

**Universidade de Brasília
Instituto de Geociências
Programa de Pós-graduação em Geociências Aplicadas e Geodinâmica**

LEANDRO DE ALMEIDA SALLES

**SENSORIAMENTO REMOTO E ANÁLISE ESPACIAL NA DETERMINAÇÃO
DE PROCESSOS HIDROLÓGICOS NO BIOMA CERRADO**

Tese de Doutorado nº 57

(*ÁREA DE CONCENTRAÇÃO: GEOPROCESSAMENTO E ANÁLISE AMBIENTAL*)

BRASÍLIA – DF

2020

LEANDRO DE ALMEIDA SALLES

**SENSORIAMENTO REMOTO E ANÁLISE ESPACIAL NA DETERMINAÇÃO
DE PROCESSOS HIDROLÓGICOS NO BIOMA CERRADO**

Tese de Doutorado apresentada visando à obtenção do título de Doutor em Geociências Aplicadas e Geodinâmica, na área de concentração de Geoprocessamento e Análise Ambiental, pelo Programa de Pós-graduação em Geociências Aplicadas e Geodinâmica, do Instituto de Geociências da Universidade de Brasília.

Prof. Dr. Henrique Llacer Roig
Orientador

BRASÍLIA – DF

2020

FICHA CATALOGRÁFICA

Ficha catalográfica elaborada automaticamente,
com os dados fornecidos pelo(a) autor(a)

Ss Salles, Leandro de Almeida
Sensoriamento remoto e análise espacial na determinação
de processos hidrológicos no bioma Cerrado / Leandro de
Almeida Salles; orientador Henrique Llacer Roig. --
Brasília, 2020.
180 p.

Tese (Doutorado - Doutorado em Geociências Aplicadas) -- Universidade de Brasília, 2020.

1. Sensoriamento remoto. 2. Análise espacial. 3. Precipitação. 4. Evapotranspiração. 5. Bioma Cerrado. I. Roig, Henrique Llacer, orient. II. Título.

LEANDRO DE ALMEIDA SALLES

**SENSORIAMENTO REMOTO E ANÁLISE ESPACIAL NA DETERMINAÇÃO DE
PROCESSOS HIDROLÓGICOS NO BIOMA CERRADO**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Geociências Aplicadas e Geodinâmica do Instituto de Geociências da Universidade de Brasília, como requisito parcial para a obtenção do grau de Doutor.

30 de abril de 2020

Prof. Dr. Henrique Llacer Roig (Orientador – UNB)

Prof. Dr. Lineu Neiva Rodrigues (EMBRAPA)

Prof. Dr. Jansle Vieira Rocha (UNICAMP)

Prof. Dr. João José da Silva Júnior (UNB)

Prof. Dr. Edson Eyji Sano (Suplente – UNB)

*“São as águas de março fechando o verão
É a promessa de vida no teu coração”*
Tom Jobim

DEDICATÓRIA
À minha esposa Adriana,
À minha filha Clarice,
Aos meus pais Paulo e Heloísa.
Muito obrigado por tudo!

AGRADECIMENTOS

Gostaria de agradecer minha querida esposa Adriana pelo amor, companheirismo e carinho ao longo de mais uma caminhada e etapa da minha vida.

À minha filha Clarice pelo amor, pelos ensinamentos e por iluminar a minha vida com a sua companhia.

Aos meus pais, irmãos, avós, sobrinhos e demais membros da minha família pelo amor e amizade que nos une e por sempre me apoiarem.

Ao meu orientador Prof. Dr. Henrique Roig pelos ensinamentos, pelas horas dedicadas à elaboração desta Tese, pela sua confiança e por todas as oportunidades.

Ao Dr. Gabriel Senay e ao Prof. Dr. Dennis Ojima pela confiança, ensinamentos e oportunidade de realizar o meu Doutorado Sanduíche no Colorado State University (CSU).

Ao Dr. Jorge Enoch pela confiança e oportunidades, pelos ensinamentos e pelos trabalhos realizados em parceria ao longo desses anos.

Ao Prof. Dr. Jansle Vieira Rocha, ao Prof. Dr. João José da Silva Júnior, ao Prof. Dr. Lineu Neiva Rodrigues e ao Prof. Dr. Edson Eyji Sano por aceitarem participar da banca examinadora.

Ao Instituto Brasília Ambiental por investir na minha formação profissional e aos amigos de lá que sempre me apoiaram. À CAPES pela oportunidade concedida no Programa de Doutorado Sanduiche no Exterior, Processo nº 88881.187622/2018-01.

Ao Dr. Frédéric Satgé pelos ensinamentos e trabalhos realizados em parceria ao longo desses anos.

Ao Dr. Morris Scherer Warren, Prof. Dr. Lineu Neiva Rodrigues e aos demais colegas da ANA pelas oportunidades no grupo de pesquisa sobre Evapotranspiração (ANA, EMBRAPA e UnB) que foram fundamentais para o desenvolvimento desta Tese e para participação no Programa de Doutorado Sanduíche no Exterior no CSU.

Aos professores Elder, Tati, Rejane, Marina e Koide, ao Serjão e Mendes e aos demais membros da UnB que participaram dessa caminhada. Aos amigos do Laboratório de Sensoriamento Remoto e Análise Espacial, Diogo, Fred, Édio, Luciano, Rita, Welber, Kauem, Kássia, Henrique Bernini e demais pela convivência acadêmica e pela amizade que se formou. Por fim, aos amigos Miguel, Thiago Ayres, Gabriel Damasco, Felipe e Thiago Meirelles, Lya, Jorge, Vicente, Rodolfo, Marcos Gabriel, Irving, Flores, Garisto, Calixto, Rubinho, Grilo, Pedro Ivo, entre vários outros, pela convivência, amizade e companhia ao longo desses anos.

RESUMO

SALLES, L.A.S. **Sensoriamento remoto e análise espacial na determinação de processos hidrológicos no bioma Cerrado.** Tese (Doutorado em Geociências Aplicadas e Geodinâmica) – Instituto de Geociências, Universidade de Brasília, Brasília, 2020.

Este trabalho avaliou o uso de sensoriamento remoto e análise espacial no diagnóstico da precipitação (P), da evapotranspiração real (ET_r), e de vazões (Q) no Bioma Cerrado. Foram avaliadas estimativas de P por sensoriamento remoto (P_{sr}), obtidas pelo *Tropical Rainfall Measuring Mission* (TRMM) (*TRMM Multi-satellite Precipitation Analysis* (TMPA 3B42)) e pelo *Global Precipitation Measurement* (GPM) (*Integrated Multi-satellitE Retrievals for GPM* (IMERG) e o *Global Satellite Mapping of Precipitation* (GSMaP)). Também foram avaliadas estimativas de ET_r do modelo *Operational Simplified Surface Energy Balance* (SSEBop) feitas com dados do *Moderate resolution Imaging Spectroradiometer* (MODIS), do *Enhanced Thematic Mapper Plus* (ETM+) e do *Thermal Infrared Sensor* (TIRS). As estimativas de P_{sr} e ET_r foram validadas em diferentes condições e também foram utilizadas no modelo hidrológico *Soil and Water Assessment Tool* (SWAT) para simular Q e ET_r em bacia hidrográfica agrícola. Os resultados demonstram que a geração de produtos de P_{sr} obtidos a partir de dados da missão GPM (IMERG e GS MaP) é capaz de garantir a continuidade no monitoramento de P no Brasil central, com o IMERG apresentando as melhores correlações com a rede de pluviômetros na maior parte dos cenários avaliados. De modo geral, as simulações de Q pelo modelo SWAT utilizando dados do IMERG superou o uso do TMPA e do GS MaP e até mesmo, em alguns casos, as simulações feitas com os dados da rede de pluviômetros, apresentando coeficiente Nash & Sutcliffe (NS) $> 0,75$. O modelo SSEBop conseguiu estimar a ET_r de forma satisfatória em áreas de pastagem, reflorestamento e com vegetação nativa utilizando dados provenientes do ETM+ e do TIRS, com coeficiente de determinação (R^2), respectivamente, iguais a 0,8, 0,59 e 0,91 nos melhores cenários avaliados. Por fim, a série temporal de ET_r proveniente de dados do MODIS contribuiu positivamente na simulação de Q e ET_r pelo modelo SWAT ao nível de sub-bacia, com NS $> 0,6$ nos cenários de validação que calibraram ambas as variáveis em conjunto com o algoritmo de otimização SUFI-2, e que apresentaram melhores níveis de incertezas na estimativa dos parâmetros.

Palavras-chave: TRMM, GPM, SSEBop, SWAT, IMERG, TMPA

ABSTRACT

SALLES, L.A.S. **Remote sensing and spatial analysis in determining hydrological processes in the Cerrado biome.** Thesis (Doctorate in Applied Geosciences and Geodynamic) – University of Brasilia, 2020.

This work assessed the use of remote sensing and spatial analysis in determining hydrological processes, aiming at establishing the diagnosis of precipitation, actual evapotranspiration (ET_a), and streamflow in the Cerrado Biome. Satellite precipitation estimates (SPEs) generated from the Tropical Rainfall Measuring Mission (TRMM) (TRMM Multi-satellite Precipitation Analysis (TMPA 3B42)) and the Global Precipitation Measurement (GPM) (Integrated Multi-satellitE Retrievals for GPM (IMERG) and the Global Satellite Mapping of Precipitation (GSMaP)) were evaluated. The ET_a was assessed using the Operational Simplified Surface Energy Balance (SSEBop) model with data from the Moderate resolution Imaging Spectroradiometer (MODIS), the Enhanced Thematic Mapper Plus (ETM+) and the Thermal Infrared Sensor (TIRS). The SPEs and the ET_a were assessed under different conditions and were used with the Soil and Water Assessment Tool (SWAT) to simulate Q and ET_a in an agricultural river basin. The results demonstrate that the new generation of SPEs obtained from the GPM era datasets (IMERG and GS MaP) is able to guarantee continuity in the monitoring of precipitation in central Brazil, with IMERG presenting the best correlations with the rain gauges. Overall, SWAT presented a better performance simulating streamflow using IMERG compared with TMPA and GS MaP and, in some cases, the simulations which used the rain gauge network dataset, with Nash & Sutcliffe (NS) efficiency > 0.75 . SSEBop model estimated ET_a satisfactorily in areas of pasture, reforestation and native vegetation, using data from ETM + and TIRS, with a coefficient of determination (R^2), respectively, equal to 0.8, 0.59 and 0.91 in the scenarios with the best results. Finally, the ET_a time series from MODIS contributed positively to SWAT's simulation of streamflow and ET_a at the sub-basin level, with $NS > 0.6$ in the validation scenarios which used parameters ranges obtained by calibrating both variables simultaneously with the SUFI-2 optimization algorithm, also displaying the best levels of uncertainties in the estimation of the parameters.

Key-words: TRMM, GPM, SSEBop, SWAT, IMERG, TMPA

SUMÁRIO

APRESENTAÇÃO.....	15
CAPÍTULO 1.....	18
1. Introdução	18
2. Objetivos	21
2.1. Objetivo Geral.....	21
2.2. Objetivos Específicos	21
3. Estado da arte.....	21
3.1. A evapotranspiração estimada por sensoriamento remoto	21
3.2. A precipitação estimada por sensoriamento remoto	28
3.3. Integração do modelo hidrológico com sensoriamento remoto.....	31
Referências	34
CAPÍTULO 2 - AVALIAÇÃO DA DINÂMICA ESPACIAL E TEMPORAL DE PRODUTOS GLOBAIS DE PRECIPITAÇÃO POR SENSORIAMENTO REMOTO....	47
1. Introduction	49
2. Data and Methodology.....	51
2.1. Study Area.....	51
2.2. Precipitation Data.....	52
2.2.1. Integrated Multi-satellitE Retrievals for Global Precipitation Measurement (IMERG)	52
2.2.2. Global Satellite Mapping of Precipitation (GSMaP)	53
2.2.3. Tropical Rainfall Measurement Mission Multi-Satellite Precipitation Analysis (TMPA)	53
2.2.4. Rain Gauges.....	54
2.3. Method.....	54
2.3.1. Pre-processing	54
2.3.2. Comparison Methodology	55
2.3.2.1. Annual Comparison.....	55
2.3.2.2. Monthly Comparison.....	56
2.3.2.3. Daily Comparison	57
3. Results	58
3.1. Annual Analysis	58
3.2. Monthly Analysis	59
3.3. Daily Analysis.....	63
4. Discussion.....	65

5. Conclusions	68
References	69
CAPÍTULO 3 - SENSORIAMENTO REMOTO PARA AVALIAR O IMPACTO DA EVAPOTRANSPIRAÇÃO REAL NA UMIDADE DO SOLO EM DIFERENTES CAMADAS AO LONGO DO PERFIL EM DIFERENTES COBERTURAS	76
1. Introduction	77
2. Data.....	80
2.1. Study area.....	80
2.2. Input datasets.....	82
2.3. Ground-based validation datasets.....	82
2.4. Other ancillary datasets	83
3. Methodology	83
3.1. The SSEBop modeling approach.....	83
3.2. Landsat 7 and 8 data processing	85
3.3. The soil moisture modeling approach.....	86
4. Results and discussion.....	87
4.1. SSEBop's calibration and parametrization results	87
4.2. Local and seasonal relations between remote sensing and soil moisture-based evapotranspiration.....	89
4.3. Global relations between remote sensing and soil moisture-based evapotranspiration	94
5. Conclusions	101
6. References	102
CAPÍTULO 4 - SIMULAÇÃO HIDROLÓGICA UTILIZANDO DADOS DE EVAPOTRANSPIRAÇÃO REAL E PRECIPITAÇÃO OBTIDOS POR SENSORIAMENTO REMOTO EM BACIA HIDROGRÁFICA DO BIOMA CERRADO.	112
1. Introdução.....	114
2. Materiais e Métodos	117
2.1 Área de Estudo.....	117
2.2 Aspectos gerais do SWAT	119
2.3. Base de dados	120
2.4 Dados de precipitação por sensoriamento remoto.....	123
2.4.1 Tropical Rainfall Measuring Mission Multi-Satellite Precipitation Analysis (TMPA)	123
2.4.2 Integrated Multi-satellitE Retrievals for Global Precipitation Measurement (IMERG)	124
2.4.3 Global Satellite Mapping of Precipitation (GSMaP)	125

2.5 Dados de evapotranspiração real por sensoriamento remoto	125
2.6 Configuração do SWAT (pré-processamento).....	127
2.7 Análise de incertezas e calibração do modelo SWAT	127
2.8 Avaliação da simulação hidrológica.....	129
2.9 Cenários de integração do modelo SWAT com dados obtidos por sensoriamento remoto	130
3. Resultados e Discussões	133
3.1. Simulações com dados de precipitação por sensoriamento remoto	133
3.1.1. Análise de incertezas e calibração do modelo SWAT na simulação da vazão diária utilizando dados de precipitação por sensoriamento remoto	133
3.1.2. Análise de incertezas e calibração do modelo SWAT na simulação da vazão média mensal utilizando dados de precipitação por sensoriamento remoto	136
3.2. Simulações com dados de evapotranspiração real por sensoriamento remoto.....	142
3.2.1. Análise de incertezas e calibração do modelo SWAT na simulação da evapotranspiração real e da vazão média mensal.....	142
3.2.2. Validação das simulações de evapotranspiração real e da vazão média mensal pelo modelo SWAT	146
4. Conclusões.....	155
Referências bibliográficas.....	157
CAPÍTULO 5.....	165
1. Considerações finais	165
2. Próximos passos	169
ANEXO I.....	170
ANEXO II	171

