

## CALIBRAÇÃO HIDROLÓGICA DO MODELO SWAT+ COM DADOS DE PRECIPITAÇÃO E EVAPOTRANSPIRAÇÃO DERIVADOS DE SENSORIAMENTO REMOTO EM BACIAS HIDROGRÁFICAS COM ESCASSEZ DE DADOS

© Leonardo dos Santos Segantin <sup>1\*</sup>, © Marcelo Loureiro Garcia <sup>2</sup>

<sup>1</sup> Programa de Pós-Graduação em Geociências e Meio Ambiente - Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), CEP 13506-900, Rio Claro, SP, Brasil. E-mail: leonardo.segantin@unesp.br

<sup>2</sup> Departamento de Engenharia Ambiental - Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), CEP 13506-900, Rio Claro, SP, Brasil. E-mail: marcelo.garcia@unesp.br

\*Autor correspondente



This is an open access article distributed under the terms of the Creative Commons Attribution 4.0 International License.

### RESUMO

A limitação de dados hidrometeorológicos observacionais, como precipitação e vazão, representa um dos principais desafios para a modelagem hidrológica e a gestão de recursos hídricos em bacias hidrográficas. Este estudo avaliou o desempenho dos dados de precipitação do produto CHIRPS para a Bacia do Ribeirão Claro (SP) em relação aos dados observados in situ de duas estações pluviométricas em um período de 21 anos (2000-2020), utilizando métricas estatísticas e índices extremos de precipitação definidos pelo Expert Team on Climate Change Detection and Indices (ETCCDI). O modelo semi-distribuído SWAT+ foi calibrado e validado em escala mensal utilizando dados de evapotranspiração real derivados do produto MODIS, com o objetivo de avaliar sua aplicabilidade como alternativa à calibração baseada em séries de vazão. Os resultados indicaram que o CHIRPS apresenta bom desempenho na representação das médias de precipitação em escalas mensal e sazonal. Entretanto, os eventos de precipitação extrema foram subestimados, enquanto meses com baixos acumulados de precipitação tenderam a ser superestimados pelo produto. O modelo SWAT+, utilizando os dados do CHIRPS, reproduziu satisfatoriamente as séries mensais de evapotranspiração do MODIS, com valores de NSE entre 0,53 e 0,68, KGE entre 0,62 e 0,80 e PBIAS entre 3,28 e 4,53%. Esses resultados evidenciam o potencial do uso integrado de produtos de sensoriamento remoto para a calibração de modelos hidrológicos em bacias com escassez de dados hidrometeorológicos, ampliando assim as possibilidades de aplicação dessas ferramentas em regiões com monitoramento hidrológico limitado.

*Palavras-chave:* Recursos hídricos; Modelagem hidrológica, Sensoriamento remoto; Evapotranspiração; SWAT; CHIRPS.

### ABSTRACT

HYDROLOGICAL CALIBRATION OF THE SWAT+ MODEL USING PRECIPITATION AND EVAPOTRANSPIRATION DATA DERIVED FROM REMOTE SENSING IN DATA-SCARCE BASINS. The limited availability of observed hydrometeorological data, such as precipitation and streamflow, represents one of the main challenges for hydrological modeling and water resources

management in river basins. This study evaluated the performance of precipitation data from the CHIRPS dataset for the Ribeirão Claro watershed (São Paulo State, Brazil) against in situ observations from two rain gauge stations over a 21-year period (2000–2020), using statistical metrics and extreme precipitation indices defined by the Expert Team on Climate Change Detection and Indices (ETCCDI). The semi-distributed hydrological model SWAT+ was calibrated and validated at a monthly scale using actual evapotranspiration data derived from the MODIS product, aiming to evaluate its applicability as an alternative to streamflow-based calibration. The results indicated that CHIRPS performs well in representing mean precipitation at monthly and seasonal scales. However, extreme precipitation events were underestimated, while months with low accumulated precipitation tended to be overestimated. The SWAT+ model, driven by CHIRPS data, satisfactorily reproduced the monthly MODIS evapotranspiration series, with NSE values ranging from 0.53 to 0.68, KGE from 0.62 to 0.80, and PBIAS from 3.28 to 4.53%. These findings highlight the potential of integrating remote sensing products for hydrological model calibration in data-scarce basins, thereby expanding the applicability of these tools in regions with limited hydrological monitoring.

*Keywords:* Water resources; Hydrological modeling; Remote sensing; Evapotranspiration; SWAT; CHIRPS.

## RESUMEN

CALIBRACIÓN HIDROLÓGICA DEL MODELO SWAT+ CON DATOS DE PRECIPITACIÓN Y EVAPOTRANSPIRACIÓN OBTENIDOS MEDIANTE TELEDETECCIÓN EN CUENCAS HIDROGRÁFICAS CON ESCASEZ DE DATOS. La limitada disponibilidad de datos hidrometeorológicos observacionales, como precipitación y caudal, representa uno de los principales desafíos para la modelación hidrológica y la gestión de los recursos hídricos en cuencas hidrográficas. Este estudio evaluó el desempeño de los datos de precipitación del producto CHIRPS para la cuenca del Ribeirão Claro (estado de São Paulo, Brasil) en comparación con datos observados in situ de dos estaciones pluviométricas durante un período de 21 años (2000–2020), utilizando métricas estadísticas e índices extremos de precipitación definidos por el Expert Team on Climate Change Detection and Indices (ETCCDI). El modelo hidrológico semidistribuido SWAT+ fue calibrado y validado a escala mensual utilizando datos de evapotranspiración real derivados del MODIS, con el objetivo de evaluar su aplicabilidad como alternativa a la calibración basada en series de caudal. Los resultados indicaron que CHIRPS presenta un buen desempeño en la representación de las precipitaciones medias a escala mensual y estacional. Sin embargo, los eventos de precipitación extrema fueron subestimados, mientras que los meses con bajos acumulados de precipitación tendieron a ser sobreestimados. El modelo SWAT+, utilizando los datos de CHIRPS, reprodujo satisfactoriamente las series mensuales de evapotranspiración del MODIS, con valores de NSE entre 0,53 y 0,68, KGE entre 0,62 y 0,80 y PBIAS entre 3,28 y 4,53%. Estos resultados evidencian el potencial del uso integrado de productos de teledetección para la calibración de modelos hidrológicos en cuencas con escasez de datos hidrometeorológicos, ampliando así las posibilidades de aplicación de estas herramientas en regiones con monitoreo hidrológico limitado.

*Palabras clave:* Recursos hídricos; Modelación hidrológica; Teledetección; Evapotranspiración; SWAT; CHIRPS.

## 1 INTRODUÇÃO

A água é um recurso essencial para a manutenção da vida, o desenvolvimento econômico sustentável e o equilíbrio dos ecossistemas. Os recursos hídricos, em escala global, têm se tornado cada vez mais vulneráveis devido à crescente demanda associada ao aumento populacional e urbanização (He et al., 2021), mudanças climáticas (Ravinahdrasana & Franzke, 2025), poluição antrópica (Wang et al., 2024) e alterações no uso e cobertura do solo (Liu et al., 2023). Esse cenário é ainda mais crítico em países em desenvolvimento, que apresentam uma tendência mais acentuada de depleção dos recursos hídricos superficiais nas últimas décadas (Li & Zhao, 2025).

Nesse contexto, a modelagem hidrológica constitui uma ferramenta fundamental para o planejamento e a gestão dos recursos hídricos, permitindo compreender, simular e prever o resultado de processos hidrológicos em uma bacia hidrográfica em diferentes cenários. Entre os modelos hidrológicos disponíveis atualmente, o Soil and Water Assessment Tool (SWAT) e sua versão reestruturada SWAT+ (Bieger et al., 2017) são amplamente utilizados para estudos hidrológicos envolvendo alterações no balanço hídrico (Campos et al., 2024; Costa et al., 2024; Segantin & Garcia, 2026; Sharma et al., 2023), transporte de nutrientes (Eccles et al., 2023), extremos hidroclimáticos (Liu et al., 2022), transporte de sedimentos (Daba et al., 2023) e produtividade agrícola (Čerkasova et al., 2023).

A aplicação destes modelos, entretanto, requer o uso de dados observacionais, principalmente climáticos e de vazão, para calibrar e validar o modelo, tornando o processo complexo em bacias não monitoradas e dificultando a pesquisa e aplicações operacionais (Dembélé et al., 2020; Lins et al., 2024; Ningthoujam e Romeji, 2024). Dados de precipitação, por exemplo, são normalmente obtidos a partir da instalação e monitoramento de estações pluviométricas. No entanto, esses equipamentos apresentam diversas desvantagens, incluindo a cobertura espacial limitada, que resulta na baixa densidade da rede de monitoramento; presença de falhas nas medições, resultando em séries temporais incompletas; deficiências nos instrumentos e custo elevado de manutenção (Gebrechorkos et al., 2024; Kidd et al., 2017; Kidd & Huffman, 2011).

Nesse contexto, produtos de precipitação derivados de reanálise e sensoriamento remoto

têm se consolidado como alternativas viáveis para estudos climáticos e hidrológicos em regiões com escassez de dados observacionais, oferecendo cobertura espacial contínua e séries temporais consistentes em formato de raster (Bekić & Leskovar, 2025; Cui et al., 2019; Gebrechorkos et al., 2024; Junqueira et al., 2022; Romilly & Gebremichael, 2011; Sheffield et al., 2018).

A precipitação é a principal entrada de água em uma bacia hidrográfica, responsável pela variabilidade espaço-temporal dos demais componentes do balanço hídrico (Gebrechorkos et al., 2024; Sheffield et al., 2018). Nas últimas décadas, observou-se o desenvolvimento de um grande número de produtos de precipitação derivados de sensoriamento remoto, com diferentes objetivos, resoluções espaciais e temporais e variáveis de entrada (Dembélé et al., 2020). Entre eles, o Climate Hazards Group Infrared Precipitation with Stations (CHIRPS) (Funk et al., 2015) se destaca por disponibilizar dados diários de precipitação em escala quase global (50°S-50°N) em alta resolução espacial (0.05°), cobrindo um período superior a 40 anos, baseado em dados de satélite e observações *in situ*.

Embora frequentemente utilizados, dados climatológicos advindos de produtos de sensoriamento remoto apresentam incertezas e erros inerentes. De acordo com Bárdossy et al. (2022), as incertezas relacionadas à precipitação são responsáveis por até 50% dos erros em modelos hidrológicos. Em dados derivados de satélite, essas incertezas são associadas a medidas do sensor, frequência de amostragem e representação inadequada dos processos físicos das nuvens em algumas regiões (Dembélé et al., 2020; Romilly & Gebremichael, 2011). Desse modo, a validação dos dados de precipitação quanto a sua precisão temporal, espacial e capacidade de representar eventos extremos é essencial para garantir a aplicabilidade desses produtos em estudos hidrológicos, como o monitoramento de secas, previsão de enchentes, operação de reservatórios, desenvolvimento de estratégias e planos de gestão sustentável de recursos hídricos e estudos climáticos (Gebrechorkos et al., 2024; Rivera et al., 2018).

Diversos estudos avaliaram a precisão do CHIRPS para o território brasileiro, baseando-se na comparação dos dados do produto com dados observacionais de postos pluviométricos (Almeida et al., 2024; Cavalcante et al., 2020; Costa et al., 2019; Oliveira-Júnior et al., 2021; Paredes-Trejo et al., 2017; Silva et al., 2020). Entretanto,

a avaliação hidrológica desse tipo de produto, ou seja, sua aplicabilidade na calibração de modelos hidrológicos, permanece pouco explorada. Como exemplo, Rufino et al. (2025) aplicaram o modelo SWAT forçado por dados do CHIRPS para a Bacia do Rio Jarí, na região amazônica, obtendo bons resultados na calibração das vazões. Similarmente, Dhanesh et al. (2020), utilizando dados do CHIRPS, obtiveram bons resultados para a calibração das vazões em escala mensal nas bacias dos rios Chapecó e Canoas, na região Sul.

A calibração de modelos hidrológicos é normalmente realizada por meio de um ajuste iterativo dos parâmetros do modelo, de modo a se obter uma boa representação das vazões simuladas no exutório da bacia (Sirisena et al., 2020). Entretanto, bacias não monitoradas ou com escassez de dados frequentemente não apresentam estações fluviométricas e séries consistentes de dados de vazão, o que dificulta o processo de calibração. Nesse contexto, a utilização de variáveis hidrológicas alternativas estimadas por sensoriamento remoto, como a evapotranspiração, tem sido frequentemente aplicada na calibração de modelos hidrológicos nessas regiões (Guo et al., 2022; Ningthoujam & Romeji, 2024; Zheng et al., 2025).

A evapotranspiração é um componente chave do balanço hídrico, consistindo da transpiração e interceptação da chuva por parte da vegetação e também da evaporação do solo, sendo a sua compreensão essencial para estudos relacionados à gestão dos recursos hídricos, agricultura e mudanças climáticas (Guo et al., 2022; Zhu et al., 2025). Entretanto, apesar do crescente uso da evapotranspiração derivada de sensoriamento remoto na calibração de modelos hidrológicos, ainda existem importantes incertezas relacionadas à capacidade dessa abordagem em representar adequadamente os processos hidrológicos internos da bacia. Diferentemente da vazão, que integra a resposta hidrológica do sistema no exutório da bacia, a evapotranspiração representa predominantemente fluxos verticais de água e energia, podendo não capturar de forma adequada processos relacionados à geração de escoamento superficial, recarga subterrânea e dinâmicas do fluxo de base. Além disso, a calibração baseada em uma única variável hidrológica pode intensificar problemas de equifinalidade, nos quais diferentes conjuntos de parâmetros produzem desempenhos semelhantes para a variável analisada, mas representam de forma distinta os processos internos do modelo

(Beven & Binley, 1992; Taia et al., 2023).

Essas limitações tornam-se particularmente relevantes em bacias tropicais, onde a forte sazonalidade climática, a elevada variabilidade espacial da precipitação e a interação entre disponibilidade hídrica e demanda energética controlam simultaneamente os processos de evapotranspiração e geração de vazão. Nessas condições, ainda permanece pouco compreendido em que medida produtos climáticos derivados de sensoriamento remoto (e.g., precipitação e temperatura), associados à calibração hidrológica baseada exclusivamente em evapotranspiração, são capazes de reproduzir adequadamente a dinâmica hidrológica da bacia e fornecer estimativas consistentes dos componentes do balanço hídrico em bacias não monitoradas.

Dessa forma, a principal lacuna científica identificada na literatura consiste na limitada compreensão sobre a aplicabilidade da calibração hidrológica do SWAT+ baseada em dados de evapotranspiração, utilizando dados climáticos exclusivamente derivados de sensoriamento remoto, em pequenas bacias tropicais com escassez de monitoramento hidrológico. Hipotetiza-se que a utilização integrada dos dados de precipitação do CHIRPS e das séries de evapotranspiração do MODIS pode permitir a obtenção de uma representação hidrológica coerente da bacia, mesmo na ausência de dados fluviométricos consistentes.

Inserida nesse contexto, a Bacia do Ribeirão Claro, integrante da Bacia do Rio Corumbataí, desempenha papel estratégico em escala regional, sendo fundamental para o abastecimento público e para as atividades de irrigação. Devido ao uso do solo predominantemente agrícola e à presença de áreas urbanas, especialmente no trecho a jusante, a qualidade das águas do Ribeirão Claro tem sido historicamente comprometida, sobretudo em relação à presença de nutrientes e coliformes (Malagutti & Tauk-Tornisielo, 2014; Segantin et al., 2025). Ademais, de acordo com a Agência das Bacias Piracicaba-Capivari-Jundiá (PCJ), a demanda hídrica na bacia poderá superar a disponibilidade já em 2030, com tendência de agravamento nos anos subsequentes (FAB-PCJ, 2020). Apesar de sua relevância e dos problemas já identificados, a bacia não dispõe de uma rede de monitoramento hidrológico consistente, e os dados climáticos disponíveis são escassos, impondo limitações à aplicação de estudos de modelagem hidrológica e à gestão sustentável dos recursos hídricos na região.

