do Rio Grande, Rio Correntes e Rio Carinhanha). No entanto, estudos, em outras áreas, reportam um ciclo temerário entre expansão agrícola, redução da produtividade agrícola, o desmatamento e a redução dos serviços ecossistêmicos (Acheampong et al., 2019; Maeda et al., 2021). Desta forma, o estudo do impacto da expansão agrícola na produtividade da região do oeste da Bahia é de relevância econômica, pois se este for negativo pode prejudicar o agronegócio da respectiva região (Oliveira et al., 2013; Bajželj e Richards, 2014, Serrão et al., 2021).

De um modo geral, os estudos apontaram que o desmatamento induz uma diminuição da evapotranspiração e aumento da vazão (Ridwansyah et al., 2020; Chanapathi e Thatikonda, 2020). Apesar disso, como destacado por Cuo (2016) não existe uma relação linear entre desmatamento e aumento da vazão, por isso a importância de estudo de diferentes áreas e diferentes situações como o caso da presença de um aquífero.

A principal ferramenta para compreender e para prever os efeitos que as mudanças de uso do solo podem causar em uma região é o modelo hidrológico (Devia et al., 2015). Em âmbito mundial, poucos estudos de hidrologia vêm sendo conduzidos em regiões brasileiras (Amorim e Chaffe, 2019) e o maior número destes estudos estão concentrados nas bacias hidrográficas do Paraná e do Atlântico Nordeste

Oriental. Na bacia do São Francisco, onde está localizado o oeste da Bahia, a maioria de estudos estão voltados para a geração de energia hidroelétrica. No entanto, apesar de menos frequentes, pode-se citar o estudo de Ferraz et al. (2021) que utilizaram o modelo hidrológico SWAT (*Soil and Water Assessment Tool*) para simulação hidrológica da bacia do Rio Correntes. Porém, apesar de flexível, o SWAT não é um modelo hidrológico voltado para o território brasileiro, ao contrário do modelo INLAND (*Integrated Model of Land Surface Processes*) que é o pacote de superfície utilizado no *Brazilian Earth System Model*. Além disso, os estudos com diversificados modelos hidrológicos, bem como suas calibrações, ajudarão a evoluir a ciência nessa área (Beven, 2019).

## 1.1 OBJETIVO

O presente estudo tem como objetivo geral avaliar os efeitos hidrológicos da expansão agrícola ocorrida no oeste da Bahia, procurando entender como o desmatamento ocorrido na região pode estar afetando os recursos hídricos, e o papel do aquífero neste contexto.

### 1.1.1 OBJETIVOS ESPECÍFICOS

Os objetivos específicos deste projeto são:

- i) Calibrar o Modelo Integrado de Processos Superficiais (INLAND) e o *Terrestrial Hydrology Model with Biogeochemistry* (THMB) para a região do oeste da Bahia;
- ii) Avaliar o impacto do desmatamento na vazão da região;
- iii) Avaliar a contribuição do aquífero para a vazão da região.

## 2 REVISÃO DE LITERATURA

### 2.1 Efeitos climáticos da mudança no uso do solo

O sistema climático é um sistema muito complexo que é resultado da interação entre atmosfera, superfície terrestre, oceanos, gelo, vegetação, entre outros fatores (Solomon et al., 2007). Essa complexidade dificulta a compreensão dos efeitos causados pelas mudanças de uso do solo, como o desmatamento, que é objeto de interesse deste estudo. Esses efeitos podem variar de região para região devido a distribuição desigual da radiação solar, diferentes disposições entre o oceano e a superfície e as diferentes características físicas de cada área.

O desmatamento pode causar consequências na chuva em diferentes escalas espaciais, como mostra as revisões realizadas por Lawrence e Vandecar (2015) e Perugini et al. (2017). Estes estudos demonstraram que o desmatamento induzido pela expansão agrícola, podem aumentar a temperatura média, ocasionando períodos de calores extremos, e podem diminuir a precipitação média. Estudos como Bala et al. (2007) e Feddema et al. (2005) mostraram que o desmatamento das florestas tropicais, por exemplo, leva a um aumento da temperatura global média. Em outras palavras, o resfriamento causado pela redução do albedo das áreas desmatadas é compensado pelo efeito estufa do CO<sub>2</sub> adicionado na atmosfera. Em escalas menores, as consequências são mais incertas porque depende das características físicas e climáticas da região. De um modo geral, o desmatamento das regiões tropicais tende a criar um clima quente e seco sobre a área desmatada (Lejeune et al., 2015; Dubreuil et al., 2012).

No entanto, Negri et al. (2004), em um estudo realizado sobre a Amazônia, mostraram que o desmatamento até pode aumentar o volume de chuva de uma região. Este aumento está relacionado ao fato da região desmatada ser pequena e estar cercada por uma grande área de floresta densa. Essas regiões, com vegetação densa, reciclam de modo mais eficiente a água mantendo a umidade específica do ar (fator importante para a precipitação) (Spracklen et al., 2012). Além disso, o aumento de temperatura na região desmatada induz movimentos verticais, reduzindo a pressão do ar e assim, extraíndo o ar úmido da floresta vizinha. Esse ar úmido sobe e provoca as chuvas convectivas na área desmatada. No entanto, estes resultados contraditórios de aumento de precipitação só devem ocorrer até que o desmatamento não ultrapasse

o chamado "*tipping point*". Alguns autores, como Boers et al. (2017), estimam que esse ponto de virada está entre 30% a 50% de desmatamento da área total. Depois desse ponto, a floresta tende a declinar, diminuindo a precipitação da região.

Os efeitos do desmatamento podem ser separados em efeitos biogeoquímicos e efeitos biofísicos (conforme Bala et al., 2007; Bonan, 2008). Esses efeitos alteram, principalmente, os ciclos da água, de carbono e de energia. Os efeitos biofísicos alteram as propriedades físicas da superfície do planeta impactando na circulação atmosférica. Já os efeitos biogeoquímicos alteram a absorção, reciclagem e disposição dos compostos químicos que afetam o clima. Um dos principais efeitos biogeoquímicos do desmatamento é a liberação do carbono (na forma de CO<sub>2</sub>) estocado nas plantas e no solo. O desmatamento, inclusive, é a segunda maior fonte antropogênica de CO<sub>2</sub> (van der Werf et al., 2009). Este gás é um dos principais gases do efeito estufa e, portanto, sua liberação afeta diretamente o clima (Solomon et al., 2007). Por ser uniformemente distribuído na atmosfera, os seus efeitos são globais não importando o local onde foi liberado. Por essas razões a relação entre o desmatamento e o ciclo do carbono é amplamente estudada (Bala et al., 2007; Baccini et al., 2012; Houghton et al., 2012; Song et al., 2015; Pendrill et al., 2019), inclusive a região do oeste baiano (Salmona et al., 2016).

Exemplos de efeitos biofísicos do desmatamento são a diminuição da rugosidade, o aumento do albedo e a diminuição da evapotranspiração (como mostraram von Randow et al. (2004) e Dubreuil et al. (2012) por meio de dados de campo). O aumento do albedo conduz a um aumento da fração de radiação solar refletida, diminuindo assim a quantidade de energia disponível na superfície. A diminuição da rugosidade faz com que o ar que passa sobre a região seja menos propenso a gerar vértices turbulentos. Esse fato diminui a movimentação vertical do ar, que é um fator importante para a precipitação nas regiões tropicais. Simultâneo a diminuição da rugosidade também ocorre a diminuição do índice de área foliar e da profundidade da raiz. Esses fatores somados diminuem a evapotranspiração, alterando a distribuição do saldo de radiação entre o calor latente e o calor sensível (como exemplificado por Costa et al., 2007). Com uma menor evapotranspiração e, conseqüentemente, menor fluxo de calor latente, mais energia é dissipada em forma de calor sensível.

## 2.2 Modelagem hidrológica

No último século, a hidrologia evoluiu devido a necessidade de compreender os complexos sistemas hídricos do planeta (Sivapalan e Blöschl, 2017). Essa área da ciência é responsável por identificar e solucionar problemas em diversos aspectos da vida. Dentro da hidrologia, o estudo das vazões dos rios é uma subárea de elevada importância (Porporato e Ridolfi, 2001). O fenômeno de vazões é muito complexo e envolve uma grande variedade de escalas espaciais e temporais. Uma das ferramentas mais utilizadas para prever o comportamento e compreender os processos relacionados a esse fenômeno é a modelagem hidrológica (Devia et al., 2015). Segundo Allaby e Allaby (1999), a modelagem hidrológica é a caracterização de recursos e sistemas hidrológicos reais pelo uso de modelos físicos de pequena escala, sendo uma representação matemática e de simulações computacionais. Em outras palavras, estes modelos podem ser caracterizados como uma formulação matemática e física do fluxo de água e seus componentes acerca de certa superfície ou subsuperfície terrestre.

Os modelos hidrológicos representam o procedimento mais eficiente e viável de prever a disponibilidade de água e seus sistemas de distribuição, sob uma variedade de condições ambientais, como por exemplo, o desmatamento (Guug et al., 2020). Em termos práticos, além da compreensão de um sistema hidrológico, a modelagem pode auxiliar na tomada de decisões em escala local (Alcantara et al., 2019). O principal objeto de estudo de modelos hidrológicos são as bacias hidrográficas, os quais consistem em áreas do território ou de uma superfície composta por um rio principal e seus afluentes, que escoam sobre um ou mais canais de escoamento para o mesmo curso d'água, abastecendo-o (Varejão-Silva, 2001).

Os modelos hidrológicos são classificados como modelos empíricos e modelos mecanísticos. Os modelos empíricos, também chamados de modelos orientados por dados, utilizam relações estatísticas entre os dados de entrada e os de saída, sem considerar as características e os processos do sistema hidrológico (Sitterson et al., 2017). Nesse tipo de modelo, o sistema hidrológico, muitas vezes, é considerado obscuro, onde pouco se sabe a respeito dos processos internos que transformam precipitação em vazão (Granata et al., 2016). Isto pode simplificar a modelagem, mas impede o avanço do conhecimento desses processos internos e, conseqüentemente,

a compreensão do fenômeno estudado. Estes modelos envolvem equações matemáticas derivadas de séries temporais de entrada e saída de modo simultâneo e não dos processos físicos de uma bacia. Os modelos empíricos podem ser baseados em estatísticas, usando modelos de regressão cujo objetivo é encontrar uma relação funcional entre as entradas e saídas, ou baseados em inteligência artificial, como técnicas de redes neurais, lógica *fuzzy* e técnicas de aprendizado de máquina (Devia et al., 2015).

No entanto, para um maior conhecimento dos sistemas hidrológicos e para uma adequada avaliação do impacto no clima, sob mudanças na cobertura do solo, se faz necessária a utilização dos modelos mecanísticos. Esta classe de modelos consiste em uma representação matemática idealizada do fenômeno real (Devia et al., 2015) e baseiam-se na compreensão espacial e temporal da física relacionada a processos de balanço hídrico (evapotranspiração, infiltração, escoamento), conservação de massa, energia e *momentum* (Sitterson et al., 2017). Ainda, segundo Sitterson et al. (2017), a maior vantagem desses modelos é a conexão entre os parâmetros e as características físicas da região de estudo. Nesta classe de modelos, os parâmetros são associados as características físicas da região de estudo e caso o objetivo seja estudar a dinâmica da resposta hidrológica a uma mudança ambiental, os modelos mecanísticos seriam os mais indicados (Guug et al., 2020).

Dentre os diversos modelos mecanísticos existentes, o modelo SWAT (*Soil and Water Assessment Tool*) é um dos mais reportados na literatura (Chanapathi e Thatikonda, 2020; Ridwansyah et al., 2020; Moghadam et al., 2021; Serrão et al., 2021) e foi desenvolvido pelo *Agricultural Research Service* (ARS) e pelo *United States Department of Agriculture* (USDA) (Arnold et al., 2012). O SWAT é um modelo hidrológico semi-distribuído, contínuo no tempo e baseado em unidades de resposta hidrológica (HRU – *Hydrological Response Units*) (Arnold et al., 1998). O SWAT divide a área de drenagem em sub-bacias e, posteriormente, divide cada sub-bacia em unidades hidrológicas de acordo com as características de solo, vegetação e terreno (Zhang et al., 2018). Segundo Devia et al. (2015), para obter uma previsão precisa da circulação de água, nutrientes e sedimentos, é necessário simular o ciclo hidrológico que integra a circulação geral da água na área de captação e, portanto, o modelo SWAT faz uso da seguinte equação de balanço hídrico na bacia:

$$U_t = U_0 + \sum_{i=1}^t (R - E_s - I - ET - E_{sub})$$

em que  $U_t$  é a umidade do solo no tempo  $t$  (em dias),  $U_0$  é a umidade base,  $R$  é o volume da chuva em mm de água,  $E_s$  é o escoamento superficial,  $I$  é a infiltração de água do solo para as camadas subjacentes,  $ET$  é a evapotranspiração,  $E_{sub}$  é o escoamento da água subterrânea.

Nos modelos semi-distribuídos, a bacia hidrográfica é dividida em várias sub-bacias assumindo-se uma uniformidade espacial de suas características. No entanto, caso exista a heterogeneidade espacial nesta sub-divisões seria importante a contabilização da mesma no modelo (Melone et al., 2005). Já nos modelos distribuídos, a bacia hidrográfica é dividida em uma grade com células retangulares e então, esta heterogeneidade passa a ser contabilizada. Dessa forma, caso o estudo tenha disponível dados de qualidade e sob um processo de calibração eficiente, a utilização de um modelo totalmente distribuído é vantajosa para entender a distribuição espacial das variáveis de produção, como escoamento, umidade do solo, evaporação real, rendimento da colheita.

Dentre os modelos totalmente distribuídos, destaca-se o modelo DHSVM (*Distributed Hydrology Soil Vegetation Model*) que é reportado em estudos como o de Alvarenga et al. (2016a), Alvarenga et al. (2016b) e Zhang et al. (2018). O DHSVM é um modelo hidrológico totalmente distribuído baseado em *grid* e foi desenvolvido pela Universidade de Washington e pelo *Pacific Northwest National Laboratory* (Wigmosta et al., 1994). O balanço hídrico simulado no sistema solo-vegetação para cada célula da grade pode ser escrito como:

$$\Delta S_{S1} + \Delta S_{S2} + \Delta S_{io} + \Delta S_{iu} + \Delta W = P - E_{io} - E_{iu} - E_s - E_{to} - E_{tu} - P_2$$

em que  $\Delta S_{S1}$  e  $\Delta S_{S2}$  são, respectivamente, as variações superior e inferior do estoque de água do solo,  $\Delta S_{io}$  e  $\Delta S_{iu}$  são, respectivamente as variações no estoque de interceptação do dossel inferior e superior,  $\Delta W$  é a variação no conteúdo de neve acumulada,  $P$  é a precipitação,  $E_{io}$  e  $E_{iu}$  são, respectivamente, o volume evaporado do dossel inferior e superior,  $E_s$  é volume evaporado da superfície do solo,  $E_{to}$  e  $E_{tu}$  são, respectivamente, o volume transpirado do dossel inferior e superior e  $P_2$  é o escoamento da última camada do solo.

### 2.2.1 INLAND

Os modelos SWAT e DHSVM não são modelos desenvolvidos especificamente para o território brasileiro. No entanto, por meio de um financiamento do programa Rede Clima e dos Institutos Nacionais de Ciência e Tecnologia do Ministério da Ciência e Tecnologia, o modelo INLAND (*Integrated Model of Land Surface Processes* – Sampaio et al., 2012) foi desenvolvido para ser o pacote de superfície do *Brazilian Earth System Model*. O modelo INLAND também é um modelo totalmente distribuído baseado em *grid*, como o DHSVM. A aplicação do INLAND ainda é incipiente, o que desperta o interesse de analisar a capacidade desse modelo para a modelagem hidrológica (assim como realizado para os demais modelos). Em relação aos estudos utilizando o INLAND, podem ser citados estudos como os de: Dias et al. (2015) que utilizaram o INLAND para entender os efeitos da mudança da cobertura do solo na evapotranspiração e no fluxo de pequenas bacias hidrográficas na Bacia do Alto Rio Xingu, Lyra et al. (2016) que utilizaram o INLAND para realizar projeções de mudanças climáticas de alta resolução na Amazônia, Castro et al. (2018) que utilizaram também o acoplamento do INLAND e do THMB e mostraram que esses modelos foram capazes de representar bem a vazão para a bacia Amazônia, Dionizio et al. (2018) utilizaram o INLAND para estudar os efeitos da influência da variabilidade climática, do fogo e da limitação de fósforo na estrutura e na dinâmica da vegetação da fronteira Amazônia-Cerrado, Goergen et al. (2020) que utilizaram o INLAND para representar os fluxos de energia e de CO<sub>2</sub> sobre um campo nativo do bioma Pampa, Brumatti et al. (2020) que utilizaram o INLAND para estudar o comportamento de sistemas agrícolas de dupla safra no Brasil sob mudanças no clima e na cobertura do solo e Caen et al. (2021) que compararam o modelo INLAND e o modelo JULES (*Joint UK Land Environment Simulator*) em todo o território brasileiro usando o ciclo do carbono como referência.