LISTA DE SIGLAS

- ALEXI – *Atmosphere-Land Exchange Inversion*
AMSR-E – *Advanced Microwave Scanning Radiometer-Earth Observing System*
AMSU-B – *Advanced Microwave Sounding Unit-B*
B – *Bias* (Análise de contingência)
BIAS - *Bias*
BHRQ – Bacia Hidrográfica do Reservatório de Queimado
CHIRPS – *Climate Hazards Group InfraRed Precipitation with Stations*
CMORPH – *Climate Prediction Center morphing method*
CSI – *Critical Success Index*
CC – Coeficiente de Correlação
CV – Coeficiente de variação
CPC – *Climate Prediction Center*
DisTrad – *Disaggregation procedure for radiometric surface temperature*
DPR – *Dual-frequency Precipitation Radar*
ET – Evapotranspiração
ET_r – Evapotranspiração real
ET_o – Evapotranspiração de referência
ETM+ – *Enhanced Thematic Mapper Plus*
FAR – *False Alarm Ratio*
GMI – *GPM Microwave Imager*
GEO – Geoestacionário
GOES – *Geostationary Operational Environmental Satellite*
GPM – *Global Precipitation Measurement*
GsMap – *Global Satellite Mapping of Precipitation*
IAF – Índice de área foliar
IMERG – *Integrated multi-satellite retrievals for GPM*
IR – Infravermelho
JAXA – *Japan Aerospace Exploration Agency*
k_c – fator de cultura
k_s – coeficiente de estresse hídrico
LEO – *Low earth-orbiting*
LST – *Land Surface Temperature*
Meteosat – *Meteorological Satellite*
MNFinverso – *Inverse Minimum Noise Fraction*
MTSat – *Multi-functional Transport Satellite*
NASA – *National Aeronautics and Space Administration*
NDVI – *Normalized Difference Vegetation Index*
NS – Coeficiente Nash & Sutcliffe
MAE – *Mean Absolute Error*
MAPE – *Mean Absolute Percent Error*
METRIC – *Mapping Evapotranspiration with Internalized Calibration*
MODIS – *Moderate resolution Imaging Spectroradiometer*
P – Precipitação
PBIAS – *Percent bias*
POD – *Probability of Detection*
PMW – *Passive micro-wave*
RMSE – *Root Mean Squared Error*

RMSE_c – *Centered Root Mean Squared Error*

RMSEP – *Percent Root Mean Squared Error*

PR – *Precipitation Radar*

P_{sr} – Precipitação por sensoriamento remoto

SEBAL – *Surface Energy Balance for Land*

SEBI – *Surface Energy Balance Index*

SEBS – *Surface Energy Balance System*

SSMI/I – *Special Sensor Microwave Imager*

SSEBop – *Operational Simplified Surface Energy Balance*

SR – *Success Ratio*

SUFI-2 – *Sequential Uncertainty Fitting*

SWAT – *Soil and Water Assessment Tool*

SWAT-CUP – *SWAT Calibration and Uncertainty Programs*

TIRS – *Thermal Infrared Sensor*

TMPA – TRMM *Multi-satellite Precipitation Analysis*

TMI – TRMM *Microwave Imager*

TRMM – *Tropical Rainfall Measuring Mission*

TSEB – *Two-Source Energy Balance*

TSTIM – *Two-Source Time-Integrated Model*

VIS – visível

APRESENTAÇÃO

O presente documento tem como objetivo o cumprimento do regulamento do Programa de Pós-Graduação em Geociências Aplicadas e Geodinâmica, do Instituto de Geociências da Universidade de Brasília (IG/UnB), para a obtenção do título de Doutor em Geociências Aplicadas e Geodinâmica, na área de concentração Geoprocessamento e Análise Ambiental. O documento é composto por cinco capítulos, sendo o primeiro uma introdução ao tema da pesquisa; os três subsequentes foram desenvolvidos no formato de artigo científico, os quais foram elaborados visando responder a hipótese estabelecida; e o último com as principais conclusões obtidas nesta tese de doutorado. Até a presente data, o artigo apresentado no capítulo 2 já foi publicado na revista Water (<https://doi.org/10.3390/w11040668>), enquanto os artigos propostos nos capítulos 3 e 4 estão sendo preparados para publicação.

O primeiro capítulo apresenta uma introdução ao tema, contextualizando a problemática que motivou a pesquisa e expõe a hipótese estabelecida nesta tese. Em seguida, são apresentados o objetivo geral e os objetivos específicos que foram definidos visando respostas à hipótese. Por fim, é apresentado o estado da arte do tema pesquisado.

O artigo apresentado no segundo capítulo faz uma avaliação de produtos globais que estimam a Precipitação (P) na região do Brasil central, a partir de dados obtidos por diversos sensores a bordo de satélites geoestacionários e de baixa órbita. A importância deste artigo no contexto da Tese de doutorado consiste em contribuir para o conhecimento relacionado a metodologias de monitoramento da chuva utilizando produtos de P obtidos por sensoriamento remoto, uma vez que a chuva é a principal variável de entrada do ciclo hidrológico e muitas regiões do Cerrado brasileiro possuem baixa densidade de estações de monitoramento. Avalia-se como a determinação da dinâmica espacial e temporal da P por sensoriamento remoto (P_{sr}) pode contribuir com o monitoramento ambiental de recursos hídricos. O artigo apresenta uma análise de consistência espacial e temporal de produtos de P gerados a partir da missão *Global Precipitation Measurement* (GPM) e sua antecessora, a *Tropical Rainfall Measuring Mission* (TRMM), avaliando a continuidade na geração de dados de P de uma missão espacial para a outra. O estudo compara os dados do TRMM *Multi-satellite Precipitation Analysis* (TMPA), *Integrated multi-satellite retrievals for GPM* (IMERG), e o *Global Satellite Mapping of Precipitation* (GSMP) com dados da rede de monitoramento de chuvas existentes na região do Distrito Federal e entorno em diferentes escalas temporais. O artigo faz uma avaliação em termos quantitativos das estimativas de P do IMERG, GSMP e TMPA, e também em termos categóricos, ao avaliar a detecção da ocorrência de eventos chuvosos por esses produtos.

Já o artigo apresentado no terceiro capítulo faz uma avaliação dos impactos da Evapotranspiração real (ET_r) em diferentes coberturas do solo no bioma Cerrado. A importância deste artigo no contexto da Tese de doutorado consiste em contribuir para o conhecimento relacionado à ET_r e ao uso de água por culturas agrícolas, florestais e pela vegetação nativa, utilizando o sensoriamento remoto da superfície como ferramenta de análise, uma vez que, por ocorrer no estado gasoso, a ET_r é a variável do ciclo hidrológico mais difícil de se monitorar e cuja determinação em modelos hidrológicos muitas vezes não é avaliada. A avaliação foi realizada a partir da correlação entre a ET_r estimada pelo modelo *Operational Simplified Energy Balance* (SSEBop) e a Evapotranspiração de cultura (ET_c) simulada a partir de um coeficiente de estresse hídrico do solo (k_s), obtidos para diferentes profundidades. Foram utilizadas imagens Landsat 7 e 8 para o cálculo da ET_r por meio do modelo. Já o k_s foi calculado a partir de amostras do teor de umidade do solo coletadas em seis profundidades (0,25m; 0,75m; 1,25m; 1,75m; 2,25m; 2,75m). Inicialmente, para avaliar a parametrização do modelo no nosso estudo, os resultados do modelo SSEBop foram validados com dados de ET_r obtidos por meio da razão de Bowen na mesma região por estudo desenvolvido por pesquisadores parceiros vinculados a Universidade de Brasília e outras instituições (EMBRAPA e Agência Nacional de Águas (ANA)) e disponibilizados na literatura. Posteriormente, os resultados da ET_r obtidos por sensoriamento foram correlacionados com os dados de ET_c em diferentes cenários, com o objetivo de se estabelecer relações da ET_r com a variação da umidade do solo nas diferentes camadas do solo avaliadas ao longo do perfil até 3.0m. Foi realizada uma avaliação dos impactos da ET_r na variação da umidade do solo ao longo do período de estiagem. Também foi avaliado o uso da ET_c para validar os resultados de ET_r obtidos por sensoriamento remoto em diferentes cenários de cobertura do solo. A partir da análise, foi possível comparar e relacionar a variação da ET_r com a variação da ET_c em diferentes profundidades do solo e assim fazer inferências acerca do uso de água pela pastagem, pelo reflorestamento e pelo Cerradão ao longo do tempo.

O artigo desenvolvido no quarto capítulo buscou dar sequência aos artigos desenvolvidos nos capítulos anteriores por meio da avaliação do uso de produtos globais de P_{sr} e de ET_r , gerados a partir de dados obtidos por sensoriamento remoto, no modelo de simulação hidrológica *Soil and Water Assessment Tool* (SWAT). A importância deste artigo no contexto da Tese de doutorado consiste em verificar como dados obtidos por sensoriamento remoto podem contribuir nas simulações de vazões e outras variáveis hidrológicas em bacias hidrográficas agrícolas no bioma Cerrado, onde o monitoramento convencional nem sempre tem uma cobertura adequada. Os dados de P_{sr} , analisados no 1º artigo (capítulo 2), foram testados como entrada ao modelo SWAT. Com isso, avaliou-se o impacto das estimativas de P do IMERG, GSMAp e TMPA na

simulação de vazões e nas incertezas decorrente da calibração dos parâmetros do modelo SWAT. No que concerne ao uso de dados de ET estimado por sensoriamento remoto em modelos hidrológicos, o artigo avaliou o uso de dados globais e gratuitos de ET_r estimada pelo modelo SSEBop (mesmo do artigo 2, capítulo 3, porém com um upscale) em séries temporais de imagens do *Moderate resolution Imaging Spectroradiometer* (MODIS), na etapa de calibração e validação do modelo SWAT. Nessa etapa, avaliaram-se os benefícios da calibração desse processo hidrológico que, por ser um intermediário na simulação de vazões pelo modelo SWAT, não é observado na maioria das aplicações.

Por fim, o último capítulo tem como objetivo trazer as considerações finais da pesquisa. Nesse capítulo é feita uma avaliação final acerca da hipótese e dos objetivos estabelecidos para a tese de doutorado, e são apresentadas sugestões para estudos que podem ser realizados no futuro.

Também, foram anexados nesta tese outros resultados relevantes que foram obtidos ao longo do desenvolvimento do doutorado e que complementam as discussões acerca da hipótese estabelecida. No Anexo I, estão os resultados apresentados na sessão de posters da *American Geophysical Union* (AGU) 2018 Fall Meeting. Nesse estudo foi avaliada a consistência de dados P_{sr} dos produtos CHIRPS e MSWEP na bacia hidrográfica do São Francisco (BHSF). Em seguida foram avaliados os dados de ET_r estimados pelo SSEBop utilizando imagens do MODIS e realizada uma análise do fechamento do balanço hídrico anual em diferentes sub-bacias da BHSF.

O Anexo II apresenta um artigo publicado na Applied Geography Journal (<https://doi.org/10.1016/j.apgeog.2018.02.007>), que aborda a determinação de variáveis relacionadas à água subterrânea utilizando análise espacial. Para abordar esse tema, foi elaborado modelo estatístico utilizando a metodologia de regressão com pesos espaciais, com o objetivo de estabelecer correlações entre variáveis ambientais e a amplitude máxima de variação do lençol freático observada em poços piezométricos instalados na bacia hidrográfica do alto rio Jardim. Esta pesquisa teve início no curso de especialização em Geoprocessamento Ambiental pela Universidade de Brasília, sendo aprimorada no início do curso de doutorado.

CAPÍTULO 1

1. Introdução

Nos últimos anos, diferentes regiões brasileiras enfrentaram crises hídricas (BRASIL, 2019). A capital do Brasil, por exemplo, atravessou a pior crise hídrica da sua história (LIMA *et al.*, 2018). O baixo nível dos reservatórios de abastecimento durante o período de chuvas levou ao primeiro racionamento que atingiu a maior parte da população (BRASIL, 2019). Alguns fatores contribuem para a intensificação da crise hídrica no Distrito Federal, entre eles estão: o aumento da produção agrícola (CODEPLAN, 2013); o crescimento populacional do DF nos últimos 30 anos (CODEPLAN, 2015), a sazonalidade do clima e as variações climáticas anuais (LIMA *et al.*, 2018; BRASIL, 2019).

A ocorrência de conflitos pelo uso da água é consequência direta desse cenário, o que torna indispensável o gerenciamento e o monitoramento dos recursos hídricos. O monitoramento dos recursos hídricos envolve a coleta de um conjunto de variáveis hidrológicas, meteorológicas, sedimentológicas, as quais são utilizadas em modelos com o objetivo de estimar os diferentes componentes do balanço hídrico, e a produção de água em bacias hidrográficas. No entanto, o monitoramento de processos hidrológicos em bacias hidrográficas demanda infraestrutura e equipamentos especializados, os quais, adicionados a variabilidade espacial e temporal inerentes aos sistemas ambientais, dificultam a sua implementação em muitas regiões.

Nos tempos atuais o uso de geotecnologias se tornou de extrema importância para o monitoramento de processos hidrológicos em bacias hidrográficas. Diferentes métodos de análise espacial, utilizando sistemas de informação geográfica e dados de sensoriamento remoto, foram se estabelecendo e se popularizando, na medida em que métodos computacionais foram avançando, sendo amplamente empregados no manejo e conservação do solo e dos recursos hídricos (e.g. ARNOLD *et al.*, 1998; BASTIAANSSEN *et al.*, 1998; ALLEN *et al.*, 2007; HUFFMAN *et al.*, 2007; SENAY *et al.*, 2013; HOU *et al.*, 2014; SENAY *et al.*, 2017; HUNTINGTON *et al.*, 2017; BRASIL, 2020).

A nova geração de satélites orbitais, por sua vez, está disponibilizando imagens gratuitas com resolução espacial, temporal, radiométrica, e espectral cada vez melhores (BERGER *et al.*, 2012; ROY *et al.*, 2014; HUFFMAN *et al.*, 2015). O sensoriamento remoto, em especial com satélites, fornece continuamente e espacialmente informações da superfície terrestre que são relevantes para a parametrização de variáveis biofísicas (QIANG *et al.*, 2016).

O uso de Veículos Aéreos Não Tripulados (VANTS) com câmeras termais, multi e hiperespectrais também tem crescido nos últimos anos e se mostrado uma boa alternativa para obtenção de dados e estudos aplicados em diferentes áreas (COLOMINA & MOLINA, 2014;

EGEA *et al.*, 2017; SANTESTEBAN *et al.*, 2017; OLIVETTI *et al.*, 2020). Assim, o sensoriamento remoto permite analisar o mesmo problema de forma multiescalar permitindo diversas abordagens. Isso oferece boas oportunidades no monitoramento hidrológico e na gestão dos recursos hídricos, principalmente em tempos de crise em que a quantidade do recurso hídrico se torna mais escassa.