Frete ao exposto, este trabalho tem como objetivo principal avaliar a aplicabilidade de produtos climáticos derivados de sensoriamento remoto na calibração de um modelo hidrológico para a Bacia do Ribeirão Claro. Especificamente, busca-se: (1) avaliar o desempenho dos dados de precipitação estimados pelo CHIRPS em relação aos dados observados de duas estações pluviométricas na bacia; (2) avaliar o desempenho do modelo SWAT+ em reproduzir as séries de evapotranspiração do MODIS utilizando dados climáticos do CHIRPS e (3) analisar os componentes do balanço hídrico simulados pelo SWAT+ para a bacia.

## 2 MATERIAIS E MÉTODOS

### 2.1 Área de estudo

A Bacia do Ribeirão Claro (Figura 1) está localizada no Estado de São Paulo, abrangendo os municípios de Rio Claro, Corumbataí, Cordeirópolis e Santa Gertrudes, estendendo-se por uma área de aproximadamente 281 km<sup>2</sup>. O Ribeirão

Claro nasce na zona rural de Corumbataí, atravessando áreas de pastagem e cultivos de cana-de-açúcar em seu alto curso. No município de Rio Claro, atravessa a Floresta Estadual Edmundo Navarro Andrade (FEENA), posteriormente desaguando na margem esquerda do Rio Corumbataí.

A bacia está inserida no bioma Mata Atlântica, considerado um dos cinco maiores hotspots de biodiversidade do mundo, caracterizada por uma alta diversidade biológica e endemismo (Myers et al., 2000). Entretanto, a região é hoje marcada por intensa fragmentação florestal resultante do processo histórico de uso e ocupação do solo, atualmente constituído predominantemente da monocultura da cana-de-açúcar e pastagens (Valente & Vettorazzi, 2005).

O clima da bacia é do tipo Cwa na classificação de Köppen, caracterizado por verões quentes e chuvosos e invernos secos e frios. A precipitação anual varia entre 1.300 e 1.600 mm e as temperaturas médias anuais variam entre 20 e 22 °C (Alvares et al., 2014). O Ribeirão Claro é responsável por 40,51% do abastecimento do município

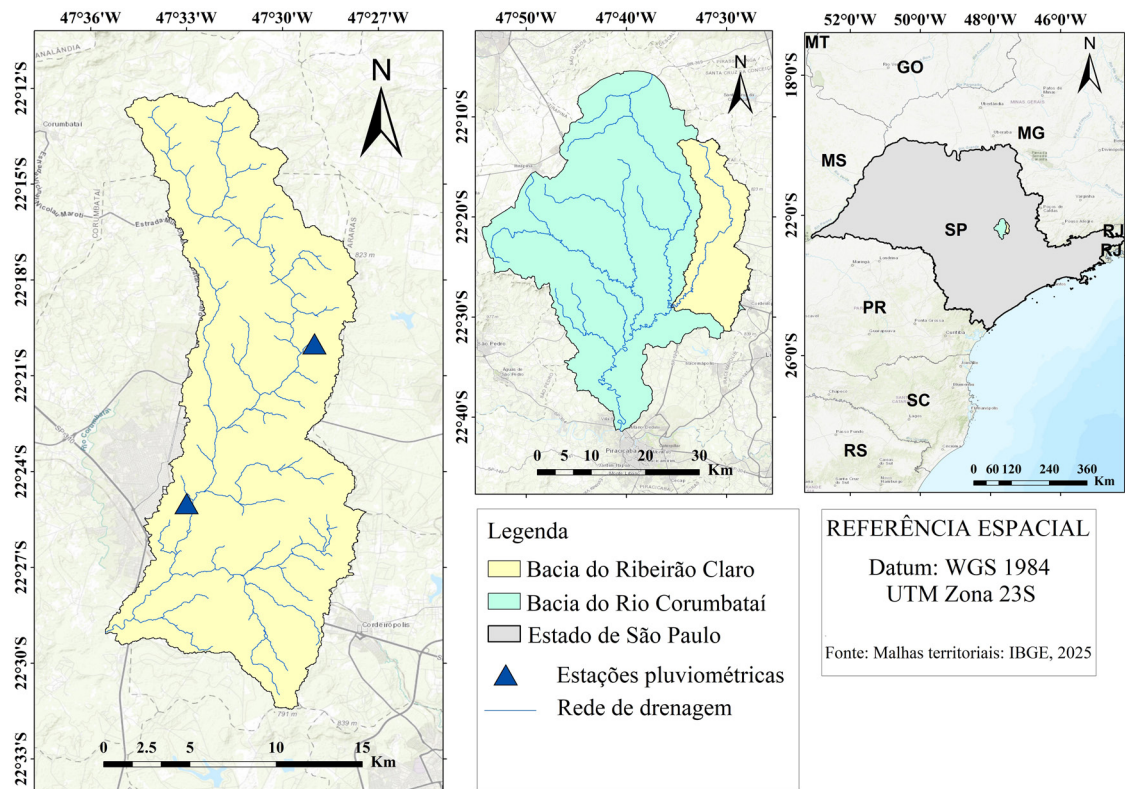


FIGURA 1 – Localização da Bacia do Ribeirão Claro, com destaque para as estações pluviométricas analisadas.

FIGURE 1 – Location of the Ribeirão Claro basin, highlighting the analyzed rain gauge stations.

de Rio Claro, cuja captação ocorre na FEENA, posteriormente tratada na Estação de Tratamento de Água (ETA) Rio Claro I, com capacidade de 495 L s<sup>-1</sup> (FAB-PCJ, 2020).

## 2.2 Aquisição dos dados de evapotranspiração

Devido à ausência de dados medidos de vazão na Bacia do Ribeirão Claro, foram utilizados dados de evapotranspiração derivados de sensoriamento remoto para a calibração e validação do SWAT+. Os dados foram obtidos do MODerate Resolution Imaging Spectroradiometer (MODIS), operacionalizado pela NASA. Foi utilizada a coleção MOD16A2GF (Running et al., 2021), em um período compreendendo 21 anos (2000-2020). O produto apresenta resolução espacial de 500 m e escala temporal de 8 dias, a qual foi reduzida para escala mensal para a calibração do modelo.

O algoritmo MOD16 é fundamentado na equação de Penman–Monteith (Monteith, 1965) e estima a evapotranspiração terrestre a partir da soma da evaporação do solo, da evaporação da água interceptada pelo dossel antes de atingir o solo, da sublimação do gelo e da neve e da transpiração das plantas. O algoritmo MOD16 é descrito em detalhes por Mu et al. (2011).

## 2.3 Validação dos dados do CHIRPS

Para avaliar a exatidão dos dados de precipitação estimados pelo CHIRPS, foram utilizadas séries diárias de dados de duas estações pluviométricas do tipo báscula, 2247018 e 2247020 (Tabela 1), mantidas pela Agência de Águas do Estado de São Paulo (SP – ÁGUAS) e disponíveis na plataforma HIDROWEB (<https://www.snirh.gov.br/hidroweb>) (Figura 1). As estações foram escolhidas por estarem localizadas dentro dos limites da bacia e apresentarem um baixo percentual de falhas para o período do estudo (2000-2020), as

TABELA 1 – Estações pluviométricas utilizadas. As linhas abaixo de cada estação representam o pixel correspondente do CHIRPS.

TABLE 1 – Rain gauge stations used. The lines below each station represent the corresponding CHIRPS pixel.

Estação	Latitude	Longitude	Altitude (m)	Período	Falhas (%)
2247018	-22,333	-47,383	600	2000-2020	3,02
CHIRPS	-22,324	-47,475	655	2000-2020	0,00
2247020	-22,416	-47,550	600	2000-2020	3,62
CHIRPS	-22,424	-47,575	589	2000-2020	0,00

quais foram preenchidas pelo método da razão normal (Wangwongchai et al., 2023).

A validação foi realizada comparando-se a série observada à célula do raster do CHIRPS cujo centroide está mais próximo das coordenadas de cada estação (*point-to-pixel*). O método é amplamente utilizado para a validação de dados de precipitação estimados por sensoriamento remoto, evitando erros decorrentes de interpolações espaciais de estações pluviométricas esparsas e irregularmente distribuídas (Al-Shamayleh et al., 2024; Cavalcante et al., 2020; Wu et al., 2019). A comparação foi realizada utilizando a série temporal mensal para os 21 anos do estudo (n = 252) e em escala sazonal, representando as estações de verão (DJF), outono (MAM), inverno (JJA) e primavera (SON) (n = 63), com base em quatro critérios estatísticos: coeficiente de correlação (r), raiz do erro quadrático médio (RMSE), percentual de viés (PBIAS) e coeficiente de Nash-Sutcliffe (NSE), descritos pelas equações 1, 2, 3 e 4. Ainda, aplicou-se os testes t de Student e Mann-Whitney (Mann & Whitney, 1947) para testar a hipótese de existência de diferenças significativas entre as médias e medianas, respectivamente, das séries observadas e estimadas pelo CHIRPS.

$$r = \frac{\sum_{i=1}^n (O_i - \underline{O})(P_i - \underline{P})}{\sqrt{\sum_{i=1}^n (O_i - \underline{O})^2} \sqrt{\sum_{i=1}^n (P_i - \underline{P})^2}} \quad \text{Eq. (1)}$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad \text{Eq. (2)}$$

$$\text{PBIAS} = \frac{\sum_{i=1}^n O_i - P_i}{\sum_{i=1}^n O_i} * 100 \quad \text{Eq. (3)}$$

$$\text{NSE} = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \underline{O})^2} \quad \text{Eq. (4)}$$

sendo n é o total de observações,  $O_i$  é o i-ésimo valor observado,  $\underline{O}$  é a média dos valores observados,  $P_i$  é o i-ésimo valor da série do CHIRPS,  $\underline{P}$  é a média dos valores do CHIRPS.

Para avaliar a eficiência do CHIRPS em reproduzir os eventos extremos de precipitação na bacia, foram utilizados oito índices definidos pelo Expert Team on Climate Change Detection and Indices (ETCCDI), listados na Tabela 2. Os índices foram calculados anualmente para cada estação e pixel correspondente do CHIRPS, sendo também calculada a média anual para o período.

TABELA 2 – Índices de extremos de precipitação analisados.

TABLE 2 – Extreme precipitation indices analyzed.

Índice	Descrição	Unidade
CDD	Dias secos consecutivos - Número máximo de dias consecutivos sem precipitação (< 1 mm) no ano	Dias
CWD	Dias úmidos consecutivos - Número máximo de dias consecutivos com precipitação > 1 mm no ano	Dias
R1mm	Número de dias úmidos - Número de dias no ano com precipitação superior a 1 mm	Dias
R10mm	Dias de precipitação intensa - Número de dias no ano com precipitação superior a 10 mm	Dias
R20mm	Dias de precipitação muito intensa - Número de dias no ano com precipitação superior a 20 mm	Dias
R30mm	Dias de precipitação extrema - Número de dias no ano com precipitação superior a 30 mm	Dias
RX1day	Precipitação máxima diária no ano	mm
R95p	Dias muito úmidos - Precipitação total anual de dias com precipitação acima do percentil 95	mm

## 2.4 O modelo SWAT+

O SWAT+ é um modelo físico, semi-distribuído e contínuo utilizado para simular os componentes do balanço hídrico e avaliar impactos das mudanças climáticas e uso do solo no escoamento superficial, infiltração, degelo, erosão e sedimentação, práticas de uso do solo e transformação de nutrientes. A simulação desses processos é descrita em detalhes por Neitsch et al. (2011). Foi utilizado o SWAT+ (Rev. 61.0.1) através do plug-in QSWAT+ (3.1.2) acoplado ao software de geoprocessamento QGIS (3.40.6).

O SWAT+ inicialmente delimita a rede de drenagem e a bacia através de um Modelo Digital de Elevação (MDE), posteriormente discretizando-a em sub-bacias. As sub-bacias são então discretizadas em Unidades de Resposta Hidrológica (HRUs) através de uma combinação única de uso do solo, classe de solo e declividade. Uma nova adição do SWAT+ em relação ao SWAT se refere a introdução das Unidades de Paisagem (LSUs), permitindo a separação dos processos de áreas superiores das wetlands. Para tal, foi utilizado o método Slope Position, baseado na inversão do MDE, que estima as áreas inundáveis a partir do cálculo de um coeficiente que considera a topografia e as zonas suscetíveis à inundação durante períodos de alta vazão (Rathjens et al., 2016). A fase terrestre do balanço hídrico é calculada conforme a seguinte equação (Neitsch et al., 2011):

$$SW_i = SW_o + \sum_{i=1}^t (R_{day} - Q_{surf} - E_a - W_{seep} - Q_{gw}) \text{ Eq. (5)}$$

onde  $SW_i$  é o conteúdo final de água no solo (mm),  $SW_o$  é o conteúdo inicial de água no solo no dia  $i$  (mm),  $R_{day}$  é a precipitação no dia  $i$  (mm),  $Q_{surf}$  representa o escoamento superficial no dia  $i$  (mm),  $E_a$  é a evapotranspiração real no dia  $i$  (mm),  $W_{seep}$  é a percolação no dia  $i$  (mm), e  $Q_{gw}$  é o fluxo de retorno no dia  $i$  (mm).

A evapotranspiração potencial foi calculada internamente pelo modelo utilizando o método de Hargreaves (Hargreaves et al., 1985), descrito na Equação 6. O método de Muskingum foi utilizado para a propagação de vazão nos canais. Para o cálculo da evapotranspiração real, o modelo considera inicialmente a evaporação de qualquer precipitação interceptada pelo dossel da planta, posteriormente determinando a máxima transpiração e sublimação/evaporação do solo com uma abordagem semelhante a de Ritchie (1972).

$$\lambda E_o = 0,0023 \cdot H_o \cdot (T_{mx} - T_{mn})^{0,5} \cdot (T_{av} + 17,8) \text{ Eq. (6)}$$

onde  $E_o$  é a evapotranspiração potencial ( $\text{mm d}^{-1}$ ),  $\lambda$  é o calor latente de vaporização ( $\text{MJ kg}^{-1}$ ),  $H_o$  é a radiação extraterrestre ( $\text{MJ m}^{-2} \text{ d}^{-1}$ ),  $T_{mx}$  é a temperatura máxima do ar em determinado dia ( $^{\circ}\text{C}$ ),  $T_{mn}$  é a temperatura mínima do ar em determinado dia ( $^{\circ}\text{C}$ ) e  $T_{av}$  é a temperatura média do ar em determinado dia ( $^{\circ}\text{C}$ ).

### 2.4.1 Implementação do modelo

Para a sua implementação, o SWAT+ requer dados topográficos, de uso e cobertura do solo, das classes e características dos solos, e dados climáticos. O Modelo Digital de Elevação (MDE) (Figura 2a) com resolução espacial de 30 m foi obtido do Shuttle Radar Topography Mission (SRTM) da NASA (Farr et al., 2007). O mapa de declividade foi derivado a partir do MDE, utilizando a função Slope no QGIS, com valores expressos em porcentagem. As classes de declividade apresentadas na Figura 2c foram definidas com base no histograma de distribuição dos valores obtidos. O mapa de uso e ocupação do solo (Figura 2b) com resolução de 30 m foi obtido do Projeto MapBiomass (Souza et al., 2020).