O INLAND é um modelo desenvolvido a partir do IBIS (*Integrated Biosphere Simulator*) (Foley et al., 1996), e foi projetado para representar os processos que ocorrem na superfície terrestre. O modelo pode ser dividido em módulos de Vegetação (em que se trata da fenologia e da dinâmica da vegetação), de Biogeoquímica do solo (ciclo do carbono e nitrogênio) e dos Processos superficiais (física do dossel, física do solo e fisiologia vegetal).

A vegetação é representada por 16 tipos funcionais de plantas (*Plant functional types* - PFTs) (Tabela 1), com propriedades distintas de área foliar, alocação de carbono e conversão de biomassa para raiz, folhas e tronco, atividade máxima da enzima Rubisco, coeficiente de respiração e condutância estomática, entre outras.

Tabela 1. Descrição dos dezesseis tipos funcionais de plantas.

Número	Tipo funcional da planta
1	Árvores tropicais, de folhas largas e permanentemente verdes
2	Árvores tropicais de folhas largas, decíduas secas
3	Árvores de clima temperado quentes, de folhas sempre verdes
4	Árvores coníferas de clima temperado, com folhas sempre verdes
5	Árvores decíduas de clima temperado frio, de folhas sempre verdes
6	Árvores coníferas boreal, de folhas permanentemente verdes
7	Árvores boreais, coníferas decíduas de clima frio
8	Árvores decíduas boreais de clima frio, de folhas largas
9	Arbustos permanentemente verdes
10	Arbustos decíduos
11	Gramíneas tipo C4
12	Gramíneas tipo C3
13	Soja
14	Milho
15	Trigo
16	Cana de açúcar

Algumas especificações a respeito do modelo INLAND são descritas a seguir:

**i. Vegetação:** A vegetação é modelada em duas camadas, dossel superior (árvores) e dossel inferior (gramíneas e arbustos). Essas camadas competem por água e luz solar, uma vez que enquanto o dossel superior recebe a maior incidência de luz solar, o dossel inferior tem uma maior facilidade de retirar água do solo.

**ii. Captura de água:** A captura de água pela planta é comandada pela distribuição de raízes pelo perfil do solo e esta distribuição é parametrizada (beta) e separada para cada dossel.

**iii. Solo:** O solo é dividido em camadas para capturar as variações de temperatura e de umidade em várias escalas temporais (diurna, sazonal e interanual).

**iv. Fluxo de água:** O fluxo vertical de água no solo responde a gravidade e ao potencial de água do solo que varia de acordo com a umidade e textura do solo.

**v. Vapor de água:** As trocas de vapor de água e carbono entre o dossel e a atmosfera é controlado pela fotossíntese e a condutância estomática.

**vi. Fotossíntese:** A fotossíntese é limitada pela luz solar e pela enzima Rubisco.

**vii. Condutância:** A condutância estomática é calculada em relação a concentração de CO<sub>2</sub> na superfície da folha e é definida como a diferença entre a concentração de vapor entre a folha e o ar exterior, a inclinação (m) e o intercepto (b) da relação condutância-fotossíntese.

**viii. Precipitação:** De um modo simplificado, a precipitação que atinge o solo é dividida entre o escoamento superficial (grunoff) e a água armazenada para infiltração e evaporação (Wpud). Essa divisão está relacionada a lâmina de água no Wpud e a lâmina máxima suportada. Após a divisão, são calculadas as taxas de evaporação do Wpud e da primeira camada do solo, assim como a taxa de transpiração da vegetação. Em seguida, ocorre a infiltração da água armazenada no Wpud no solo e a água que não fica retida é considerada como escoamento de subsuperfície (gdrain) (Figura 1).

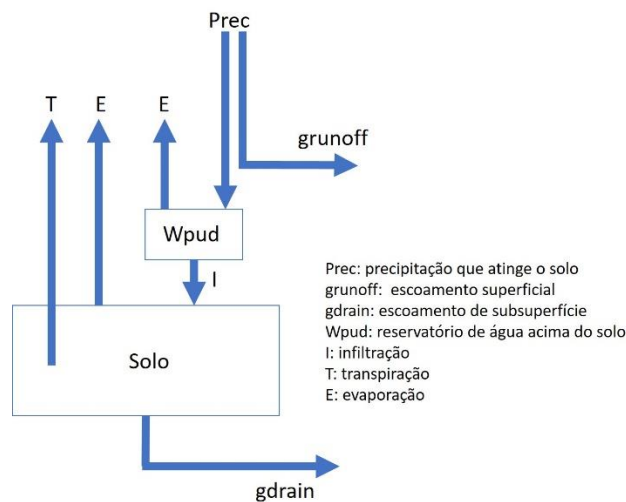


Figura 1. Dinâmica da água no solo simulada pelo modelo INLAND (*Integrated Model of Land Surface Processes*).

### 2.2.2 THMB

O THMB é um modelo hidrológico desenvolvido por Coe et al. (2002) e aperfeiçoado por Coe et al. (2008). Esse modelo simula os processos hidrológicos de superfície terrestre como a vazão dos rios e o nível e a extensão das planícies de inundação. Para tanto, este modelo necessita dos mapas de topografia (derivados do mde) e dos dados de escoamento (grunoff e gdrain) gerados pelo modelo INLAND. Como descrito em Coe et al. (2002), esse modelo possui três reservatórios, um para o escoamento superficial ( $W_s$ ), um para o escoamento de subsuperfície ( $W_d$ ) e outro para o rio ( $W_r$ ). Os reservatórios de escoamento superficial e de subsuperfície são fomentados diretamente pelos fluxos de saída do INLAND. Durante a simulação do THMB, a água presente nesses reservatórios (superficial e subsuperficial) é movida aos poucos para o rio e assim, todo o fluxo de água do modelo é controlado pelo tempo de residência de cada reservatório. As equações que descrevem o processo que ocorre nos reservatórios estão apresentadas a seguir:

$$\frac{d(W_s)}{dt} = grunoff - \frac{W_s}{T_s}$$

$$\frac{d(W_d)}{dt} = gdrain - \frac{W_d}{T_d}$$

$$\frac{d(W_r)}{dt} = \left( \frac{W_s}{T_s} + \frac{W_d}{T_d} \right) - \frac{W_r}{T_r} + \sum F_{in}$$

em que  $T_s$ ,  $T_d$ ,  $T_r$  são, respectivamente, o tempo de residência dos reservatórios superficial, subsuperficial e do rio, e  $\sum F_{in}$  é o somatório dos fluxos de água das células a montante. Os tempos de residência do escoamento superficial e subsuperficial ( $T_s$  e  $T_d$ ) são parâmetros do modelo e o tempo de residência do rio ( $T_r$ ) é definido como a razão entre a distância ( $d$ ) entre a célula atual e a célula a jusante e a velocidade efetiva do rio ( $u$ ), conforme apresentado a seguir:

$$T_r = d/u$$

A distância  $d$  pode ser calculada como a distância em linha reta ( $L$ ) entre os centros das células multiplicado pela sinuosidade do rio ( $C_s$ ) (que é derivado do mapa de fluxo) e a velocidade efetiva ( $u$ ) é proporcional ao produto da energia de inclinação ( $S$ ) e o raio hidráulico do rio ( $R$ ). Logo, expressões para  $d$  e  $u$  são, respectivamente, dadas por:

$$d = LC_s$$

$$u = u_0(RS)^{0,5}$$

em que  $u_0$  é a velocidade efetiva mínima do rio (0,27 m/s). A energia de inclinação ( $S$ ) é a razão entre o gradiente topográfico ( $i_c$ ) e o gradiente de referência ( $i_0 = 0,5 \times 10^{-4}$  m/m) e o raio hidráulico ( $R$ ) é a razão do perímetro do rio ( $P_r$ ) pelo perímetro de referência ( $P_0 = 60$  m), ou seja,

$$S = i_c/i_0$$

$$R = P_r/P_0$$

Por sua vez, o perímetro do rio ( $P_r$ ) é calculado em função da área acumulada ( $A$ ) conforme definido por Coe et al. (2008):

$$P_r = 0,421A^{0,592}$$

Como visto nas definições anteriores, o THMB não está adaptado para simular a vazão levando em consideração um aquífero. Porém, esse é justamente o caso da região de estudo deste trabalho (oeste da Bahia). Por isso, é necessário fazer uma

ampliação do modelo THMB, adicionando um reservatório para o aquífero ( $W_a$ ) junto com o seu respectivo tempo de residência ( $T_a$ ). Nesse contexto, o  $gdrain$  será dividido de acordo com uma fração de partição ( $dpart$ ), que foi incluída como parâmetro do modelo, com uma parte indo para o reservatório de escoamento subsuperficial e a outra para o reservatório do aquífero. Com essa ampliação, as equações do modelo que controlam os reservatórios são alteradas conforme apresentado a seguir:

$$\frac{d(W_s)}{dt} = grunoff - \frac{W_s}{T_s}$$

$$\frac{d(W_d)}{dt} = (dpart)gdrain - \frac{W_d}{T_d}$$

$$\frac{d(W_a)}{dt} = (1 - dpart)gdrain - \frac{W_a}{T_a}$$

$$\frac{d(W_r)}{dt} = \left( \frac{W_s}{T_s} + \frac{W_d}{T_d} + \frac{W_a}{T_a} \right) - \frac{W_r}{T_r} + \sum F_{in}$$

em que se pressupõe que o tempo de residência do aquífero ( $T_a$ ) é muito maior que os outros tempos de residência ( $T_s$  e  $T_d$ ), e o reservatório do aquífero ( $W_a$ ) irá acumular um maior volume de água e ter uma participação ( $W_a/T_a$ ) maior e mais constante na vazão. Essa ampliação só ocorre para as células do modelo em que se é configurada a existência do aquífero, para as demais células são consideradas as equações sem essas alterações.

### 2.3 Calibração

Os modelos hidrológicos evoluíram em conjunto com a evolução do poder computacional (Sidle, 2021), partindo-se de modelos com poucas equações até os mais complexos, multidisciplinares e que fazem uso de um grande número de parâmetros. Estes parâmetros são dependentes das características da região estudada e necessitam de serem ajustados aos dados, desta forma, tornam-se vitais para a qualidade da simulação. O processo de ajuste dos parâmetros de um modelo hidrológico é uma etapa complexa, e que exige do pesquisador esforço e entendimento do comportamento do modelo e de seus parâmetros. Apesar dos avanços nos métodos de coleta e da quantidade de dados hidrológicos disponíveis

(Chen e Wang, 2018), ainda não é possível dispor de todas as informações necessárias aos modelos hidrológicos mais complexos. Isto porque esses modelos requerem um alto grau de detalhes para representar o ambiente (os quais são dependentes de propriedades físicas do solo, topografia, umidade do solo, aquífero, dentre outras descrições) (Estes et al., 2013).

O ajuste dos parâmetros pode ser realizado por meio de um processo denominado de calibração, que contorna tal adversidade, fazendo uso de algumas informações disponíveis e tentando identificar as informações faltantes. Segundo Pechlivanidis et al. (2011), a calibração pode ser definida como o processo de seleção de valores adequados de parâmetros de modo que o comportamento hidrológico possa ser simulado o mais próximo possível aos dados reais. Os parâmetros podem assumir infinitos valores, uma vez que no modelo hidrológico se tem mais parâmetros do que observações disponíveis, e assim, alguns destes conjuntos de valores podem levar a soluções que atenderão as equações, mas que não representarão o fenômeno estudado. O ajuste dos parâmetros pode ser realizado por um processo manual ou automático. O ajuste manual é feito por tentativa e erro, porém, apesar de uma técnica simples, exige repetidas execuções do modelo e repetidas análises dos resultados e elevada experiência do usuário (Tucci, 1998), além de que a complexidade desses modelos e o grande número de parâmetros dificultam muito essa tarefa. Alguns estudos fizeram uso da calibração manual (Alvarenga et al., 2016a; Zhang et al., 2018). Em contrapartida, a calibração automática é o caminho mais viável para situações em que o conhecimento a respeito da área estudada é incipiente. Dentre os algoritmos de calibração automática, pode-se citar o método de Monte Carlo (Zhang et al., 2016), o método baseado na probabilidade da incerteza da estimativa (Freer et al., 1996), o algoritmo genético (Chanapathi e Thatikonda, 2020; Ridwansyah et al., 2020; Seibert, 2000; Moghadam et al., 2021; Serrão et al., 2021), gradiente reduzido generalizado (Ayvaz e Gurarlan, 2017) e esquema de otimização global da estratégia de evolução (Hansen e Hansen, 2006).

A calibração de modelos é um ramo antigo da hidrologia, assim como, os estudos a respeito das complexidades relacionadas a esse processo. Desde a década de 70, já existem pesquisas com intuito de identificar as melhores formas de abordar esse tipo de problema (IBBITT, 1970; Johnston e Pilgrim, 1976; Pickup, 1977). Estes estudos indicaram que as heurísticas, as quais usam as informações do passado para

decidir os futuros passos, seriam as mais eficazes no processo de calibração. Ademais, a estrutura não linear dos modelos e a impossibilidade de analisar todas as possíveis soluções fizeram com que as heurísticas se sobressaíssem ainda mais nessa tarefa. Dentre os vários modelos de heurísticas estudados com esta finalidade, os que mais se destacaram foram os algoritmos evolutivos (AEs) (Wang, 1991; Duan et al., 1992; Nicklow et al., 2010), principalmente, o subconjunto denominado de algoritmo genético.

No entanto, apesar de uma extensa classe de AEs, pesquisas recentes demonstraram que os AEs atuais possuem desempenhos muito similares, e, portanto, nenhum deles pode ser considerado superior (Arsenault et al., 2013; Piotrowski et al., 2017; Theuer et al., 2017; Mostafaie et al., 2018). Apesar da decisão do algoritmo ser um passo importante para a calibração, também existem outros objetos de escolha a serem feitos para garantir a eficiência desse processo, como, por exemplo, quais e quantas medidas de erro a serem utilizadas. No entanto, essas decisões parecem ser dependentes do modelo e da situação calibrada.

A métrica escolhida deve ser capaz de representar de modo satisfatório o comportamento do processo hidrológico calibrado. Em geral, algumas das métricas mais utilizadas são o erro absoluto médio (*Mean Absolute Error* - MAE), o erro quadrático médio (*Mean Squared Error* - MSE), raiz quadrada do erro quadrático médio (*Root Mean Squared Error* - RMSE), o coeficiente de determinação ( $R^2$ ) e razão do desvio-padrão (*observations standard deviation ratio* – RSR, que obtida por meio da razão entre o RSME e o desvio-padrão dos valores observados). Cada uma destas métricas possuem suas particularidades. Por exemplo, o coeficiente de determinação é insensível às diferenças aditivas e proporcionais, o erro absoluto médio é muito sensível a valores extremos e o erro quadrático médio coloca mais ênfase em valores extremos. Desta maneira, não é possível definir uma métrica que seja adequada a todas as situações problema (Gupta et al., 1998).

No entanto, apesar de simples, estas medidas podem não contemplar todas as especificidades de um processo de calibração. O coeficiente de eficiência Nash-Sutcliffe (NSE) foi definido por Nash e Sutcliffe (1970) e tem sido uma das métricas amplamente utilizadas na área de modelagem hidrológica (Pushpalatha et al., 2012; Santos et al., 2018; Song, 2020). O coeficiente NSE é dado por:

$$NSE = 2\alpha r - \alpha^2 - \delta^2$$

em que  $r$  é o coeficiente de correlação linear entre os valores observados e simulados,  $\alpha = \frac{\sigma_s}{\sigma_o}$  sendo  $\sigma_s$  e  $\sigma_o$ , respectivamente, os desvios-padrão dos valores simulados e observados, e  $\delta = \frac{\mu_s - \mu_o}{\sigma_o}$  sendo  $\mu_s$  e  $\mu_o$ , respectivamente, as médias dos valores simulados e observados. Dessa forma, é possível perceber que esta medida contempla a correlação, o viés e a variabilidade dos valores simulados e observados, e então, representando de modo mais adequado estatisticamente estes dois conjuntos de valores.

No entanto, Gupta et al. (2009) demonstraram que a variabilidade da vazão não é corretamente contabilizada na métrica NSE. Diante desta adversidade, Gupta et al. (2009) e Kling et al. (2012) propuseram a medida de eficiência de Kling-Gupta (KGE) que combina as mesmas informações estatísticas da NSE, porém, contorna o problema detectado na mesma. A KGE é definida por:

$$KGE = 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2}$$

em que  $\beta = \frac{\mu_s}{\mu_o}$  sendo  $\mu_o$  a média dos valores observados. Nos últimos anos, a métrica KGE tem sido progressivamente utilizada para calibração de modelos hidrológicos (Becker et al., 2019; Quintero et al., 2020; Lee e Choi, 2021).

O processo de calibração poderia ser simplificado caso seu objetivo fosse apenas a reprodução dos dados observados, sem que houvesse a preocupação dos valores e das interpretações dos parâmetros encontrados. No entanto, nesses casos a calibração nem sempre poderia ser classificada como uma calibração consistente. Uma calibração consistente é aquela onde os parâmetros calibrados estão de acordo com os conceitos hidrológicos, que sejam independentes dos dados de entrada e que faça o modelo ter um bom desempenho para períodos diferentes dos dados o qual o modelo foi calibrado. Isto é mais uma das questões envolvendo o processo de calibração (Gupta et al., 1999; Martinez e Gupta, 2011; Kollat et al., 2012; Shafii e Tolson, 2015), uma vez que a calibração também é uma ferramenta de aprendizado sobre os parâmetros em si e é responsável por extrair dos parâmetros as características da situação calibrada.