O avanço das geotecnologias também permitiu que modelos hidrológicos sejam cada vez mais utilizados no Brasil e no mundo (e.g. QIN *et al.*, 2008; LIMA, 2010; STRAUCH *et al.*, 2012; FERRIGO, 2014; SALLES *et al.*, 2015; CASTRO *et al.*, 2015; SIMONS *et al.*, 2016; POORTINGA *et al.*, 2017; COELHO *et al.*, 2017; FRANCO & BONUMÁ, 2017; ARAÚJO, 2018; DENG *et al.*, 2019; LUO *et al.*, 2019; TRIANA *et al.*, 2020). Entretanto, apesar do número crescente de usuários de modelos hidrológicos no Brasil, ainda há desafios para serem superados (BRESSIANI *et al.*, 2015). Os dados de entrada são fontes de incertezas no processo de modelagem e a carência de dados também prejudica todo o processo (TUCCI, 1998).

As incertezas podem ter origem tanto na aleatoriedade inerente aos sistemas naturais, não sendo possível controlá-las, denominadas de incertezas aleatórias, quanto na falta de conhecimento técnico-científico a respeito de determinada variável, parâmetro, sendo conhecida como incerteza epistêmica e podendo ser evitada na medida em que as tecnologias e o conhecimento evoluem (PIELKE JR, 2003; HELTON *et al.*, 2006).

A Evapotranspiração real (ET_r) (*Actual Evapotranspiration* (ET_a)) é uma variável que faz parte do balanço hídrico que é complexa de se mensurar, pois apresenta grande variabilidade espacial e temporal, e que a estimativa por meio de sensoriamento remoto tem se mostrado eficiente (KARIMI & BASTIAANSSEN, 2015).

O conhecimento da ET_r é necessário para determinação do balanço hídrico em bacias hidrográficas, permitindo a predição e a estimativa do escoamento superficial e da recarga da água subterrânea (IDSO *et al.*, 1975). Desse modo, quantificar o uso de água em áreas irrigadas ou em escala regional é relevante para avaliação do balanço hídrico visando o planejamento, o manejo adequado e a gestão dos recursos hídricos (ALLEN *et al.*, 2007; BRASIL, 2020).

Existem três métodos de se calcular série temporal de evaporação em escala regional (SAVENIJE, 1997): alteração de escala a partir de observações pontuais; monitoramento e modelagem dos componentes da equação do balanço energético com base em sensoriamento remoto; e modelagem hidrológica do balanço hídrico. De modo geral, as técnicas de sensoriamento remoto calculam a evapotranspiração sem precisar considerar outros componentes do ciclo hidrológico, o que diminui a propagação de erros proveniente de outro processo aos resultados obtidos da evapotranspiração (MOHAMED *et al.*, 2004).

A Precipitação (P) é outra variável que faz parte do balanço hídrico que é complexa de se mensurar, pois apresenta grande variabilidade espacial e temporal, e que a estimativa por meio de sensoriamento remoto tem evoluído significativamente. A Precipitação é uma variável fundamental para os processos hidrológicos que ocorrem na superfície ao longo do tempo e do espaço (HONG *et al.*, 2006).

Historicamente, o registro da P tem sido relevante para a meteorologia, para o cálculo do balanço hídrico em oceanos e áreas continentais e para o balanço de energia na atmosfera (GRIFFITH *et al.*, 1978), bem como para a engenharia hidrológica, uma vez que o manejo dos recursos hídricos, seja para irrigação, controle de cheias, enfrentamento de secas, ou na administração de reservatórios, requer o conhecimento de quando, o quanto e onde precipitou (HOU *et al.*, 2014).

Os dados de estações pluviométricas e de radar são utilizados extensivamente para medição de P, sendo que cada metodologia tem suas vantagens e desvantagens (GRIFFITH *et al.*, 1978). Entretanto, as observações de estações pluviométricas e de radares meteorológicos fixos são limitadas em regiões montanhosas e em áreas remotas (HONG *et al.*, 2006), assim como em regiões economicamente subdesenvolvidas. O sensoriamento remoto é a única metodologia capaz de estimar a P em escala global com acurácia uniforme (OKAMOTO *et al.*, 2005), sendo de grande importância para o monitoramento e para o manejo dos recursos hídricos.

Assim como a P e a ET_r, os processos hidrológicos que ocorrem no solo também apresentam grande variabilidade espacial e temporal e são complexos de se monitorar. Com isso, estudos sobre o armazenamento da água no solo e sobre águas subterrâneas também são relevantes para o balanço hídrico pela importância desses processos hidrológicos para as vazões de rios no bioma Cerrado. O fato de muitos rios na região serem perenes, mesmo com a sazonalidade do clima, com uma estação seca e chuvosa bem definidas, ilustra a relevância de estudos sobre esses processos hidrológicos. Dados de bacias experimentais no bioma Cerrado indicam que o fluxo de base representa 90% da vazão observada, enquanto os 10% restantes são gerados pelo escoamento superficial decorrente de eventos chuvosos (LIMA, 2010).

No cenário imposto por crises hídricas em diferentes regiões do país, o monitoramento do uso dos recursos hídricos se torna cada vez mais relevante. Dessa maneira, devido à importância e à necessidade de análises de sistemas hidrológicos para gestão adequada dos recursos hídricos, este estudo busca avaliar o uso de modelos espaciais, produtos de sensoriamento remoto, assim como o uso de modelos hidrológicos visando contribuir com o monitoramento ambiental e a simulação de processos hidrológicos em regiões tropicais, visando à melhoria no diagnóstico e

prognóstico da precipitação (P), da evapotranspiração real (ET_r), e de vazões (Q) no Bioma Cerrado.

Problema: a gestão dos recursos hídricos em muitas regiões carece de séries históricas consistentes de dados hidrológicos, assim como possui problemas na parametrização de modelos e na representação de processos hidrológicos que ocorrem em regiões tropicais, visto que a maioria dos modelos foram desenvolvidos e validados em regiões de clima temperado, e que existem problemas no monitoramento das variáveis hidrológicas necessárias para a modelagem.

Considerando o exposto, estabeleceu-se nesta pesquisa a hipótese de que a determinação da dinâmica espacial e temporal da ET e da P por sensoriamento remoto melhora o monitoramento ambiental assim como o processo de simulação de modelos chuva-vazão na gestão de recursos hídricos em bacias hidrográficas do bioma Cerrado.

2. Objetivos

2.1. Objetivo Geral

O objetivo dessa pesquisa consiste em contribuir com o monitoramento ambiental e a simulação de processos hidrológicos em regiões tropicais, visando à melhoria no diagnóstico e prognóstico da precipitação (P), da evapotranspiração real (ET_r), e de vazões (Q) no Bioma Cerrado.

2.2. Objetivos Específicos

- Avaliar séries temporais de produtos globais de P por sensoriamento remoto no monitoramento ambiental entre duas gerações de algoritmos desenvolvidos, verificando a continuidade da disponibilização dos dados;
- Avaliar a ET_r estimada a partir de dados de sensoriamento remoto em diferentes tipos de cobertura do solo e sua relação com a dinâmica da água do solo;
- Avaliar o uso de séries temporais de P e ET_r estimadas por sensoriamento remoto na simulação de Q e ET_r por modelo hidrológico em bacia hidrográfica.

3. Estado da arte

3.1. A evapotranspiração estimada por sensoriamento remoto

O desenvolvimento de metodologias que estimam a evaporação por meio de variáveis meteorológicas que podem ser coletadas facilmente, como a temperatura do ar e a pressão de vapor da água foi bastante explorado no século passado. O interesse é antigo, podendo ser ilustrado quando Bowen (1926) estabeleceu que o processo de evaporação e difusão do vapor de

uma superfície com água para o ar acima é idêntico ao encontrado pela condução de energia da superfície com água para o ar (BOWEN, 1926).

A ET_r pode ser observada a partir de: (i) mensurações diretas, por meio de técnicas de *eddy covariance* que mensuram os fluxos turbulentos de vapor, pela razão de Bowen, ou pela análise de perdas de água observadas em lisímetros; e (ii) medidas indiretas utilizando o balanço de energia ou o balanço hídrico (MENENTI & CHOUDHURY, 1993; GOWDA *et al.*, 2008).

A necessidade de coletar muitos parâmetros e características da superfície cuja mensuração em áreas extensas não é simples, como a pressão de vapor, a temperatura do ar, a umidade do solo, a velocidade do vento, e a rugosidade da superfície, limita a aplicação das metodologias que mensuram diretamente a ET_r (IDSO *et al.*, 1975).

Medidas regionalizadas de evaporação são necessárias para estudos de balanço hídrico e para se conhecer relações entre a superfície e a atmosfera, no entanto, medidas do fluxo de calor obtidas diretamente em escalas maiores do que 10km não são triviais, tornando métodos de coleta de dados por sensoriamento remoto atraentes, mesmo quando se utilizam relações semi-empíricas (MENENTI & CHOUDHURY, 1993).

Existe interesse no desenvolvimento de métodos robustos e operacionais para mapear o fluxo de energia, uma vez que mapas com resolução 10¹-10²m podem ser relevantes para agricultura de precisão, para o monitoramento de secas, na modelagem de água subterrânea e para detectar mudanças em sistemas naturais e manejados em decorrência de gatilhos antrópicos ou climáticos (ANDERSON *et al.*, 2004).

Ao longo dos anos, a ciência foi revelando diferentes evidências que contribuíram para o desenvolvimento de metodologias que hoje são utilizadas para estimar a ET_r a partir de dados coletados por sensoriamento remoto. Com a perspectiva e o subsequente lançamento em 1972, do primeiro satélite civil desenvolvido para o monitoramento da superfície terrestre, o *Earth Resources Technology Satellite* (ERTS-1), renomeado em 1975 para LandSat-1, buscou-se verificar se os dados coletados remotamente poderiam fornecer estimativas da evaporação de água no solo ao longo de um período específico.

Nessa época, evidências demonstraram que para diferentes tipos de solos, em condições de umidade distintas, a evaporação real pode ser obtida pelas medidas de temperatura coletadas remotamente por radiômetros instalados em plataformas orbitais (IDSO *et al.*, 1975). Não obstante, apenas com o lançamento dos satélites *Heat Capacity Mapping Mission* (HCMM) e *Tiros-N* em 1978, que coletavam dados na frequência do termal (10,5 - 12,5μm) em diferentes horários do dia, foi possível utilizar dados de sensoriamento remoto para estudos de fluxos de energia e umidade na superfície terrestre (PRICE, 1980).

O estabelecimento de relações entre o índice de área foliar (IAF) e a ET_r (STERN, 1965; RITCHIE & BURNETT, 1970; RITCHIE *et al.*, 1976), o desenvolvimento e a validação de índices de vegetação (ROUSE *et al.*, 1973; TUCKER, 1979; HUETE, 1988), o estabelecimento de relações entre a banda termal e o teor de umidade do solo (PRICE, 1980) são outros exemplos da evolução do conhecimento que foram contribuindo para que fossem desenvolvidos os métodos que estimam a ET_r com dados coletados por sensoriamento remoto, utilizados nos dias atuais.

De modo geral, os modelos de ET_r podem ser categorizados em dois tipos: métodos empíricos, em que são estabelecidas relações derivadas de dados obtidos por sensoriamento remoto com dados medidos em superfície por meio de modelo estatístico; e métodos analíticos, que variam em complexidade, buscam estabelecer os processos físicos, e necessitam de dados medidos direta e indiretamente por sensoriamento remoto e por instrumentos em superfície (LI *et al.*, 2009).

O primeiro modelo empírico proposto combinou medidas de temperatura com a radiação líquida para estimar ET_r (JACKSON *et al.*, 1977). Do ponto de vista teórico, o modelo empírico proposto Jackson e colaboradores (1977) não apresentou contradições, no entanto, foi demonstrada a impossibilidade de uma parametrização global dos coeficientes do modelo para todas as situações (SEGUIN & ITIER, 1983). Apesar de ser uma metodologia relativamente simples, a sua aplicabilidade requer a parametrização dos coeficientes da regressão, o que pode tornar o emprego do método em escala regional um problema (LI *et al.*, 2009).

A abordagem analítica de estimar a ET_r utiliza o método residual do balanço de energia na superfície. O método residual do balanço de energia calcula a ET_r a partir do fluxo de calor latente, o qual é estimado através do balanço de energia na superfície conforme equação a seguir:

$$L_E E = R_n - G - H \quad (1)$$

em que L_EE é o fluxo de calor latente (W·m⁻²), R_n é a radiação líquida (W·m⁻²), G₀ é fluxo de calor no solo (W·m⁻²), e H é o fluxo de calor sensível (W·m⁻²).

Na abordagem analítica, os modelos podem ser classificados como sendo de uma camada (*Single-source models*) e modelos de duas camadas (*Dual-source models*), cuja diferença principal consiste na separação do fluxo de energia da superfície em um ou dois componentes, separando o cálculo dos processos físicos que ocorrem no solo daqueles que ocorrem no dossel da vegetação.

Os modelos de duas camadas requerem o conhecimento da temperatura no solo e no dossel da vegetação, no entanto, o dado de temperatura de superfície, *Land Surface Temperature* (LST), obtido por sensoriamento remoto é uma medida única obtida em superfícies heterogêneas (YANG & SHANG, 2013). Um dos caminhos para superar esse obstáculo foi o desenvolvimento

do *Two-Source Energy Balance* (TSEB), uma metodologia que decompõem o dado de LST obtido por sensoriamento remoto em dois componentes utilizando duas imagens de LST quase instantâneas (NORMAN *et al.*, 1995).

Posteriormente, esse método foi adaptado no *Two-Source Time-Integrated Model* (TSTIM), com a inclusão de um componente atmosférico composto por imagens quase instantâneas da temperatura na camada limite da atmosfera (*Planetary Boundary Layer (PBL)*), o que tornou o modelo independente de medidas de temperatura do ar, utilizadas anteriormente como entrada (ANDERSON *et al.*, 1997).

O TSTIM passou a ser denominado como *Atmosphere-Land Exchange Inversion - ALEXI*, quando a metodologia, que inicialmente havia sido aplicada em uma escala na ordem de 100m, foi executada na escala continental, utilizando dados do satélite geoestacionário *Geostationary Environmental Satellite* (GOES-8) (MECIKALSKI *et al.*, 1999). Outras derivações desses modelos foram testadas ao longo do tempo com diferentes finalidades (NORMAN *et al.*, 2000; ANDERSON *et al.*, 2004; YANG & SHANG, 2013).

Apesar dos modelos de duas camadas serem considerados uma evolução dos modelos com uma camada (NORMAN & KUSTAS; HUMES, 1995; YANG & SHANG, 2013), modelos de uma camada são amplamente difundidos, existindo diferentes metodologias que foram sendo desenvolvidas ao longo do tempo como o: *Surface Energy Balance Index* (SEBI) (MENENTI & CHOUDHURY, 1993); o *Surface Energy Balance for Land* (SEBAL) (BASTIAANSSEN *et al.*, 1998a; BASTIAANSSEN *et al.*, 1998b), o *Mapping Evapotranspiration with Internalized Calibration* (METRIC) (ALLEN *et al.*, 2007); e o *Surface Energy Balance System* (SEBS) (SU, 2002).