O mapa pedológico (Figura 2d) em escala 1:250.000 foi obtido junto ao Instituto Brasileiro de Geografia e Estatística (IBGE) ([https://geoftp.ibge.gov.br/informacoes\\_ambientais/pedologia/vetores/escala\\_250\\_mil/](https://geoftp.ibge.gov.br/informacoes_ambientais/pedologia/vetores/escala_250_mil/)). As características de cada classe de solo foram levantadas de diferentes fontes. Os grupos hidrológicos dos solos foram identifi-

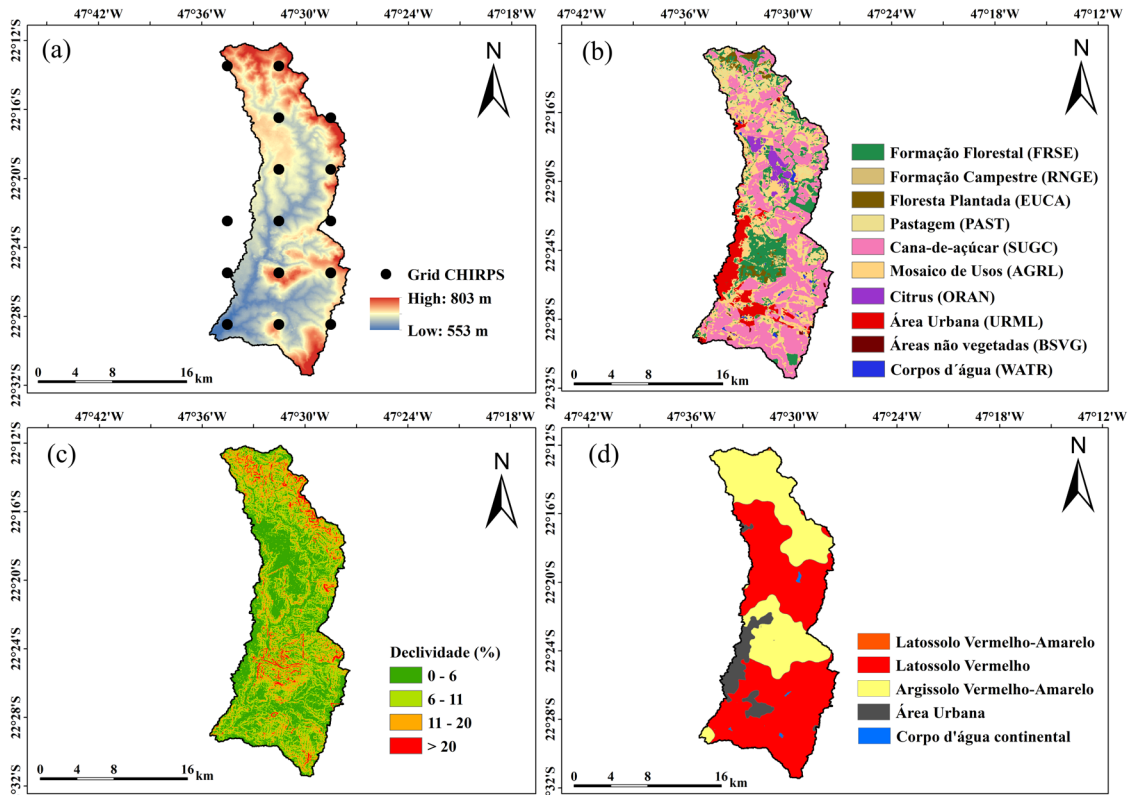


FIGURA 2 – (a) Modelo Digital de Elevação (MDE) e discretização do raster do CHIRPS/CHIRTS, (b) Mapa de uso e ocupação do solo, (c) Classes de declividade adotadas e (d) Mapa pedológico. Referência Espacial – Datum: WGS 84, UTM Zona 23S.

FIGURE 2 – (a) Digital Elevation Model (DEM) CHIRPS/CHIRTS grid discretization, (b) land use and land cover map, (c) adopted slope classes, and (d) soil map. Spatial Reference - Datum: WGS 84, UTM Zone 23S.

cados conforme proposto por Sartori et al. (2005). A condutividade hidráulica saturada (SOL\_K) e a capacidade de água disponível (SOL\_AWC) foram calculados por funções de pedotransferência (Saxton & Rawls, 2006). A profundidade, textura, matéria orgânica e demais parâmetros foram obtidos do trabalho de Almeida et al. (2023).

Os dados de precipitação foram obtidos em escala diária do banco de dados do CHIRPS e posteriormente reduzidos para escala mensal. Os dados diários de temperatura do ar mínima e máxima, necessários para a estimativa da evapotranspiração potencial pelo modelo, foram levantados a partir do banco de dados do Climate Hazards Center InfraRed Temperature with Stations (CHIRTS) (Verdin et al., 2020), que possui a mesma resolução e discretização do CHIRPS. Foram utilizados 15 pontos para cobrir toda a área da bacia (Figura 2a). O modelo foi implementado considerando limites de 10% para uso do solo, declividade e tipos de solo, resultando na criação de 1442 HRUs.

#### 2.4.2 Análise de sensibilidade, calibração e avaliação do modelo

Previamente à calibração do modelo, foi realizada uma análise de sensibilidade para a determinação dos parâmetros mais influentes na simulação da evapotranspiração na bacia, por meio do software SWAT+ Toolbox. Foi utilizado o método Latin Hypercube Sampling One-Factor-At-a-Time, que opera em loops, calculando os efeitos parciais da variação de cada parâmetro em cada loop, onde o efeito final para cada variável é definido como a média dos efeitos parciais (Griensven et al., 2006).

O período do estudo cobriu 21 anos (2000-2020), sendo os três primeiros (2000-2002) utilizados como um período de aquecimento para estabilizar as condições iniciais do modelo. O período de calibração compreendeu 12 anos (2003-2014), e os seis últimos anos (2015-2020) foram utilizados para validar o modelo. A calibração foi realizada em escala mensal, visando capturar as dinâmicas

temporais gerais de evapotranspiração na bacia e considerando as limitações de dados observacionais disponíveis e as incertezas associadas aos produtos climáticos utilizados, sendo amplamente adotada em estudos semelhantes (e.g., Ha et al., 2018; Koltsida & Kallioras, 2022; Ningthoujam & Romeji, 2024; Parajuli et al., 2018; Sevastas et al., 2025).

A performance do SWAT+ em simular as séries mensais de evapotranspiração do MODIS foi avaliada a partir de quatro indicadores estatísticos baseados em Moriasi et al. (2007): NSE (Equação 4), PBIAS (Equação 3), Razão entre a Raiz do Erro Quadrático Médio e o Desvio Padrão das Observações (RSR) (Equação 7) e Coeficiente de Kling-Gupta (KGE) (Equação 8) (Gupta et al., 2009). O modelo foi calibrado utilizando o NSE como função objetivo no SWAT+ Toolbox.

$$RSR = \frac{RMSE}{\sigma_{obs}} \quad \text{Eq. (7)}$$

$$KGE = 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad \text{Eq. (8)}$$

$$\alpha = \frac{\alpha_s}{\alpha_o} \quad \text{Eq. (9)}$$

$$\beta = \frac{\mu_s}{\mu_o} \quad \text{Eq. (10)}$$

onde  $\sigma_{obs}$  é o desvio padrão dos dados observados,  $\alpha_s$  e  $\alpha_o$  representam o desvio padrão dos dados simulados e observados, respectivamente, e  $\mu_s$  e  $\mu_o$  representam as médias dos dados simulados e observados, respectivamente.

### 3 RESULTADOS E DISCUSSÃO

#### 3.1 Validação dos dados do CHIRPS

##### 3.1.1 Validação mensal e sazonal

Os resultados estatísticos da comparação dos dados do CHIRPS com as estações são apresentados na Tabela 3. De modo geral, todos os períodos avaliados apresentaram valores elevados para o coeficiente de correlação, indicando uma boa representação da variabilidade temporal e do ciclo sazonal da precipitação. A série dos acumulados mensais apresentou valor de 0,89 em ambas as estações. Em escala sazonal, os valores variaram entre 0,72 no outono e 0,90 no inverno e primavera. Resultados semelhantes foram obtidos por Costa et al. (2019) para a região sudeste, com valores de correlação mensais variando entre 0,92 e 1. Ainda, os testes t de Student e Mann-Whitney não indicaram diferenças estatísticas

TABELA 3 – Performance estatística dos dados do CHIRPS em relação aos dados observados.

TABLE 3 – Statistical performance of CHIRPS data in relation to observed data.

Estação	r	RMSE (mm)	PBIAS (%)	NSE	p-valor (teste t)	p-valor (MW)
<i>Mensal</i>						
2247018	0,89	46,26	0,89	0,80	0,9055	0,6844
2247020	0,89	50,05	7,19	0,78	0,3248	0,8107
<i>DJF</i>						
2247018	0,80	69,45	-0,42	0,61	0,9543	0,5982
2247020	0,84	70,71	6,49	0,62	0,3675	0,8376
<i>MAM</i>						
2247018	0,76	48,02	-1,86	0,52	0,8862	0,8797
2247020	0,72	50,66	5,48	0,46	0,6592	0,6747
<i>JJA</i>						
2247018	0,89	35,07	21,11	0,70	0,2275	0,7308
2247020	0,90	30,07	24,98	0,61	0,1985	0,6998
<i>SON</i>						
2247018	0,90	30,89	-0,38	0,81	0,9711	0,8836
2247020	0,81	39,39	4,51	0,66	0,6467	0,7771

ticamente significativas entre as séries em nenhum período analisado, considerando um nível de 5% de significância ( $p > 0,05$ ).

O RMSE, por sua vez, apresentou valores moderados entre as séries, com maiores erros no verão, durante a estação chuvosa, e menores valores no inverno e primavera, associados principalmente à subestimação de eventos de maior magnitude. Resultado semelhante foi obtido por Santos et al. (2022), que verificaram valores de RMSE variando entre 36,4 e 49,3 mm entre as séries mensais observadas e estimadas pelo CHIRPS para a região central do Estado de São Paulo. Por utilizar o quadrado dos resíduos em sua formulação, o indicador torna-se sensível a diferenças de magnitude moderada. Esse comportamento é visto na Figura 3, que apresenta a comparação temporal entre os valores mensais das estações e os dados do CHIRPS para o período do estudo. É possível observar uma tendência de subestimação nos meses de maior precipitação acumulada, que ocorrem entre dezembro e fevereiro. Essa tendência é também verificada na regressão linear entre as séries mensais, onde os coeficientes angulares inferiores à unidade indicam uma tendência sistemática de subestimação pelo CHIRPS, especialmente para eventos de maior magnitude e na estação 2247020 (0,704). Por outro lado, os interceptos positivos sugerem leve superestimativa em eventos de baixa precipitação.

A Figura 4 mostra a distribuição mensal dos acumulados de precipitação observados e estimados

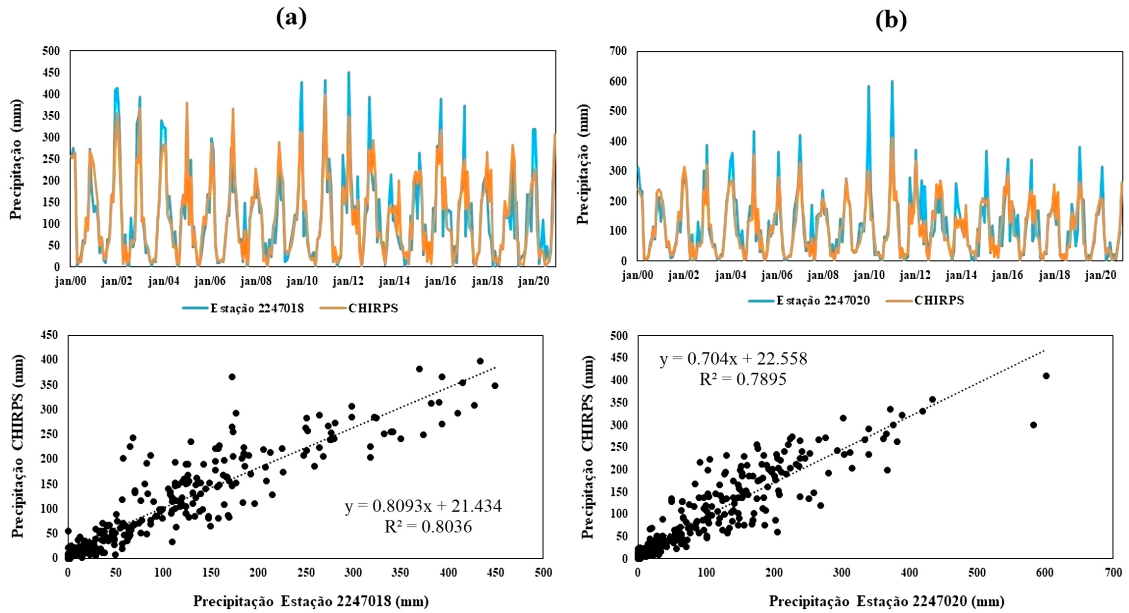


FIGURA 3 – Precipitação mensal observada e estimada pelo CHIRPS e regressão linear para (a) estação 2247018 e (b) estação 2247020.

FIGURE 3 – Observed and CHIRPS-estimated monthly precipitation and linear regression for (a) station 2247018 and (b) station 2247020.

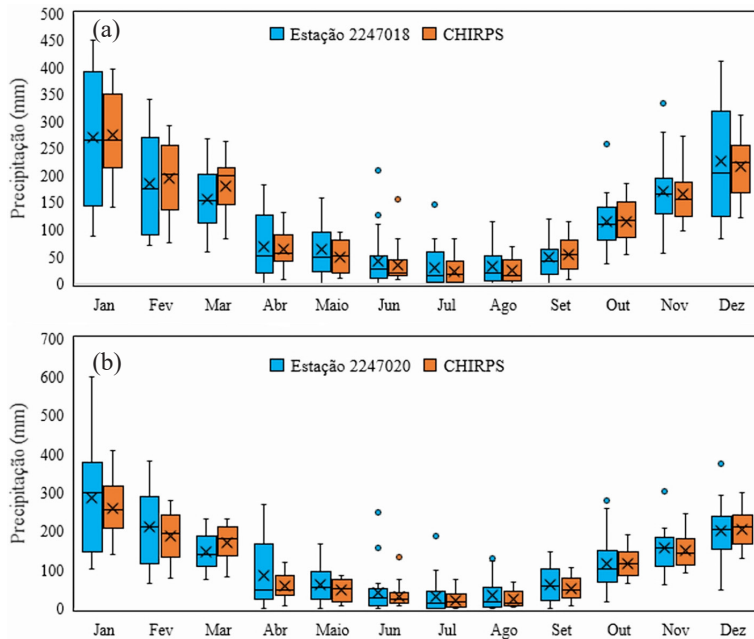


FIGURA 4 – Distribuição mensal da precipitação observada e do CHIRPS entre 2000 e 2020 para (a) estação 2247018 e (b) estação 2247020. No gráfico, as caixas representam o intervalo interquartil (percentis 25-75), com a linha interna indicando a mediana e o “X” representando a média. As retas representam os valores mínimos e máximos dentro de 1.5 vezes o intervalo interquartil, enquanto os pontos externos representam valores atípicos (outliers) fora desse intervalo.

FIGURE 4 – Monthly distribution of observed precipitation and CHIRPS data between 2000 and 2020 for (a) station 2247018 and (b) station 2247020. In the plot, the boxes represent the interquartile range (25th–75th percentiles), with the internal line indicating the median and the “X” representing the mean. The whiskers extend to the minimum and maximum values within 1.5 times the interquartile range, while the points beyond them represent outliers outside this interval.

pelo CHIRPS. Observa-se que as médias e medianas apresentam valores semelhantes em quase todos os meses, demonstrando boa concordância entre os valores médios e medianos das séries mensais, com a exceção mais notável sendo o mês de março em ambas as estações. Entretanto, os dados do CHIRPS apresentam menor variabilidade, tendendo a superestimar os valores mensais de precipitação mais baixos e a subestimar os valores mais elevados (em até 87%), especialmente nos meses de verão na estação 2247020, conforme evidenciado pelos percentis. Resultados semelhantes foram observados em estudos realizados na região amazônica (Cavalcante et al., 2020; Paredes-Trejo et al., 2017) e Bolívia (Torres-Batló & Martí-Cardona, 2020).