### 2.3.1 Optis

O processo de calibração torna-se complexo pois, como mencionado anteriormente, não existe unicidade no conjunto de parâmetros ótimos, ou seja, múltiplos conjuntos de parâmetros ótimos podem ser indicados como o melhor resultado. Essas questões levaram os pesquisadores a inserirem o conceito de fronteira de Pareto nos algoritmos evolucionários, que são fronteiras no espaço de busca em que não existe nenhuma solução melhor que as soluções que estão na fronteira e que as soluções que pertencem a ela são equivalentes.

Os primeiros algoritmos a utilizarem esse conceito foram o *Non-dominated Sorting Genetic Algorithm* (NSGA), o *Niched-Pareto Genetic Algorithm* (NPGA) e o *Multiobjective Genetic Algorithm* (MOGA). Como esses algoritmos não apresentavam uma única solução, mas sim um conjunto delas, definições de efetividade e de eficiência foram introduzidas (Zitzler et al., 2000). A efetividade pode ser decomposta em duas partes: (i) quão perto as soluções do algoritmo estão da fronteira de Pareto ótima e (ii) quão espalhadas por essa fronteira elas estão. Já, a eficiência indica quão rápido as melhores soluções são encontradas.

Visando aprimorar a efetividade e a eficiência dos algoritmos surgiu uma segunda geração de AEs que implementaram os conceitos de elitismo e de ordenação eficiente de indivíduos não-dominados (Reed et al., 2013). Elitismo consiste em sempre manter os melhores indivíduos de uma geração para a outra e a ordenação eficiente de indivíduos não-dominados consiste numa forma de selecionar os indivíduos que maximizem a diversidade dos indivíduos. Exemplos de AEs da segunda geração são: *Strength Pareto Evolutionary Algorithm* (SPEA), *Strength Pareto Evolutionary Algorithm 2* (SPEA2), *Pareto Archived Evolution Strategy* (PAES), *Non-dominated Sorting Genetic Algorithm II* (NSGA-II), *Niched Pareto Genetic Algorithm 2* (NPGA 2), *Pareto Envelope-based Selection Algorithm* (PESA). Com o passar do tempo inúmeros outros algoritmos foram surgindo e segundo Coello e Cortés (2005), desde a primeira aparição de um AE em 1985 até o ano de 1995, o número de artigos nessa área era pequeno. Entretanto, depois de 1995, o crescimento de artigos na área foi exponencial (são mais de 1450 artigos).

O Optis, uma metodologia desenvolvida por Varejão et al. (2013), é um algoritmo de otimização multi-objetivo baseado no algoritmo genético NSGA-II (*Nondominated*

*Sorted Genetic Algorithm II*) proposto por Deb et al. (2002). O Optis recebe como entrada uma configuração e uma lista de parâmetros contendo nome, limite inferior e superior de cada parâmetro. A configuração define um número de conjunto de parâmetros que serão testados em cada iteração e o número de iterações que serão realizadas. Para cada conjunto de parâmetros, o Optis configura e executa o modelo e posteriormente, classifica o resultado de acordo com as funções objetivo definidas. Ao passo que todos os conjuntos de parâmetros de uma iteração estão classificados, os melhores são escolhidos e uma nova iteração se inicia. Ao fim da última iteração o melhor (ou melhores, dependendo do número de funções objetivo definidas) conjunto de parâmetros é apresentado como resultado (Figura 2).

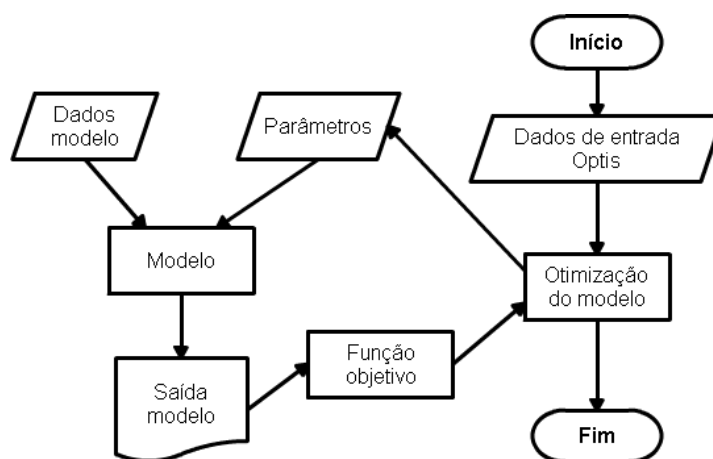


Figura 2. Estrutura organizacional do Optis.

As técnicas baseadas na genética são utilizadas para definir os conjuntos de parâmetros (indivíduos) utilizados em cada iteração. Para a primeira iteração são escolhidos valores aleatórios dentro do limite de cada parâmetro. A partir da segunda, os melhores indivíduos classificados na iteração anterior são “cruzados” (partes de dois indivíduos são usadas para gerar novos indivíduos) para formar uma nova população. Alguns indivíduos ainda recebem uma “mutação” (alteração de algum valor de modo aleatório).

A cada iteração, um conjunto de parâmetros é classificado por meio das funções objetivo. O algoritmo pode conter uma (mono-objetivo) ou mais (multi-objetivo) funções. A utilização de diferentes funções são modos diferentes de comparar os resultados simulados com os dados observados. Assim, o número e tipo

de função objetivo pode alterar o resultado do processo de calibração. Em calibrações mono-objetivo um único conjunto de parâmetros é escolhido como o resultado final, enquanto que, em calibrações multi-objetivas um grupo de conjuntos (chamados de fronteira de Pareto) é escolhido como resultado.

### 3 Material e métodos

#### 3.1 Aquífero Urucuia

A região de estudo é uma área de drenagem situada no oeste da Bahia. O oeste da Bahia é formado por três grandes bacias hidrográficas, as bacias do Rio Grande, Rio Correntes e Rio Carinhanha. Estas bacias estão localizadas sobre o Sistema Aquífero Urucuia (SAU) (Figura 3).

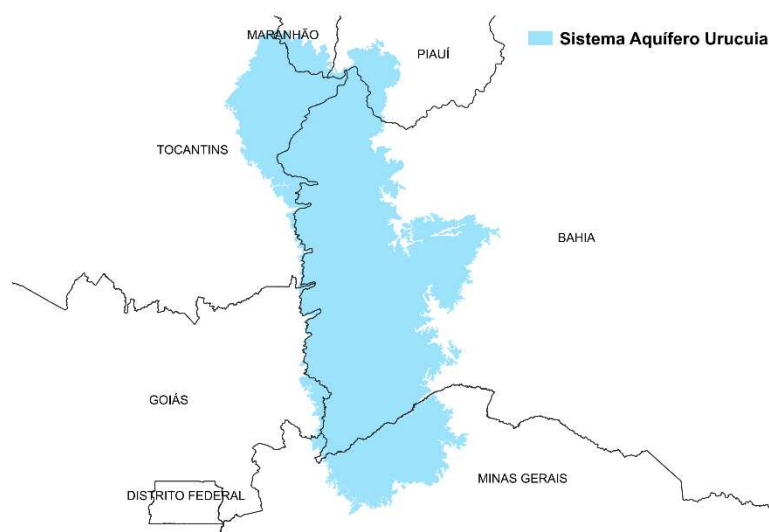


Figura 3. Representação do Sistema Aquífero Urucuia (SAU).

A área de drenagem é relativa à estação 46543000 da Agência Nacional de Águas (ANA). Esta estação está localizada no Rio das Ondas, um afluente do Rio Grande, na latitude -12,14 e longitude -45,10 (Figura 4).

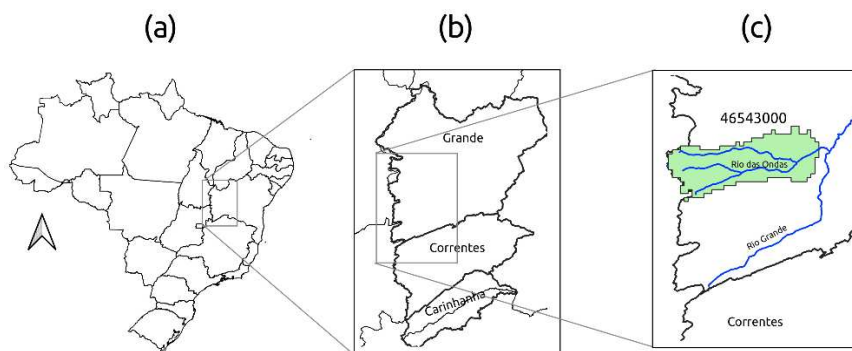


Figura 4. (a) Território brasileiro com destaque a Região do oeste da Bahia, (b) Bacias que formam o Sistema Aquífero Uruçuia (bacias do rio Grande, rio Correntes e rio Carinhanha), (c) Localização da estação fluvial automática 46543000.

A coleta de dados de vazão da estação 46543000 pela ANA começou em 1977. Até o ano de 2015 (período de estudo deste trabalho) a porcentagem de falha da série de dados é de 4%, sendo que 76% dos dados coletados estão persistidos, ou seja, é uma série bem confiável e sem muitas falhas, o que é importante para o estudo de calibração. A ANA fornece apenas a série de vazão e o tamanho da área de drenagem, mas não o mapa da área. Para gerar esse mapa foi utilizado o modelo digital de elevação (mde, que possui uma resolução espacial de 90 metros) da *Shuttle Radar Topography Mission* (Farr et al., 2007), a localização da estação e o *software Geographic Resources Analysis Support System* (GRASS GIS).

O GRASS GIS é um *software* livre e de código aberto de geoprocessamento e modelagem espacial mantido pela *Open Source Geospatial Foundation* (OSGeo). Com a função *watershed* do GRASS GIS foi possível utilizar o mde para gerar os mapas de direção, fluxo e área acumulada. O mapa de direção indica qual a direção do escoamento em cada ponto do mapa; o mapa de área acumulada indica quanto pontos escoam, direta ou indiretamente, para cada ponto do mapa; e o mapa de fluxo identifica os caminhos de maior escoamento (possíveis rios). Ao utilizando esses mapas e a localização da estação, a função *water.outlet* permite definir a área de drenagem. A área gerada (Figura 4) possui uma extensão de 5.369 km<sup>2</sup>, 0,2% menor que a extensão informada pela ANA, que estima que essa estação possui uma área de 5.380 km<sup>2</sup>.

### 3.2 Dados climáticos

Os dados climáticos utilizados nas simulações foram produzidos por Xavier et al. (2015). Esse banco de dados possui mapas de precipitação, temperatura, radiação solar, velocidade do vento para o período de 1980 a 2015. Esse banco foi gerado a partir da interpolação dos dados de 3.625 estações meteorológicas fornecidos pelo Instituto Nacional de Meteorologia (INMET), a ANA e o Departamento de Águas e Energia Elétrica de São Paulo (DAEE). Desta interpolação foi gerado um mapa de precipitação com uma resolução espacial de  $0,25^{\circ} 8 \times 0,25^{\circ}$ .

A precipitação média da área de drenagem da estação 46543000 no período de 1980 a 2015 (Figura 5) mostra uma região com um bom índice de precipitação, sendo a precipitação média desse período de 3,32 mm/dia. Durante esse período a precipitação média atingiu um pico de 5 mm/dia em 1985 e uma mínima de 1,9 mm/dia em 2007. Mas ao analisar o gráfico é possível verificar que existe uma maior variabilidade no início do período (entre 1980 e 1993) em relação ao restante da série. É também no início da série que estão os maiores valores anuais de precipitação. Esses fatores podem indicar que a precipitação da região está se modificando, como discutido por Pousa et al. (2019).




Figura 5. Série anual de precipitação (mm/dia) nas áreas de drenagem da estação 46543000, extraídas do mapa de precipitação produzido por Xavier et al. (2015), considerando o período de 1980 a 2015.

De fato, ao analisar as décadas separadamente (Tabela 2), é possível notar que a precipitação vem diminuindo década a década, o que pode dar a ideia de uma provável tendência de diminuição ao longo dos anos. Por exemplo, a média da última

década de dados foi de 0,85 mm/dia menor que dos primeiros 10 anos da série, representando uma diminuição de 23%.

Tabela 2. Precipitação média (mm/dia) nas áreas de drenagem da estação 46543000 considerando o período de 1980 a 2015.

Período	1980 a 1989	1990 a 1999	2000 a 2009	2010 a 2015
Precipitação média (mm/dia)	3,70	3,38	3,16	2,85

### 3.3 Dados de uso do solo

Os dados de uso do solo foram produzidos por Pimenta et al. (2021) e mostram que a região do oeste da Bahia está passando por um elevado crescimento agrícola (Figura 6). Em toda a região, a porcentagem de cobertura de vegetação natural foi de 90% em 1990 para 60% em 2015. O oeste da bacia do rio Grande (onde está localizada a estação 46543000) é umas das áreas mais afetadas pela expansão agrícola da região.

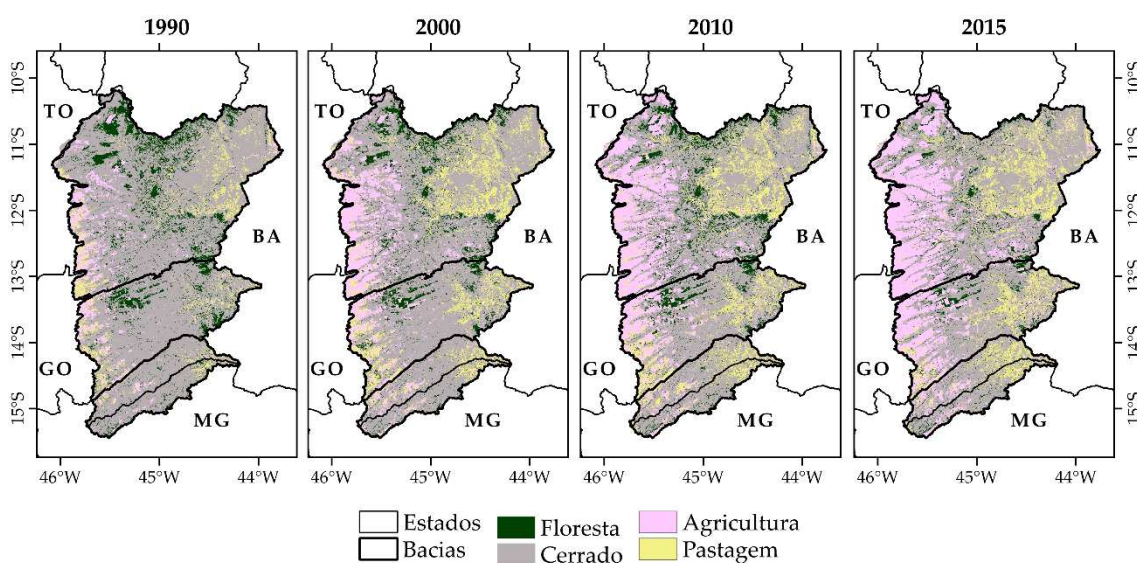


Figura 6. Mudança de uso do solo no oeste da Bahia entre 1990 e 2015.

Na área de drenagem da estação 46543000, a porcentagem de cobertura natural (Floresta e Cerrado) foi de 78% em 1990 para 47% em 2015 (Figura 7). A taxa de desmatamento nesse período foi quase que constante, com um valor médio de 1,2% ao ano. A Tabela 3 mostra como estava a porcentagem de cada classe (Floresta, Cerrado, Pastagem e Agricultura) nos anos de 1990, 2007 e 2015.




Figura 7. Porcentagem da área de vegetação natural no período entre 1990 e 2015 para as áreas de drenagem da estação 46543000.

Tabela 3. Porcentagem da área de drenagem da estação 46543000 com floresta, cerrado, pastagem e agricultura nos anos de 1990, 2007 e 2015.

Ano	Floresta (%)	Cerrado (%)	Pastagem (%)	Agricultura (%)
1990	15	63	5	17
2007	13	46	1	40
2015	9	38	1	52

### 3.4 Modelos hidrológicos

Para realizar a simulação das vazões foram acoplados dois modelos, o INLAND (*Integrated Model of Land Surface Processes*) e o THMB (*Terrestrial Hydrology Model with Biogeochemistry*). O INLAND é o responsável por fazer o balanço hídrico e o THMB por controlar o tempo do deslocamento e a formação dos fluxos de água. O INLAND está disponível em <http://www.ccst.inpe.br/projetos/inland/>.

### 3.4.1 Acoplamento INLAND e THMB

Para a calibração foi feito um acoplamento dos modelos INLAND e THMB. O INLAND recebe como entrada os dados climáticos, simula os processos da interação atmosfera × biosfera e gera os escoamentos de superfície e de sub-superfície. Esses dados de escoamento junto com os mapas topográficos derivados do mde são passados para o THMB que simula o fluxo de água em cada reservatório do modelo e determina os valores de vazão em cada célula (Figura 8).




Figura 8. Fluxograma da sequência de execução dos modelos INLAND (*Integrated Model of Land Surface Processes*) e THMB (*Terrestrial Hydrology Model with Biogeochemistry*).

O INLAND possui uma limitação de não fazer um mapeamento dinâmico do uso do solo que possa variar no tempo. Portanto, com o intuito de incluir os efeitos causados pela mudança na cobertura do solo, o modelo INLAND foi executado, paralelamente, quatro vezes para simular o escoamento para cada classe de cobertura do solo. Os resultados obtidos serão ponderados (célula a célula) pela porcentagem da área coberta por cada classe e depois repassados ao THMB (Figura 9).