O SEBAL, por exemplo, foi desenvolvido em 1995 na Holanda (BASTIAANSSEN, 1995), e teve a metodologia e a validação publicada posteriormente em 1998 (BASTIAANSSEN *et al.*, 1998a; BASTIAANSSEN *et al.*, 1998b). Desde a sua criação, o modelo SEBAL já foi aplicado no mundo inteiro, em diferentes condições de uso do solo e clima. Há exemplos de aplicação do modelo SEBAL na China (DU *et al.*, 2013; ZHOU *et al.*, 2014), no Sri Lanka (BASTIAANSSEN & CHANDRAPALA, 2003), no Gana (HENDRICKX *et al.*, 2006), na Turquia (BASTIAANSSEN, 2000), e nos Estados Unidos (TASUMI *et al.*, 2005), ou seja, em todos os continentes: na Ásia, África, Europa e América. No Brasil, também há exemplos de estudos que utilizaram o modelo SEBAL para estimar a evapotranspiração (BASTIAANSSEN *et al.*, 2001; TEIXEIRA *et al.*, 2009; LIMA *et al.*, 2014).

O SEBAL é capaz de ser utilizado em problemas de irrigação e relacionado à gestão dos recursos hídricos, auxiliando no estabelecimento: de relações entre uso do solo e uso da água

para o planejamento de bacias hidrográficas; de modelos hidrológicos; do desempenho da irrigação; de condições de monitoramento da degradação da vegetação nativa, entre outros (BASTIAANSSEN *et al.*, 2005).

Assim como o SEBAL, o METRIC também foi amplamente utilizado nos últimos anos no Brasil e no mundo (SCHERER-WARREN, 2011; TREZZA *et al.*, 2013; SINGH & SENAY, 2015; CARRILLO-ROJAS *et al.*, 2016; KILIC *et al.*, 2016). O METRIC utiliza os princípios e técnicas propostas no SEBAL, em uma metodologia que utiliza calibração interna para mapear a ET_r em alta resolução espacial, diferenciando-se, principalmente, na abordagem empregada para definir o balanço energético nos pixels âncoras (ALLEN *et al.*, 2007). Outro ponto que diferencia o METRIC do SEBAL consiste na abordagem utilizada para determinar a fração evaporativa utilizada para transformar o fluxo de calor latente em ET diária (GOWDA *et al.*, 2008).

A principal diferença entre os métodos SEBI, SEBAL, METRIC, e SEBS consiste no modo em que o fluxo de calor sensível é estimado, entretanto, todos esses algoritmos utilizam pixels âncoras para definir nas imagens o contraste de LST entre uma superfície seca e outra úmida (GOWDA *et al.*, 2008). Independente do método utilizado para estabelecer a referência fria e quente, o limiar seco representa a condição em que a LST é máxima ocorrendo baixas taxas, ou até mesmo, ausência de ET_r, enquanto o limiar úmido representa o inverso: LST mínimo com alta/máxima taxa de ET_r (LI *et al.*, 2009).

Com isso, identificam-se na imagem de satélite duas situações que são utilizadas como referência: uma com fluxo de calor sensível máximo associado a um fluxo de calor latente mínimo; e a outra com a situação inversa, em que o calor sensível é mínimo e o fluxo de calor latente é máximo (BASTIAANSSEN *et al.*, 1998a; ALLEN *et al.*, 2007). Essa é uma metodologia interessante, pois fixa os possíveis valores de ET_r calculados em um intervalo do histograma existente na imagem. No entanto, os resultados encontrados variam de acordo com o usuário, incorporando incertezas ao processo (MORTON *et al.*, 2013).

A inexistência de áreas irrigadas nas imagens pode subestimar o intervalo potencial de LST, acarretando erros na espacialização da ET_r (GOWDA *et al.*, 2008). Além disso, as estimativas da fração evaporativa são sensíveis aos *end-members* selecionados na imagem para representar os pixels âncoras, sendo outra dificuldade no emprego desse tipo de técnica (LONG & SINGH, 2013).

Os algoritmos também podem ser divididos nos seguintes grupos: aqueles que utilizam o balanço de energia; os que usam índices de vegetação e suas derivações; e os algoritmos que utilizam diagramas triangulares/trapezoidais entre a temperatura na superfície e o índice de vegetação para inferir o valor relativo de ET_r (KARIMI & BASTIAANSSEN, 2015).

A ideia de se associar um fator de cultura a uma taxa de ET potencial foi evoluindo ao longo do tempo, sendo bastante estudada no século passado. A predição da ET_r sem o conhecimento completo do balanço de energia requer a inclusão de um fator que seja associado à planta para reduzir a ET potencial para a ET_r , ao longo das etapas de crescimento das plantas (RITCHIE & BURNETT, 1970). A ET potencial associa dados climáticos e a radiação solar para definir as condições ambientais que são externas ao processo de ET, e, por isso, o coeficiente de cultura é utilizado para ajustar a situação potencial para a taxa real (ET_r) da cultura agrícola avaliada (SEEVERS & OTTMANN, 1994).

O Índice de Área Foliar (IAF) foi uma das variáveis inicialmente utilizadas como fator de cultura (STERN, 1965; RITCHIE & BURNETT, 1970). O estabelecimento de relações entre o comportamento espectral da vegetação com variáveis biofísicas, como o IAF (TUCKER, 1979; WEISER *et al.*, 1986; LEPRIEUR, 1989), fez com que diferentes estudos buscassem estabelecer o Índice de Vegetação por Diferença Normalizada, *Normalized Difference Vegetation Index* (NDVI) (ROUSE *et al.*, 1973) como um fator de cultura para estimar a ET_r ao longo do tempo (CHOUDHURY *et al.*, 1994; SEEVERS & OTTMANN, 1994; GLENN *et al.*, 2011; KAMBLE *et al.*, 2013; AKDIM *et al.*, 2014; ADAMALA *et al.*, 2016).

Com a publicação do FAO *Irrigation and Drainage Paper n°56: Crop Evapotranspiration*, que sugeriu uma metodologia padrão para estimar a ET_r (ALLEN *et al.*, 1998), houve o interesse em integrar essa metodologia com dados obtidos por sensoriamento remoto. O método calcula a ET_r a partir da combinação: (i) de um fator de cultura (k_c); (ii) com a Evapotranspiração de referência (ET_o) calculada pelo método Penman-Monteith; (iii) podendo utilizar um fator para representar o déficit hídrico para refletir a condição de umidade do solo (k_s); (iv) tanto em uma abordagem *single crop* quanto *dual crop* para determinação do fator de cultura (ALLEN *et al.*, 1998). Ao longo do tempo, estudos buscaram adaptar esse método substituindo o fator de cultura pelo índice de vegetação (DUCHEMIN *et al.*, 2006; GONZALEZ-DUGO *et al.*, 2009; ER-RAKI *et al.*, 2010; AKDIM *et al.*, 2014).

As estimativas da ET_r pelo método FAO-56 podem ser utilizadas para validar os resultados obtidos com os algoritmos que utilizam dados de sensoriamento remoto (AKDIM *et al.*, 2014). A validação dos resultados também é feita tanto ao nível de bacia hidrográfica, utilizando o balanço hídrico (BASTIAANSSEN & CHANDRAPALA, 2003; MOHAMED *et al.*, 2004; SENAY *et al.*, 2016), quanto com dados obtidos em *in situ* por lisímetros (SENAY, *et al.*, 2014) ou pelos métodos da razão de Bowen e correlação turbulenta a partir de estações agrometeorológicas (TEIXEIRA *et al.*, 2009; ZHOU *et al.*, 2014).

Por fim, vale mencionar a respeito do *Simplified Surface Energy Balance Approach* (SSEBop) por ser uma metodologia mais recente que buscou simplificar a aplicação do processo, integrando os princípios dos métodos discutidos anteriormente (SENAY *et al.*, 2007; SENAY *et al.*, 2013). O SSEBop não calcula explicitamente o fluxo de calor sensível por meio da metodologia de Monin-Obukov, conforme é feito no METRIC, SEBAL e SEBS, no entanto, o algoritmo utiliza uma variação de temperatura predefinida em situações extremas o que não reduz a performance do modelo (SINGH & SENAY, 2015).

Assim como os demais métodos, o SSEBop também foi validado por meio de medidas *in situ* feitas por lisímetros (SENAY *et al.*, 2014), por estações agroclimatológicas (SINGH, *et al.*, 2013), e com o método do balanço hídrico (SENAY *et al.*, 2016) demonstrando o seu potencial. Em estudo comparativo do SSEBop, com o METRIC, o SEBAL e o SEBS, ficou demonstrado que a complexidade do modelo não significa que o modelo terá um desempenho melhor, uma vez que os resultados do SSEBop foram similares ao encontrado com o METRIC (o mais complexo dos quatro métodos), e melhor do que os demais (SINGH & SENAY, 2015).

O SSEBop se mostrou capaz de gerar mapa de uso de água mensal e anual (SINGH *et al.*, 2013). O emprego do SSEBop com dados provenientes de técnicas de desagregação espacial de imagens, para melhorar, por exemplo, a resolução do MODIS a partir de imagens LandSat, também foram testadas com sucesso (SINGH *et al.*, 2014). Também ficou demonstrada a aplicabilidade do SSEBop em estudos para estimar o uso de água anual com a nova geração de dados do LandSat8 (SENAY *et al.*, 2016).

Até o momento foram descritos métodos desenvolvidos ao longo dos últimos 50 anos para estimar a ET_r utilizando dados obtidos por sensoriamento remoto. De modo geral, o conhecimento científico relacionado ao uso do sensoriamento para estimar a ET_r envolve: (i) a proposição e validação dos algoritmos em diferentes regiões do mundo (JACKSON *et al.*, 1977; MENENTI & CHOUDHURY, 1993; NORMAN *et al.*, 1995; BASTIAANSSEN *et al.*, 1998a; SU, 2002; ALLEN *et al.*, 2007; SENAY *et al.*, 2007; SENAY *et al.*, 2013); a (ii) integração entre metodologias (ANDERSON *et al.*, 2004; SINGH & IRMAK, 2011; YANG & SHANG, 2013; BISQUERT *et al.*, 2016); e (iii) aplicação em problemas hidrológicos, meteorológicos e agronômicos (AKDIM *et al.*, 2014; SEMMENS *et al.*, 2015; CARRILLO-ROJAS *et al.*, 2016; WEBSTER *et al.*, 2016).

Os estudos também comparam e avaliam os diferentes satélites e as gerações de produtos na medida em que as plataformas orbitais vão se sucedendo (TREZZA *et al.*, 2013; KILIC *et al.*, 2016; SENAY *et al.*, 2016).

3.2. A precipitação estimada por sensoriamento remoto

Desde o lançamento do primeiro satélite meteorológico em 1960 (*Television InfraRed Observational Satellite* (TIROS 1)), muitos sensores foram desenvolvidos para observar a atmosfera terrestre, os quais podem ser classificados em duas categorias principais: os sensores que coletam dados na região do visível (VIS) e do infravermelho (IR), disponível em satélites geoestacionários (GEO) e em satélites de baixa órbita, *Low Earth Orbiting* (LEO); e os sensores passivos de micro-ondas, *Passive Microwave* (PMW) a bordo de satélites do tipo LEO (GRUBER & LEVIZZANI, 2008).

Apesar de sensores em plataformas orbitais não conseguirem medir diretamente a P que atinge a superfície, eles conseguem mensurar outras variáveis que podem ser altamente correlacionadas com a chuva (EBERT *et al.*, 1996). As estimativas de precipitação derivadas por dados na região do VIS/IR dependem principalmente das características no topo das nuvens, sendo que o dado coletado no VIS pode ser utilizado para inferir a espessura da nuvem e a sua altitude, enquanto o dado de temperatura emitida no IR é utilizado para mensurar a temperatura no topo das nuvens. (GRUBER & LEVIZZANI, 2008).

Historicamente, os sensores passivos de micro-ondas (PMW) foram a principal fonte de estimativas de P proveniente de satélites, o que será mantido nos próximos anos (HUFFMAN *et al.*, 2015). Os dados de sensores PMW provenientes de satélites LEO, como, por exemplo, o *Microwave Imager* (TMI) a bordo do satélite da *Tropical Rainfall Measuring Mission* (TRMM) ou o *Advanced Microwave Scanning Radiometer-Earth Observing System* (AMSR-E) a bordo do *Aqua*, possuem uma boa relação física entre os hidrometeoros que resultam em P na superfície (HUFFAMAN *et al.*, 2007).

Os algoritmos que processam dados de PMW na superfície terrestre comumente estimam a chuva a partir do espalhamento da radiação de micro-ondas de alta frequência, e.g. 85.5 GHz, enquanto nos oceanos utilizam-se frequências mais baixas, entre 10-30GHz, pois a detecção da P sobre a superfície terrestre é complexa, em virtude da alta variabilidade espaço-temporal e da alta magnitude de emissividade associada à vegetação e ao solo ($\epsilon \sim 0.9$), quando comparada a baixa e quase que uniforme emissividade dos oceanos ($\epsilon \sim 0.4 - 0.5$), na qual aproveita-se o contraste entre a superfície e os pingos de chuva para se estimar a P (OLIVEIRA *et al.*, 2016).

Apesar dos sensores PMW apresentarem melhores correlações com a precipitação do que os sensores no VIS/IR (EBERT *et al.*, 1996), a cobertura espacial e temporal de satélites LEO é um fator limitante para sua aplicação (HUFFAMAN *et al.*, 2007; GRUBER & LEVIZZANI, 2008). Os sensores no VIS/IR a bordo de satélites GEO conseguem superar esta limitação, uma vez que

podem fornecer dados globais a cada 15 minutos (HOU *et al.*, 2014), apesar das estimativas não serem tão precisas (TANG *et al.*, 2016).

Assim, enquanto os sensores de IR a bordo de satélites geoestacionários conseguem, a partir de derivações de informações provenientes do topo das nuvens, fornecer estimativas de P em alta resolução temporal, e.g. a cada 15 minutos em algumas plataformas, os sensores micro-ondas ainda são utilizados para mensurar a P em virtude da boa relação entre o tamanho das partículas de chuvas e o comprimento de ondas utilizado (HOU *et al.*, 2014).

A boa capacidade de satélites meteorológicos fornecerem dados teve como consequência o desenvolvimento de muitos algoritmos para estimar P por sensoriamento remoto ao longo do tempo (EBERT *et al.*, 1996). A maior parte dos métodos utilizavam a noção que nuvens convectivas podem produzir mais chuvas e que a P tende a ser correlacionada com nuvens claras (VIS) e frias (IR) (RICHARDS & ARKIN, 1981). Segundo Ebert e colaboradores (1996), os primeiros algoritmos desenvolvidos para estimar a P por sensoriamento remoto utilizavam dados obtidos no IR e no VIS provenientes de satélites LEO (e.g. BARRETT, 1970) no entanto, rapidamente também surgiram métodos capazes de processar os dados de satélites GEO (e.g. GRIFFITH *et al.*, 1978; RICHARDS & ARKIN, 1981).