A análise do PBIAS indica valores relativamente baixos em todos os períodos, com exceção do inverno, sugerindo um bom ajuste entre o volume total de precipitação observado e estimado pelo CHIRPS. Entretanto, quando os dados estimados apresentam subestimação e superestimação em proporções semelhantes, os valores do PBIAS podem aparentar bom desempenho mesmo quando o ajuste apresenta limitações (Moriassi et al., 2007). Esse comportamento explica os resultados observados, uma vez que o CHIRPS apresentou tendências simultâneas de subestimação e superestimação em quase todos os meses, resultando na compensação dos erros. A exceção ocorre nos meses de inverno, especialmente junho e agosto, onde a subestimação é mais frequente e em maior magnitude, resultando em valores de PBIAS entre 21,11 e 24,98% e indicando um menor volume total estimado nesse período.

Parte das discrepâncias observadas entre os dados do CHIRPS e as estações pluviométricas pode estar associada à diferença de escala espacial entre as medições. Enquanto os pluviômetros registram a precipitação em um ponto específico, os dados do CHIRPS representam valores médios em células espaciais (pixels) de aproximadamente 0,05°. Esse processo de agregação espacial tende a suavizar eventos extremos de precipitação, resultando frequentemente em menor variabilidade e subestimação de eventos intensos quando comparados a medições pontuais (Dinku et al., 2018).

A tendência geral de superestimação dos meses menos chuvosos pelo CHIRPS pode ainda ser resultado de erros nas medições dos postos pluviométricos, que apresentam problemas conhecidos em relação a precisão das medições da precipitação leve, como a possibilidade de evaporação no

coletor e deformação do campo de vento acima da abertura do pluviômetro, o que pode levar à subestimação desses eventos pelas estações (Adam & Lettenmaier, 2003; Kidd & Huffman, 2011; Tapiador et al., 2012).

### 3.1.2 Validação dos índices extremos

As médias anuais calculadas para os índices extremos das estações e do CHIRPS são apresentadas na Tabela 4, enquanto as variações anuais são mostradas na Figura 5. Considerando as médias anuais, os dados do CHIRPS superestimaram levemente o CWD para a estação 2247018 e apresentaram resultados similares para a estação 2247020. O CDD foi subestimado, enquanto o número de dias úmidos no ano (R1mm) foi superestimado em ambas as estações, especialmente após 2010. Esse padrão indica uma tendência à fragmentação dos períodos secos e à distribuição da precipitação em um maior número de dias com baixos acumulados por parte do CHIRPS. Como consequência, pode ocorrer uma suavização da intensidade diária da chuva, com possível redução na magnitude dos eventos extremos quando comparados aos dados observados. Esse comportamento é corroborado pela análise dos índices R30mm, RX1day e R95p, que foram significativamente subestimados pelo CHIRPS, reforçando o padrão de menor representação da precipitação extrema já evidenciado na escala mensal.

Os eventos de precipitação extrema no sudeste brasileiro ocorrem principalmente no verão, influenciados pela atuação da Zona de Convergência do Atlântico Sul (ZCAS), que se origina da interat-

TABELA 4 – Médias anuais dos índices extremos para a Bacia do Ribeirão Claro entre 2000 e 2020. As colunas à direita de cada estação representam o pixel correspondente do CHIRPS.

TABLE 4 – Annual mean values of extreme precipitation indices for the Ribeirão Claro basin between 2000 and 2020. The columns to the right of each station represent the corresponding CHIRPS pixel.

Índice	22417018	CHIRPS	22417020	CHIRPS
CDD	45,52	41,86	49,24	37,38
CWD	7,71	8,19	7,33	7,29
R1mm	88,19	93,67	83,81	93,24
R10mm	45,10	56,05	46,24	53,57
R20mm	23,57	22,90	24,10	20,62
R30mm	12,62	7,86	12,52	6,90
RX1day	89,07	55,01	86,70	55,14
R95p	297,46	212,27	309,26	203,26




FIGURA 5 – Variações anuais dos índices extremos de precipitação para a Bacia do Ribeirão Claro entre 2000 e 2020.

FIGURE 5 – Annual variations of extreme precipitation indices for the Ribeirão Claro basin between 2000 and 2020.

ção entre os sistemas frontais em caráter estacionário e a convecção tropical (Carvalho et al., 2004; Reboita et al., 2010). Durante o inverno, observa-se uma redução significativa da precipitação na região, associada ao enfraquecimento do Sistema de Monção da América do Sul e à diminuição do transporte de umidade proveniente da Amazônia, além da maior influência de sistemas de alta pressão subtropicais que favorecem condições atmosféricas mais estáveis (Reboita et al., 2010). Nesse contexto, os resultados observados podem estar relacionados à dificuldade do CHIRPS em representar adequadamente a ausência ou presença de precipitação em determinados processos de diferentes sistemas meteorológicos, especialmente relacionados à ZCAS. Esse comportamento, entretanto, não é exclusivo de dados originados de sensoriamento remoto. Lyra et al. (2018), por exemplo, utilizaram modelos climáticos regionais (RCMs) para avaliar projeções climáticas futuras de extremos de precipitação e temperatura nas regiões metropolitanas de São Paulo, Rio de Janeiro e Santos, observando subestimação dos eventos de precipitação histórica associada à ZCAS.

Além dos efeitos de escala espacial, discutidos anteriormente, parte dessas discrepâncias também pode estar associada às limitações dos algoritmos de estimativa de precipitação baseados em sensores infravermelhos utilizados pelo CHIRPS. O método do infravermelho termal baseia-se em uma relação temperatura-altura, partindo da premissa física de que, na troposfera, a temperatura diminui com a altitude. Desse modo, a temperatura do topo das nuvens atuaria como um indicador de sua altura, assumindo que nuvens mais altas e frias estejam associadas a maiores volumes de precipitação. Entretanto, esta é uma relação indireta, uma vez que nuvens mais frias, com as cirrus, nem sempre produzem precipitação (Valencia et al., 2026). Além disso, em regiões tropicais, onde sistemas convectivos frequentemente apresentam elevada variabilidade espacial e temporal, a relação entre a temperatura do topo da nuvem e a precipitação superficial tende a ser mais complexa. Nesses ambientes, nuvens relativamente mais quentes e com bases mais baixas podem produzir precipitações intensas, levando à subestimação desses eventos pelos sensores infravermelhos (So & Shin, 2018).

A capacidade limitada do CHIRPS em detectar eventos de precipitação extrema é comumente reportada na literatura. No Brasil, Cavalcante et al. (2020), em estudo na região amazônica, também observaram uma tendência de subestimação do

CHIRPS para os índices CDD, RX1day, RX5day e R50mm, enquanto o R10mm também foi superestimado. Bai et al. (2018) verificaram uma tendência de subestimação em precipitações diárias na faixa de 20-55 mm d<sup>-1</sup> e superestimação em faixas inferiores à 5 mm d<sup>-1</sup> na China. Al-Shamayleh et al. (2024) constaram o mesmo padrão na Bacia do Rio Wala, Jordânia, onde os dados do CHIRPS subestimaram os valores do CDD, R20mm e R30mm.

Essas divergências podem afetar significativamente os resultados de simulações hidrológicas utilizando os dados do CHIRPS. Por exemplo, a subestimação de eventos de precipitação extrema pode atenuar a geração de escoamento superficial no SWAT+, que utiliza o método da curva número (CN) baseado em um limite diário de precipitação que deve ser excedido para a geração de escoamento, definido com base nas condições de umidade antecedente, solos e uso do solo (Neitsch et al., 2011). Da mesma forma, em períodos com baixa disponibilidade hídrica, pequenas superestimativas da precipitação podem alterar a dinâmica do armazenamento de água no solo e influenciar a evapotranspiração real simulada, reduzindo artificialmente a intensidade do déficit hídrico sazonal. Esse comportamento pode ainda contribuir para a manutenção do fluxo de base e da produção de água durante a estação seca.

A aplicabilidade de dados de sensoriamento remoto a estudos de modelagem hidrológica depende de sua precisão e dos objetivos do estudo. De modo geral, os dados do CHIRPS apresentaram tanto vantagens quanto limitações. Com base nos índices avaliados, o CHIRPS apresentou desempenho insatisfatório na detecção de eventos extremos de precipitação na bacia, reduzindo assim sua confiabilidade em estudos baseados nesses eventos, como a estimativa de vazões de pico e previsão de enchentes (Odey & Cho, 2025).

Em termos médios, entretanto, o CHIRPS apresentou boa precisão na representação das variações sazonais da precipitação na bacia, capturando de forma eficaz as alternâncias entre as estações seca e chuvosa, apesar das limitações. Essa conclusão é consistente com estudos anteriores que sugerem a aplicabilidade do CHIRPS para análises sazonais e mensais em diferentes regiões, como Brasil (Silva et al., 2020), Argentina (Rivera et al., 2018), Paquistão (Nawaz et al., 2021), Irã (Mianabadi et al., 2022), China (Pang et al., 2020) e Indonésia (Wiwoho et al., 2021). Dessa forma, os dados do CHIRPS apresentam potencial para estudos de

modelagem contínua, envolvendo estimativas do balanço hídrico de longo prazo na bacia.

### 3.2 Análise de sensibilidade e avaliação do modelo

O ranqueamento dos parâmetros mais sensíveis para a simulação da evapotranspiração mensal na Bacia do Ribeirão Claro, bem como os valores ajustados no período de calibração é mostrado na Tabela 5. Os parâmetros identificados como mais sensíveis foram o armazenamento máximo de água no dossel (CANMX), fator de compensação de evaporação no solo (ESCO), fator de compensação de absorção das plantas (EPCO) e máximo índice de área foliar potencial (LAI\_POT). Resultado semelhante foi obtido por Ningthoujam e Romeji (2024) para a simulação da evapotranspiração real utilizando o SWAT em uma bacia hidrográfica em Manipur (Índia), utilizando dados do MODIS e GLEAM (Global Land Evaporation Amsterdam Model). Koltsida e Kallioras (2022) também obtiveram os parâmetros ESCO e EPCO entre os mais sensíveis para a calibração da evapotranspiração na Bacia do Rio Kifissos, Grécia.

O parâmetro LAI\_POT representa o valor máximo potencial do índice de área foliar que uma determinada espécie vegetal pode atingir ao longo de seu ciclo de crescimento. O índice de área foliar (LAI), por sua vez, corresponde à razão entre a área total das folhas da vegetação e a área do solo ( $m^2 m^{-2}$ ), refletindo a densidade da cobertura vegetal. Valores mais elevados de LAI tendem a aumentar as taxas de transpiração das plantas e a interceptação da precipitação, além de reduzir o escoamento

superficial e o potencial de erosão, uma vez que o dossel vegetal dissipa parte da energia cinética das gotas de chuva antes que estas atinjam o solo (Jiang et al., 2024). O parâmetro ESCO representa o fator de compensação da evaporação do solo, responsável por modificar a distribuição da extração de água ao longo do perfil do solo para atender à demanda evaporativa (Neitsch et al., 2011). Dessa forma, valores elevados de ESCO permitem maior contribuição das camadas inferiores do solo, o que pode resultar em maior evaporação do solo e redução na quantidade total de água armazenada no perfil. De forma análoga, o EPCO representa o fator de compensação de absorção da planta, regulando a capacidade das plantas em extrair água das camadas mais profundas do solo quando a disponibilidade nas camadas superiores é limitada (Neitsch et al., 2011).

O parâmetro CANMX controla a interceptação da precipitação pela vegetação, influenciando a fração da água que pode ser temporariamente retida no dossel antes de atingir o solo. A interceptação constitui um componente importante da evapotranspiração em regiões florestadas, especialmente em áreas onde a precipitação é dominada por eventos sinóticos de longa duração, podendo representar até cerca de 30% da precipitação total. Em regiões tropicais, nas quais predominam eventos convectivos de curta duração e alta intensidade, a interceptação tende a desempenhar um papel mais modesto no balanço hídrico, geralmente apresentando valores máximos próximos de 15% (Miralles et al., 2010).

TABELA 5 – Resultado da análise de sensibilidade e parâmetros calibrados.

TABLE 5 – Sensitivity analysis results and calibrated parameter values.

Rank	Parâmetro	Descrição	Mínimo	Máximo	Ajustado
1	v_CANMX	Quantidade máxima de água que pode ficar retida no dossel quando este está completamente desenvolvido (mm)	0	10	2,05
2	v_ESCO	Fator de compensação da evaporação do solo	0	1	0,92
3	v_EPCO	Fator de compensação de absorção da planta	0	1	0,65
4	r_LAI_POT	Máximo índice de área foliar potencial ( $m^2 m^{-2}$ )	-20	20	15,5
5	r_SOL_AWC	Capacidade de água disponível na camada de solo ( $mm mm^{-1}$ )	-20	20	-2,48
6	v_EVLAI	Índice de área foliar no qual não ocorre evaporação da superfície da água	0	10	3,52
7	v_PERCO	Coefficiente de percolação	0	1	0,56
8	r_CN2	Número de curva da condição de umidade II	-20	20	3,63
9	r_SOL_BD	Densidade aparente da camada de solo ( $g cm^{-3}$ )	-20	-20	-19,85
10	r_SOL_K	Condutividade hidráulica saturada do solo ( $mm h^{-1}$ )	-20	20	15,25

Nota: “v” e “r” referem-se aos métodos de substituição e porcentagem, respectivamente.  
Note: “v” and “r” refer to the substitution and percentage methods, respectively.

Após a análise de sensibilidade, o modelo foi calibrado para o período de 2003 a 2014 e validado entre 2015 e 2020. Os resultados das simulações mensais de evapotranspiração pelo SWAT+ para a Bacia do Ribeirão Claro, comparados aos valores estimados pelo MODIS, são apresentados na Figura 6. De modo geral, o SWAT+, utilizando os dados de precipitação do CHIRPS e de temperatura do CHIRTS, foi capaz de capturar adequadamente a variabilidade temporal da série de evapotranspiração estimada pelo MODIS. Entretanto, observa-se uma tendência de subestimação da evapotranspiração simulada pelo modelo durante a estação seca, especialmente no período de validação, mesmo com a tendência de superestimação da precipitação durante os meses menos chuvosos, sugerindo que a disponibilidade hídrica na bacia permaneceu limitada nesse período. Esse comportamento indica que a propagação de erros associados ao CHIRPS para o SWAT+ não ocorre de forma linear, evidenciando a complexidade das interações entre precipitação, armazenamento hídrico do solo e evapotranspiração em regiões tropicais sazonais, além das incertezas associadas tanto aos dados climáticos de entrada quanto aos produtos de evapotranspiração derivados de sensoriamento remoto.

Resultado similar foi observado por Ha et al. (2018) na Bacia do Rio Day (Vietnã). Segundo os autores, essa tendência pode estar associada à metodologia adotada pelo modelo na determinação do estresse hídrico durante o período seco, baseada

na umidade do solo. Isso pode indicar que a capacidade de armazenamento hídrico dos solos esteja subestimada na parametrização adotada ou ainda estar relacionado à representação dos fluxos verticais de água entre a camada superficial do solo e o aquífero não confinado. De forma semelhante, Koltsida e Kallioras (2022) também observaram subestimação da evapotranspiração simulada pelo SWAT em relação ao MODIS durante o período seco, atribuindo esse padrão tanto à representação da umidade do solo quanto à elevada demanda hídrica das culturas agrícolas nessa estação. Esses resultados sugerem que, em condições de déficit hídrico, o modelo pode restringir a evapotranspiração de maneira mais intensa do que aquela estimada por produtos de sensoriamento remoto, onde essas diferenças podem introduzir maiores incertezas na representação dos fluxos hidrológicos durante a estação seca.