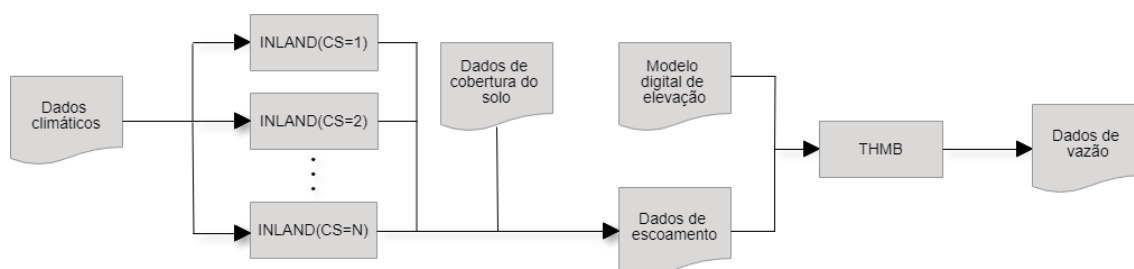


Figura 9. Fluxograma da sequência de execução dos modelos, utilizando uma configuração do INLAND (*Integrated Model of Land Surface Processes*) para cada classe de cobertura do solo.

Foram selecionados para a calibração, os parâmetros do INLAND relacionados a evapotranspiração ( $v_{max}$ ,  $coef_m$ ,  $\beta_1$  e  $\beta_2$ ), e infiltração de água no solo (SHC) e os parâmetros de tempo de residência (TR) e partição ( $d_{part}$ ) do escoamento de sub-superfície do THMB (Tabela 4).

Tabela 4. Descrição dos parâmetros calibrados dos modelos INLAND (*Integrated Model of Land Surface Processes*) e THMB (*Terrestrial Hydrology Model with Biogeochemistry*).

Nome	Descrição	Unidade de medida
$\beta_1$	Distribuição vertical de raízes do dossel inferior	adimensional
$\beta_2$	Distribuição vertical de raízes do dossel superior	adimensional
$coef_m$	Coeficiente m relacionado a condutância estomática	adimensional
$d_{part}$	Partição do escoamento de subsuperfície	adimensional
SHC	Condutividade hidráulica saturada do solo	$m\ s^{-1}$
T	Tempo de residência da água no reservatório	s
$v_{max}$	Capacidade de atividade máxima da enzima Rubisco	$mol\ CO_2\ m^{-2}s^{-1}$

A importância e funcionalidade dos parâmetros que ainda não foram descritas anteriormente:

- i. **beta1 e beta2 ( $\beta$ ):** A distribuição vertical de raízes no solo para cada dossel é obtida através do modelo de Jackson et al. (1997):

$$y = \beta^d$$

em que  $y$  é a proporção cumulativa da raiz da superfície do solo até a profundidade  $d$  (em centímetros).

- ii. **coefm:** O parâmetro coefm está associado a condutância estomática, que controla a eficiência de uso da água em relação à fotossíntese. Pelo modelo de Ball e Berry (1997) usado no INLAND, a condutância estomática ( $g_s$ ) se relaciona linearmente com a assimilação de  $\text{CO}_2$  ( $A$ ) por meio de:

$$g_s = \text{coefm} A \frac{H_s}{C_s} + \text{coefb}$$

em que  $H_s$  é a humidade relativa na superfície da folha e  $C_s$  é fração de  $\text{CO}_2$  na superfície da folha. A inclinação coefm representa a influência da atividade fotossintética da folha sobre a condutância estomática, dessa forma, é possível verificar que a condutância estomática controla a eficiência de uso da água em relação à fotossíntese.

- iii. **dpart:** O parâmetro dpart não possui interpretação física, apenas representa a partição do fluxo de drenagem.
- iv. **SHC:** O parâmetro SHC está associado a capacidade de transporte de água, solutos e substâncias químicas no solo. A condutividade hidráulica saturada do solo é calculada por meio da equação de Campbell (1985):

$$SHC = SC_s \left( \frac{\psi_e}{\psi_m} \right)^{2+3/b} = SC_s \left( \frac{\theta}{\theta_s} \right)^{2b+3}$$

$$\psi_m = \psi_e \left( \frac{\theta}{\theta_s} \right)^{-b}$$

em que  $\psi_e$  é o potencial de entrada de ar,  $SC_s$  é a condutividade saturada do solo,  $\theta$  é o teor de água,  $\theta_s$  é o teor de água e  $b$  é o expoente da equação associado a liberação de umidade.

- v. **vmax:** O parâmetro vmax se refere à capacidade fotossintética da planta, ou seja, é a capacidade de carboxilação da enzima RuBisCO, o qual catalisa a reação de  $\text{CO}_2$  durante seu processo de assimilação nas folhas. RuBisCO consiste na molécula receptora de  $\text{CO}_2$  no ciclo de Calvin. A

limitação de assimilação bruta de carbono dada pela taxa de carboxilação da rubisco ( $J_c$ ) se relaciona com a capacidade fotossintética por meio de:

$$J_c = \begin{cases} \frac{vmax(c_i - \Gamma_*)}{c_i + K_c \left(1 + \frac{o_i}{K_o}\right)}, & \text{se } C3 \\ vmax, & \text{se } C4 \end{cases}$$

em que  $K_c$  e  $K_o$  são constantes de Michaelis-Menten, respectivamente, para  $CO_2$  e  $O_2$  (que variam com a temperatura),  $c_i$  e  $o_i$  são as concentrações, respectivamente, de  $CO_2$  e  $O_2$  dentro da folha e  $\Gamma_*$  é o ponto de compensação do  $CO_2$ .

Os parâmetros  $vmax$  e  $coefm$  foram calibrados separadamente para cada classe de vegetação (árvores, arbustos, gramínea C3 e C4 e cultura agrícola). O parâmetro  $SHC$  foi separado por uso do solo (floresta, cerrado, pastagem, agricultura). O parâmetro  $TR$  foi separado para reservatório de subsuperfície e aquífero. No total, foram calibrados vinte e três parâmetros.

O Optis foi configurado com 90 gerações de 48 indivíduos, sendo que cada indivíduo executa de 1980 a 2015. Os primeiros doze anos foram utilizados para a inicialização dos modelos. O período restante foi dividido em calibração (1992 a 2007) e validação (2008 a 2015). A função objetivo utilizada foi a medida de eficiência de Kling-Gupta (KGE) proposta por Gupta et al. (2009) e Kling et al. (2012). Os valores dos parâmetros não calibrados e utilizados neste estudo foram os valores padrões reportados por Foley et al. (1996).

Também se avaliou a calibração e validação por meio de medidas descritivas dos dados simulados e observados e por meio do ajuste do modelo estatístico definido a seguir:

$$y_{obs} = \beta_0 + \beta_1 y_{sim} + e$$

em que  $y_{obs}$  e  $y_{sim}$  são, respectivamente, os valores observados e simulados do modelo INLAND,  $\beta_0$  e  $\beta_1$  são os parâmetros do modelo representando, respectivamente, a constante da regressão e o coeficiente de regressão,  $\beta_1$  indica se houve superestimação ( $\beta_1 < 1$ ) ou subestimação ( $\beta_1 > 1$ ) dos valores simulados e erro aleatório.

A diferença entre as séries temporais observada e simulada, em todo o período observado, foi avaliada por meio do teste Kolmogorov-Smirnov para duas séries temporais (Durbin 1961) cuja hipótese nula é definida como igualdade entre as séries, o que auxilia na avaliação da qualidade da calibração.

Todo o processo de calibração foi realizado em uma *workstation* DELL R730 XD com dois processadores intel Xeon E52698 de 32 núcleos cada e 256 GB de memória ram.

### **3.5 Experimento numérico**

A primeira etapa do estudo era encontrar uma configuração (valores para os parâmetros) que ajustasse os modelos a região de estudo. Para tanto foi realizada uma calibração dos modelos para o período de 1992 a 2007. Após a calibração, o resultado foi validado no período de 2008 a 2015. Desta maneira, 66% dos dados foram utilizados para a calibração e o restante para a validação. Utilizando o conjunto de parâmetros calibrados e validados, foram realizadas simulações em três cenários distintos, visando entender o efeito do desmatamento no ciclo hidrológico da região e o papel do aquífero nessa situação:

- Cenário padrão, em que a simulação considerou as mudanças de uso do solo e de o aquífero.
- Cenário sem aquífero, em que a simulação considerou as mudanças de uso do solo, mas o THMB foi configurado para não ter aquífero.
- Cenário sem desmatamento, em que a simulação considerou o aquífero, mas manteve o uso do solo constante e igual ao de 1990.

### **3.6 Avaliação do impacto do desmatamento na vazão**

Primeiramente, foi avaliado o efeito do desmatamento na vazão da região comparando-se a série dos valores simulados da vazão do cenário padrão e do cenário sem desmatamento, considerando o período entre 1992 a 2015. O teste Kolmogorov-Smirnov para duas séries temporais (hipótese nula é definida como igualdade entre as séries) foi utilizado para verificar a diferença estatística entre a

série de valores no cenário padrão e no cenário sem desmatamento visando identificar se houve ou não impacto na vazão. Havendo alteração na vazão, avaliou-se os valores de drenagem profunda e de escoamento superficial por meio de uma regressão linear múltipla, em ambos os cenários, visando entender quais dos dois componentes causaram o aumento ou a diminuição da vazão.

### **3.7 Avaliação da contribuição do aquífero para a regulação da vazão**

Primeiramente, foi avaliado a contribuição do aquífero para a vazão da região comparando-se a série e medidas descritivas dos valores simulados da vazão do cenário padrão e do cenário sem aquífero, considerando o período entre 1992 a 2015. As medidas descritivas utilizadas foram a vazão mínima esperada em 90% do tempo ( $Q_{90}$ ), a vazão mínima esperada em 10% do tempo ( $Q_{10}$ ) e a média da vazão. O teste Kolmogorov-Smirnov para duas séries temporais (hipótese nula é definida como igualdade entre as séries) foi utilizado para verificar a diferença estatística entre a série de valores no cenário padrão e no cenário sem o aquífero visando identificar se houve ou não impacto na vazão.

Além disso, com intuito de verificar qual dos dois, desmatamento ou aquífero, tem um impacto maior na vazão na região de estudo foi calculado a distância de *Dynamic Time Warping* (DTW - Pree et al., 2014) entre as séries sem desmatamento e sem aquífero e a série do cenário padrão, aquela série que apresentar maior distância, o fator relacionado a ela será considerado de maior impacto na vazão.

## **4 Resultados e Discussão**

### **4.1. Calibração**

Na área relativa à Bacia do Rio Grande existe uma grande carência de estações fluviométricas, mas dentre elas podemos citar a estação 46543000. Esta estação está localizada na Fazenda Redenção no município de Barreiras e teve, aproximadamente, 31% de área desmatada entre os anos de 1990 e 2015. Diante da importância agrícola desta região e vislumbrando o estudo do impacto da expansão agrícola da região do oeste da Bahia, a modelagem hidrológica da região da estação 46543000 pode ser uma boa representação da conversão da vegetação natural para a agricultura devido a expansão agrícola ocorrida em todo o território do oeste baiano.

A primeira análise realizada foi a calibração do sistema para a estação 46543000 e esta foi feita utilizando o período de 1992 a 2007. Após 21 horas de execução e a experimentação de 1.440 conjuntos de parâmetros do modelo, o Optis indicou como melhor solução, baseada na medida KGE, o conjunto de parâmetros apresentado na Tabela 5.

Tabela 5. Solução ótima para os parâmetros dos modelos INLAND (*Integrated Model of Land Surface Processes*) e THMB (*Terrestrial Hydrology Model with Biogeochemistry*) encontrada pelo processo de calibração via Optis.

Parâmetro	Valor calibrado
coefm_arv	7,2435
coefm_arb	13,2030
coefm_c3	2,1717
coefm_c4	3,1073
coefm_agr	13,9804
vmax_arv	$1,6122 \times 10^{-5}$
vmax_arb	$5,1197 \times 10^{-5}$
vmax_c3	$2,7196 \times 10^{-5}$
vma_c4	$6,5455 \times 10^{-5}$
vmax_agr	$2,5292 \times 10^{-5}$
SHC_agr	$4,2432 \times 10^{-5}$
SHC_pas	$5,0886 \times 10^{-6}$
SHC_cer	$4,5255 \times 10^{-5}$
SHC_flo	$2,5304 \times 10^{-6}$
beta1	$9,6762 \times 10^{-1}$
beta2	$9,9785 \times 10^{-1}$
dpart	$2,5862 \times 10^{-1}$
T <sub>d</sub>	$1,2450 \times 10^6$
T <sub>a</sub>	$9,8778 \times 10^8$

coefm: Coeficiente m relacionado a condutância estomática; vmax: Capacidade de atividade máxima da enzima Rubisco; SHC: Condutividade hidráulica saturada do solo; beta1: Distribuição vertical de raízes do dossel inferior; beta2: Distribuição vertical de raízes do dossel superior; dpart: Partição do escoamento de subsuperfície; T<sub>d</sub>: Tempo de residência da água no reservatório de subsuperfície; T<sub>a</sub>: Tempo de residência da água no reservatório do aquífero; classes de vegetação: árvores (arv), arbustos (arb), gramínea C3 e C4 e cultura agrícola (agr).

De acordo com Foley et al. (1996), os valores padrão de vmax e coefm para floresta tropical são, respectivamente,  $6.5 \times 10^{-5} \text{ mol CO}_2 \text{ m}^{-2}\text{s}^{-1}$  e 10. Ao comparar estes valores aos encontrados neste estudo é possível verificar que os valores de vmax e coefm para a floresta ( $vmax\_arv = 1,6122 \times 10^{-5}$  e  $coefm\_arv = 7,2435$ ) são baixos, indicando uma fotossíntese limitada para esse tipo de vegetação. Isso pode ter sido consequência do fato do clima da região não ser propício para o desenvolvimento de árvores tropicais. Já os valores de vmax e coefm para cerrado

( $v_{max\_arb} = 5,1197 \times 10^{-5}$  e  $coefm\_arb = 13,2030$ ) são mais altos, indicando uma maior fotossíntese e, conseqüentemente, um maior desenvolvimento, o que é condizente com a região, onde a maior parte de vegetação natural é o cerrado. A gramínea C3 apresenta baixo valor de  $v_{max}$  ( $v_{max\_c3} = 2,7196 \times 10^{-5}$ ) enquanto que a gramínea C4 ( $v_{max\_c4} = 6,5455 \times 10^{-5}$ ) apresenta valor próximo ao padrão de Foley et al. (1997). Em relação ao parâmetro  $coefm$ , ambas as gramíneas apresentaram baixos valores ( $coefm\_c3 = 2,1717$  e  $coefm\_c4 = 3,1073$ ), indicando que os estômatos estejam mais fechados nestes dosséis e, conseqüentemente, as taxas de fotossíntese também mais baixas (Miner e Bauerle, 2017).

Em relação aos parâmetros de distribuição de raízes ( $\beta_1$  e  $\beta_2$ ), Jackson et al. (1997) reportaram que valores altos de  $\beta$  (acima de 0,98) correspondem a uma maior proporção de raízes em profundidade e baixos valores de  $\beta$  (abaixo de 0,98) têm maior proporção de raízes próximas à superfície do solo. Estes resultados corroboram os valores de distribuição de raízes encontrados neste estudo, sendo que o parâmetro referente ao dossel superior ( $\beta_2 = 9,9785 \times 10^{-1}$ ) é maior que o parâmetro referente ao dossel inferior ( $\beta_1 = 9,6762 \times 10^{-1}$ ).

Em relação ao parâmetro SHC, valores mais altos de condutividade hidráulica saturada do solo (SHC) eram esperados para a vegetação natural (floresta e cerrado) e mais baixos para pastagem e agricultura. No entanto, o SHC da floresta foi calibrado com o menor valor ( $2,5304 \times 10^{-6}$ ) e o SHC da agricultura foi calibrado com um valor próximo ao do cerrado (respectivamente,  $4,2432 \times 10^{-5}$  e  $4,5255 \times 10^{-5}$ ). Segundo Dionizio e Costa (2019), os valores médios de condutividade hidráulica saturada para o oeste da Bahia é de  $4,5240 \times 10^{-5}$  para o cerrado,  $4,0198 \times 10^{-5}$  para a floresta,  $1,4160 \times 10^{-5}$  para a pastagem e  $1,7279 \times 10^{-5}$  para a agricultura. O valor calibrado para o cerrado ficou bem próximo ao valor médio de Dionizio e Costa (2019), mas os valores calibrados para floresta e agricultura foram distantes dos valores médios reportados. Já, em relação ao parâmetro  $de_{part}$ , tem-se que a divisão entre o fluxo de drenagem entre os reservatórios de subsuperfície e o de aquífero foram, respectivamente, de ~26% e ~74%. Com um tempo de residência do reservatório subsuperfície de, aproximadamente, 15 dias, e para o aquífero de, aproximadamente, de 31 anos.