Nos últimos anos, muitas pesquisas foram conduzidas visando o desenvolvimento de algoritmos para integrar os dados obtidos por sensores PMW e VIS/IR (GRUBER & LEVIZZANI, 2008). Desde o lançamento do satélite da missão TRMM em 1997, foram desenvolvidos algoritmos que combinam dados de IR e de PMW em diferentes níveis, como: o *Climate Prediction Center Morphing Technique* (CMORPH) (JOYCE *et al.*, 2004); o *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks* (PERSIANN) (HSU *et al.*, 1997; SOROOSHIAN *et al.*, 2000; HONG *et al.*, 2004); o *Global Satellite Mapping of Precipitation* (GsMap) (OKAMOTO & USHIO, 2005; KUBOTA *et al.*, 2007; USHIO *et al.*, 2009); e o *TRMM Multi-satellite Precipitation Analysis* (TMPA) (HUFFAMAN *et al.*, 2007).

A missão TRMM foi desenvolvida pela *National Aeronautics and Space Administration* (NASA) e pela *Japan Aerospace Exploration Agency* (JAXA), operando entre novembro 1997 a abril de 2015, e foi importante marco na história do sensoriamento remoto aplicado no monitoramento da P, pois colocou em órbita o primeiro radar meteorológico ativo, denominado *Precipitation Radar* (PR), além de outros quatro sensores de alta tecnologia: o *Microwave Imager* (TMI); o *Visible Infrared scanner* (VIRS); o *Lightning Imaging Sensor* (LIS); e o *Clouds and the Earth's Radiant Energy System* (CERES) (TRMM, 2017).

Dezesete anos após o seu lançamento, a missão TRMM chegou ao fim sendo substituída pela missão GPM. Construído com base no sucesso do TRMM, o GPM *Core Observatory* entrou em órbita em Fevereiro de 2014 (HOU *et al.*, 2014). O projeto GPM é liderado pelos Estados Unidos e pelo Japão com cooperação internacional da França, Índia, China e da União Europeia (USHIO *et al.*, 2009).

Existem três principais evoluções no GPM: (i) aumento na inclinação da órbita de 35° para 65°, permitindo um aumento na cobertura escaneada; (ii) inclusão de radar de duas frequências, com a finalidade de detectar melhor precipitações mais leves; (iii) e inclusão de canais de alta frequência (165,5 e 183,3 GHz) que foram adicionados ao sensor de PMW, com a expectativa de facilitar o sensoriamento de precipitação leve e sólida (HUFFMAN *et al.*, 2015).

O algoritmo *Integrated multi-satellite retrievals for GPM* (IMERG) foi desenvolvido pela NASA para unir, calibrar e interpolar dados provenientes de diversos sensores PMW e IR em órbita terrestre (HUFFMAN *et al.*, 2015). GsMap é o projeto japonês correspondente para o processamento de dados na missão GPM (HUFFMAN *et al.*, 2015^b).

Desde que os dados GPM começaram a serem disponibilizados, muitos estudos avaliaram os produtos na Ásia, África, Europa, América do Norte e na América do Sul. Muitos estudos buscaram comparar os produtos do GPM (IMERG e GsMap) com produtos provenientes do TRMM (TMPA), em períodos com sobreposição de dados, e os resultados encontrados variaram. Muitos detectaram melhores resultados com o IMERG e o GsMap (SHARIFI *et al.*, 2016; KIM *et al.*, 2017; XU *et al.*, 2017; CHEN & LI, 2016; WANG *et al.*, 2017), todavia, em alguns casos o TMPA apresentou resultados similares (SAHLU *et al.*, 2016; TAN & DUAN, 2017) ou até mesmo melhores em alguns cenários (YUAN *et al.*, 2017; SATGÉ *et al.*, 2017).

O GPM *Microwave Imager* (GMI) e o *Dual-frequency Precipitation Radar* (DPR) abordos do satélite GPM melhoraram a capacidade de detecção de eventos de chuva de baixa intensidade quando comparados com o TRMM *Microwave Imager* (TMI) e o *Precipitation Radar* (PR), abordos do satélite TRMM (KIM *et al.*, 2017). Todavia, fatores topográficos podem influenciar negativamente no desempenho de produtos de P obtidos por sensoriamento remoto, como o IMERG ou o TMPA (KIM *et al.*, 2017).

A resolução espacial é outro fator que limita o registro da P por sensoriamento remoto, principalmente aquelas que ocorrem em áreas menores e que possuem menor intensidade (SHARIFI *et al.*, 2016). Apesar do IMERG ainda necessitar de melhorias em regiões de maiores latitudes, altitudes, ou em áreas secas (YUAN *et al.*, 2017), foi possível encontrar estudos que registraram melhorias nos resultados dos produtos da era GPM (SHARIFI *et al.*, 2016; KIM *et al.*, 2017; SATGÉ *et al.*, 2017).

Estudos de validação dos produtos de sensoriamento remoto que estimam P são recomendados para identificar informações relevantes sobre a qualidade, as limitações e as incertezas que são associadas ao produto (OLIVEIRA *et al.*, 2016). Apesar de ser possível encontrar estudos que obtiveram bons resultados de validação dos produtos de P estimados por sensoriamento remoto, a necessidade de uma avaliação criteriosa também já foi reportada (KARIMI & BASTIAANSSEN, 2015). As incertezas nas estimativas de P por meio de sensoriamento remoto podem, por exemplo, ser decorrentes das limitações nas resoluções espacial e temporal utilizadas para coletar o dado (HONG *et al.*, 2006).

O erro associado ao produto de sensoriamento remoto que estimam P depende da região estudada, do tipo e da magnitude da P, o que torna a avaliação desses produtos relevante para compreender o contexto adequado para utilizá-los, assim como é um processo relevante para os desenvolvedores dos algoritmos (SAHLU *et al.*, 2016). Os produtos de sensoriamento remoto que estimam a P geralmente apresentam um erro absoluto com maior variabilidade (e.g. 0 to 65%), quando comparado com o erro obtido quando se estima a ET_r (e.g. 0 to 20%) com sensoriamento remoto (KARIMI & BASTIAANSSEN, 2015).

A avaliação das diferenças entre os produtos derivados do GPM, como o IMERG e/ou GsMap, com o TRMM, nesse contexto, se torna relevante para permitir que os pesquisadores e outros usuários desses produtos possam fazer ajustes necessários para as suas pesquisas e aplicações (LIU, 2015).

3.3. Integração do modelo hidrológico com sensoriamento remoto

O interesse em utilizar dados de sensoriamento remoto como entrada em modelos hidrológicos foi um objetivo a ser atingido, na medida em que as pesquisas foram avançando e tornando as metodologias operacionais (RANGO, 1994; MCLAUGHLIN, 1994). Atualmente são encontrados estudos que utilizaram diferentes dados de sensoriamento remoto como entrada em modelos hidrológicos para estimar, entre outros, vazões, escoamento superficial e recarga subterrânea (QIN *et al.*, 2008; STRAUCH *et al.*, 2012; SIMONS *et al.*, 2016; POORTINGA *et al.*, 2017; COELHO *et al.*, 2017).

O avanço das geotecnologias nos últimos 20 anos também permitiu a evolução de modelos que realizam simulação hidrológica. O modelo SWAT foi desenvolvido pelo *Agricultural Research Service* norte-americano (ARS/USDA), sendo um modelo conceitual que opera em passos diários (ARNOLD *et al.*, 1998).

O modelo simula os fenômenos físicos do ciclo hidrológico existentes em uma bacia hidrográfica associados ao uso do solo, como o escoamento superficial e subterrâneo, produção

de sedimentos e qualidade da água (SRINIVASAN & ARNOLD, 1994). O objetivo com o desenvolvimento do modelo SWAT foi prever o impacto do manejo do uso do solo nos recursos hídricos, na produção de sedimentos em bacias não monitoradas (ARNOLD *et al.*, 1998).

O modelo foi integrado com o Sistema de Informações Geográficas para facilmente extrair os dados de entrada para modelar bacias hidrográficas, distribuir espacialmente os parâmetros para permitir simulações contínuas em um intervalo de tempo, em nível de grandes bacias hidrográficas (SRINIVASAN & ARNOLD, 1994).

O SWAT é um modelo conceitual complexo com parametrização espacialmente distribuída (ARNOLD *et al.*, 2000). Na prática, não existem modelos totalmente distribuídos, pois sempre são feitas discretizações, de forma que o modelo distribuído se torna concentrado em uma pequena sub-divisão (TUCCI, 1998).

O modelo já foi utilizado no mundo inteiro, em diferentes condições de uso do solo e clima. Entre os diversos estudos com o modelo SWAT, podemos citar exemplos de aplicação desse modelo na China (LI, *et al.*, 2009), nos Estados Unidos (ARNOLD *et al.*, 2000), no Benim (BOSSA *et al.*, 2012), na Alemanha (JULICH *et al.*, 2012) ou seja, na Ásia, América, África e Europa.

No Brasil, também há diversos estudos que utilizaram o modelo SWAT. Em uma revisão da aplicação do modelo SWAT no Brasil, Bressiani *et al.* (2015) identificou mais de 100 estudos no período entre 1999 e 2015. No Bioma Cerrado, alguns estudos foram conduzidos nos últimos anos (e.g. SARMENTO, 2010; STRAUCH *et al.*, 2012; STRAUCH; VOLK, 2013; STRAUCH *et al.*, 2013; FERRIGO, 2014; SALLES *et al.*, 2015; CASTRO *et al.*, 2016; TÁVORA, 2017; ARAÚJO, 2018).

Apesar do grande número de estudos realizados no Brasil com o modelo SWAT, ainda há muitos desafios para serem superados, principalmente no que concerne à melhoria da base física do modelo, ou seja, representações realísticas capazes de contemplar os processos hidrológicos que ocorrem em regiões tropicais.

Mesmo com os resultados satisfatórios obtidos com o modelo SWAT no Brasil, o processo de calibração pode esconder problemas significantes, como a representação inadequada das características da vegetação e de culturas agrícolas, bem como a representação inadequada proveniente de outros dados de entrada (BRESSIANI *et al.*, 2015). A aquisição das variáveis de entrada, a estrutura do modelo (equações e simplificações utilizadas para representar o sistema), e a estimativa dos parâmetros estão entre as principais fontes de incertezas envolvidas em estudos hidrológicos (TUCCI, 1998).

Algumas iniciativas já foram feitas para melhorar a base física das simulações hidrológicas em regiões de clima tropical. Strauch e colaboradores (2012) avaliaram as incertezas nas simulações de vazões decorrentes do uso de diferentes dados de P e concluíram que, apesar de o uso de dados pontuais coletados dentro da bacia hidrográfica estudada fornecer resultados satisfatórios, a integração desses dados com dados distribuídos espacialmente reduz as incertezas nos *outputs*, sendo uma opção para melhorar a modelagem.

Strauch & Volk (2013) propuseram alteração do código do SWAT com uma função logística de declínio do Índice de Área Foliar, para melhorar a representação da senescência das folhas da vegetação nativa de regiões tropicais na modelagem. Também foi proposta uma base de dados de solos para a aplicação do modelo SWAT em bacias hidrográficas do Bioma Cerrado, visando melhorar a base física do modelo na representação das propriedades físicas dos solos de regiões tropicais (LIMA *et al.*, 2013).

No que concerne à integração dos resultados de metodologias que estimam a ET_r com base em dados de sensoriamento remotos com o modelo SWAT, para melhorar as estimativas de evapotranspiração na modelagem hidrológica, temos o estudo de Franco & Bonumá (2017) que foi realizado no Brasil. Nesse estudo utilizaram-se séries temporais de ET_r por sensoriamento remoto obtidas com o METRIC na calibração do modelo SWAT para avaliar as incertezas e o desempenho na simulação de ET e Q. Também há alguns exemplos desse tipo de estudo no mundo (IMMERZEELE *et al.*, 2008; GAO & LONG, 2008; GITHUI *et al.*, 2012; AWAN & ISMAEEL, 2014), principalmente como fonte de informação para a calibração do modelo SWAT.

O uso de metodologias que estimam a ET_r com dados obtidos por sensoriamento remoto pode contribuir para a redução de incertezas em modelos hidrológicos distribuídos que empregam metodologias tradicionais para o cálculo da ET_r (BASTIAANSSEN *et al.*, 2010). No entanto, a integração dessas estimativas em modelos hidrológicos ainda é um desafio para a comunidade científica sendo, muitas vezes, subutilizada (KARIMI & BASTIAANSSEN, 2015).

O entendimento da distribuição espacial e temporal da P é relevante para o manejo dos recursos hídricos em bacias hidrográficas entre 100km² e 100.000km², quando utiliza-se como entrada a integração da chuva de horas a dias (HONG *et al.*, 2006). Apesar da quantidade de estudos, o desempenho dos produtos de satélites que estimam a precipitação pode ser insatisfatório e requer cuidado quando aplicados para modelagem hidrológica e para gestão da água (KARIMI & BASTIAANSSEN, 2015).

Os processos necessários para derivar P a partir de dados de sensoriamento remoto são mais complexos do que para estimar a ET (KARIMI & BASTIAANSSEN, 2015). Na medida em que

as estimativas de P obtidas por sensoriamento remoto são utilizadas em avaliações hidrológicas, em várias escalas espaciais e temporais, as estimativas do erro e de como ele se propaga nos modelos precisam ser avaliadas como um todo de modo que os usuários tenham confiança para a tomada de decisão (HONG *et al.*, 2006).

Com isso, o desempenho dos produtos de precipitação estimados por sensoriamento remoto não é satisfatório e requer atenção quando aplicado para a modelagem hidrológica e para o gerenciamento de recursos hídricos (KARIMI & BASTIAANSSEN, 2015).

A avaliação do erro associado aos produtos de P estimados por sensoriamento remoto e a sua propagação em modelos é um elemento indispensável para se analisar a qualidade do dado e para melhorar as técnicas de simulação hidrológica (HONG *et al.*, 2006).

Referências

- Adamala, S.; Rajwade, Y. A.; Reddy, Y. V. K. Estimation of wheat crop evapotranspiration using NDVI vegetation index. *Journal of Applied and Natural Science*, 8, 1, 159–166, 2016. Doi: <https://doi.org/10.31018/jans.v8i1.767>
- Akdim, N.; Alfieri S. M.; Habib, A.; Choukri, A.; Cheruiyot, E.; Labbassi, K.; Menenti, M. Monitoring of Irrigation Schemes by Remote Sensing: Phenology versus Retrieval of Biophysical Variables. *Remote Sensing*, 6, 5815-5851, 2014. Doi: <https://doi.org/10.3390/rs6065815>
- Allen, R. G.; Pereira, L. S.; Raes, D.; Smith, M. Crop evapotranspiration: guidelines for computing crop water requirements. In: *Irrigation and Drainage Paper 56*, FAO, Rome, Italy, 1998.
- Allen, R. G.; Tasumi, M.; Trezza, R. Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC) – Model. *Journal of Irrigation and Drainage Engineering*, 133, 380–394, 2007. Doi: [https://doi.org/10.1061/\(ASCE\)0733-9437\(2007\)133:4\(380\).](https://doi.org/10.1061/(ASCE)0733-9437(2007)133:4(380).)
- Anderson, M. C.; Norman, J. M.; Mecikalski, J. R.; Torn R. D.; Kustas, W. P.; Basara, J. B. A Multiscale Remote Sensing Model for Disaggregating Regional Fluxes to Micrometeorological Scales. *Journal of Hydrometeorology*, 5, 343-363, 2004. Doi: [https://doi.org/10.1175/1525-7541\(2004\)005<0343:AMRSMF>2.0.CO;2](https://doi.org/10.1175/1525-7541(2004)005<0343:AMRSMF>2.0.CO;2)
- Anderson, M. C.; Norman, J. M.; Diak, J.M.; Kustas, W. P.; Mecikalski, J. R. A Two-Source Time-Integrated Model for Estimating Surface Fluxes Using Thermal Infrared Remote Sensing. *Remote sensing of Environment*, 60, 195-216. Doi: [https://doi.org/10.1016/S0034-4257\(96\)00215-5](https://doi.org/10.1016/S0034-4257(96)00215-5)
- Araújo, D. L. Avaliação dos impactos da exploração de águas subterrâneas na bacia do Ribeirão Rodeador por meio de simulação integrada entre os modelos SWAT e MODFLOW. Dissertação de Mestrado em Tecnologia Ambiental e Recursos Hídricos, Publicação PTARH. DM 213/2018,

Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 186p. 2018.