Entretanto, as diferenças entre as estimativas do SWAT+ e do MODIS podem também estar relacionadas às distintas abordagens utilizadas para representar o armazenamento e a disponibilidade de água no solo. No SWAT+, a evapotranspiração real é controlada pelo balanço hídrico diário e pela água disponível no perfil do solo, sendo progressivamente reduzida à medida que ocorre o esgotamento da umidade armazenada, além de depender das características físicas da bacia, como pedologia, profundidade do solo, cobertura vegetal e uso do solo (Neitsch et al., 2011). Em períodos

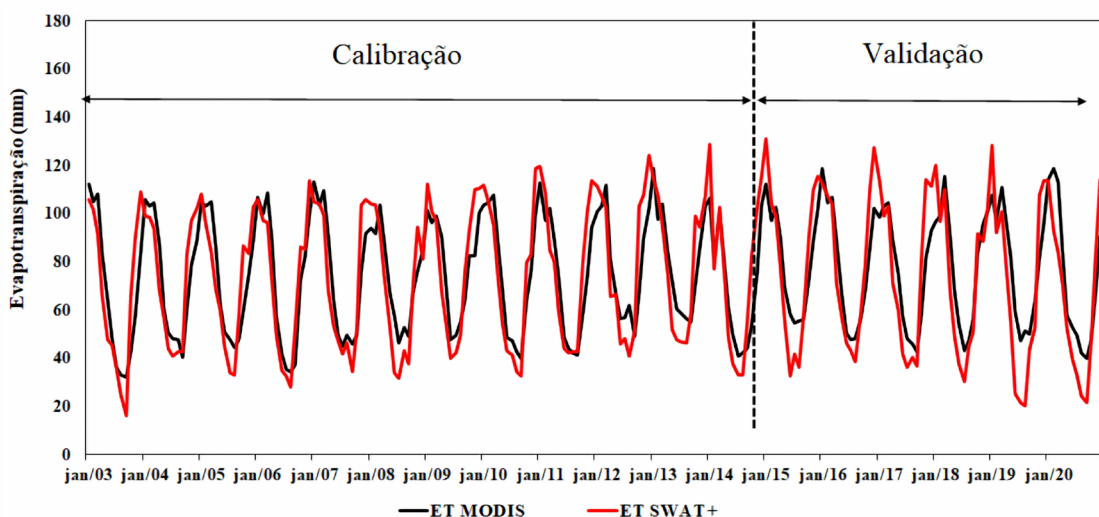


FIGURA 6 – Comparação entre a evapotranspiração mensal estimada pelo MODIS e simulada pelo SWAT+ para a Bacia do Ribeirão Claro.

FIGURE 6 – Comparison between monthly evapotranspiration estimated by MODIS and simulated by SWAT+ for the Ribeirão Claro basin.

secos, a evapotranspiração passa a depender predominantemente da água armazenada nas camadas subsuperficiais do solo e da capacidade do sistema radicular em acessar essa água. À medida que o solo seca, a condutividade hidráulica diminui e a água remanescente passa a ficar mais fortemente retida na matriz do solo, reduzindo de forma não linear a capacidade de absorção de água pelas raízes e a disponibilidade hídrica para evaporação e transpiração vegetal (Cai et al., 2022). Dessa forma, pequenas diferenças na representação do armazenamento hídrico do solo podem resultar em diferenças significativas nas taxas simuladas de evapotranspiração durante períodos de déficit hídrico.

Já os produtos de evapotranspiração derivados de sensoriamento remoto, como o MODIS, utilizam abordagens empíricas e relações biofísicas associadas à cobertura vegetal e ao balanço de energia da superfície, o que pode resultar em respostas distintas sob condições de déficit hídrico, especialmente em relação à evaporação do solo e ao estresse hídrico da vegetação (Fisher et al., 2008; Mu et al., 2011). Dessa forma, parte das divergências observadas pode estar associada não apenas às limitações do modelo hidrológico, mas também às diferenças conceituais entre os métodos utilizados para estimar a evapotranspiração.

De acordo com Abbaspour et al. (2015), as incertezas do modelo são geralmente associadas a simplificações conceituais; processos que ocorrem na bacia, mas não são considerados pelo modelo; processos que estão presentes no modelo, mas sua ocorrência é desconhecida ao usuário ou não considerada devido à limitação de dados (e.g., reservatórios, represas, práticas agrícolas) e qualidade dos dados de entrada. Neste trabalho, o terceiro ponto é particularmente importante. A Bacia do Ribeirão Claro apresenta ocupação do solo predominantemente agrícola, através da monocultura da cana-de-açúcar. Entretanto, devido à ausência de dados, nenhuma rotina de práticas agrícolas (e.g., fertilização e datas exatas de colheita e plantio) foi implementada no modelo. De acordo com Hernandez et al. (2018), esse tipo de informação é essencial para estimativas consistentes da evapotranspiração e sua influência no balanço hídrico.

Esse aspecto pode ser particularmente relevante para explicar a subestimação da evapotranspiração simulada durante a estação seca em relação ao MODIS. A cultura da cana-de-açúcar apresenta dinâmica fenológica complexa, associada aos ciclos de corte, rebrota e desenvolvimento vegetati-

vo, além de sistemas radiculares profundos capazes de acessar água em camadas subsuperficiais do solo. Dessa forma, simplificações relacionadas à representação do manejo agrícola e da fenologia da cultura no SWAT+ podem limitar a capacidade do modelo em reproduzir adequadamente a dinâmica sazonal da evapotranspiração na bacia. Isso torna-se ainda mais relevante uma vez que o SWAT+ utiliza uma versão simplificada do modelo Environmental Policy Impact Climate (EPIC) para simular o crescimento da vegetação (Neitsch et al., 2011). Entretanto, o EPIC foi originalmente desenvolvido para climas temperados, podendo não representar adequadamente o crescimento da vegetação em regiões tropicais, onde a precipitação ou o fotoperíodo são os principais fatores de controle (Strauch & Volk, 2013).

Em relação a qualidade dos dados, destaca-se que os dados de temperatura estimados pelo CHIRTS não foram validados para a bacia devido à ausência de observações, representando assim outra fonte de incerteza. Este é um fator importante, uma vez que a evapotranspiração potencial no SWAT+ foi estimada pelo método de Hargreaves, que se baseia exclusivamente na temperatura do ar como variável de entrada (Hargreaves et al., 1985; Neitsch et al., 2011). Dessa forma, embora o CHIRTS apresente boa correlação e estatísticas de erro relativamente baixas para a região sudeste do Brasil (Verdin et al., 2020), eventuais erros sistemáticos nos dados de temperatura em escala de bacia podem ser propagados ao longo da modelagem hidrológica, afetando não apenas a estimativa da evapotranspiração, mas também os demais componentes do balanço hídrico simulados pelo modelo. Estudos anteriores demonstram que produtos climáticos derivados de sensoriamento remoto e reanálise podem apresentar desempenho espacialmente variável em regiões tropicais, especialmente em áreas com elevada heterogeneidade climática e de uso do solo, reforçando a necessidade de interpretar os resultados considerando as incertezas associadas aos dados de entrada (López-Bermeo et al., 2022; Paredes-Trejo et al. 2017; Wiwoho et al., 2021). O método de Hargreaves no SWAT, por sua vez, tem demonstrado bons resultados quando comparado a produtos de evapotranspiração derivados de sensoriamento remoto (Ningthoujam & Romeji, 2024; Odusanya et al., 2019).

Deve-se ainda destacar as incertezas inerentes ao MODIS. Estudos anteriores indicam que produtos de evapotranspiração derivados de sensoriamento remoto podem apresentar erros entre 10 e

20% (Glenn et al., 2011). Ainda, Mu et al. (2011) estimaram erros de 24,1% para o produto MOD16 em relação a observações de torres de fluxo (eddy covariance). Essas incertezas estão associadas, entre outros fatores, à parametrização do algoritmo, à resolução espacial do produto, à qualidade dos dados meteorológicos de entrada e à representação da cobertura vegetal em determinados biomas (Mu et al., 2011). Em escala de bacia hidrográfica, tais limitações podem afetar a representação espaço-temporal da evapotranspiração, influenciando diretamente o processo de calibração hidrológica. Ademais, devido à ausência de medições observacionais locais de evapotranspiração, não foi possível realizar uma validação independente do produto MODIS para a área de estudo, o que constitui uma limitação adicional desta pesquisa.

Estatisticamente, o modelo apresentou, no período de calibração, KGE (0,80) e PBIAS (3,28%) classificados como “muito bons”, além de RSR (0,57) e NSE (0,68) classificados como “bons”, indicando adequada eficiência na simulação das séries mensais de evapotranspiração do MODIS (Tabela 6). No período de validação, o PBIAS (4,53%) manteve-se classificado como “muito bom”, enquanto as demais métricas foram enquadradas como “satisfatórias”. Essa redução no desempenho era esperada, uma vez que os parâmetros são otimizados durante a calibração e mantidos constantes na validação, que utiliza um conjunto de dados independente. Moriasi et al. (2007) comentam ainda que, por esse motivo, classificações de desempenho mais rigorosas devem ser atribuídas à calibração, em comparação com a etapa de validação. Ainda, a agregação temporal em escala mensal tende a suavizar a variabilidade de curto prazo das séries hidrológicas, reduzindo a representação de eventos extremos e potencialmente favorecendo o desempenho de métricas estatísticas. Assim, o de-

sempenho obtido pode ser parcialmente influenciado pela escala temporal adotada.

Estes resultados são condizentes com outros estudos que avaliaram a eficiência do SWAT na calibração da evapotranspiração com dados estimados por sensoriamento remoto. Lins et al. (2024) compararam os resultados do modelo com dados do MODIS para a Bacia Experimental Jatobá, em Pernambuco, obtendo valores de NSE variando entre 0,49 e 0,62 e PBIAS variando entre 6,2 e 23,1% para diferentes usos do solo. Strauch e Volk (2013) obtiveram valores de NSE variando entre 0,43 e 0,65 para o período de calibração e entre 0,36 e 0,71 para o período de validação utilizando dados do MODIS, obtendo melhores resultados na região do cerrado e em formações campestres quando comparados à formações florestais. Abitew et al. (2023) calibraram o SWAT+ com dados de evapotranspiração do MODIS para a Bacia do Rio Mara, na Tanzânia, obtendo valores de KGE variando entre 0,58 (0,49) e 0,64 (0,71) e PBIAS variando entre 0,2 (0,3) e -8,4% (-6,1%) para o período de calibração (validação) em diferentes classes de uso do solo. Parajuli et al. (2018), em estudo sobre a Bacia do Rio Sunflower (USA), de ocupação predominantemente agrícola, obtiveram valores de R<sup>2</sup> variando entre 0,61 e 0,63 e NSE entre 0,50 e 0,60 na calibração e validação do modelo utilizando dados do MODIS.

Esses resultados indicam que, embora existam algumas incertezas e limitações inerentes, a utilização de dados de evapotranspiração do MODIS na calibração de modelos hidrológicos apresenta potencial como uma alternativa viável para bacias não monitoradas ou com escassez de dados hidrológicos, como a Bacia do Ribeirão Claro. Visando o aprimoramento dos resultados obtidos, trabalhos futuros na bacia podem se beneficiar da análise de produtos adicionais de precipitação e evapotranspiração, bem como da incorporação de outras variáveis hidrológicas estimadas por sensoriamento remoto para auxiliar no processo de calibração, como a umidade do solo.

Entretanto, é importante destacar que a calibração realizada utilizando apenas a evapotranspiração não garante necessariamente a representação adequada dos fluxos hidrológicos horizontais da bacia, como o escoamento superficial e o fluxo de base. Embora a evapotranspiração constitua uma variável hidrológica fundamental do balanço hídrico, sua utilização isolada pode resultar em diferentes combinações de parâmetros capazes de reproduzir satisfatoriamente os fluxos verticais,

TABELA 6 -Avaliação estatística do SWAT+ para a simulação da evapotranspiração.

TABLE 6 – Statistical evaluation of SWAT+ for evapotranspiration simulation.

Período	NSE	KGE	PBIAS (%)	RSR
Calibração	0,68 <sup>b</sup>	0,80 <sup>a</sup>	3,28 <sup>a</sup>	0,57 <sup>b</sup>
Validação	0,53 <sup>c</sup>	0,62 <sup>c</sup>	4,53 <sup>a</sup>	0,68 <sup>c</sup>

<sup>a</sup>Muito bom; <sup>b</sup>Bom; <sup>c</sup>Satisfatório. Baseado em Moriasi et al. (2007). As classificações para o KGE foram adotadas como as mesmas do NSE.

<sup>a</sup>Very good; <sup>b</sup>Good; <sup>c</sup>Satisfactory. Based on Moriasi et al. (2007). The classifications for KGE were adopted as the same as those used for NSE.

mas com representações distintas dos processos internos do modelo devido à equifinalidade. Taia et al. (2023), por exemplo, observaram que a calibração isolada da evapotranspiração no SWAT pode resultar em melhor ajuste desse componente, ao mesmo tempo em que aumenta a variabilidade simulada da umidade do solo e da produção de água. Assim, os resultados obtidos neste estudo devem ser interpretados principalmente sob a perspectiva da consistência do balanço hídrico e da dinâmica espaço-temporal da evapotranspiração, e não como uma validação completa da resposta hidrológica da bacia.

### 3.3 Análise do balanço hídrico

Os componentes do balanço hídrico calculados pelo SWAT+ calibrado para a Bacia do Ribeirão Claro são apresentados na Tabela 7, enquanto as variações mensais são mostradas na Figura 7. Em média, a bacia recebe cerca de 1344 mm de precipitação anual. A evapotranspiração é o maior componente do balanço hídrico na bacia, consumindo cerca de 883 mm, o que representa aproximadamente 66% da precipitação. Esse resultado é consistente com estudos realizados em bacias tropicais, tanto em escala regional quanto global. Moura et al. (2025), aplicando o modelo SWAT para a Bacia do Rio Corumbataí, obtiveram um valor médio simulado de evapotranspiração de 794,4 mm para o período de 2003 a 2010. Campos et al. (2024), em estudo na Bacia do Rio Bonito (Espírito Santo), observaram que a evapotranspiração re-

presentou aproximadamente 72% da precipitação anual. De forma semelhante, Guug et al. (2020), analisando a Bacia Sherigu (Gana), com predominância de uso agrícola, verificaram evapotranspiração equivalente a cerca de 72% da precipitação, atribuindo esse comportamento às elevadas temperaturas e baixa umidade relativa. Mwangu et al. (2025), em estudo na Bacia do Rio Ssezibwa (Uganda), também observaram relação semelhante (69%), além de projeções de aumento simultâneo da evapotranspiração e precipitação em cenários climáticos futuros.

De modo geral, a evapotranspiração real (AET) e a evapotranspiração potencial (PET) apresentaram comportamento sazonal consistente com o regime climático da bacia. A AET é fortemente controlada pela disponibilidade hídrica, sendo influenciada principalmente pela precipitação, enquanto a PET é determinada predominantemente por variáveis atmosféricas, como temperatura e radiação solar (Dakhlaoui et al., 2020; Zhang et al., 2025). O padrão observado é típico de regiões de clima tropical subúmido, caracterizadas por verões com maior disponibilidade de água e temperaturas mais elevadas, e invernos secos e com temperaturas mínimas moderadas, resultando na redução das taxas de evapotranspiração durante a estação seca. Na estação chuvosa, por sua vez, os valores mensais de precipitação são consideravelmente maiores que a PET, consistente com o padrão observado para o Estado de São Paulo (Blain et al., 2018).

O escoamento superficial apresentou valores mais elevados entre janeiro e março, com médias mensais variando aproximadamente entre 40 e 60 mm. Durante a estação seca, os valores permaneceram próximos de zero, como esperado em função da redução significativa da precipitação nesse período. Observa-se, contudo, que entre outubro e dezembro, embora ocorra o aumento das chuvas, o escoamento superficial ainda se mantém relativamente baixo. Esse comportamento pode ser explicado pelas condições iniciais de umidade do solo no início da estação chuvosa, quando o armazenamento hídrico ainda não foi completamente restabelecido. Conforme apresentado na Figura 7, a umidade do solo na camada superficial encontra-se relativamente baixa em outubro, aumentando gradualmente até atingir seus valores máximos em janeiro. Esse mecanismo é particularmente relevante no SWAT+, que utiliza o método da Curva Número (CN) para estimar o escoamento superficial, com base no conceito de umidade antecedente (Neitsch et al., 2011).

TABELA 7 - Componentes do balanço hídrico simulados pelo SWAT+ na Bacia do Ribeirão Claro.

TABLE 7 – Water balance components simulated by SWAT+ in the Ribeirão Claro watershed.