Os valores inesperados de alguns parâmetros podem ser conseqüências do tamanho reduzido de variáveis observadas (Rajib et al., 2018, Széles et al., 2020). A

inclusão de mais variáveis, como evapotranspiração, no processo de calibração podem auxiliar na melhoria da consistência dos parâmetros (Rajib et al., 2018). No entanto, Mohammed et al. (2021) mostraram que um número limitado de variáveis pode ser suficiente para garantir um desempenho razoavelmente bom em calibrações hidrológicas. A deficiência na disponibilização de dados hidrológicos, como no caso do oeste da Bahia, pode dificultar a realização de um adequado programa de gestão e planejamento dos recursos hídricos (Moreira e Silva, 2010). O conhecimento da vazão e da disponibilidade de água da região é fundamental também para o planejamento de uso do solo (Pereira et al., 2003).

Apesar dos valores inconsistentes de alguns parâmetros, o conjunto de parâmetros obteve um índice de KGE de 0,83 para o período de calibração. Um valor elevado levando em conta que o valor máximo desse índice é 1, e considerado um bom resultado segundo Towner et al. (2019) e Thiemig et al. (2013), que classificaram valores acima de 0,75 como valores adequados para a calibração. Diante destes indícios, podemos inferir que o sistema conseguiu reproduzir bem a vazão observada para esse período nesta estação. Para validar o sistema, foi utilizado o período de 2008 a 2015, sendo que para esse período o KGE foi de 0,80, um valor ligeiramente mais baixo que o do período de calibração, o que já é esperado, e que pode ser explicado por uma maior diferença nas vazões mínimas que ocorrem nesse período (Figura 10). Apesar de menor, esse também é um valor elevado, indicando a boa capacidade dos modelos calibrados em reproduzir e prever a vazão durante todo o período. Ao analisar outras métricas de erro como NSE e RMR obtemos, respectivamente, aproximadamente 0,70 e 0,55. Moriasi et al. (2007) e Chanapathi e Thatikonda (2020) indicam que a simulação de um modelo pode ser julgada como satisfatória se  $NSE > 0,50$  e  $RSR < 0,70$ . Desta forma, estas indicações também corroboram a calibração realizada neste estudo.




Figura 10. Valores observados e simulados de vazão ( $\text{m}^3/\text{s}$ ) para as áreas de drenagem da estação 46543000, considerando o período entre 1992 a 2015.

Para um maior detalhamento os resultados foram avaliados, separadamente, para os períodos de calibração e de validação. A Tabela 6 apresenta algumas medidas estatísticas descritivas dos valores simulados e observados nos períodos de calibração e de validação para a estação 46453000. Além disso, ocorre, nos dados observados, uma diminuição dos valores médios do período de calibração para o período de validação. Um dos motivos dessa diminuição pode ter sido causado pela mudança na precipitação, no período de 1990 a 2007, a precipitação média ao dia foi 3,25 mm/dia (desvio-padrão de 3,43 mm/dia) e no período de 2008 a 2015, a precipitação média ao dia foi 3,01 mm/dia (desvio-padrão de 3,09 mm/dia).

Tabela 6. Medidas estatísticas descritivas dos valores simulados e observados nos períodos de calibração e validação para a estação 46453000.

Período	Natureza	Média (m <sup>3</sup> /s)	Mínimo (m <sup>3</sup> /s)	Máximo (m <sup>3</sup> /s)	Coeficiente de variação (%)
Calibração	Observado	47,70	25,37	79,40	27,52
	Simulado	45,97	28,64	122,73	33,26
Validação	Observado	39,44	21,76	104,36	32,03
	Simulado	44,61	28,64	96,57	29,74

No entanto, nos valores simulados não foi possível se verificar uma diminuição relevante e no período de calibração pode se verificar uma diferença significativa entre os máximos dos valores observados e simulados. Uma hipótese seria a não consideração no modelo INLAND de fatores como a irrigação que afetam diretamente a vazão (Pousa et al., 2019). Em relação ao coeficiente de variação (CV), pode-se afirmar que os valores observados e simulados são igualmente homogêneos, uma vez que apresentam pouca variação no CV (variam de 27,52% a 33,26%).

Uma análise visual dos resultados confirma o que foi indicado pelo KGE. Na Figura 10 é possível verificar que a simulação em vários meses ficou bem próxima dos valores observados, mantendo uma média, amplitude e comportamento similares. Ainda na Figura 10, apenas em alguns meses, o valor simulado esteve distante do valor observado, pode-se citar março de 1997 em que o simulado teve uma vazão maior (o valor simulado foi 106 m<sup>3</sup>/s e o observado foi 65 m<sup>3</sup>/s) ou em dezembro de

2011 quando o observado teve uma vazão maior que o simulado (o valor simulado foi 81 m<sup>3</sup>/s e o observado foi 104 m<sup>3</sup>/s). A igualdade estatística entre a distribuição das séries observada e simulada foi confirmada através do teste Kolmogorov-Smirnov bilateral que apresentou valor-p de 0,053 (considerando um nível de significância a 5% - Figura 11).

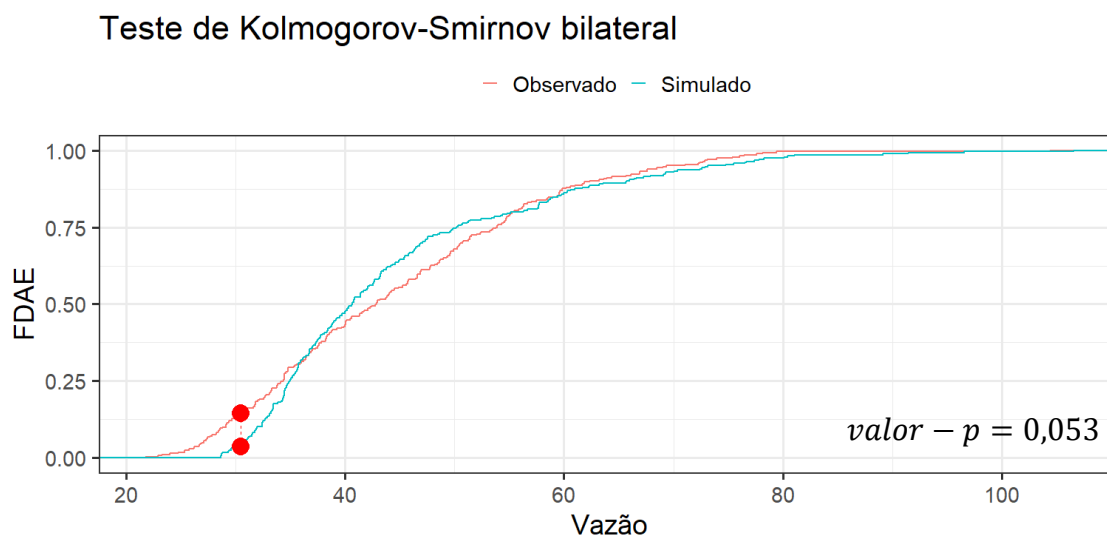


Figura 11. Curvas das funções de distribuição acumulada empírica (FDAE) da vazão simulada e observada no cenário padrão. Os pontos em vermelho representam o local onde a distância entre as curvas é máxima (reta tracejada). O valor-p do teste de Kolmogorov-Smirnov bilateral é também apresentado.

De fato, se compararmos algumas características descritivas, de ambas as séries, nos períodos de calibração e validação pode se verificar essa semelhança (Tabela 7). Na calibração, a diferença na vazão média entre o simulado e o observado foi de 0,6 m<sup>3</sup>/s, o que representa uma diferença de 1,35% apenas. Na validação, a diferença na vazão média entre o simulado e o observado foi de 3,97 m<sup>3</sup>/s, o que representa uma diferença de 10,07%, valor maior ao reportado para calibração. Na calibração, em termos de vazões mínimas e máximas (Q90 e Q10), essa diferença foi ligeiramente maior e ficou, respectivamente, em torno de 9,97% e 8,60%. Na validação, a diferença entre os valores de Q90 e Q10 foi ainda maior e ficou, respectivamente, em torno de 18,12% e 11,50%.

Tabela 7. Características dos valores observados e simulados de vazão (m<sup>3</sup>/s) para as áreas de drenagem da estação 46543000, considerando o período de calibração e validação.

Período	Dados	Q90 (m <sup>3</sup> /s)	Média (m <sup>3</sup> /s)	Q10 (m <sup>3</sup> /s)
Calibração	Observado	29,1	44,5	72,1
	Simulado	32,0	45,1	65,9
Validação	Observado	26,65	39,44	54,71
	Simulado	31,48	43,41	61,00

Para analisar o comportamento geral das duas séries, a Figura 12 apresenta os gráficos de dispersão e as retas ajustadas entre os valores simulados e observados para o período de calibração e de validação. Pelo coeficiente de determinação ( $R^2$ ) da reta é possível perceber que aproximadamente 75% da variação presente nos valores observados está sendo explicada pelos valores simulados utilizando o modelo linear em ambos os períodos (calibração e validação). Ou seja, por meio dessa medida é possível inferir que as simulações em ambos os períodos simulam de maneira satisfatória os dados observados. Ao observar os valores dos coeficientes de regressão ( $\hat{\beta}_1$ ), é possível verificar que no período de calibração há uma maior superestimação percentual dos valores observados (menor valor de  $\hat{\beta}_1$ ). No entanto, analisando os valores das constantes de regressão ( $\hat{\beta}_0$ ), no período de calibração, existe uma correção maior destes valores devido ao maior valor de  $\hat{\beta}_0$  e como consequência há uma aproximação maior nos valores simulados e observados do que no período de validação. No entanto, como mencionado anteriormente, o fato de o período de validação apresentar menores valores para as medidas de qualidade de ajuste não inviabiliza a utilização do modelo calibrado, visto o valor adequado de KGE.

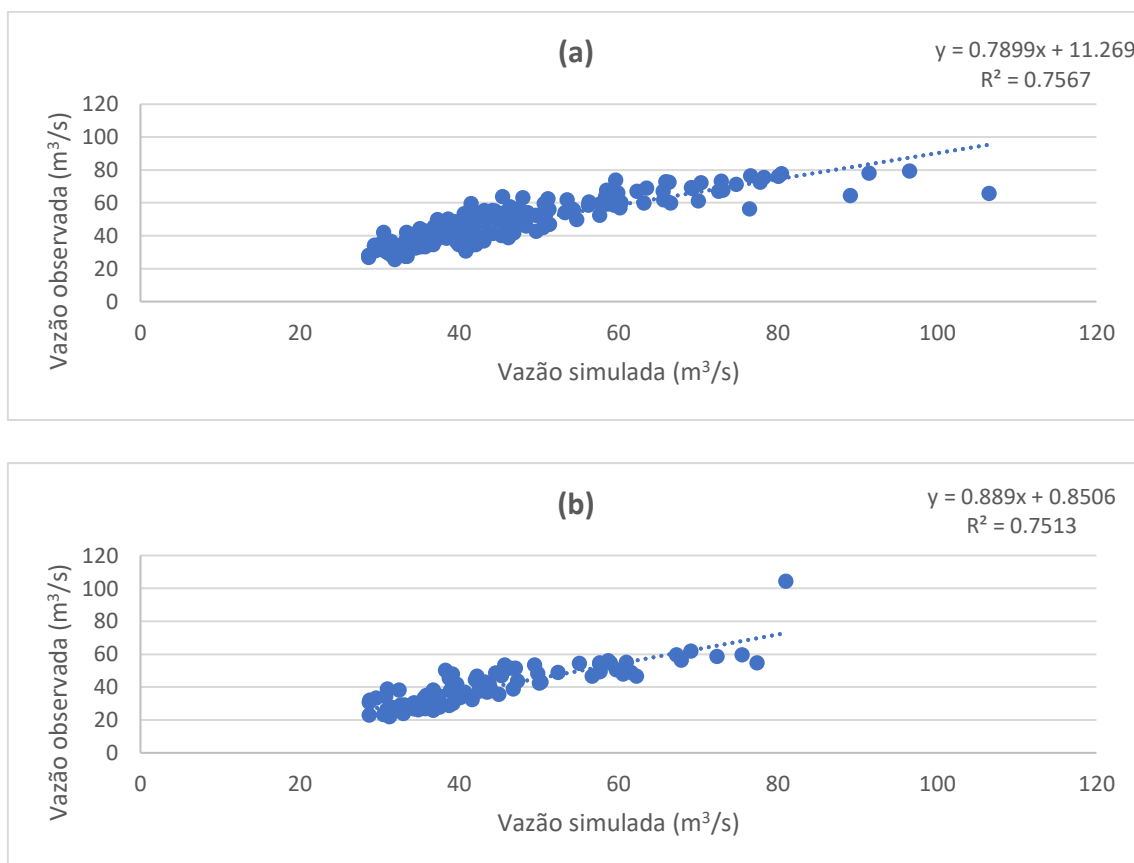


Figura 12. Gráfico de dispersão da vazão ( $m^3/s$ ) com linha de tendência linear do período de (a) calibração (de 1992 a 2007) e de (b) validação (de 2008 a 2015).

Baseado nesse bom resultado de calibração, é possível concluir que os modelos conseguiram representar de forma eficiente o aquífero e a mudança do uso do solo da região. Dessa maneira, torna-se possível analisar o impacto desses dois fatores para a vazão.

#### 4.2 Avaliação do impacto do desmatamento na vazão

Ao realizar a simulação com o cenário sem desmatamento, e comparar a diferença entre esse cenário e o cenário atual (com desmatamento) é possível verificar que o desmatamento causou um impacto direto na vazão (Figura 13).




Figura 13. Média anual de vazão ( $\text{m}^3/\text{s}$ ) simulada para os cenários padrão e sem desmatamento para a área de drenagem da estação 46543000, considerando o período entre 1992 a 2015.

Ademais, ao aplicar o teste de Kolmogorov-Smirnov unilateral a direita, é possível verificar que há indícios de que a distribuição da série de vazão sem desmatamento é menor que a distribuição da série do cenário padrão, visto que o valor-p do teste foi igual a 0,02 (considerando um nível de significância a 5% - Figura 14). Esse resultado é condizente com outros estudos já realizados que detectaram o impacto do desmatamento em outras regiões no mundo (Ridwansyah et al., 2020; Tirupathi e Shashidhar, 2020; Farias et al., 2020; Garg et al., 2019; Kundu et al., 2017; Alvarenga et al., 2016b). É possível perceber que o impacto ocorre com maior intensidade no final da série, como possível consequência do ritmo de crescimento quase que constante do desmatamento (Figura 7).




Figura 14. Curvas das funções de distribuição acumulada empírica (FDAE) da vazão simulada nos cenários padrão e sem desmatamento. Os pontos em vermelho representam o local onde a distância entre as curvas é máxima (reta tracejada). O valor-p do teste de Kolmogorov-Smirnov unilateral a direita é também apresentado.

Com a presença de desmatamento, verificou-se um aumento em todas as medidas descritivas da vazão (Tabela 8). Esse aumento é mais substancial nos valores mínimos do que nos valores máximos. A  $Q_{90}$ , por exemplo, tem um aumento de 6,04% enquanto a  $Q_{10}$  tem um aumento de 1,45%. Desse ponto de vista, o desmatamento aumenta o volume de água disponível, auxiliando quem depende

desse volume (por exemplo, para outorgas). No entanto, a depender do volume, pode se causar mais prejuízos por enchentes, por exemplo.

Tabela 8. Medidas estatísticas descritivas dos valores simulados da vazão considerando o cenário padrão e o cenário sem desmatamento para a estação 46453000.

Cenário	Média (m <sup>3</sup> /s)	Mínimo (m <sup>3</sup> /s)	Máximo (m <sup>3</sup> /s)	Q90 (m <sup>3</sup> /s)	Q10 (m <sup>3</sup> /s)	CV (%)
Padrão	45,1	28,64	122,73	32,30	65,79	31,86
Sem desmatamento	43,3	27,29	121,63	30,46	64,85	33,90

CV é o coeficiente de variação.

A vazão média para os dois cenários foi de 45,1 m<sup>3</sup>/s para o cenário padrão e de 43,3 m<sup>3</sup>/s para o cenário sem desmatamento, uma diferença de 1,8 m<sup>3</sup>/s. Ao aplicar o teste de Kolmogorov-Sminorv para uma amostra verificou-se que a vazão em ambos os cenários não apresentara distribuição normal, com valores-p inferiores a 0,00001. Desta forma, utilizou o teste de Wilcoxon unilateral a direita para testar se há diferença entre as vazões média, e encontrou-se um valor-p igual 0,007, indicando que o cenário padrão apresentou média maior que o cenário sem desmatamento. Deste modo, um desmatamento de 31% (Figura 7) levou a um aumento de 4% na vazão simulada. Farias et al. (2020), por exemplo, encontrou um aumento de 37% na vazão com um aumento de 76% de desmatamento na Bacia hidrográfica do Mundaú no Brasil, enquanto Moghadam et al (2021) encontrou um aumento de vazão de 2% com 20% de desmatamento em uma Bacia Heterogênea Montanhosa. Mas, como concluiu Cuo (2016), não existe uma relação linear entre desmatamento e aumento da vazão, dessa forma, o impacto do desmatamento é complexo e depende de inúmeras características da região estudada.