Arnold, J. G.; Muttiah, R.S.; Srinivasan, R.; Allen, P. M. Regional estimation of base flow and groundwater recharge in the Upper Mississippi river basin. *Journal of Hydrology*, 227, 1, 21–40, 2000. Doi: [https://doi.org/10.1016/S0022-1694\(99\)00139-0](https://doi.org/10.1016/S0022-1694(99)00139-0)

Arnold, J. G.; Srinivasan, R.; Muttiah, R.S.; Williams, J. R. Large area hydrologic modeling and assessment part I: model development. *Journal of the American Water Resources Association*, 34, 1, 73–89, 1998. Doi: <https://doi.org/10.1111/j.1752-1688.1998.tb05961.x>

Awan, U. K. ; Ismaeel, A. A new technique to map groundwater recharge in irrigated areas using a SWAT model under changing climate. *Journal of Hydrology*, 519, 1368-1382. Doi: <http://dx.doi.org/10.1016/j.jhydrol.2014.08.049>

Barrett, E. C. The estimation of monthly rainfall from satellite data. *Monthly Weather Review*, 98, 4, 322–327, 1970. Doi: [https://doi.org/10.1175/1520-0493\(1970\)098<0322:TEOMRF>2.3.CO;2](https://doi.org/10.1175/1520-0493(1970)098<0322:TEOMRF>2.3.CO;2)

Bastiaanssen, W. G. M.; Thoreson, B.; Clark, B.; Davids, G. Discussion of “Application of SEBAL Model for Mapping Evapotranspiration and Estimating Surface Energy Fluxes in South-Central Nebraska” by Ramesh K. Singh, Ayse Irmak, Suat Irmak, and Derrel L. Martin. *Journal of Irrigation and Drainage Engineering*, 136, 4, 282–283, 2010. Doi: [https://doi.org/10.1061/\(ASCE\)0733-9437\(2008\)134:3\(273\)](https://doi.org/10.1061/(ASCE)0733-9437(2008)134:3(273))

Bastiaanssen, W. G. M.; Chandrapala, L. Water balance variability across Sri Lanka for assessing agricultural and environmental water use. *Agricultural Water Management*, 58, 171–192, 2003. Doi: [https://doi.org/10.1016/S0378-3774\(02\)00128-2](https://doi.org/10.1016/S0378-3774(02)00128-2)

Bastiaanssen, W. G. M.; Brito, R. A. L.; Bos, M. G.; Souza, R. A., Cavalcanti, E. B.; Bakker, M. M. Low cost satellite data for monthly irrigation performance monitoring: Benchmarks from Nilo Coelho, Brazil. *Irrigation and Drainage Systems*, 15, 1, 53–79, 2001. Doi: <https://doi.org/10.1023/A:1017967021198>

Bastiaanssen, W. G. M. Regionalization of surface flux densities and moisture indicators in composite terrain: a remote sensing approach under clear skies in Mediterranean climates. Doctoral thesis. Wageningen Agricultural University, Wageningen, The Netherlands, 273p., 1995.

S Bastiaanssen, W. G. M. SEBAL-based sensible and latent heat fluxes in the irrigated Gediz Basin, Turkey. *Journal of Hydrology*, 229, 87-100, 2000. Doi: [https://doi.org/10.1016/S0022-1694\(99\)00202-4](https://doi.org/10.1016/S0022-1694(99)00202-4)

Bastiaanssen, W. G. M.; Noordman, E. J. M.; Pelgrum, H.; Davids, G.; Thoreson, B. P.; Allen, R. G. SEBAL Model with Remotely Sensed Data to Improve Water-Resources Management under Actual Field Conditions. *Journal of Irrigation and Drainage Engineering*, 131, 85-93, 2005. Doi: [https://doi.org/10.1061/\(ASCE\)0733-9437\(2005\)131:1\(85\)](https://doi.org/10.1061/(ASCE)0733-9437(2005)131:1(85))

Bastiaanssen, W. G. M.; Menenti, M.; Feddes, R.; Holtslag, A. A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. *Journal of Hydrology*, 212, 198–212,

1998a. Doi: [https://doi.org/10.1016/S0022-1694\(98\)00253-4](https://doi.org/10.1016/S0022-1694(98)00253-4)

Bastiaanssen, W. G. M.; Pelgruma, H.; Wang, J.; Ma, Y.; Moreno, J. F.; Roerink, G. J.; van der Wal, T. A remote sensing surface energy balance algorithm for land (SEBAL). 2. Validation. *Journal of Hydrology*, 212–213, 213–229, 1998. Doi: [https://doi.org/10.1016/S0022-1694\(98\)00254-6](https://doi.org/10.1016/S0022-1694(98)00254-6)

Berger, M.; Moreno, J.; Johannessen J. A.; Levelt, P. F.; Hanssen, R. F. ESA's sentinel missions in support of Earth system science. *Remote Sensing of Environment*, 120, 84–90, 2012. Doi: <https://doi.org/10.1016/j.rse.2011.07.023>

Bisquert, M.; Sánchez, J. M.; López-Urrea, R.; Caselles, V. Estimating high resolution evapotranspiration from disaggregated thermal images. *Remote Sensing of Environment*, 187, 423-433, 2016. Doi: <http://dx.doi.org/10.1016/j.rse.2016.10.049>

Bossa A. Y.; Diekkrüger, B.; Igué, A. M.; Gaiser, T. Analyzing the effects of different soil databases on modeling of hydrological processes and sediment yield in Benin (West Africa). *Geoderma* 173-174, 61–74, 2012. Doi: <http://dx.doi.org/10.1016/j.geoderma.2012.01.012>

Bowen, I. S. The ratio of heat losses by conduction and by evaporation from any water surface. *Physical Review*, 27, 779–787, 1926.

Brasil. Conjuntura dos recursos hídricos no Brasil 2019: informe anual. Brasília, DF: Agência Nacional de Águas – ANA, 2019. 100p.

Brasil. ANA, Agência Nacional de Águas. Estimativas de evapotranspiração real por sensoriamento remoto no Brasil. Brasilia: ANA, 41p, 2020.

Bressiani, D.A.; Gassman, P.W.; Fernandes, J.G.; Garbossa, L.H.P.; Srinivasan, R.; Bonumá, N.B.; Mendiondo, E.M. A review of soil and water assessment tool (SWAT) applications in Brazil: Challenges and prospects. *International Journal of Agricultural and Biological Engineering*, v. 8, n. 3, p. 1–27, 2015.

Carrillo-Rojas, G.; Silva, B.; Córdova, M.; Céller, R.; Bendix, J. Dynamic Mapping of Evapotranspiration Using an Energy Balance-Based Model over an Andean Páramo Catchment of Southern Ecuador. *Remote Sensing*, 8, 160, 2016. Doi: <https://doi.org/10.3390/rs8020160>

Castro, K.B.; Roig, H.L.; Lima, J.E.F.W.; Ferrigo, S. Aplicação de série temporal mínima para simulação de vazões em bacia experimental do Cerrado. *Revista Brasileira de Cartografia (online)*, v. 68, p. 1497-1513, 2016.

Chen, F.; Li, X. Evaluation of IMERG and TRMM 3B43 monthly precipitation products over mainland China. *Remote Sensing*, 8, 472, 2016. Doi: <https://doi.org/10.3390/rs8060472>

Choudhury, B. J.; Ahmed, N. U.; Idso, S. B.; Reginato, R. J.; Daughtry, C. S. T. Relations between Evaporation Coeflqients and Vegetation Indices Studied by Model Simulations. *Remote Sensing of Environment*, 50, 1, 1–17, 1994. Doi: [https://doi.org/10.1016/0034-4257\(94\)90090-6](https://doi.org/10.1016/0034-4257(94)90090-6)

CODEPLAN, Companhia de Planejamento do Distrito Federal. SAFRA 2012/13: Produção

recorde de grãos no Brasil e na região geoeconômica de Brasília. Brasilia, DF, 2013.

CODEPLAN, Companhia de Planejamento do Distrito Federal. Pesquisa Distrital por Amostra de Domicílios do Distrito Federal – PDADDF – 2015. Brasilia, DF, 2015.

Coelho, V. H. R.; Montenegro, S.; Almeida, C. N. Silva, B. B.; Oliveira, L. M.; Gusmão, A. C. V.; Freitas, E. S.; Montenegro, A. A. A. Alluvial groundwater recharge estimation in semi-arid environment using remotely sensed data *Journal of Hydrology*, 548, 1–15, 2017. Doi: <http://dx.doi.org/10.1016/j.jhydrol.2017.02.054>

Colomina, I.; Molina, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92, 79–97, 2014. Doi: <http://dx.doi.org/10.1016/j.isprsjprs.2014.02.013>

Deng, P.; Zhang, M.; Bing, J.; Jia, J.; Zhang, D. Evaluation of the GSMP_Gauge products using rain gauge observations and SWAT model in the Upper Hanjiang River Basin. *Atmospheric Research* 219, 153–165, 2019. Doi: <https://doi.org/10.1016/j.atmosres.2018.12.032>

Du J.; Song K.; Wang Z.; Zhang B.; Liu D. Evapotranspiration estimation based on MODIS products and surface energy balance algorithms for land (SEBAL) model in Sanjiang Plain, Northeast China. *Chinese Geographical Science*, 23, 1, 73–91, 2013. Doi: <http://dx.doi.org/10.1007/s11769-013-0587-8>

Duchemin B.; Hadria, R.; Erraki, S.; Boulet, G.; Maisongrande, P.; Chehbouni, A.; Escadafal, R.; Ezzahar, J.; Hoedjes, J. C. B.; Kharrou, M. H.; Khabba, S.; Mougenot, B.; Olioso, A.; Rodriguez, J.-C.; Simonneau, V. Monitoring wheat phenology and irrigation in Central Morocco: On the use of relationships between evapotranspiration, crops coefficients, leaf area index and remotely-sensed vegetation indices. *Agricultural Water Management*, 79, 1–27, 2006. Doi: <http://dx.doi.org/10.1016/j.agwat.2005.02.013>

Ebert, E. E.; Manton, M. J.; Arkin, P.A.; Allam, R. J.; Holpin, G. E.; Gruber, A. Results from the GPCP Algorithm Intercomparison Programme. *Bulletin of the American Meteorological Society*, 77, 12, 2875–2887, 1996. Doi: [http://dx.doi.org/10.1175/1520-0477\(1996\)077<2875:RFTGAI>2.0.CO;2](http://dx.doi.org/10.1175/1520-0477(1996)077<2875:RFTGAI>2.0.CO;2)

Egeaa, G.; Padilla-Díaz, C. M.; Martinez-Guantera, J.; Fernández, J. E.; Pérez-Ruiz, M. Assessing a crop water stress index derived from aerial thermal imaging and infrared thermometry in super-high density olive orchards. *Agricultural Water Management* 187, 210–221, 2017. Doi: <http://dx.doi.org/10.1016/j.agwat.2017.03.030>

Er-Raki, S.; Chehbouni, A.; Duchemin, B. Combining satellite remote sensing data with the FAO-56 dual approach for water use mapping in irrigated wheat fields of a semi-arid region. *Remote Sensing*, 2, 375–387, 2010. doi: <http://dx.doi.org/10.3390/rs2010375>

Ferrigo, S. Análise de consistência dos parâmetros do modelo SWAT obtidos por calibração automática – Estudo de caso da bacia do lago Descoberto – DF. Dissertação de Mestrado em Tecnologia Ambiental e Recursos Hídricos, Publicação PTARH.DM-159/14, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 164 p. 2014.

Franco, A.C.L.; Bonumá, N.B. Multi-variable SWAT model calibration with remotely sensed evapotranspiration and observed flow. *Brazilian Journal of Water Resources*, 22(e35), 2017.

GsMap. Global Satellite Mapping of Precipitation (GSMaP) for GPM. Available online: https://www.eorc.jaxa.jp/GPM/doc/algorithm/GSMaPforGPM_20140902_E.pdf (acesso em: 10/07/ 2018).

Gao, Y.; Long, D. Intercomparison of remote sensing-based models for estimation of evapotranspiration and accuracy assessment based on SWAT. *Hydrological Processes*, 22, 4850–4869, 2008. Doi: <http://dx.doi.org/10.1002/hyp.7104>

Githui, F.; Selle, B.; Thayalakumaran, T. Recharge estimation using remotely sensed evapotranspiration in an irrigated catchment in southeast Australia. *Hydrological Processes*, 26, 9, 1379–1389, 2012. Doi: <http://dx.doi.org/10.1002/hyp.8274>

Glenn, E. P.; Neale, C. M. U.; Hunsaker, D. J.; Nagler, P. L. Vegetation index-based crop coefficients to estimate evapotranspiration by remote sensing in agricultural and natural ecosystems. *Hydrological Processes*, 25, 4050-4062, 2011. Doi: <http://dx.doi.org/10.1002/hyp.8392>

Gonzalez-Dugo, M. P.; Neale, C. M. U.; Mateos, L.; Kustas, W. P.; Prueger, J. H.; Anderson, M. C.; Li, F. Agricultural and Forest Meteorology, 149, 1843–1853, 2009. Doi: doi:10.1016/j.agrformet.2009.06.012

Gowda, P. H.; Chavez, J. L.; Colaizzi, P. D.; Evett, S. R.; Howell, T. A.; Tolk, J. A. ET mapping for agricultural water management: present status and challenges. *Irrigation Science*, 26, 2008, 223–237. Doi: <http://dx.doi.org/10.1007/s00271-007-0088-6>

Griffith, C. G.; Woodley, W. L.; Grube, P. G.; Martin, D. W.; Stout, J.; Sikdar, D. N. Rain Estimation from Geosynchronous Satellite Imagery: Visible and Infrared Studies. *Monthly Weather Review*, 106, 1153–1171, 1978.