<i>Variável</i>	<i>SWAT+ (mm)</i>
Precipitação	1344,1
Evapotranspiração Real	883,3
Evapotranspiração Potencial	1501,7
Escoamento Superficial	169,2
Escoamento Lateral	14,5
Percolação	285,6
Fluxo de Retorno	241,4
Revap	30,0
Recarga do Aquífero Profundo	14,3
Produção de água	425,1
$\Delta S$	-7,9

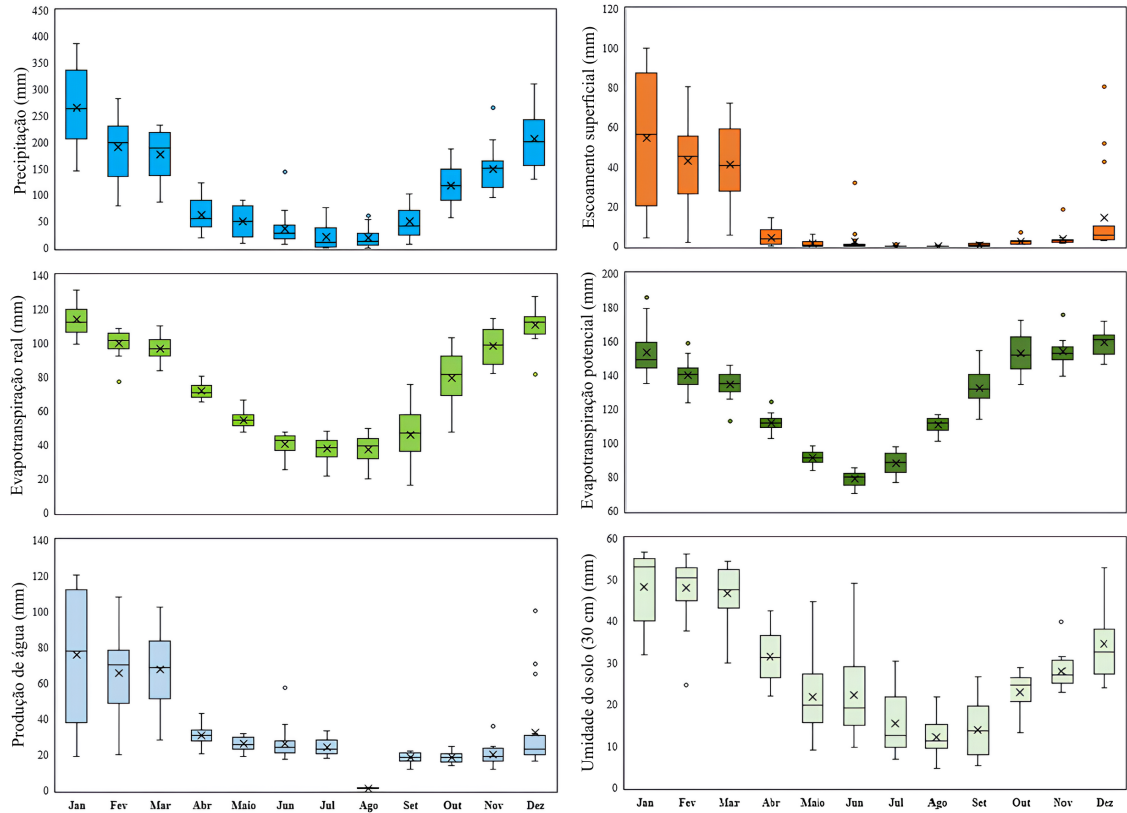


FIGURA 7 – Variabilidade mensal dos componentes do balanço hídrico da Bacia do Ribeirão Claro. No gráfico, as caixas representam o intervalo interquartil (percentis 25-75), com a linha interna indicando a mediana e o “X” representando a média. As retas representam os valores mínimos e máximos dentro de 1,5 vezes o intervalo interquartil, enquanto os pontos externos representam valores atípicos (outliers) fora desse intervalo.

FIGURE 7 – Monthly variability of the water balance components of the Ribeirão Claro basin. In the plot, the boxes represent the interquartile range (25th–75th percentiles), with the internal line indicating the median and the “X” representing the mean. The whiskers extend to the minimum and maximum values within 1.5 times the interquartile range, while the points beyond them represent outliers outside this interval.

A média de 169,2 mm também é coerente com o observado por Moura et al. (2025) para a Bacia do Rio Corumbataí (193,15 mm). Os valores levemente menores observados na Bacia do Ribeirão Claro podem estar associados às menores altitudes e declividades em relação ao panorama geral da Bacia do Rio Corumbataí, além da predominância de Latossolos e, em menor proporção, Argissolos. Essas características tendem a favorecer a infiltração em detrimento do escoamento superficial, contribuindo para a elevada aptidão agrícola da bacia.

A recarga do aquífero profundo foi estimada em 14,3 mm, representando cerca de 1% da precipitação total. Proporção semelhante foi observada em outros estudos conduzidos em bacias da Mata Atlântica (Campos et al., 2024; Costa et al., 2024) e em outras bacias tropicais (Guug et al., 2020),

sugerindo que grande parte da água percolada permanece armazenada no aquífero raso, responsável por sustentar o escoamento de base e alimentar os canais durante a estação seca. A produção de água na bacia apresentou sazonalidade marcada, com maiores valores entre janeiro e março, acompanhando o período chuvoso. Durante a estação seca, embora reduzidos, os valores mantiveram-se relativamente constantes (com exceção de agosto), evidenciando a contribuição do escoamento de base nesse período.

A Figura 8 mostra as variações espaciais de alguns componentes do balanço hídrico simulados pelo SWAT+ para a Bacia do Ribeirão Claro. De modo geral, os resultados mostram uma evapotranspiração mais elevada nas áreas florestadas, superiores a 1000 mm, especialmente na FEENA, refletindo a maior densidade da vegetação e capa-

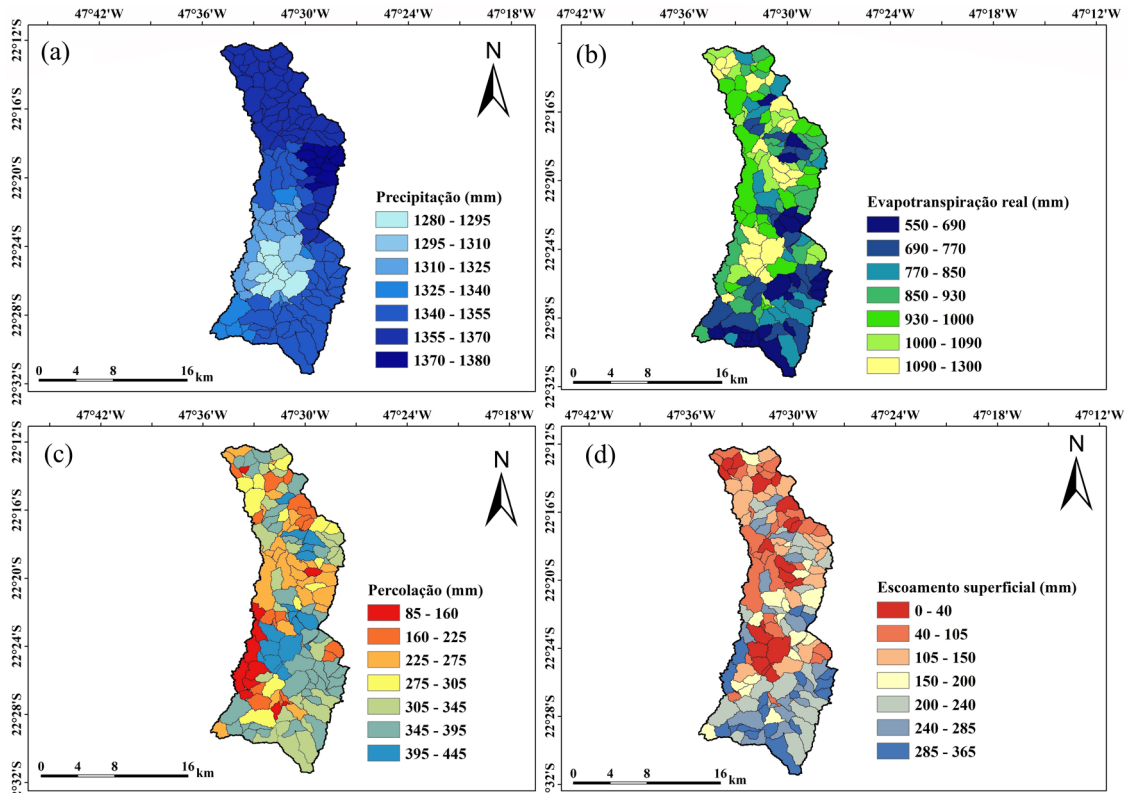


FIGURA 8 – Variação espacial dos componentes do balanço hídrico na Bacia do Ribeirão Claro. (a) Precipitação, (b) Evapotranspiração, (c) Percolação e (d) Escoamento superficial. Referência Espacial – Datum: WGS 84, UTM Zona 23S.

FIGURE 8 – Spatial variation of the water balance components in the Ribeirão Claro basin. (a) Precipitation, (b) Evapotranspiration, (c) Percolation, and (d) Surface runoff. Spatial Reference – Datum: WGS 84, UTM Zone 23S.

cidade de transpiração dessas áreas, mesmo apresentando as menores médias de precipitação da bacia. Valores elevados também foram observados nas áreas de citricultura, consistentes com os resultados obtidos por Hernandez et al. (2018). Na porção sul da bacia, onde predomina o cultivo de cana-de-açúcar, observam-se os menores valores de evapotranspiração, variando entre 550 e 850 mm, inferiores aos reportados na literatura para áreas agrícolas semelhantes. Hernandez et al. (2018), por exemplo, estimaram evapotranspiração média em torno de 895,5 mm para bacias com predominância de cana-de-açúcar em Monte Mor (SP) e Fazenda Monte Alegre (GO). Esse comportamento pode estar associado à tendência de subestimação da evapotranspiração simulada pelo SWAT+ durante a estação seca em relação aos dados do MODIS, discutida anteriormente.

Os valores mais elevados de escoamento superficial também coincidiram com as áreas de predominância da cana-de-açúcar e regiões urbanizadas. Esse comportamento pode estar associado

às alterações físicas do solo decorrentes do manejo agrícola intensivo, incluindo compactação pelo tráfego de máquinas e impermeabilização do solo. Em contraste, áreas florestadas apresentaram menores valores de escoamento superficial, consistentes com a maior interceptação da precipitação, infiltração e proteção do solo proporcionadas pela cobertura vegetal. Consistente com esse padrão, a percolação apresentou os maiores valores na região da FEENA, refletindo a influência dos sistemas radiculares mais profundos e da maior porosidade do solo sob cobertura florestal, que favorecem a infiltração e o deslocamento vertical da água no perfil do solo, contribuindo para a recarga sub-superficial e manutenção do fluxo de base. De modo geral, com exceção da possível subestimação da evapotranspiração nas áreas de predominância da cana-de-açúcar, os resultados demonstram que o SWAT+ foi capaz de reproduzir satisfatoriamente os padrões espaciais esperados dos componentes do balanço hídrico na Bacia do Ribeirão Claro.

#### 4 CONCLUSÕES

Este estudo avaliou a aplicabilidade de produtos de sensoriamento remoto para estudos hidrológicos em bacias não monitoradas ou com escassez de dados, por meio da validação dos dados de precipitação do CHIRPS e análise da precisão do SWAT+ em simular as séries de evapotranspiração estimadas pelo MODIS para a Bacia do Ribeirão Claro.

Os dados do CHIRPS apresentaram boa capacidade em representar a variabilidade sazonal da precipitação na bacia, considerando os dois postos pluviométricos avaliados, apresentando coeficientes de correlação variando entre 0,72 e 0,90 e valores de PBIAS relativamente baixos, com exceção do período de inverno, onde obteve 24,98%. Entretanto, o produto apresentou menor variabilidade mensal, superestimando a precipitação nos meses menos chuvosos e subestimando-a consideravelmente nos meses mais chuvosos. Os índices extremos de precipitação refletiram esse comportamento, com subestimação do R30mm, RX1day, R95p e CDD, enquanto o índice R1mm foi superestimado, indicando um maior número de dias chuvosos e a redução da intensidade dos eventos de precipitação extrema comparado aos dados observados dos postos. Dessa forma, a aplicabilidade do CHIRPS para estudos hidrológicos na bacia fica condicionada aos objetivos específicos do estudo.

O SWAT+, alimentado pelos dados de precipitação do CHIRPS e temperatura do CHIRTS, foi capaz de reproduzir satisfatoriamente as séries mensais de evapotranspiração estimadas pelo MODIS, apresentando leve tendência de subestimação no período seco, com valores de NSE e KGE de 0,68 e 0,80 para o período de calibração, e 0,53 e 0,62 para o período de validação, respectivamente. Os componentes do balanço hídrico simulados pelo modelo calibrado apresentaram valores coerentes com o regime climático e as características ambientais da bacia, indicando consistência física na partição da precipitação entre evapotranspiração, escoamento e recarga.

Entretanto, os resultados devem ser interpretados considerando as limitações inerentes à abordagem adotada. A calibração baseada exclusivamente em evapotranspiração não garante necessariamente a representação adequada dos fluxos hidrológicos horizontais da bacia, como escoamento superficial e fluxo de base, especialmente devido aos efeitos da equifinalidade e às incertezas associadas aos produtos de sensoriamento remoto

utilizados. Adicionalmente, simplificações relacionadas à representação do manejo agrícola e da dinâmica fenológica da vegetação no SWAT+, particularmente em áreas de cultivo de cana-de-açúcar, podem influenciar a simulação da evapotranspiração em regiões tropicais agrícolas.

Ainda assim, os resultados demonstram que a integração de produtos climáticos derivados de sensoriamento remoto representa uma alternativa promissora para aplicações hidrológicas em bacias com escassez de dados observacionais, especialmente para análises de balanço hídrico e variabilidade hidrológica sazonal. Nesse contexto, destaca-se a importância de abordagens multivariáveis e da avaliação integrada das incertezas para aumentar a robustez física das simulações hidrológicas em regiões não monitoradas.

#### 6 AGRADECIMENTOS

Os autores agradecem aos dois revisores anônimos pelas valiosas sugestões, comentários e observações, que contribuíram significativamente para o aprimoramento do manuscrito.