Para entender ainda mais o impacto do desmatamento sobre a vazão pode-se analisar os valores de drenagem profunda e de escoamento superficial. A Figura 15 apresenta um gráfico de dispersão com plano de regressão entre a vazão, a drenagem

profunda e o escoamento superficial considerando os valores simulados na presença de desmatamento. Pelo coeficiente de determinação ajustado das retas é possível perceber que, aproximadamente, 63% da variação presente nos valores de vazão está sendo explicada pelos valores de drenagem profunda e escoamento superficial utilizando o modelo linear (Eq. 1).

$$Vazão = 0,33drenagem + 1,01escoamento \quad (R^2 = 0,63) \quad \text{Eq.(1)}$$

Vale ressaltar que ambos os coeficientes e a constante da regressão apresentam significância estatística (valor-p <10<sup>-6</sup>) na Eq. 1. Ao analisar a estimativa dos coeficientes de regressão, verifica-se que existe uma diferença significativa entre ambas sendo, respectivamente, iguais a 0,33 m<sup>3</sup>/s e 1,01 m<sup>3</sup>/s. No primeiro caso, a cada aumento em 1 m<sup>3</sup>/s na drenagem profunda estima-se um aumento médio de 0,33 m<sup>3</sup>/s na vazão, desde que o escoamento permaneça constante. No segundo caso, a cada aumento em 1 m<sup>3</sup>/s no escoamento superficial estima-se um aumento médio de 1,01 m<sup>3</sup>/s na vazão, desde que a drenagem profunda permaneça constante. Dessa forma, é possível inferir que o escoamento superficial possui um impacto maior na vazão em relação a drenagem profunda.




Figura 15. Gráfico de dispersão com plano de regressão entre a vazão e a drenagem profunda e o superficial considerando os valores simulados na presença de desmatamento.

A Figura 16 apresenta um gráfico de dispersão com plano de regressão entre a vazão e a drenagem profunda e o superficial considerando os valores simulados na ausência de desmatamento. Pelo coeficiente de determinação ajustado das retas é possível perceber que, aproximadamente, 63% da variação presente nos valores de vazão está sendo explicada pelos valores de drenagem profunda e escoamento superficial utilizando o modelo linear (Eq. 2).

$$Vaz\tilde{a}o = 0,34drenagem + 1,10escoamento \quad (R^2 = 0,63) \quad \text{Eq.(2)}$$

Vale ressaltar que ambos os coeficientes e a constante da regressão apresentam significância estatística (valor-p < 10<sup>-6</sup>) na Eq. 2. Ao comparar os valores das estimativas da constante e dos coeficientes de regressão apresentados nas Figuras 15 e 16, observa-se, na presença do desmatamento, uma diminuição do impacto da drenagem profunda (0,01 – cerca de 2,94%) e uma diminuição (0,09 – cerca de 8,18%) do impacto do escoamento superficial na vazão. Ao aplicar o teste *t-student*, visando verificar se há diferença significativa entre os coeficientes de regressão dos cenários padrão e sem desmatamento, encontrou-se valores-p iguais a 0,90 e 0,03, indicando que não foi significativa a diferença entre os efeitos da drenagem profunda na vazão e foi significativa a diferença entre os efeitos do escoamento superficial entre os cenários. Portanto, com a inclusão do desmatamento, a drenagem profunda continua impactando a vazão com a mesma intensidade enquanto que o escoamento superficial diminui a sua intensidade de impacto. Com mais desmatamento, tem-se uma diminuição evapotranspiração, um aumento na drenagem profunda e mantém-se constante o escoamento superficial (Tabela 9). Aliando essas alterações aos resultados anteriores (o impacto da drenagem profunda mante-se e do escoamento diminui), podemos dizer que, para essa região, o desmatamento aumenta a responsabilidade do aquífero para a vazão.




Figura 16. Gráfico de dispersão com plano de regressão entre a vazão e a drenagem profunda e o superficial considerando os valores simulados na ausência de desmatamento.

Analisando os valores médios para todo o período (Tabela 9), o escoamento superficial se manteve praticamente o mesmo nos dois cenários, enquanto que a drenagem profunda teve um aumento de 18% com o desmatamento e a evapotranspiração teve uma diminuição de 4,31%.

Tabela 9. Valores médios de drenagem profunda ( $\text{m}^3/\text{s}$ ) e escoamento superficial ( $\text{m}^3/\text{s}$ ) para a área de drenagem da estação 46543000, considerando o período entre 1992 a 2015.

Cenário	Drenagem profunda ( $\text{m}^3/\text{s}$ )	Escoamento superficial ( $\text{m}^3/\text{s}$ )	Evapotranspiração ( $\text{m}^3/\text{s}$ )
Padrão	40,6	8,7	149,32
Sem desmatamento	34,4	8,6	156,05

Ademais, ao aplicar o teste de Kolmogorov-Smirnov unilateral a direita, é possível verificar que a distribuição da série de drenagem profunda sem desmatamento é menor que a distribuição da série do cenário padrão, visto que o valor-p do teste foi de 0,04 (Figura 17).

### Teste de Kolmogorov-Smirnov unilateral a direita




Figura 17. Curvas das funções de distribuição acumulada empírica (FDAE) da drenagem profunda simulada considerando o cenário padrão e do cenário sem desmatamento. Os pontos em vermelho representam o local onde a distância entre as curvas é máxima. O valor-p do teste de Kolmogorov-Smirnov unilateral a direita é também apresentado.

Em contrapartida, ao aplicar o teste de Kolmogorov-Smirnov bilateral na série do escoamento, é possível verificar que a distribuição da série de escoamento

superficial sem desmatamento é estatisticamente igual a distribuição da série do cenário padrão, visto que o valor-p do teste foi igual a 0,71 (Figura 18).




Figura 18. Curvas das funções de distribuição acumulada empírica (FDAE) do escoamento superficial simulado considerando o cenário padrão e do cenário sem desmatamento. Os pontos em vermelho representam o local onde a distância entre as curvas é máxima. O valor-p do teste de Kolmogorov-Smirnov bilateral é também apresentado.

Como o desmatamento, normalmente, resulta em aumento de escoamento superficial (Moghadam et al., 2021; Ridwansyah et al., 2020), o fato de não ter aumentado para essa região mostra o potencial de infiltração do solo. Diante deste fator, como não teve um aumento de escoamento, todo o aumento da vazão é causado pelo aumento na drenagem profunda. Com o aumento da drenagem profunda com o desmatamento, assim como foi reportado em outros estudos (Farias et al., 2020; Moghadam et al., 2021), este estudo também encontrou uma diminuição da evapotranspiração (Tabela 9) e um aumento da recarga do aquífero, uma vez que a maior parte (relativo ao parâmetro  $d_{part}$ ) da drenagem profunda vai para o aquífero. Essa recarga maior do aquífero aumenta o seu volume total, aumentando a sua contribuição para a vazão. Esse aumento do volume é representado pelo aumento do

reservatório do aquífero modelado no THMB que foi de  $15,3 \times 10^6 \text{ m}^3$  no cenário sem desmatamento para  $15,4 \times 10^6 \text{ m}^3$  no cenário padrão.

### 4.3 Avaliação da contribuição do aquífero para a regulação da vazão

No cenário sem aquífero, onde a drenagem profunda chega mais rápido na vazão, por conta do alto tempo de residência do reservatório referente ao aquífero, a vazão média para o período de 1992 a 2015 é maior que a vazão média do cenário padrão (Tabela 10). Isso mostra que o aquífero reteve uma parte do volume extra que recebeu entre 1992 e 2015 para ser liberada nos próximos anos. Outro ponto é que sem o aquífero, as vazões mais baixas ( $Q_{90}$ ) ficam mais baixas e as vazões maiores ( $Q_{10}$ ) ficam ainda maiores (Tabela 10). Isso mostra o efeito regularizador do aquífero na vazão, que também pode ser observado na comparação da vazão média anual entre os cenários padrão e sem aquífero (Figura 19).

Como pode ser notado comparando-se as Figuras 13 e 19, a ausência do aquífero afeta mais a vazão do que a presença do desmatamento. Isto pode ser comprovado calculando a distância DTW. Esta distância foi igual a 905,87 entre a série do cenário sem desmatamento e do cenário padrão, em contrapartida, a distância entre a série do cenário sem aquífero e o cenário padrão foi igual a 2875,50. Dessa forma, ao comparar os dois fatores, a ausência do aquífero impacta a vazão numa proporção muito maior que a presença do desmatamento.

Tabela 10. Medidas estatísticas descritivas dos valores simulados da vazão considerando o cenário padrão e o cenário sem aquífero para a estação 46453000.

Cenário	Média ( $\text{m}^3/\text{s}$ )	Mínimo ( $\text{m}^3/\text{s}$ )	Máximo ( $\text{m}^3/\text{s}$ )	$Q_{90}$ ( $\text{m}^3/\text{s}$ )	$Q_{10}$ ( $\text{m}^3/\text{s}$ )	CV (%)
Padrão	45,13	28,64	122,73	32,30	65,79	31,86
Sem aquífero	49,63	8,75	133,11	22,15	82,94	46,83




Figura 19. Média anual de vazão ( $\text{m}^3/\text{s}$ ) simulada para os cenários padrão e sem aquífero para a área de drenagem da estação 46543000, considerando o período entre 1992 a 2015.

Sem o aquífero a  $Q_{90}$  foi reduzida de 32,30 m<sup>3</sup>/s para 21,15 m<sup>3</sup>/s, representando uma redução de 34,52%. Ao aplicar o teste de Kolmogorov-Smirnov bilateral, é possível verificar que a distribuição da série de vazão sem aquífero é diferente que a distribuição da série do cenário padrão, visto que o valor-p do teste foi inferior a 0,00001 (Figura 20). No entanto, não foi possível detectar qual das séries é maior ou menor pois em toda a série a diferença é flutuante.

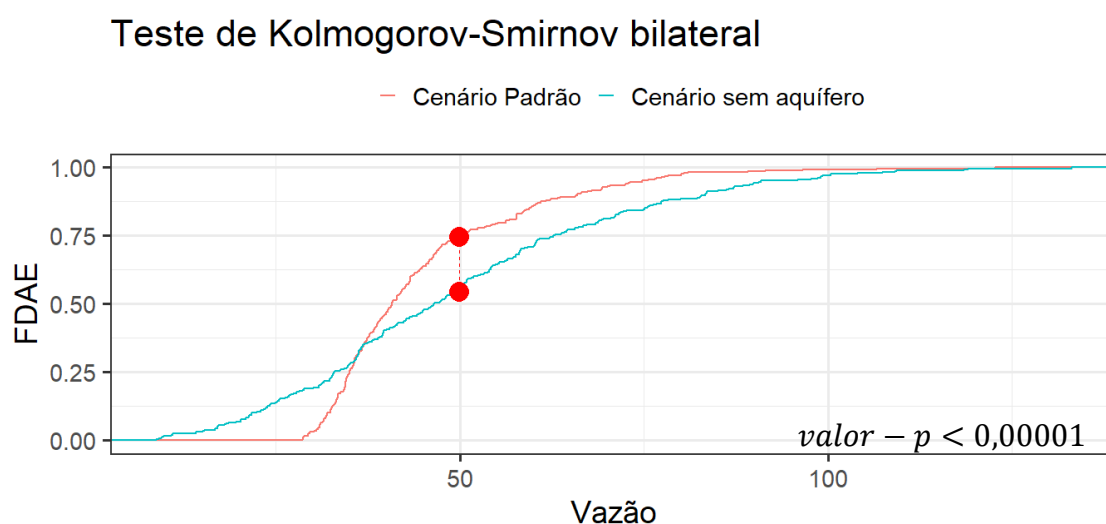


Figura 20. Curvas das funções de distribuição acumulada empírica (FDAE) da vazão simulada considerando o cenário padrão e o cenário sem aquífero. Os pontos em vermelho representam o local onde a distância entre as curvas é máxima. O valor-p do teste de Kolmogorov-Smirnov bilateral é também apresentado.

A Figura 21 apresenta um gráfico de dispersão com plano de regressão entre a vazão, a drenagem profunda e o escoamento superficial e a Figura 22 apresenta um gráfico de dispersão e a reta ajustada entre a vazão e a drenagem profunda, considerando os valores simulados na ausência do aquífero. O efeito do escoamento sobre a vazão (Eq. 3), no modelo da Figura 21, não apresenta significância estatística (valor-p = 0,064). Agora, ao analisar o modelo da Figura 22, percebe-se que na ausência do aquífero, a influência da drenagem profunda sob a vazão é maior (Eq. 4). Dessa forma, uma hipótese para a diminuição do impacto do escoamento é que, sem o aquífero, a drenagem profunda chega na vazão diretamente, influenciando fortemente a vazão.

$$Vaz\tilde{a}o = 0,50drenagem + 0,54escoamento \quad (R^2 = 0,61) \quad \text{Eq.(3)}$$

$$Vaz\tilde{a}o = 0,61drenagem \quad (R^2 = 0,61) \quad \text{Eq.(4)}$$

Ao analisar apenas a vaz\~ao, o desmatamento poderia parecer positivo pois aumenta a recarga do aqu\~ifero, conseq\~uentemente, aumentando a vaz\~ao m\~edia da regi\~ao. Por\~em, como foi mostrado, o aumento da vaz\~ao \~e conseq\~u\~encia da diminui\~cao da evapotranspira\~cao. Essa diminui\~cao altera o ciclo hidrol\~ogico e afeta o clima em diferentes escalas (Lawrence e Vandecar, 2015 e Perugini et al., 2017) podendo ter um *feedback* negativo longo prazo (Oliveira et al., 2013). E, como reportado por Moghadam et al. (2021), o efeito das mudan\~cas clim\~aticas na vaz\~ao \~e mais significativo que o efeito causado pelo desmatamento. Desta forma, os agricultores e exploradores da regi\~ao do oeste da Bahia deveriam pensar em medidas para administra\~cao dessa expans\~ao agr\~icola mediante ao desmatamento, uma vez que a situa\~cao s\~o n\~ao est\~a mais evidente (o Q<sub>90</sub> n\~ao est\~a mais baixo) devido \~a presen\~ca do aqu\~ifero na regi\~ao.




Figura 21. Gráfico de dispersão com plano de regressão entre a vazão e a drenagem profunda e o superficial considerando os valores simulados na ausência do aquífero.




Figura 22. Gráfico de dispersão com reta ajustada entre a vazão e a drenagem profunda considerando os valores simulados na ausência do aquífero.

Como mencionado anteriormente, há uma escassez de estudos com modelagem hidrológica no oeste da Bahia e visto a importância econômica da região para o agronegócio, faz-se necessário uma crescente de estudos científicos na região. As políticas de combate, controle e prevenção ao desmatamento devem ser orientadas por meio dos modelos hidrológicos calibrados de modo eficiente para que seja possível prever o que ocorrerá nos próximos anos e décadas. É importante que a população e exploradores da região, bem como os políticos, encontrem formas e tecnologias de precisão para a preservação do aquífero, que é um recurso finito. Além disso, faz-se necessário investimentos financeiros para a coleta de dados, como informações sobre evapotranspiração e umidade do solo, para um aprimoramento ainda maior da calibração do modelo, para tornar ainda mais eficientes as políticas de conscientização e a preservação do meio ambiente.

## 5 Conclusão

Nesse estudo foi possível calibrar os modelos INLAND e THMB para a região do oeste da Bahia. Ainda que alguns dos parâmetros calibrados não estejam consistentes com os valores esperados, a simulação de vazão obtida está próxima aos valores observados e apresentou adequada medida de qualidade de calibração. Ademais, foi possível identificar que o desmatamento causa um impacto significativo na vazão. O impacto identificado implicou no aumento da vazão, causado pelo aumento da drenagem profunda que aumentava o volume do aquífero e, conseqüentemente, aumentava a sua contribuição na vazão. Isso faz com que aumente não só a vazão média como também as vazões mínimas e máximas, aumentando a disponibilidade de água no rio. Porém, esse aumento da drenagem profunda é decorrente da diminuição da evapotranspiração, que pode afetar o clima da região, diminuindo a precipitação que é a maior fonte de entrada de água para a hidrologia da região.

Os resultados deste estudo mostraram também que o aquífero Urucuia é um grande regulador da vazão da região. Sem o aquífero, as vazões mínimas seriam menores e as vazões máximas seriam maiores. Isto poderia ser prejudicial para quem depende do rio porque teria pouco volume de água nos períodos secos e riscos maiores de enchentes nos períodos chuvosos. Portanto, sem a presença do aquífero, provavelmente, a situação da região estaria agravada.

Nosso estudo é um primeiro passo para entender o impacto do desmatamento e a contribuição do aquífero para a vazão na região de estudo. Estudos futuros podem investigar o impacto do desmatamento nas condições climáticas e com isso as conseqüências do clima na vazão e como esses fatores cumulativos e cíclicos podem comprometer a saúde econômica e ambiental do oeste da Bahia. Além disso, seria importante para a melhoria na eficiência da calibração o aumento de dados observados in situ, como observações sobre evapotranspiração e umidade do solo.