Gruber, A.; Levizzani, V. Assessment of Global Precipitation Products. *World Climate Research Programme – WCRP Report*, 128, 2008

Hendrickx, J. M. H.; Hong, S.-H.; Friesen, J.; Compaore, H.; Giesen, N. C. van de; Rodgers, C.; Vlek, P. L. G. Mapping energy balance fluxes and root zone soil moisture in the White Volta Basin using optical imagery. *Targets and Backgrounds XII: Characterization and Representation*, 6239, 2010. Doi: <http://dx.doi.org/10.11117/12.665235>

Hong, Y.; Hsu, K.-L.; Sorooshian, S.; Gao, X. Precipitation Estimation from Remotely Sensed Imagery Using an Artificial Neural Network Cloud Classification System. *Journal of Applied Meteorology*, v. 43, p. 1834–1852, 2004. Doi: <https://doi.org/10.1175/JAM2173.1>

Hong, Y.; Hsu, K.-L.; Moradkhani, H.; Sorooshian, S. Uncertainty quantification of satellite precipitation estimation and Monte Carlo assessment of the error propagation into hydrologic response. *Water Resources Research*, 42, W08421, 2006. Doi: <https://doi.org/10.1029/2005WR004398>

Hou, A.R.; Kakar, R.K.; Neeck, S.; Azarbarzin, A.A.; Kummerow, C.D.; Kojima, M.; Oki, R.; Nakamura, K.; Iguchi, T. The global precipitation measurement mission. *Bulletin of the*

American Meteorological Society, 95, 701–722, 2014. Doi: <https://doi.org/10.1175/BAMS-D-13-00164.1>

Hsu, K.L.; Gao, X.; Sorooshian, S.; Gupta, H. V. Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks. *Journal of Applied Meteorology*, v. 36, p. 1176–1190, 1997.

Huete, A. R. A Soil-Adjusted Vegetation Index (SAVI). *Remote Sensing of Environment*, 25, 3, 295–309, 1988. Doi: [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)

Huffman, G.J.; Bolvin, D.T.; Nelkin, E.J.; Wolff, D.B.; Adler, R.F.; Gu, G.; Hong, Y.; Bowman, K.P.; Stocker, E.F. The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-Global, Multiyear, Combined-Sensor Precipitation Estimates at Fine Scales. *Journal of Hydrometeorology*, 8, 38–55, 2007.

Huffman, G.J.; Bolvin, D.T. TRMM and Other Data Precipitation Data Set Documentation; NASA: Greenbelt, MD, USA, 2015.

Huffman, G.J.; Bolvin, D.T.; Braithwaite, D.; Hsu, K.; Joyce, R.; Kidd, C.; Nelkin, E.J.; Xie, P. Algorithm Theoretical Basis Document (ATBD) Version 4.5: NASA Global Precipitation Measurement (GPM) Integrated Multi-satellitE Retrievals for GPM (IMERG); NASA: Greenbelt, MD, USA, 2015.

Huntington, J., Hegewisch, K., Daudert, B., Morton, C., Abatzoglou, J., McEvoy, D., and T., Erickson. Climate Engine: Cloud Computing of Climate and Remote Sensing Data for Advanced Natural Resource Monitoring and Process Understanding. *Bulletin of the American Meteorological Society*, 2017. Doi: <http://journals.ametsoc.org/doi/abs/10.1175/BAMS-D-15-00324.1>.

Idso, S. B.; Jackson, R. D.; Reginato, R. J. Estimating evaporation: a technique adaptable to remote sensing. *Science*, 189, 991–992, 197510.1126/science.189.4207.991

Immerzeel, W.W.; Gaur, A.; Zwart, S.J. Integrating remote sensing and a process-based hydrological model to evaluate water use and productivity in a south Indian catchment. *Agricultural Water Management*, 95, 11–25, 2008. Doi: <https://doi.org/10.1016/j.agwat.2007.08.006>

Jackson, R. D.; Reginato, R. J.; Idso, S. B. Wheat canopy temperature: A practical tool for evaluating water requirements. *Water Resources Research*, 13, 3, 651–656, 1977. Doi: <https://doi.org/10.1029/WR013i003p00651>

Joyce, R.J.; Janowiak, J.E.; Arkin, P.A.; Xie, P. CMORPH: A Method that Produces Global Precipitation Estimates from Passive Microwave and Infrared Data at High Spatial and Temporal Resolution. *Journal of Hydrometeorology*, 5, 487–503, 2004. Doi: [https://doi.org/10.1175/1525-7541\(2004\)005<0487:CAMTPG>2.0.CO;2](https://doi.org/10.1175/1525-7541(2004)005<0487:CAMTPG>2.0.CO;2)

Julich, S.; Breuer, L.; Frede, H. G. Integrating heterogeneous landscape characteristics into watershed scale modelling. *Advances in Geosciences*, 31, 31–38, 2012. Doi: <https://doi.org/10.5194/adgeo-31-31-2012>

Kamble, B.; Kilic, A.; Hubbard, K. Estimating crop coefficients using remote sensing-based vegetation index. *Remote Sensing*, 5, 1588–1602, 2013. Doi: <https://doi.org/10.3390/rs5041588>

Karimi, P.; Bastiaanssen, W. G. M. Spatial evapotranspiration, rainfall and land use data in water accounting - Part 1: Review of the accuracy of the remote sensing data. *Hydrology and Earth System Sciences*, v. 19, p. 507–532, 2015.

Kilic, A.; Allen, R.; Trezza, R.; Ratcliffe, I.; Kamble, B.; Robison, C.; Ozturk, D. Sensitivity of evapotranspiration retrievals from the METRIC processing algorithm to improved radiometric resolution of Landsat 8 thermal data and to calibration bias in Landsat 7 and 8 surface temperature. *Remote Sensing of Environment* 185, 198–209, 2016. Doi: <http://dx.doi.org/10.1016/j.rse.2016.07.011>

Kim, K.; Park, J.; Baik, J.; Choi, M. Evaluation of topographical and seasonal feature using GPM IMERG and TRMM 3B42 over Far-East Asia. *Atmospheric Research*, 187, 95–105, 2017. Doi: <http://dx.doi.org/10.1016/j.atmosres.2016.12.007>

Kubota, T.; Shige, S.; Hashizume, H.; Aonashi, K.; Takahashi, N.; Seto, S.; Hirose, M.; Takayabu, Y. N.; Ushio, T.; Nakagawa, K.; Iwanami, K.; Kachi, M.; Okamoto, K. Global Precipitation Map Using Satellite-Borne Microwave Radiometers by the GSMAp Project: Production and Validation. *IEEE Transactions on Geoscience and Remote Sensing*, v. 45, n. 7, p. 2259–2275, 2007. Doi: <http://dx.doi.org/10.1109/TGRS.2007.895337>

Leprieur, C. E. Red edge measurements and canopy structure: a first look with AVIRIS data. In: 12th Canadian Symposium on Remote Sensing Geoscience and Remote Sensing Symposium, 2093–2096, 1989. Doi: <http://dx.doi.org/10.1109/IGARSS.1989.577785>

Li, Z.-L.; Tang, R.; Wan, Z.; Bi, Y.; Zhou, C.; Tang, B.; Yan, G.; Zhang, X. A Review of Current Methodologies for Regional Evapotranspiration Estimation from Remotely Sensed Data. *Sensors*, 9, 3801–3853, 2009. Doi: <http://dx.doi.org/10.3390/s90503801>

Li, Z.; Liu, W.; Zhang, X.; Zheng, F. Impacts of land use change and climate variability on hydrology in an agricultural catchment on the Loess Plateau of China. *Journal of Hydrology*, 377, 35–42, 2009. Doi: <http://dx.doi.org/10.1016/j.jhydrol.2009.08.007>

Lima, E. de P.; Sediyma, G. C.; Andrade, R. G.; Lopes, V. D.; Silva, B. B. Evapotranspiração real diária em sub-bacias do Paracatu , utilizando produtos do sensor Modis. *Revista Ceres*, 61, 1, 17–27, 2014. Doi: <https://doi.org/10.1590/S0034-737X2014000100003>

Lima, J. E. F. W. Modelagem numérica do fluxo da água no solo e do escoamento de base em uma bacia experimental em área agrícola no Cerrado. Tese Doutorado. Brasília: Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, 2010.

Lima, J. E. F. W.; Silva, E. M.; Strauch, M.; Lorz, C. Development of a soil database for applying SWAT model in a catchment of the Brazilian Savanna. In: Proceedings of the SWAT-2013 Conference, Toulouse-FR. p.1-10, 2013.

Lima, J. E. F. W; Freitas, G. K.; Pinto, M. A. T.; Salles, P. S. B. A. Gestão da crise hidrica 2016 – 2018: Experiências do Distrito Federal. Brasília, DF: Adasa: Caesb: Seagri: Emater, DF, 2018, 328 p.

Liu, Z. Comparison of Integrated Multi-satellitE Retrievals for GPM (IMERG) and TRMM Multi-satellite Precipitation Analysis (TMPA) Monthly Precipitation Products: Initial Results. *Journal of Hydrometeorology*, 17, 777–790, 2016. Doi: <https://doi.org/10.1175/JHM-D-15-0068.1>

Long, D.; Singh, V. P. Assessing the impact of end-member selection on the accuracy of satellite-based spatial variability models for actual evapotranspiration estimation. *Water Resources Research*, 49, 2601–2618, 2013. Doi: <https://doi.org/10.1002/wrcr.20208>

Luo X.; Wu W.; He D.; Li Y.; Ji X. Hydrological Simulation Using TRMM and CHIRPS Precipitation Estimates in the Lower Lancang-Mekong River Basin. *Chinese Geographical Science*, 29,1, 13–25, 2019. Doi: <https://doi.org/10.1007/s11769-019-1014-6>

McLaughlin, D. Recent developments in hydrologic data assimilation. *Reviews of Geophysics*, 33, 977–984, 1994. Doi: <https://doi.org/10.1029/95RG00740>

Mecikalski, J. R.; Diak, G. R.; Anderson, M. C.; Norman, J. M. Estimating fluxes on continental scales using remotely sensed data in an atmospheric-land exchange model. *Journal of Applied Meteorology*, 38, 9, 1352–1369, 1999. Doi: [https://doi.org/10.1175/1520-0450\(1999\)038<1352:EFOCSU>2.0.CO;2](https://doi.org/10.1175/1520-0450(1999)038<1352:EFOCSU>2.0.CO;2)

Menenti, M.; Choudhury, B. J. Parameterization of land surface evaporation by means of location dependent potential evaporation and surface temperature range. In: *Proceedings of IAHS conference on Land Surface Processes*, 212, 561–568, 1993.

Mohamed, Y. A.; Bastiaanssen, W. G. M.; Savenije, H. H. G. Spatial variability of evaporation and moisture storage in the swamps of the upper Nile studied by remote sensing techniques. *Journal of Hydrology*, 289, 145–164, 2004. Doi: <https://doi.org/10.1016/j.jhydrol.2003.11.038>

Morton, C. G.; Huntington, J. L.; Pohll, G. M.; Allen, R. G.; McGwire, K. C.; Bassett, S. D. *Journal of the American Water Resources Association*, 49, 3, 549–562, 2013. Doi: <https://doi.org/10.1111/jawr.12054>

Norman, J. M.; Kustas, W. P.; Prueger, J. H.; Diaket, G. R. Surface flux estimation using radiometric temperature: A dual temperature-difference method to minimize measurement errors. *Water Resources Research*, 36, 8, 2263–2274, 2000. Doi: <https://doi.org/10.1029/2000WR900033>

Norman, J. M.; Kustas, W. P.; Humes, K. S. Source approach for estimating soil and vegetation energy fluxes in observations of directional radiometric surface temperature. *Agricultural and Forest Meteorology*, 77, 263–293, 1995. Doi: [https://doi.org/10.1016/0168-1923\(95\)02265-Y](https://doi.org/10.1016/0168-1923(95)02265-Y)

Okamoto, K.; Ushio, T.; Iguchi, T.; Takahashi, N.; Iwanami, K. The Global Satellite Mapping of Precipitation (GSMP) Project. In: *Proceedings. IEEE International Geoscience and Remote Sensing Symposium*, 3414–3416, 2005. Doi: <https://doi.org/10.1109/IGARSS.2005.1526575>

Oliveira, R.; Maggioni, V.; Vila, D.; Morales, C. Characteristics and Diurnal Cycle of GPM Rainfall Estimates over the Central Amazon Region. *Remote Sensing*, 544, 8, 2016. Doi: <https://doi.org/10.3390/rs8070544>

Olivetti, D.; Roig, H.; Martinez, J.-M.; Borges, H.; Ferreira, A.; Casari, R.; Salles, L.; Malta, E. Low-cost unmanned aerial multispectral imagery for siltation monitoring in reservoirs. *Remote sensing*. Aceito para publicação.

Poortinga, A.; Bastiaanssen, W.; Simons, G.; Saah, D.; Senay, G.; Fenn, M.; Bean, B; Kadyszewski, J. A Self-Calibrating Runoff and Streamflow Remote Sensing Model for Ungauged Basins Using Open-Access Earth Observation Data. *Remote Sensing*, 86, 9, 2017. Doi: <https://doi.org/10.3390/rs9010086>

Price, J. C. The potential of remotely sensed thermal infrared data to infer surface soil moisture and evaporation. *Water Resources Research*, 16, 4, 787–795, 1980. Doi: <https://doi.org/10.1029/WR016i004p00787>

Qin, C.; Jia, Y.; Su, Z.; Zhou, Z.; Qiu, Y.; Suhui, S.. Integrating remote sensing information into a distributed hydrological model for improving water budget predictions in large-scale basins through data assimilation. *Sensors*, 8, 4441–4465, 2008. Doi: <https://doi.org/10.3390/s8074441>

Rango, A. Application of remote sensing methods to hydrology and water resources. *Hydrological Sciences Journal*, 39, 4, 309–320, 1994. Doi: <https://doi.org/10.1080/02626669409492752>

Richards, F.; Arkin, P. On the Relationship between Satellite-Observed Cloud Cover and Precipitation. *Monthly Weather Review*, 109, 1081–1093, 1981. Doi: [https://doi.org/10.1175/1520-0493\(1981\)109<1081:OTRBSO>2.0.CO;2](https://doi.org/10.1175/1520-0493(1981)109<1081:OTRBSO>2.0.CO;2)

Ritchie, J. T.; Burnett, E. Dryland Evaporative Flux in a Subhumid Climate: II. Plant Influences. *Agronomy Journal*, 63, 1, 1970. Doi: [10.2134/agronj1971.00021962006300010019x](https://doi.org/10.2134/agronj1971.00021962006300010019x)

Ritchie, J. T.; Rhoades, E. D.; Richardson, C. W. Calculating evaporation from native grassland watershed. *Transactions of the ASAE*, 19, 6, 1093–1103, 1976. Doi: <https://doi.org/10.13031/2013.36184>

Rouse, J. W.; Haas, R. H.; Well, J. A.; Deering, D. W. Monitoring vegetation systems in the great plains with ERTS. *Proceedings of the Third ERTS Symposium*, Washington DC, 10-14 December, 309-317, 1973.

Roy, D. P.; Wulder, M.A.; Loveland, T.R.; Woodcock, C.E.; Allen, R.G.; Anderson, M.C.; Helder, D.; Irons, J.R.; Johnson, D.M.; Kennedy, R.; Scambos, T.A.; Schaafk, C.B.; Schott, J.R.; Sheng, Y.; Vermote, E.F.; Belward, A.S.; Bindschadler, R.; Cohen, W.B.; Gao, F.; Hippel, J.D.; Hostert, P.; Huntington, J.; Justice, C.O.; Kilic, A.; Kovalskyy, V.; Lee, Z.P.; Lymburner, L.; Masek, J.G.; McCorkel, J.; Shuai, Y.; Trezza, R.; Vogelmann, J.; Wynne, R.H.; Zhu, Z. Landsat-8: Science and product vision for terrestrial global change research. *Remote Sensing of Environment*, 145, 154–172, 2014.