#### 7 REFERÊNCIAS

- Abbaspour, K. C., Rouholahnejad, E., Vaghefi, S., Srinivasan, R., Yang, H., & Kløve, B. (2015). A continental-scale hydrology and water quality model for Europe: Calibration and uncertainty of a high-resolution large-scale SWAT model. *Journal of Hydrology*, 524, 733–752. <https://doi.org/10.1016/j.jhydrol.2015.03.027>
- Abitew, T. A., Arnold, J., Jeong, J., Jones, A., & Srinivasan, R. (2023). Innovative approach to prognostic plant growth modeling in SWAT+ for forest and perennial vegetation in tropical and Sub-Tropical climates. *Journal of Hydrology X*, 20, Article 100156. <https://doi.org/10.1016/j.hydroa.2023.100156>
- Adam, J. C., & Lettenmaier, D. P. (2003). Adjustment of global gridded precipitation for systematic bias. *Journal of Geophysical Research: Atmospheres*, 108(D9), Article 4257. <https://doi.org/10.1029/2002jd002499>
- Almeida, A. L. S. P., Macedo, D. R., Santos, H. A., Ribeiro, S. M. C., & Hughes, R. M. (2023). Managing water resources in complex tropical basins: tailored SWAT ecohydrological

- modeling to the Rio das Velhas, Brazil. *Revista Brasileira de Recursos Hídricos*, 28(33). <https://doi.org/10.1590/2318-0331.282320230034>
- Almeida, G. S. S., Silva, E. M., Silva, V. P. R., Campos, J. H. B. C., & Silva, M. T. (2024). Performance of the Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS) Model in the Northeast Region of Brazil. *Revista Brasileira de Geografia Física*, 17(6), 4117–4130. <https://doi.org/10.26848/rbgf.v17.6.p4396-4408>
- Al-Shamayleh, S., Tan, M. L., Samat, N., Rahbeh, M., & Zhang, F. (2024). Performance of CHIRPS for estimating precipitation extremes in the Wala Basin, Jordan. *Journal of Water & Climate Change*, 15(3), 1349–1363. <https://doi.org/10.2166/wcc.2024.611>
- Alvares, C. A., Stape, J. L., Sentelhas, P. C., Gonçalves, J. L. M., & Sparovek, G. (2014). Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, 22(6), 711–728. <https://doi.org/10.1127/0941-2948/2013/0507>
- Bai, L., Shi, C., Li, L., Yang, Y., & Wu, J. (2018). Accuracy of CHIRPS satellite-rainfall products over Mainland China. *Remote Sensing*, 10(3), Article 362. <https://doi.org/10.3390/rs10030362>
- Bárdossy, A., Kilsby, C., Birkinshaw, S., Wang, N., & Anwar, F. (2022). Is precipitation responsible for the most hydrological model uncertainty? *Frontiers in Water*, 4, Article 836554. <https://doi.org/10.3389/frwa.2022.836554>
- Bekić, D., & Leskovar, K. (2025). Evaluating CHIRPS and ERA5 for long-term runoff modelling with SWAT in alpine headwaters. *Water*, 17(14), Article 2116. <https://doi.org/10.3390/w17142116>
- Beven, K. & Binley, A. (1992) The future of distributed models: Model calibration and uncertainty prediction. *Hydrological Processes*, 6(3), 279-298. <https://doi.org/10.1002/hyp.3360060305>
- Bieger, K., Arnold, J. G., Rathjens, H., White, M. J., Bosch, D. D., Allen, P. M., Volk, M., & Srinivasan, R. (2017). Introduction to SWAT+, A Completely restructured version of the soil and water assessment tool. *Journal of the American Water Resources Association*, 53(1), 115–130. <https://doi.org/10.1111/1752-1688.12482>
- Blain, G. C., Ávila, A. M. H., & Pereira, V. R. (2018). Using the normality assumption to calculate probability-based standardized drought indices: selection criteria with emphases on typical events. *International Journal of Climatology*, 38(S1), e418–e436. <https://doi.org/10.1002/joc.5381>
- Cai, G., Ahmed, M. A., Abdalla, M. & Carminati, A. (2022). Root hydraulic phenotypes impacting water uptake in drying soils. *Plant, Cell & Environment*, 45(3), 650–663. <https://doi.org/10.1111/pce.14259>
- Campos, F. L. M., Coelho, A. L. N., Bressiani, D. A., & Campos, I. C. H. M. (2024). Uso do modelo hidrológico SWAT+ para quantificação e espacialização de processos em apoio ao planejamento ambiental. *Revista Pantaneira*, 24, 119–137. <https://periodicos.ufms.br/index.php/revpan/article/view/21316>
- Carvalho, L. M. V., Jones, C., & Liebmann, B. (2004). The South Atlantic Convergence Zone: intensity, form, persistence, and relationships with intraseasonal to interannual activity and extreme rainfall. *Journal of Climate*, 17(1), 88–108. [https://doi.org/10.1175/1520-0442\(2004\)017%3C0088:TSACZI%3E2.0.CO;2](https://doi.org/10.1175/1520-0442(2004)017%3C0088:TSACZI%3E2.0.CO;2)
- Cavalcante, R. B. L., Ferreira, D. B. S., Pontes, P. R. M., Tadeschi, R. G., Costa, C. P. W., & Souza, E. B. (2020). Evaluation of extreme rainfall indices from CHIRPS precipitation estimates over the Brazilian Amazonia. *Atmospheric Research*, 238, Article 104879. <https://doi.org/10.1016/j.atmosres.2020.104879>
- Čerkasova, N., White, M., Arnold, J., Bieger, K., Allen, P., Gao, J., Gambone, M., Meki, M., Kiniry, J., & Gassman, P. W. (2023). Field scale SWAT+ modeling of corn and soybean yields for the contiguous United States: National Agroecosystem Model Development. *Agricultural Systems*, 210,

- Article 103695. <https://doi.org/10.1016/j.agry.2023.103695>
- Costa, D. A., Bayissa, Y., Villas-Boas, M. D., Maskey, S., Lugon Junior, J., Silva Neto, A. J., & Srinivasan, R. (2024). Water availability and extreme events under climate change scenarios in an experimental watershed of the Brazilian Atlantic Forest. *Science of the Total Environment*, 946, Article 174417. <https://doi.org/10.1016/j.scitotenv.2024.174417>
- Costa, J. C., Pereira, G., Siqueira, M. E., Cardozo, F. S., & Silva, V. V. (2019). Validação dos dados de precipitação estimados pelo CHIRPS para o Brasil. *Revista Brasileira de Climatologia*, 24, 228–243. <https://doi.org/10.5380/abclima.v24i0.60237>
- Cui, X., Guo, X., Wang, Y., Wang, X., Zhu, W., Shi, J., Lin, C., & Gao, X. (2019). Application of remote sensing to water environmental processes under a changing climate. *Journal of Hydrology*, 574, 592–902. <https://doi.org/10.1016/j.jhydrol.2019.04.078>
- Daba, B. I., Demissie, T. A., & Tufa, F. G. (2023). Sediment yield modeling in Awash Melkasa dam watershed, upper Awash River basin, Ethiopia. *Acta Geophysica*, 71, 2287–2306. <https://doi.org/10.1007/s11600-022-00972-8>
- Dakhlou, H., Seibert, J., & Hakala, K. (2020). Sensitivity of discharge projections to potential evapotranspiration estimation in Northern Tunisia. *Regional Environmental Change*, 20, Article 34. <https://doi.org/10.1007/s10113-020-01615-8>
- Danesh, Y., Bindhu, V. M., Senent-Aparicio, J., Brighenti, T. M., Ayana, E., Smitha, P. S., Fei, C., & Srinivasan, R. (2020). A comparative evaluation of the Performance of CHIRPS and CFSR Data for different climate zones using the SWAT Model. *Remote Sensing*, 12(18), Article 3088. <https://doi.org/10.3390/rs12183088>
- Dembélé, D., Schaefli, B., Giesen, N., & Mariétoz, G. (2020). Suitability of 17 gridded rainfall and temperature datasets for large-scale hydrological modelling in West Africa. *Hydrology and Earth System Sciences*, 24(11), 5379–5406. <https://doi.org/10.5194/hess-24-5379-2020>
- Dinku, T., Funk, C., Peterson, P., Maidment, R., Tadesse, T., Gadain, H., & Ceccato, P. (2018). Validation of the CHIRPS satellite rainfall estimates over eastern Africa. *Quarterly Journal of the Royal Meteorological Society*, 144(S1), 292–312. <https://doi.org/10.1002/qj.3244>
- Eccles, R., Zhang, H., Hamilton, D., Trancoso, R., & Syktus, J. (2023). Impacts of climate change on nutrient and sediment loads from a subtropical catchment. *Journal of Environmental Management*, 345, Article 118738. <https://doi.org/10.1016/j.jenvman.2023.118738>
- Farr, T. G., Rosen, P. A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D., & Alsdorf, D. (2007). The Shuttle Radar Topography Mission. *Reviews of Geophysics*, 45(2), Article RG2004. <https://doi.org/10.1029/2005RG000183>
- Fisher, J. B., Tu, K. P. & Baldocchi, D. D. (2008). Global estimates of the land-atmosphere water flux based on monthly AVHRR and ISLSCP-II data, validated at 16 FLUXNET sites. *Remote Sensing of Environment*, 112(3), 901–919. <https://doi.org/10.1016/j.rse.2007.06.025>
- Fundação Agência das Bacias PCJ (FAB-PCJ). (2020). *Estudo do Uso dos Recursos Hídricos na Bacia Hidrográfica do Rio Corumbataí visando estabelecer cenários e planejamento das alternativas de abastecimento de água para os municípios pertencentes a esta bacia*. Relatório Final, Piracicaba. <https://agencia.baciaspcj.org.br/wp-content/uploads/2020/07/1395-FAP-01-RH-RT-0005-Volume-II-R1.pdf>
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., Husak, G., Rowland, J., Harrison, L., Hoell, A., & Michaelsen, J. (2015). The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Scientific Data*, 2, Article 150066. <https://doi.org/10.1038/sdata.2015.66>
- Gebrechorkos, S. H., Leyland, J., Dadson, S. J., Cohen, S., Slater, L., Wortmann, M.,

- Ashworth, P. J., Bennett, G. L., Boothroyd, R., Cloke, H., Delorme, P., Griffith, H., Hardy, R., Hawker, L., McLelland, S., Neal, J., Nicholas, A., Tatem, A. J., Vahidi, E., Liu, Y., Sheffield, J., Parsons, D.R., & Darby, S.E. (2024). Global-scale evaluation of precipitation datasets for hydrological modelling. *Hydrology and Earth System Sciences*, 28(14), 3099–3118. <https://doi.org/10.5194/hess-28-3099-2024>
- Gleen, E. P., Doody, T. M., Guerschman, J. P., Huete, A. R., King, E. A., McVicar, T. R., Van Dijk, A. I. J. M., Van Niel, T. G., Yebra, M., & Zhang, Y. (2011). Actual evapotranspiration estimation by ground and remote sensing methods: the Australian experience. *Hydrological Processes*, 25(26), 4103–4116. <https://doi.org/10.1002/hyp.8391>
- Griensven, A., Meixner, T., Grunwald, S., Bishop, T., Diluzio, M., & Srinivasan, R. (2006). A global sensitivity analysis tool for the parameters of multi-variable catchment models. *Journal of Hydrology*, 324(1-4), 10–23. <https://doi.org/10.1016/j.jhydrol.2005.09.008>
- Guo, X., Wu, Z., He, H., & Xu, Z. (2022). Evaluating the potential of different evapotranspiration datasets for distributed hydrological model calibration. *Remote Sensing*, 14(3), Article 629. <https://doi.org/10.3390/rs14030629>
- 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>
- 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>
- Ha, L. T., Bastiaanssen, W. G. M., van Griensven, A., van Dijk, A. I. J. M., & Senay, G. B. (2018). Calibration of spatially distributed hydrological processes and model parameters in SWAT using remote sensing data and an auto-calibration procedure: a case study in a Vietnamese River Basin. *Water*, 10(2), Article 212. <https://doi.org/10.3390/w10020212>
- Hargreaves, G. L., Hargreaves G. H., & Riley, J. P. (1985). Agricultural benefits for Senegal River Basin. *Journal of Irrigation and Drainage Engineering*, 111(2), 113–124. [https://doi.org/10.1061/\(ASCE\)0733-9437\(1985\)111:2\(113\)](https://doi.org/10.1061/(ASCE)0733-9437(1985)111:2(113))
- He, C., Liu, Z., Wu, J., Pan, X., Fang, Z., Li, J., & Bryan, B. A. (2021). Future global urban water scarcity and potential solutions. *Nature Communications*, 12, Article 4667. <https://doi.org/10.1038/s41467-021-25026-3>
- Hernandes, T. A. D., Scarpore, F. V., & Seabra, J. E. A. (2018). Assessment of the recent land use change dynamics related to sugarcane expansion and the associated effects on water resources availability. *Journal of Cleaner Production*, 197(Part 1), 1328–1341. <https://doi.org/10.1016/j.jclepro.2018.06.297>
- Jiang, S., Wang, L., Shu, H., Li, S., & Yang, Y. (2024). “Cutting effect” of needles on the raindrop characteristics. *Journal of Hydrology*, 631, Article 130783. <https://doi.org/10.1016/j.jhydrol.2024.130783>
- Junqueira, R., Viola, M. R., Amorim, J. S., Camargos, C., & Mello, C. R. (2022). Hydrological modeling using remote sensing precipitation data in a Brazilian savanna basin. *Journal of South American Earth Sciences*, 115, Article 103773. <https://doi.org/10.1016/j.jsames.2022.103773>
- Kidd, C., Becker, A., Huffman, G. J., Muller, C. L., Joe, P., Skofronick-Jackson, G., & Kirschbaun, D. B. (2017). How much of the Earth’s surface is covered by rain gauges? *Bulletin of the American Meteorological Society*, 98(1), 69–78. <https://doi.org/10.1175/BAMS-D-14-00283.1>
- Kidd, C. & Huffman, G. (2011). Global precipitation measurement. *Meteorological Applications*, 18(3), 334–353. <https://doi.org/10.1002/met.284>
- Koltsida, E., & Kallioras, A. (2022) Multi-Variable SWAT model calibration using satellite-based evapotranspiration data and streamflow.

- Hydrology*, 9(7), Article 112. <https://doi.org/10.3390/hydrology9070112>
- Li, Y., & Zhao, G. (2025). Increasing water stress in developing countries. *The Innovation*, 7(2), Article 101037. <https://doi.org/10.1016/j.xinn.2025.101037>
- Lins, F. A. C., Montenegro, A. A. A., Farias, C. W. L. A., Silva, M. V., Souza, W. M., Moura, G. B. A., Silva, T. G. F., & Montenegro, S. M. G. L. (2024). Soil moisture and hydrological processes dynamics under climate and land use changes in a semiarid experimental basin, Brazil. *Ecohydrology & Hydrobiology*, 24(3), 681–697. <https://doi.org/10.1016/j.ecohyd.2024.02.001>
- Liu, Y., Xu, Y., Zhao, Y., & Long, Y. (2022). Using SWAT model to assess the impacts of land use and climate changes on flood in the upper Weihe river, China. *Water*, 14(13), Article 2098. <https://doi.org/10.3390/w14132098>
- Liu, Z., Rong, L., & Wei, W. (2023). Impacts of land use/cover change on water balance by using the SWAT model in a typical loess hilly watershed of China. *Geography and Sustainability*, 4(1), 19–28. <https://doi.org/10.1016/j.geosus.2022.11.006>
- López-Bermeo, C., Montaya, R. D., Caro-Lopera, F. J. & Díaz-García, J. A. (2022). Validation of the accuracy of the CHIRPS precipitation dataset at representing climate variability in a tropical mountainous region of South America. *Physics and Chemistry of the Earth, Parts A/B/C*, 127, Article 103184. <https://doi.org/10.1016/j.pce.2022.103184>
- Lyra, A., Tavares, P., Chou, S. C., Sueiro, G., Derenczynski, C., Sondermann, M., Silva, A., Marengo, J., & Giarolla, A. (2018). Climate change projections over three metropolitan regions in Southeast Brazil using the non-hydrostatic Eta regional climate model at 5-km resolution. *Theoretical and Applied Climatology*, 132, 663–682. <https://doi.org/10.1007/s00704-017-2067-z>
- Malagutti, E. N., & Tauk-Tornisielo, S. M. (2014). Qualidade das águas do Córrego Bandeirantes na sub-bacia do Ribeirão Claro, município de Rio Claro, SP, Brasil. *Holos Environment*, 14(2), 135–152. <https://doi.org/10.14295/holos.v14i2.9270>
- Mann, H. B., & Whitney, D. R. (1947). On a test of whether one of two random variables is stochastically larger than the other. *Annals of Mathematical Statistics*, 18(1), 50–60. <https://doi.org/10.1214/aoms/1177730491>
- Mianabadi, A., Salari, K., & Pourmohamad, Y. (2022). Drought monitoring using the long-term CHIRPS precipitation over Southeastern Iran. *Applied Water Science*, 12, Article 183. <https://doi.org/10.1007/s13201-022-01705-4>
- Miralles, D. G., Gash, J. H., Holmes, T. R. H., Jeu, R. A. M., & Dolman, A. J. (2010). Global canopy interception from satellite observations. *Journal of Geophysical Research: Atmospheres*, 115(D16). <https://doi.org/10.1029/2009JD013530>
- Monteith, J. L. (1965). Evaporation and environment. *Symposia of the Society for Experimental Biology*, 19, 205–234. <https://repository.rothamsted.ac.uk/id/eprint/20657/>
- 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. <http://dx.doi.org/10.13031/2013.23153>
- Moura, L. B., Lopes, T. R., Folegatti, M. V., Duarte, S. N. & Oliveira, R. K. (2025). Hydrological simulation in the Corumbataí River basin using the SWAT Model: simulation of hydrological variables and land use and land cover scenarios. *Journal of Hydrologic Engineering*, 30(1). <https://doi.org/10.1061/JHYEFF.HEENG-6285>
- Mu, Q., Zhao, M., & Running, S. W. (2011). Improvements to a MODIS global terrestrial evapotranspiration algorithm. *Remote Sensing of Environment*, 155(8), 1781–1800. <https://doi.org/10.1016/j.rse.2011.02.019>
- Mwangu, A. R., Oiondo, B. O., & Masika, D. M. (2025). Potential impacts of future variation in temperature and rainfall on hydrology and sediment yield in a water catchment in Central Uganda. *Journal of Applied Sciences*