## 6 Referências

- Acheampong, E.; Macgregor, C.; Sloan, S.; Sayer, J. 2019. Deforestation is driven by agricultural expansion in Ghana's Forest Reserves. *Scientific African*, 5: e00146. <http://dx.doi.org/10.1016/j.sciaf.2019.e00146>.
- Alcantara, M.A.; Nelson, E.J.; Shakya, K.; Edwards, C.; Roberts, W.; Krewson, C.; Ames, D.P.; Jones, N.L.; Gutierrez, A. 2019. Hydrologic Modeling as a Service (HMaaS): A New Approach to Address Hydroinformatic Challenges in Developing Countries. *Frontiers in Environmental Science*, 7: 158. <https://doi.org/10.3389/fenvs.2019.00158>.
- Allaby, A., Allaby, M., 1999. *Koppen Climate Classification. A Dictionary of Earth Sciences*, Oxford University Press, North Carolina USA. 640 pp.
- Alvarenga, L.A.; Mello, C.R.; Colombo, A.; Cuartas, L.A.; Bowling, L.C. 2016b. Assessment of Land Cover Change On the Hydrology of a Brazilian Headwater Watershed Using the Distributed Hydrology-soil-vegetation Model. *Catena*, 143: 7-17. <https://doi.org/10.1016/j.catena.2016.04.001>.
- Alvarenga, L.A.; Mello, C.R.; Colombo, A.; Cuartas, L.A.; Chou, S.C. 2016a. Hydrological responses to climate changes in a headwater watershed. *Ciência e Agrotecnologia*, 40(6): 647-657. <https://doi.org/10.1590/1413-70542016406027716>.
- Amorim, P.B., Chaffe, P.L.B. 2019. Integrating climate models into hydrological modelling: What's going on in Brazil? *Brazilian Journal of Water Resources*, 24: e31. <https://doi.org/10.1590/2318-0331.241920180176>.
- Arnold, J.G.; Moriasi, D.N.; Gassman, P.W.; Abbaspour, K.C.; White, M.J.; Srinivasan, R.; Santhi, C.; Harmel, R.D.; van Griensven, A.; Van Liew, M.W.; Kannan, N.; Jha, M.K. 2012. SWAT: Model use, calibration, and validation. *American Society of Agricultural and Biological Engineers*, 55(4): 1491-1508. <https://doi.org/10.13031/2013.42256>.
- Arnold, J.G.; Srinivasan, R. Muttiah, R.S.; Williams, J.R. 1998. Large-area hydrologic modeling and assessment: Part I. Model development. *J Journal of the American Water Resources Association*. 34(1):73-89. <https://doi.org/10.1111/j.1752-1688.1998.tb05961.x>.

Arsenault, R.; Poulin, A.; Côté, P.; Brissette, F. 2013. A comparison of stochastic optimization algorithms in hydrological model calibration. *Journal of Hydrologic Engineering*, 19: 1374-1384. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000938](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000938).

Associação de Agricultores e Irrigantes da Bahia (AIBA). 2020.

Ayvaz, M.T.; Gurarslan, G. 2017. A new partitioning approach for nonlinear Muskingum flood routing models with lateral flow contribution. *Journal of Hydrology*, 553, 142–159.

Baccini, A.; Goetz, S.; Walker, W.; Laporte, N.T.; Sun, M.; Sulla-Menashe, D.; Hackler, J.; Beck, P.S.A.; Dubayah, R.; Friedl, M.A.; Samanta, S.; Houghton, R.A. 2012. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. *Nature Climate Change*, 2: 182–185. <https://doi.org/10.1038/nclimate1354>.

Bajželj, B.; Richards, K.S. 2014. The Positive Feedback Loop between the Impacts of Climate Change and Agricultural Expansion and Relocation. *Land*, 3: 898-916. <http://dx.doi.org/10.3390/land3030898>.

Bala, G.; Caldeira, K.; Wickett, M.; Phillips, T.J.; Lobell, D.B.; Delire, C.; Mirin, A. 2007. Combined climate and carbon-cycle effects of large-scale deforestation. *Proceedings of the National Academy of Sciences*, 104(16): 6550-6555; <https://doi.org/10.1073/pnas.0608998104>.

Batistella, M.; Valladares, G.S. 2009 Farming expansion and land degradation in Western Bahia, Brazil. *Biota Neotrop.* 9(3): <http://www.biotaneotropica.org.br/v9n3/en/abstract?article+bn00909032009>.

Beck, H.E.; Pan, M.; Roy, T.; Weedon, G. P.; Pappenberger, F.; van Dijk, A. I. J. M.; Huffman, G. J.; Adler, R. F.; Wood, E. F. 2019. Daily evaluation of 26 precipitation datasets using Stage-IV gauge-radar data for the CONUS. *Hydrology and Earth System Sciences*, 23(1): 207—224. <https://doi.org/10.5194/hess-23-207-2019>.

Beven, K. 2019. How to make advances in hydrological modelling. *Hydrology Research*, 50(6): 1481–1494. <https://doi.org/10.2166/nh.2019.134>.

Boers, N.; Marwan, N.; Barbosa, H.; Kurths, J. 2017. A deforestation-induced tipping point for the South American monsoon system. *Scientific Reports*, 7, 41489. <https://doi.org/10.1038/srep41489>.

- Bonan, G. 2008. Forests and Climate Change: Forcings, Feedbacks, and the Climate Benefits of Forests. *Science*, 320: 1444-9. <https://doi.org/10.1126/science.1155121>.
- Brumatti, L.M.; Pires, G.F.; Santos, A.B. 2020. Challenges to the Adaptation of Double Cropping Agricultural Systems in Brazil under Changes in Climate and Land Cover. *Atmosphere*, 11, 1310. <https://doi.org/10.3390/atmos11121310>.
- Caen, A.; Smallman, T.L.; Castro, A.A.; Robertson, E.; von Randow, C.; Cardoso, M.; Williams, M. Evaluating two land surface models for Brazil using a full carbon cycle benchmark with uncertainties. *Climate Resilience and Sustainability*, e10. <https://doi.org/10.1002/cli2.10.4>.
- Campbell, G.S. 1985. *Soil physics with BASIC: transport models for soil-plant systems*. Elsevier, New York.
- Castro, A.A.; Cuartas, L.A.; Coe, M.T.; Von Randow, C.; Castanho, A.; Ovando, A.; Nobre, A.D.; Koumrouyan, A.; Sampaio, G.; Costa, M.H. 2018. Coupling the terrestrial hydrology model with biogeochemistry to the integrated LAND surface model: Amazon Basin applications, *Hydrological Sciences Journal*, 63:13-14, 1954-1966. <https://doi.org/10.1080/02626667.2018.1538592>.
- Chanapathi, T, Thatikonda, S. 2020. Investigating the impact of climate and land-use land cover changes on hydrological predictions over the Krishna river basin under present and future scenarios. *Science of the Total Environment*, 721:137736. <https://doi.org/10.1016/j.scitotenv.2020.137736>.
- Chen, L.; Wang, L. 2018. Recent advance in earth observation big data for hydrology. *Big Earth Data*, 2, 86–107. <https://doi.org/10.1080/20964471.2018.1435072>.
- Coe, M.T.; Costa, M.H.; Botta, A.; Birkett, C. 2002. Long-term simulations of discharge and floods in the Amazon Basin. *Journal of Geophysical Researches*, 107: 1–17. <https://doi.org/10.1029/2001JD000740>.
- Coe, M.T.; Costa, M.H.; Howard, E.A. 2008. Simulating the surface waters of the Amazon River basin: impacts of new river geomorphic and flow parameterizations. *Hydrological Processes*, 22(14): 2542–2553. <https://doi.org/10.1002/hyp.6850>.

Coello, C.A.C.; Cortés, N.C. 2005. Solving Multiobjective Optimization Problems Using an Artificial Immune System. *Genetic Programming and Evolvable Machines*, 6: 163–190. <https://doi.org/10.1007/s10710-005-6164-x>.

Companhia Nacional de Abastecimento (CONAB). 2020. Levantamento da Safra de Grãos 2019/20.

Costa, M.H.; Yanagi, S.N.M.; Souza, P.J.O.P.; Ribeiro, A.; Rocha, E.J.P. 2007. Climate change in Amazonia caused by soybean cropland expansion, as compared to caused by pastureland expansion. *Geophysical Research Letters*, 34(7): 1–4. <https://doi.org/10.1029/2007GL029271>.

Cuo, L. 2016. Land Use/Cover Change Impacts on Hydrology in Large River Basins: A Review. In: Tang, Q.; Oki, T. *Terrestrial Water Cycle and Climate Change: Natural and Human-Induced Impacts*, Geophysical Monograph 221, First Edition. American Geophysical Union. John Wiley & Sons, Inc. p. 103- 134.

Deb, K.; Pratap, A.; Agarwal, S.; Meyarivan, T. 2002. A fast and elitist multiobjective genetic algorithm: NSGA-II, in *IEEE Transactions on Evolutionary Computation*, 6(2): 182-197. <https://doi.org/10.1109/4235.996017>.

Devia, G.K.; Ganasri, B.P.; Dwarakish, G.S. 2015. A Review on Hydrological Models.

Dias, L.C.P.; Macedo, M.N.; Costa, M.H.; Coe, M.T.; Neill, C. 2015. Effects of land cover change on evapotranspiration and streamflow of small catchments in the Upper Xingu River Basin, Central Brazil. *Journal of Hydrology: Regional Studies*, 4 Part B: 108-122. <https://doi.org/10.1016/j.ejrh.2015.05.010>.

Dionizio, E.A.; Costa, M.H. 2019. Influence of Land Use and Land Cover on Hydraulic and Physical Soil Properties at the Cerrado Agricultural Frontier. *Agriculture*, 9(24). <https://doi.org/10.3390/agriculture9010024>

Dionizio, E.M.; Costa, M.H.; Castanho, A.D.A.; Pires, G.F.; Marimon, B.S.; Marimon-Junior, B.H.; Lenza, E.; Pimenta, F.M.; Yang, X.; Jain, A.K. 2018. Influence of climate variability, fire and phosphorus limitation on vegetation structure and dynamics of the Amazon–Cerrado border. *Biogeosciences*, 15: 919–936. <https://doi.org/10.5194/bg-15-919-2018>.

Duan, Q.; Sorooshian, S.; Gupta, V. 1992. Effective and efficient global optimization for conceptual rainfall-runoff models. *Water Resources Research*, 28(4): 1015-1031. <https://doi.org/10.1029/91WR02985>.

Dubreuil, V.; Debortoli, N.; Funatsu, B.; Nedelec, V.; Durieux, L. 2012. Impact of land-cover change in the Southern Amazonia Climate: A case study for the region of Alta Floresta, Mato Grosso, Brazil. *Environmental Monitoring and Assessment*, 184: 877–891. <https://doi.org/10.1007/s10661-011-2006-x>.

Durbin J. 1961. Some Methods of Constructing Exact Tests, *Biometrika* 48, 41–55.

Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). 2020. Soja em números (safra 2020/21).

Estes, L.D.; Chaney, N.; Herrera-Estrada, J.; Caylor, K.K.; Sheffield, J.; Wood, E.F. 2013. Spatial Trends in Evapotranspiration Components over Africa between 1979 and 2012 and Their Relative Influence on Crop Water Use. AGU Fall Meeting Abstracts.

Farias, C.W.L.A.; Montenegro, S.M.G.L.; Lima, J.R.S.; Srinivasan, R.; Jones, C.A. 2020. Modeling runoff response to land-use changes using the SWAT model in the Mundaú watershed, Brazil. *Journal of Environmental Analysis and Progress*, 5(2). <https://doi.org/10.24221/jeap.5.2.2020.2828.194-206>.

Feddema, J.J.; Oleson, K.W.; Bonan, G.B.; Mearns, L.O.; Buja, L.E.; Meehl, G.A.; Washington, W.M. 2005. The importance of land-cover change in simulating future climates. *Science*, 310, 1674–1678. <https://doi.org/10.1073/10.1126/science.1118160>.

Ferraz, L.L.; Sousa, L.F.; Silva, L.S.; Silva, J.O.; Tagliaferre, C.; Santos, C.A.S.; Rocha, F.A. 2021. Calibration and validation of the SWAT model for hydrological simulation in a basin in Western Bahia. *Revista Ibero Americana de Ciências Ambientais*, 12(1): 276-285. <http://doi.org/10.6008/CBPC2179-6858.2021.001.0023>.

Foley, J. A.; Prentice, I. C.; Ramankutty, N.; Levis, S.; Pollard, D.; Sitch, S.; and Haxeltine, A. 1996. An integrated biosphere model of land surface processes, terrestrial carbon balance, and vegetation dynamics. *Global Biogeochem. Cycles*, 10(4), 603– 628. <https://doi.org/10.1029/96GB02692>.

- Foley, J.A.; Kucharik, C.J.; Polzin, D. 2005. Integrated Biosphere Simulator Model (IBIS), Version 2.5. ORNL DAAC, Oak Ridge, Tennessee, USA. <https://doi.org/10.3334/ORNLDAAC/808>.
- Freer, J.; Beven, K.; Ambrose, B. 1996. Bayesian estimation of uncertainty in runoff prediction and the value of data: An application of the GLUE approach. *Water Resources Research*, 32: 2161–2173. <https://doi.org/10.1029/95WR03723>.
- Garg, V.; Nikam, B. R.; Thakur, P. K.; Aggarwal, S. P.; Gupta, P. K.; Srivastav, S. K. 2019. Human-induced land use land cover change and its impact on hydrology. *HydroResearch*, 1: 48-56. <https://doi.org/10.1016/j.hydres.2019.06.001>.
- Goergen, G.; Valdés, R.H.; Degrazia, G.A.; Gotuzzo, R.A.; Herdies, D.L.; de Gonçalves, L.G.G.; Roberti, D.R. 2020. Energy and CO<sub>2</sub> Fluxes over Native Fields of Southern Brazil through Multi-Objective Calibration of INLAND Model. *Geosciences*, 10: 479. <https://doi.org/10.3390/geosciences10120479>.
- Granata, F.; Gargano, R.; De Marinis, G. 2016. Support vector regression for rainfallrunoff modeling in urban drenagem profunda: A comparison with the EPA's storm water management model. *Water*, 8(3), 69. <https://doi.org/10.3390/w8030069>.
- Gupta, H.V.; Kling, H.; Yilmaz, K.K.; Martinez, G.F. 2009. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*, 377(1-2), 80–91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>.
- Gupta, H.V.; Sorooshian, S.; Yapo, P.O. Status of Automatic Calibration for Hydrologic Models: Comparison with Multilevel Expert Calibration. *Journal of Hydrologic Engineering*, 4(2). [https://doi.org/10.1061/\(ASCE\)1084-0699\(1999\)4:2\(135\)](https://doi.org/10.1061/(ASCE)1084-0699(1999)4:2(135)).
- Gupta, H.V.; Sorooshian, S.; Yapo, P.O.; 1998. Toward improved calibration of hydrologic models: multiple and noncommensurable measures of information. *Water Resources Research*, 34(4): 751–763. <https://doi.org/10.1029/97WR03495>.
- Guug, S.S.; Abdul-Ganiyu, S.; Kasei, R.A. 2020. Application of SWAT hydrological model for assessing water availability at the Sherigu catchment of Ghana and Southern Burkina Faso. *HydroResearch*, 3: 124-133. <https://doi.org/10.1016/j.hydres.2020.10.002>.

Hansen, N.; Hansen, N. 2006. The CMA Evolution Strategy: A Comparing Review. In: Lozano, J.A.; Larrañaga, P.; Inza, I.; Bengoetxe, E. Towards a New Evolutionary Computation. 75-102.

Houghton, R.A.; House, J.I.; Pongratz, J.; Werf, G.R. van der; DeFries, R. S.; Hansen, M. C.; Le Quéré, C.; Ramankutty, N. 2012. Carbon emissions from land use and land-cover change. *Biogeosciences*, 9(12): 5125-5142. <https://doi.org/10.5194/bg-9-5125-2012>.

IBBITT, R.P. 1970. Systematic parameter fitting for conceptual models of catchment hydrology. PhD thesis, Univ. of London.

Jackson, R. B.; Mooney, H. A.; Schulze, E.-D. 1997. A global budget for fine root biomass, surface area, and nutrient contents, *Proceedings of the National Academy of Sciences*, 94(14): 7362-7366. <https://doi.org/10.1073/pnas.94.14.7362>.

Johnston, P.R.; Pilgrim, D.H. 1976. Parameter optimization for watershed models. *Water Resources Research*, 12(3): 477-486. <https://doi.org/10.1029/WR012i003p00477>.

Kling, H.; Fuchs, M.; Paulin, M. 2012. Runoff conditions in the upper Danube basin under an ensemble of climate change scenarios. *Journal of Hydrology*, 424-4251: 264–277. <https://doi.org/10.1016/j.jhydrol.2012.01.011>.

Kollat, J.B.; Reed, P.M.; Wagener, T. 2012. When are multiobjective calibration trade-offs in hydrologic models meaningful? *Water Resources Research*, 48(3). <https://doi.org/10.1029/2011WR011534>.

Konikow, L. F.; Bredehoeft, J. D. 1992. Groundwater Models Cannot be Validated. *Advances in Water Resources*, 15, 75–83. [https://doi.org/10.1016/0309-1708\(92\)90033-X](https://doi.org/10.1016/0309-1708(92)90033-X).

Kundu, S.; Khare, D.; Mondal, A. 2017. Individual and combined impacts of future climate and land use changes on the water balance. *Ecological Engineering*, 105, 42-57. <https://doi.org/10.1016/J.ECOLENG.2017.04.061>.

Lawrence, D.; Vandecar, K. 2015. Effects of tropical deforestation on climate and agriculture. *Nature Climate Change*, 5: 27–36. <https://doi.org/10.1038/nclimate2430>.

Lee, J.S.; Choi, H.I. 2021. Improved Streamflow Calibration of a Land Surface Model by the Choice of Objective Functions—A Case Study of the Nakdong River Watershed in the Korean Peninsula. *Water*, 13, 1709. <https://doi.org/10.3390/w13121709>.