- and *Environmental Management*, 29(3), 925–937. <https://doi.org/10.4314/jasem.v29i3.31>
- Myers, N., Mittermeier, R. A., Mittermeier, C. G., Fonseca, G. A. B., & Kent, J. (2000). Biodiversity hotspots for conservation priorities. *Nature*, 403, 853–858. <https://doi.org/10.1038/35002501>
- Nawaz, M., Iqbal, M. F., & Mahmood, I. (2021). Validation of CHIRPS satellite-based precipitation dataset over Pakistan. *Atmospheric Research*, 248, Article 105289. <https://doi.org/10.1016/j.atmosres.2020.105289>
- Neitsch, S., Arnold, J., Kiniry, J., & Williams, J. (2011). *Soil & Water Assessment Tool Theoretical Documentation Version 2009*. Texas Water Resources Institute, College Station. <https://swat.tamu.edu/media/99192/swat2009-theory.pdf>
- Ningthoujam, V., & Romeji, N. (2024). SWAT Model calibration and validation with remotely sensed evapotranspiration data in Maklang-Tuyungbi-Taret lok Ungauged Basin in Manipur, India. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 49, 745–761. <https://doi.org/10.1007/s40996-024-01454-1>
- Odey, G., & Cho, Y. (2025). Event-based vs. continuous hydrological modeling with HEC-HMS: a review of use cases, methodologies, and performance metrics. *Hydrology*, 12(2), Article 39. <https://doi.org/10.3390/hydrology12020039>
- Odusanya, A. E., Mehdi, B., Schurz, C., Oke, A. O., Awokola, O. S., Awomeso, J. A., Adejuwon, J. O. & Schulz, K. (2019). Multi-site calibration and validation of SWAT with satellite-based evapotranspiration in a data-sparse catchment in southwestern Nigeria. *Hydrology and Earth System Sciences*, 23(2), 1113–1144. <https://doi.org/10.5194/hess-23-1113-2019>
- Oliveira-Júnior, J. F., Silva Júnior, C. A., Teodoro, P. E., Rossi, F. S., Blanco, C. J. S., Lima, M., Gois, G., Correia Filho, W. L. F., Santiago, D. B., & Vanderley, M. H. G. S. (2021). Confronting CHIRPS dataset and in situ stations in the detection of wet and drought conditions in the Brazilian Midwest. *International Journal of Climatology*, 41(9), 4478–4493. <https://doi.org/10.1002/joc.7080>
- Pang, J., Zhang, H., Xu, Q., Wang, Y., Wang, Y., Zhang, O., & Hao, J. (2020). Hydrological evaluation of open-access precipitation data using SWAT at multiple temporal and spatial scales. *Hydrology and Earth System Sciences*, 24(7), 3603–3626. <https://doi.org/10.5194/hess-24-3603-2020>
- Parajuli, P. B., Jayakody, P. & Ouyang, Y. (2018) Evaluation of using remote sensing evapotranspiration data in SWAT. *Water Resources Management*, 32, 985–996. <https://doi.org/10.1007/s11269-017-1850-z>
- Paredes-Trejo, F. J., Barbosa, H. A., & Kumar, T. V. L. (2017). Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil. *Journal of Arid Environments*, 139, 26–40. <https://doi.org/10.1016/j.jaridenv.2016.12.009>
- Rathjens, H., Bieger, K., Chaubey, I., Arnold, J. G., Allen, P. M., Srinivasan, R., Bosch, D. D. & Volk, M. (2016). Delineating floodplain and upland areas for hydrologic models - A comparison of methods. *Hydrological Processes*, 30(23), 4367–4383. <https://doi.org/10.1002/hyp.10918>
- Ravinahdrasana, V. P., & Franzke, C. L. E. (2025). The first emergence of unprecedented global water scarcity in the Anthropocene. *Nature Communications*, 16, Article 8281. <https://doi.org/10.1038/s41467-025-63784-6>
- Reboita, M. S., Gan, M. A., Rocha, R. P., & Ambrizzi, T. (2010). Regimes de precipitação na América do Sul: uma revisão bibliográfica. *Revista Brasileira de Meteorologia*, 25(2), 185–204. <https://doi.org/10.1590/S0102-77862010000200004>
- Ritchie, J. T. (1972). Model for predicting evaporation from a row crop with incomplete cover. *Water Resources Research*, 5(8), 1204–1213. <https://doi.org/10.1029/WR008i005p01204>
- Rivera, J.A., Marianetti, G., & Hinrichs, S. (2018). Validation of CHIRPS precipitation dataset

- along the Central Andes of Argentina. *Atmospheric Research*, 213, 437–449. <https://doi.org/10.1016/j.atmosres.2018.06.023>
- Romilly, T. G., & Gebremichael, M. (2011). Evaluation of satellite rainfall estimates over Ethiopian river basins. *Hydrology and Earth System Sciences*, 15(5), 1505–1514. <https://doi.org/10.5194/hess-15-1505-2011>
- Rufino, P. R., Gücker, B., Volk, M., Strauch, M., Cardozo, F. S., Boëchat, I. G., Faramarzi, M., & Pereira, G. (2025). Modeling the Nexus of Climate Change and Deforestation: Implications for the Blue Water Resources of the Jari River, Amazonia. *Water*, 17(5), Article 660. <https://doi.org/10.3390/w17050660>
- Running, S., Mu, Q., Zhao, M., & Moreno, A. (2021). *MODIS/Terra net evapotranspiration gap-filled 8-day L4 global 500m sin grid V061 [Data set]*. NASA Land Processes Distributed Active Archive Center. <https://doi.org/10.5067/MODIS/MOD16A2GF.061>
- Santos, B. C., Sanches, R. G., Moreira, R. M., Bourscheidt, V., & Souza, P. H. (2022). Análise espaço-temporal da precipitação na região central do estado de São Paulo utilizando dados CHIRPS. *Revista Brasileira de Geografia Física*, 15(5), 2582–2600. <https://doi.org/10.26848/rbgf.v15.5.p2582-2600>
- Sartori, A., Lombardi Neto, F., & Genovez, A. M. (2005). Classificação hidrológica de solos brasileiros para a estimativa da chuva excedente com o método do serviço de conservação do solo dos Estados Unidos Parte 1: Classificação. *Revista Brasileira de Recursos Hídricos*, 10(5), 5–18. <http://dx.doi.org/10.21168/rbrh.v10n4.p5-18>
- Saxton, K. E., & Rawls, W. J. (2006). Soil water characteristic estimates by texture and organic matter for hydrologic solutions. *Soil Science Society of America Journal*, 70(5), 1569–1578. <https://doi.org/10.2136/sssaj2005.0117>
- Segantin, L. S., Callegari-Júnior, N., Castro, M. C. A. A., & Garcia, M. L. (2025). Aplicação da análise estatística multivariada no estudo da qualidade das águas superficiais na Bacia do Rio Corumbataí. *Geociências*, 44(2), 317–333. <https://doi.org/10.5016/geociencias.v44i2.19092>
- Segantin, L. S., & Garcia, M. L. (2026). Hydrological and sediment transport responses to future climate change scenarios in southeastern Brazil under CMIP6 multi-model ensemble. *Sustainable Water Resources Management*, 12, Article 18. <https://doi.org/10.1007/s40899-026-01331-x>
- Sevastas, S., Siarkos, I. & Mallios, Z. (2025). A comparative analysis of remotely sensed and high-fidelity ArcSWAT evapotranspiration estimates across various timescales in the upper Anthemountas Basin, Greece. *Hydrology*, 12(7), Article 171. <https://doi.org/10.3390/hydrology12070171>
- Sharma, A., Patel, P. L., & Sharma, P. J. (2023). Blue and green water accounting for climate change adaptation in a water scarce river basin. *Journal of Cleaner Production*, 426, Article 139206. <https://doi.org/10.1016/j.jclepro.2023.139206>
- Sheffield, J., Wood, E. F., Pan, M., Beck, H., Coccia, G., Serrat-Capdevila, A., & Verbist, K. (2018). Satellite remote sensing for water resources management: potential for supporting sustainable development in data-poor regions. *Water Resources Research*, 54(12), 9724–9758. <https://doi.org/10.1029/2017WR022437>
- Silva, E. R. M., Barbosa, I. C. C., Silva, H. J. F., Costa, L. G. S., & Rocha, E. J. P. (2020). Análise do desempenho da estimativa de precipitação do produto CHIRPS para sub-bacia do Rio Apeú, Castanhal-PA. *Revista Brasileira de Geografia Física*, 13(3), 1094–1105. <https://doi.org/10.26848/rbgf.v13.3.p1094-1105>
- Sirisena, T. A. J. G., Maskey, S., & Ranasinghe, R. (2020). Hydrological model calibration with streamflow and remote sensing based evapotranspiration data in a data poor basin. *Remote Sensing*, 12(22), Article 3768.
- So, D. & Shin, D. B. (2018). Classification of precipitating clouds using satellite infrared observations and its implications for rainfall estimation. *Quarterly Journal of the Royal*

- Meteorological Society*, 144(S1), 133–144. <https://doi.org/10.1002/qj.3288>
- Souza, C. M., Z. Shimbo, J., Rosa, M. R., Parente, L. L., A. Alencar, A., Rudorff, B. F. T., Hasenack, H., Matsumoto, M., G. Ferreira, L., Souza-Filho, P. W. M., Oliveira, S. W., Rocha, W. F., Fonseca, A. V., Marques, C. B., Diniz, C. G., Costa, D., Monteiro, D., Rosa, E. R., Vélez-Martin, E., Weber, E. J., ..., Azevedo, T. (2020). Reconstructing three decades of land use and land cover changes in Brazilian Biomes with Landsat archive and Earth Engine. *Remote Sensing*, 12(17), Article 2735. <https://doi.org/10.3390/rs12172735>
- Strauch, M., & Volk, M. (2013). SWAT plant growth modification for improved modeling of perennial vegetation in the tropics. *Ecological Modelling*, 269, 98–112. <https://doi.org/10.1016/j.ecolmodel.2013.08.013>
- Taia, S., Scozzari, A., Erraioui, L., Kili, M., Mridekh, A., Haida, S., Chao, J. & El Mansouri, B. (2023). Comparing the ability of different remotely sensed evapotranspiration products in enhancing hydrological model performance and reducing prediction uncertainty. *Ecological Informatics*, 78, Article 102352. <https://doi.org/10.1016/j.ecoinf.2023.102352>
- Tapiador, F. J., Turk, F. J., Petersen, W., Hou, A. Y., García-Ortega, E., Machado, L. A. T., Angelis, C. F., Salio, P., Kidd, C., Huffman, G. J., & Castro, M. (2012). Global precipitation measurement: Methods, datasets and applications. *Atmospheric Research*, 104-105, 70–97. <https://doi.org/10.1016/j.atmosres.2011.10.021>
- Torres-Batló, J., & Martí-Cardona, B. (2020). Precipitation trends over the southern Andean Altiplano from 1981 to 2018. *Journal of Hydrology*, 590, Article 125485. <https://doi.org/10.1016/j.jhydrol.2020.125485>
- Valencia, S., Marín, D. E., Gómez, D., Echavarría-Porras, V., Mejía-Sepúlveda, J., Husic, A., Sullivan, S., Hoyos, N., Villegas, J. C., Harrison, L., & Green, J. K. (2026). Improvements and limitations of the new Climate Hazards Center Infrared Precipitation with Stations (CHIRPSv3) dataset: Insights from multiple spatio-temporal scales in Colombia. *Atmospheric Research*, 338, Article 108971. <https://doi.org/10.1016/j.atmosres.2026.108971>
- Valente, R. O. A., & Vettorazzi, C. A. (2005). Avaliação da estrutura florestal na bacia hidrográfica do Rio Corumbataí, SP. *Scientia Forestalis*, 68, 45–57. <https://www.ipef.br/publicacoes/scientia/nr68/cap05.pdf>
- Verdin, A., Funk, C., Peterson, P., Landsfeld, M., Tuholske, C., & Grace, K. (2020). Development and validation of the CHIRTS-daily quasi-global high-resolution daily temperature data set. *Scientific Data*, 7, Article 303. <https://doi.org/10.1038/s41597-020-00643-7>
- Wang, M., Bodirsky, B. L., Rijneveld, R., Beier, F., Bak, M. P., Batool, M., Droppers, B., Popp, A., Vliet, M. T. H., & Stokal, M. (2024). A triple increase in global river basins with water scarcity due to future pollution. *Nature Communications*, 15, Article 880. <https://doi.org/10.1038/s41467-024-44947-3>
- Wangwongchai, A., Waqas, M., Dechpichai, P., Hlaing, P. T., Ahmad, S., & Humphries, U. W. (2023). A comparison between artificial intelligence and statistical techniques. *MethodsX*, 11, Article 102459. <https://doi.org/10.1016/j.mex.2023.102459>
- Wiwoho, B. S., Astudi, I. S., Alfarizi, I. A. G., & Sucahyo, H. R. (2021). Validation of three daily satellite rainfall products in a humid tropic watershed, Brantas, Indonesia: implications to land characteristics and hydrological modelling. *Hydrology*, 8(4), Article 154. <https://doi.org/10.3390/hydrology8040154>
- Wu, W., Li, Y., Luo, X., Zhang, Y., Ji, X., & Li, X. (2019). Performance evaluation of the CHIRPS precipitation dataset and its utility in drought monitoring over Yunnan Province, China. *Geomatics, Natural Hazards and Risk*, 10(1), 2145–2162. <https://doi.org/10.1080/19475705.2019.1683082>
- Zhang, H., Chapman, S., Trancoso, R., Eccles, R., Syktus, J., & Toombs, N. (2025). Projections of actual and potential evapotranspiration from downscaled high-resolution CMIP6 climate simulations in Australia. *Hydrology and Earth*

*System Sciences*, 29(23), 6863–6884. <https://doi.org/10.5194/hess-29-6863-2025>

Zheng, D., Zhu, W., Han, Y., & Lv, A. (2025). A novel remote sensing-based calibration and validation method for distributed hydrological modelling in ungauged basins. *Journal of Hydrology*, 658, Article 133119. <https://doi.org/10.1016/j.jhydrol.2025.133119>

Zhu, Y., Zheng, Z., Zhao, G., Zhu, J., Zhao, B., Sun, Y., Gao, J., Zhang, Y. (2025). Evapotranspiration increase is more sensitive to vegetation greening than to vegetation type conversion in arid and semi-arid regions of China. *Global and Planetary Change*, 244, Article 104634. <https://doi.org/10.1016/j.gloplacha.2024.104634>

*Manuscrito submetido em 11 de março de 2026, aceito em 25 de maio de 2026.*

*Como citar:* Segantin, L. S., & Garcia, M. L. (2026). Calibração hidrológica do modelo SWAT+ com dados de precipitação e evapotranspiração derivados de sensoriamento remoto em bacias hidrográficas com escassez de dados. *Derbyana*, 47, Artigo e905.

*Contribuição dos autores:* L.S.S.: Conceitualização, Coleta e organização dos dados, Redação do manuscrito original, Análise formal, Metodologia. M.L.G.: Metodologia, Supervisão, Redação – revisão.

*Conflito de interesses:* Os autores declaram que não há conflito de interesses