Lejeune, Q.; Davin, E.L.; Guillod, B.P.; Seneviratne, S.I. 2015. Influence of Amazonian deforestation on the future evolution of regional surface fluxes, circulation, surface temperature and precipitation. *Climate Dynamics*, 44: 2769–2786. <https://doi.org/10.1007/s00382-014-2203-8>.

Lyra, A.A.; Chou, S.C.; Sampaio, G.O. Sensitivity of the Amazon biome to high resolution climate change projections. *Acta Amazonica*, 46(2): 175-188. <https://doi.org/10.1590/1809-4392201502225>.

Maeda, E. E.; Abera, T. A.; Siljander, M.; Aragão, L. E. O. C.; Moura, Y. M.; Heiskanen, J. 2021. Large-scale commodity agriculture exacerbates the climatic impacts of Amazonian deforestation. *Proceedings of the National Academy of Sciences*, 118:7, e2023787118. <https://doi.org/10.1073/pnas.2023787118>.

Martinez, G.F.; Gupta, H.V. 2011. Hydrologic consistency as a basis for assessing complexity of monthly water balance models for the continental United States. *Water Resources Research*, 47, W12540. <https://doi.org/10.1029/2011WR011229>.

Melone, F.; Barbetta, S.; Diomedede, T.; Peruccacci, S.; Rossi, M.; Tessarolo, A. 2005. Review and selection of hydrological models – integration of hydrological models and meteorological inputs, RISK AWARE - INTEREG IIIB CADSES programme.

Miner, G.L.; Bauerle, W.L. 2017. Seasonal variability of the parameters of the Ball-Berry model of stomatal conductance in maize (*Zea mays* L.) and sunflower (*Helianthus annuus* L.) under well-watered and water-stressed conditions. *Plant, Cell & Environment*, 40(9):1874-1886. <https://doi.org/10.1111/pce.12990>.

Moghadam, N.T.; Abbaspour, K.C.; Malekmohammadi, B.; Schirmer, M.; Yavari, A.R. 2021. Spatiotemporal Modelling of Water Balance Components in Response to Climate and Landuse Changes in a Heterogeneous Mountainous Catchment. *Water Resour Manage*, 35: 793–810. <https://doi.org/10.1007/s11269-020-02735-w>

Mohammed, S.A.; Solomatine, D.P.; Hrachowitz, M.; Hamouda, M.A. 2021. Impact of Dataset Size on the Signature-Based Calibration of a Hydrological Model. *Water*, 13, 970. <https://doi.org/10.3390/w13070970>

Moreira, M. C.; Silva, D. D. 2010. Atlas hidrológico da bacia hidrográfica do rio Grande. BarreirasBA, 75 p.

Moriasi, D.N.; Arnold, J.G.; Van Liew, M.W.; Bingner, R.L.; Harmel, R.D.; Veith, T.L. 2007. Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. *Transactions of the ASABE*, 50(3): 885–900.

Mostafaie, A.; Forootan, E.; Safari, A.; Schumacher, M. 2018. Comparing multi-objective optimization techniques to calibrate a conceptual hydrological model using in situ runoff and daily GRACE data. *Computational Geosciences*, 22: 789–814. <https://doi.org/10.1007/s10596-018-9726-8>.

Nash, J. E.; Sutcliffe, J. E. 1970. River flow forecasting through conceptual models: Part I. A discussion of principles. *Journal of Hydrology*, 10(3): 282-290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6).

Negri, A.J.; Adler, R.F.; Xu, L.; Surratt, J. 2004. The Impact of Amazonian Deforestation on Dry Season Rainfall. *Journal of Climate*, 17: 1306–1319. [https://doi.org/10.1175/1520-0442\(2004\)017<1306:TIOADO>2.0.CO;2](https://doi.org/10.1175/1520-0442(2004)017<1306:TIOADO>2.0.CO;2).

Nicklow, J.W.; Reed, P.M.; Savic, D.; Dessalegne, T.; Harrell, L.; Chan-Hilton, A.; Karamouz, M.; Minsker, B.; Ostfeld, A.; Singh, A.; Zechman, E. 2010. State of the art for genetic algorithms and beyond in water resources planning and management. *Journal of Water Resources Planning and Management*, 136(4): 412e432. [http://dx.doi.org/10.1061/\(ASCE\)WR.1943-5452.0000053](http://dx.doi.org/10.1061/(ASCE)WR.1943-5452.0000053).

Oliveira, L. J. C.; Costa, M. H.; Soares-Filho, B. S.; Coe, M. T. 2013. Large-scale expansion of agriculture in Amazonia may be a no-win scenario. *Environmental Research Letters*, 8. <https://doi.org/doi:10.1088/1748-9326/8/2/024021>

Pechlivanidis, I.G.; Jackson, B.M.; McIntyre, N.R.; Wheeler, H.S. 2011. Catchment Scale Hydrological Modelling: A Review of model types, calibration approaches and Uncertainty Analysis Methods in the context of recent developments in Technology and Applications. *Global NEST Journal*, 13(3): 193-214.

Pendrill, F.; Persson, U.M.; Godar, J.; Kastner, T.; Moran, D.; Schmidt, S.; Wood, R. 2019. Agricultural and forestry trade drives large share of tropical deforestation emissions. *Global Environmental Change*, 56: 1-10. <https://doi.org/10.1016/j.gloenvcha.2019.03.002>.

Pereira, S. B.; Pruski, F. F.; Novaes, L. F.; Silva, D. D.; Ramos, M. M. 2003. Distribuição espacial das variáveis hidrológicas na bacia do rio São Francisco. *Engenharia na Agricultura, Viçosa*, 11, 1-4.

Perugini, L.; Caporaso, L.; Marconi, S.; Cescatti, A.; Quesada, B.; Noblet-Ducoudré, N.; House, J.I.; Arneth, A. 2017. Biophysical effects on temperature and precipitation due to land cover change. *Environmental Research Letters*, 12:5, 053002. <https://doi.org/10.1088/1748-9326/aa6b3f>.

Pickup, G. 1977. Testing the efficiencies of algorithms and strategies for automatic calibration of rainfall-runoff models. *Hydrological Sciences Bulletin*, 22(2): 257-27. <https://doi.org/10.1080/02626667709491716>.

Pimenta, F.M.; Speroto, A.T.; Costa, M.H.; Dionizio, E.A. 2021. Historical Changes in Land Use and Suitability for Future Agriculture Expansion in Western Bahia, Brazil. *Remote Sensing*, 13: 1088. <https://doi.org/10.3390/rs13061088>.

Piotrowski, A.P.; Napiorkowski, M.J.; Napiorkowski, J.J.; Osuch, M.; Kundzewicz, Z.W. 2017. Are modern metaheuristics successful in calibrating simple conceptual rainfall-runoff models? *Hydrological Sciences Journal*, 62(4): 606-625. <https://doi.org/10.1080/02626667.2016.1234712>.

Porporato, A.; Ridolfi, L. 2001. Multivariate nonlinear prediction of riverflow. *Journal of Hydrology*, 248(1-4): 109–122. [https://doi.org/10.1016/S0022-1694\(01\)00395-X](https://doi.org/10.1016/S0022-1694(01)00395-X).

Pushpalatha, R.; Perrin, C.; Moine, N.L.; Andréassian, V. 2012. A review of efficiency criteria suitable for evaluating low-flow simulations. *Journal of Hydrology*, 420–421: 171-182. <https://doi.org/10.1016/j.jhydrol.2011.11.055>.

Quintero, F.; Krajewski, W.F.; Seo, B.C.; Mantilla, R. 2020. Improvement and evaluation of the Iowa Flood Center Hillslope Link Model (HLM) by calibration-free approach. *Journal of Hydrology*, 584, 124686. <https://doi.org/10.1016/j.jhydrol.2020.124686>.

Rajib, A.; Evenson, G. R.; Golden, H. E.; Lane, C. R. 2018. Hydrologic model predictability improves with spatially explicit calibration using remotely sensed evapotranspiration and biophysical parameters. *Journal of Hydrology*, 567, p. 668-683. <https://doi.org/10.1016/j.jhydrol.2018.10.024>.

Reed, P.M.; Hadka, D.; Herman, J.D.; Kasprzyk, J.R.; Kollat, J.B. 2013. Evolutionary multiobjective optimization in water resources: The past, present, and future. *Advances in Water Resources*, v. 51, p. 438–456. <https://doi.org/10.1016/j.advwatres.2012.01.005>.

Ridwansyah, I.; Yulianti, M.; Apip, S.O.; Shimizu, Y.; Wibowo, H.; Fakhrudin, M. 2020. The impact of land use and climate change on surface runoff and groundwater in Cimanuk watershed, Indonesia. *Limnology*, 21: 487–498. <https://doi.org/10.1007/s10201-020-00629-9>.

Salmona, Y.B.; Paiva, A.O.; Matricardi, E.A.T. 2017. Estimativas Futuras De Desmatamento E Emissões De Co<sup>2</sup> Equivalente No Oeste Baiano. *Revista Brasileira de Cartografia*, 68(7): 1385-1395.

Sampaio, G.; Cost, M.H.; Cardoso, M.; Sanches, M.; Nobre, C. 2012. 3rd International Conference on Earth System Modelling Vol., 3ICESM-354-1.

Santos, F.M.; Oliveira, R.P.; Di Lollo, J.A. 2020. Effects of Land Use Changes on Streamflow and Sediment Yield in Atibaia River Basin—SP, Brazil. *Water*, 12, 1711. <https://doi.org/10.3390/w12061711>.

Seibert, J. 2000. Multi-criteria calibration of a conceptual runoff model using a genetic algorithm. *Hydrology and Earth System Sciences*, 4: 215–224. <https://doi.org/10.5194/hess-4-215-2000>.

Serrão, E.A.O.; Silva, M.T.; Ferreira, T.R.; Paiva, L. C. A.; Assis, C. S.; Meiguins, A. M. M.; Rodrigues, V.S.; Assis, F.S.S.; Cardoso, D. J. G. 2021. Impacts of land use and land cover changes on hydrological processes and sediment yield determined using the SWAT model. *International Journal of Sediment Research*. <https://doi.org/10.1016/j.ijsrc.2021.04.002>.

Shafii, M.; Tolson, B.A. 2015. Optimizing hydrological consistency by incorporating hydrological signatures into model calibration objectives. *Water Resources Research* *Water Resources Research*, 51(5): 3796-3814. <http://dx.doi.org/10.1002/2014WR016520>.

Sidle, R.C. 2021. Strategies for smarter catchment hydrology models: incorporating scaling and better process representation. *Geoscience Letters*, 8:24. <https://doi.org/10.1186/s40562-021-00193-9>.

Sitterson, J.; Knightes, C.; Parmar, R.; Wolfe, K.; Muche, M.; Avant, B. 2017. An overview of rainfall-runoff model types. US Environmental Protection Agency Report EPA/600/R-153, p 29.

Sivapalan, M.; Blöschl, G. 2017. The growth of hydrological understanding: Technologies, ideas and societal needs shape the field. *Water Resources Research*, 53: 8137-8146. <https://doi.org/10.1002/2017WR021396>.

Solomon S, et al. Meehl GA, et al. 2007. Global climate projections. In: *Climate Change 2007: The Physical Science Basis*, ed Solomon S, et al. (Cambridge Univ Press, Cambridge, UK, and New York), pp 747–845.

Song, C.M. 2020. Hydrological Image Building Using Curve Number and Prediction and Evaluation of Runoff through Convolution Neural Network. *Water*, 12: 2292. <https://doi.org/10.3390/w12082292>.

Song, X-P.; Huang, C.; Saatchi, S.S.; Hansen, M.C.; Townshend, J.R. 2015. Annual Carbon Emissions from Deforestation in the Amazon Basin between 2000 and 2010. *PLoS ONE*, 10(5): e0126754. <https://doi.org/10.1371/journal.pone.0126754>.

Spracklen, D.V.; Arnold, S.R.; Taylor, C.M. 2012. Observations of increased tropical rainfall preceded by air passage over forests. *Nature*, 489(7415):282-5. <https://doi.org/10.1038/nature11390>.

Széles, B.; Parajka, J.; Hogan, P.; Silasari, R.,.; Pavlin, L.; Strauss, P.; Blöschl, G. 2020. The Added Value of Different Data Types for Calibrating and Testing a Hydrologic Model in a Small Catchment. *Water Resources Research*, 56(10):e2019WR026153. <https://doi.org/10.1029/2019WR026153>.

Pousa, R.; Costa, M.H.; Pimenta, F.M.; Fontes, V.C.; Brito, V.F.A.d.; Castro, M. 2019. Climate Change and Intense Irrigation Growth in Western Bahia, Brazil: The Urgent Need for Hydroclimatic Monitoring. *Water*, 11, 933. <https://doi.org/10.3390/w11050933>

Pree, H.; Herwig, B; Gruber, T.; Sick, B.; David, K.; Lukowicz, P. 2014. On general purpose time series similarity measures and their use as kernel functions in support vector machines. *Information Sciences*, 281, 478-495. <https://doi.org/10.1016/j.ins.2014.05.025>.

- Theuer, M.; Vavřík, R.; Vondrak, V.; Kuchař, Š.; Šír, B.; Portero, A. 2017. Efficient methods of automatic calibration for rainfall-runoff modelling in the Floreon+ system. *Neural Network World*, 27: 391-414. [10.14311/NNW.2017.27.022](https://doi.org/10.14311/NNW.2017.27.022).
- Thiemig, V.; Rojas, R.; Zambrano-Bigiarini, M.; Roo, A. D. 2013. Hydrological evaluation of satellite-based rainfall estimates over the Volta and Baro-Akobo Basin. *Journal of Hydrology*, 499: 324-338. <https://doi.org/10.1016/j.jhydrol.2013.07.012>.
- Tirupathi, C.; Shashidhar, T. 2020. Investigating the impact of climate and land-use land cover changes on hydrological predictions over the Krishna river basin under present and future scenarios. *Science of The Total Environment*, 721: 137736. <https://doi.org/10.1016/j.scitotenv.2020.137736>.
- Towner, J.; Cloke, H. L.; Zsoter, E.; Flamig, Z.; Hoch, J. M.; Bazo, J.; Coughlan de Perez, E.; Stephens, E. M. 2019. Assessing the performance of global hydrological models for capturing peak river flows in the Amazon basin, *Hydrol. Earth Syst. Sci.*, 23, 3057–3080, <https://doi.org/10.5194/hess-23-3057-2019>.
- Tucci, C.E.M. 1998. Modelos hidrológicos. ABRH Editora da UFRGS. Porto Alegre. 669.
- van der Werf, G.; Morton, D.; DeFries, R.; Olivier, J.G.J.; Kasibhatla, P.S.; Jackson, R.B.; Collatz, G.J.; Randerson, J.T. CO<sub>2</sub> emissions from forest loss. *Nature Geoscience*, 2: 737–738. <https://doi.org/10.1038/ngeo671>
- Varejão, C.G.; Costa, M.H.; Camargos, C.C.S. 2013. A multi-objective hierarchical calibration procedure for land surface/ecosystem models. *Inverse Problems in Science and Engineering*, 21(3): 357-386. <https://doi.org/10.1080/17415977.2011.639453>.
- Varejão-Silva, M.A. 2001. Meteorologia e climatologia. Brasília: Instituto Nacional de Meteorologia-Ministério da Agricultura. 515 p.
- von Randow, C.; Manzi, A.; Kruijt, B.; Oliveira, P.J.; Zanchi, F.B.; Silva, R.L.; Hodnett, M.G.; Gash, J.H.C.; Elbers, J.A.; Waterloo, M.J.; Cardoso, F.L.; Kabat, P. 2007. Comparative measurements and seasonal variations in energy and carbon exchange over forest and pasture in South West Amazonia. *Theoretical and Applied Climatology*, 78: 5–26. <https://doi.org/10.1007/s00704-004-0041-z>.

Wang, Q.J. 1991. The genetic algorithm and its application to calibrating conceptual rainfall-runoff models. *Water Resources Research*, 27(9): 2467–2471. <https://doi.org/10.1029/91WR01305>.

Wigmosta, M.S., Vail, L.W., Lettenmaier, D.P. 1994. A distributed hydrologyvegetation model for complex terrain. *Water Resources Research* 30, 1665–1679. <https://doi.org/10.1029/94WR00436>.

Xavier, A.C.; King, C.W.; Scanlon, B.R. 2015. Daily gridded meteorological variables in Brazil (1980–2013). *International Journal of Climatology*, 36(6): 2644–2659. <https://doi.org/10.1002/joc.4518>.

Zhang, L.; Nan, Z.; Yu, W.; Zhao, Y.; Xu, Y. 2018. Comparison of baseline period choices for separating climate and land use/land cover change impacts on watershed hydrology using distributed hydrological models. *Science of The Total Environment*, 622–623, 1016–1028. <https://doi.org/10.1016/j.scitotenv.2017.12.055>.

Zhang, Y.; Shao, Q.; Zhang, S.; Zhai, X.; She, D. 2016. Multi-metric calibration of hydrological model to capture overall flow regimes. *Journal of Hydrology*, 539: 525–538. <http://dx.doi.org/10.1016/j.jhydrol.2016.05.053>.

Zitzler, E.; Deb, K.; Thiele, L. 2000. Comparison of Multiobjective Evolutionary Algorithms: Empirical Results. *Evolutionary Computation*, 8(2): 173–195. <https://doi.org/10.1162/106365600568202>.