Sahlu, D.; Nikolopoulos, A.I.; Moges, S.A.; Anagnostou, E.N.; Hailu, D. First Evaluation of the Day-1 IMERG over the Upper Blue Nile Basin. *Journal of Hydrometeorology*, 17, 2875–2882, 2016. Doi: <https://doi.org/10.1175/JHM-D-15-0230.1>

Salles, L.A.; Lima, J.E.F.W.; Chaves, H.M.L.; Ferrigo, S.; Carvalho, H.E.S. Impacts of Using

Different Soil Databases on Streamflow Simulation in an Experimental Rural Catchment of the Brazilian Savanna. *Revista Brasileira de Geografia Física*, 8, 1, 187–195, 2015. Doi: <https://doi.org/10.26848/rbgf.v8.1.p187-195>

Santesteban, L. G.; Gennaro, S. F. Di; Herrero-Langreo, A.; Miranda, C.; Royo, J. B.; Matese, A. High-resolution UAV-based thermal imaging to estimate the instantaneous and seasonal variability of plant water status within a vineyard. *Agricultural Water Management*, 183, 49–59, 2016.

Sarmento, L. Análise de incertezas e avaliação dos fatores influentes no desempenho de modelos de simulação de bacias hidrográficas. Tese de Doutorado em Tecnologia Ambiental e Recursos Hídricos, Publicação PTARH. TD – 07/10, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 241p. 2010.

Satgé, F.; Xavier, A.; Zolá, R.; Hussain, Y.; Timouk, F.; Garnier, J.; Bonnet, M.-P. Comparative Assessments of the Latest GPM Mission's Spatially Enhanced Satellite Rainfall Products over the Main Bolivian Watersheds. *Remote Sensing*, 9, 4, 369, 2017. Doi: <https://doi.org/10.3390/rs9040369>

Savenije, H. H. G. Determination of evaporation from a catchment water balance at a monthly time scale. *Hydrology and Earth System Sciences*, 1, 93–100, 1997. Doi: <https://doi.org/10.5194/hess-1-93-1997>

Scherer-Warren, M. Desmembramento de Estimativas de Evapotranspiração Obtidas por Sensoriamento Remoto nas Componentes de Evaporação e Transpiração Vegetal. *Revista Brasileira de Geografia Física* 02, 361-373, 2012. Doi: <https://doi.org/10.26848/rbgf.v5i2.232806>

Seavers, P. M.; Ottmann, R. W. Evapotranspiration estimation using a normalized difference vegetation index transformation of satellite data. *Hydrological Sciences Journal*, 39, 4, 333–346, 1994. Doi: <https://doi.org/10.1080/02626669409492754>

Seguin, B.; Itier, B. Using midday surface temperature to estimate daily evaporation from satellite thermal IR data. *International Journal of Remote Sensing*, 4, 2, 371–383, 1983. Doi: <http://dx.doi.org/10.1080/01431168308948554>

Semmens, K. A.; Anderson, M. C.; Kustas, W. P.; Gao, F.; Alfieri, J. G.; McKee, L.; Prueger, J. H.; Hain, C. R.; Cammalleri, C.; Yang, Y.; Xia, T.; Sanchez, L.; Alsina, M. M.; Vélez, M. Monitoring daily evapotranspiration over two California vineyards using Landsat 8 in a multi-sensor data fusion approach. *Remote Sensing of Environment*, 185, 155–170, 2016. Doi: <http://dx.doi.org/10.1016/j.rse.2015.10.025>

Senay, G. B., Budde, M., Verdin, J. P., & Melesse, A. M. A coupled remote sensing and simplified surface energy balance approach to estimate actual evapotranspiration from irrigated fields. *Sensors*, 7, 2007, 979–1000. Doi: <https://doi.org/10.3390/s7060979>

Senay, G. B.; Friedrichs, M.; Singh, R. K.; Velpuri, N. M. Evaluating Landsat 8 evapotranspiration for water use mapping in the Colorado River Basin. *Remote Sensing of Environment*, 185, 2016, 171–185. Doi: <http://dx.doi.org/10.1016/j.rse.2015.12.043>

Senay, G. B.; Bohms, S.; Singh, R. K.; Gowda, P. H.; Velpuri, N. M.; Alemu, H.; Verdin, J. P. Operational Evapotranspiration Mapping Using Remote Sensing and Weather Datasets: A New Parameterization for the SSEB Approach. *Journal of the American Water Resources Association (JAWRA)* 49(3), 2013, 577–591. Doi: <https://doi.org/10.1111/jawr.12057>

Senay, G. B.; Gowda, P. H.; Bohms, S.; Howell, T. A.; Friedrichs, M.; Marek, T. H.; Verdin, J. P. Evaluating the SSEBop approach for evapotranspiration mapping with landsat data using lysimetric observations in the semi-arid Texas High Plains. *Hydrology and Earth System Sciences Discussions*, 11, 723–756, 2014. Doi: <https://doi.org/10.5194/hessd-11-723-2014>

Senay, G. B.; Schauer, M.; Friedrichs, M.; Velpuri, N. M.; Singh, R. K. Satellite-based water use dynamics using historical Landsat data (1984–2014) in the southwestern United States. *Remote Sensing of Environment*, 202, 2017, 98–112. Doi: <https://doi.org/10.1016/j.rse.2017.05.005>

Sharifi, E.; Steinacker, R.; Saghafian, B. Assessment of GPM-IMERG and Other Precipitation Products against Gauge Data under Different Topographic and Climatic Conditions in Iran: Preliminary Results. *Remote Sensing*, 8, 135, 2016. Doi: <https://doi.org/10.3390/rs8020135>

Simons, G.; Bastiaanssen, W.; Ngô, L. A.; Hain, C. R.; Anderson, M. C.; Senay, G. B. Integrating Global Satellite-Derived Data Products as a Pre-Analysis for Hydrological Modelling Studies: A Case Study for the Red River Basin. *Remote Sensing*, 8, 279, 2016. Doi: <https://doi.org/10.3390/rs8040279>

Singh, R. K.; Senay, G. B.; Velpuri, N. M.; Bohms, S.; Scott, R. L.; Verdin, J. P. Actual Evapotranspiration (Water Use) Assessment of the Colorado River Basin at the Landsat Resolution Using the Operational Simplified Surface Energy Balance Model. *Remote Sensing*, 6, 233–256, 2014. Doi: <https://doi.org/10.3390/rs6010233>

Singh, R. K.; Senay, G. B.; Velpuri, N. M.; Bohms, S.; Verdin, J. P. On the downscaling of actual evapotranspiration maps based on combination of MODIS and landsat-based actual evapotranspiration estimates. *Remote Sensing*, 6, 10483–10509, 2014. Doi: <https://doi.org/10.3390/rs61110483>

Singh, R. K.; Irmak, A. Treatment of anchor pixels in the METRIC model for improved estimation of sensible and latent heat fluxes. *Hydrological Sciences Journal*, 56, 5, 895–906, 2011. Doi: <http://dx.doi.org/10.1080/02626667.2011.587424>

Singh, R. K.; Senay, G. B. Comparison of Four Different Energy Balance Models for Estimating Evapotranspiration in the Midwestern United States. *Water*, 8, 2016, 9. Doi: <https://doi.org/10.3390/w8010009>

Sorooshian, S.; Hsu, K.-L.; Gao, X.; Gupta, H.V.; Imam, B.; Braithwaite, D. Evaluation of PERSIANN System Satellite-Based Estimates of Tropical Rainfall. *Bulletin of the American Meteorological Society*, 81, 2035–2046, 2000. Doi: [https://doi.org/10.1175/1520-0477\(2000\)081<2035:EOPSS>2.3.CO;2](https://doi.org/10.1175/1520-0477(2000)081<2035:EOPSS>2.3.CO;2)

Srinivasan, R., Arnold, J. G. Integration of a basin-scale water quality model with GIS. *Water Resources Bulletin*, 30, 3, 453–462, 1994. Doi: <https://doi.org/10.1111/j.1752-1688.1994.tb03304.x>

Stern, W. Evapotranspiration of safflower at three densities of sowing. *Journal of Agriculture Research*, 16, 961–971, 1965.

Strauch, M.; Bernhofer, C.; Koide, S.; Volk, M.; Lorz, C.; Makeschin, F. Using precipitation data ensemble for uncertainty analysis in SWAT streamflow simulation. *Journal of Hydrology*, 414–415, 413–424, 2012. Doi: <https://doi.org/10.1016/j.jhydrol.2011.11.014>

Strauch, M.; Lima, J.E.F.W.; Volk, M.; Lorz, C.; Makeschin, F. The impact of Best Management Practices on simulated streamflow and sediment load in a Central Brazilian catchment. *Journal of Environmental Management*, 127, S24–S36, 2013. Doi: <https://doi.org/10.1016/j.jenvman.2013.01.014>

Strauch, M.; Volk, M. SWAT plant growth modification for improved modeling of perennial vegetation in the tropics. *Ecological Modelling*, v. 269, p. 98–112, 2013. Doi: <https://doi.org/10.1016/j.ecolmodel.2013.08.013>

Su, Z. The Surface Energy Balance System (SEBS) for estimation of turbulent heat fluxes. *Hydrology and Earth System Sciences Discussions*, 6(1), 2002, 85–100. Doi: <https://doi.org/10.5194/hess-6-85-2002>

Tan, M. L.; Duan, Z. Assessment of GPM and TRMM Precipitation Products over Singapore. *Remote Sensing*, 9, 7, 720, 2017. Doi: <https://doi.org/10.3390/rs9070720>

Tang, G.; Ziyue Zeng, Z.; Long, D.; Guo, X. Statistical and Hydrological Comparisons between TRMM and GPM Level-3 Products over a Midlatitude Basin: Is Day-1 IMERG a Good Successor for TMPA 3B42V7? *Journal of Hydrometeorology*, 17, 1, 2016. Doi: <https://doi.org/10.1175/JHM-D-15-0059.1>

Tasumi, M.; Trezza, R.; Allen, R. G.; Wright, J. L. Operational aspects of satellite-based energy balance models for irrigated crops in the semi-arid U.S. *Irrigation and Drainage Systems*, 19, 3, 355–376, 2005. Doi: <https://doi.org/10.1007/s10795-005-8138-9>

Távora, B.E. Zona Ripária de Cerrado: Processos Hidrossedimentológicos. Tese de Doutorado em Tecnologia Ambiental e Recursos Hídricos, Publicação PTARH.TD019/2017, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 133p. 2017.

Teixeira, A. H. de C.; Bastiaanssen, W. G. M.; Ahmad, M. D.; Bos, M.G. Reviewing SEBAL input parameters for assessing evapotranspiration and water productivity for the Low-Middle São Francisco River basin, Brazil Part A: Calibration and validation. *Agricultural and Forest Meteorology*, 149, 462–476, 2009. Doi: <https://doi.org/10.1016/j.agrformet.2008.09.016>

Trezza, R.; Allen, R. G.; Tasumi, M. Estimation of actual evapotranspiration along the Middle Rio Grande of New Mexico using MODIS and landsat imagery with the METRIC model. *Remote Sensing*, 5, 10, 5397–5423, 2013. Doi: <https://doi.org/10.3390/rs5105397>

Triana, J. S. A.; Chu, M. L.; Guzman, J. A.; Moriasi, D. N. Steiner, J. L. Evaluating the Risks of Groundwater Extraction in an Agricultural Landscape under Different Climate Projections. *Water*, 12, 400, 2020. Doi: <https://doi.org/doi:10.3390/w12020400>

TRMM. TRMM Mission Comes to an End after 17 Years. Disponível em: <https://pmm.nasa.gov/trmm/mission-end>. Acesso em: 9/11/2016.

Tucker, C. J. Red and Photographic Infrared linear Combinations for Monitoring Vegetation. *Remote Sensing of Environment*, 8, 2, 127-150, 1979. Doi: [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)

Tucci, C.E.M. Modelos hidrológicos, Ed. Universidade/UFRGS/Associação Brasileira de Recursos Hídricos, Porto Alegre, 668p, 1998.

Ushio, T.; Sasahige, K.; Kubota, T.; Shige, S.; Okamoto, K.; Aonashi, K.; Inoue, T.; Takahashi, N.; Iguchi, T.; Kachi, M.; Oki, R.; Morimoto, T.; Kawasaki, Z.-I. A Kalman Filter Approach to the Global Satellite Mapping of Precipitation (GSMaP) from Combined Passive Microwave and Infrared Radiometric Data. *Journal of the Meteorological Society of Japan*, 87, 137–151, 2009. Doi: <https://doi.org/10.2151/jmsj.87A.137>

Wang, R.; Chen, J.; Wang, X. Comparison of IMERG Level-3 and TMPA 3B42V7 in Estimating Typhoon-Related Heavy Rain. *WATER*, 9, 276, 2017. Doi: <http://dx.doi.org/10.3390/w9040276>

Wang, Y. Q.; Xiong, Y. J.; Qiu, G. Y.; Zhang, Q. T. Is scale really a challenge in evapotranspiration estimation? A multi-scale study in the Heihe oasis using thermal remote sensing and the three-temperature model. *Agricultural and Forest Meteorology*, v. 230–231, p. 128–141, 2016. Doi: <http://dx.doi.org/10.1016/j.agrformet.2016.03.012>

Webster, E.; Ramp, D.; Kingsford, R. T. Spatial sensitivity of surface energy balance algorithms to meteorological data in a heterogeneous environment. *Remote Sensing of Environment*, 187, 294–319, 2016. Doi: <http://dx.doi.org/10.1016/j.rse.2016.10.019>

Weiser, R. L.; Asrar, G.; Miller, G. P.; Kanemasu, E. T. Assessing grassland biophysical characteristics from spectral measurements. *Remote Sensing of Environment*, 20, 2, 141–152, 1986. Doi: [http://dx.doi.org/10.1016/0034-4257\(86\)90019-2](http://dx.doi.org/10.1016/0034-4257(86)90019-2)

Xu, R.; Tian, F.; Yang, L.; Hu, H.; Lu, H.; Hou, A. Ground validation of GPM IMERG and TRMM 3B42v7 rainfall products over southern Tibetan Plateau based on high-density rain gauge network. *Journal of Geophysical Research: Atmospheres*, 122, 910–924, 2017. Doi: <http://dx.doi.org/10.1002/2016JD025418>

Yang, Y.; Shang, S. A hybrid dual-source scheme and trapezoid framework-based evapotranspiration model (HTEM) using satellite images: Algorithm and model test. *Journal of Geophysical Research Atmospheres*, 118, 2284–2300, 2013. Doi: <http://dx.doi.org/10.1002/jgrd.50259>

Yuan, F.; Zhang, L.; Win, K.; Ren, L.; Zhao, C.; Zhu, Y.; Jiang, S.; Liu, Y. Assessment of GPM and TRMM Multi-Satellite Precipitation Products in Streamflow Simulations in a Data-Sparse Mountainous Watershed in Myanmar. *Remote Sensing*, 9, 3, 302, 2017. Doi: <https://doi.org/10.3390/rs9030302>

Zhou, X.; Bi, S.; Yang, Y.; Tian, F.; Ren, D. Comparison of ET estimations by the three-temperature model, SEBAL model and eddy covariance observations. *Journal of Hydrology*, 519, 769–776, 2014. Doi: <http://dx.doi.org/10.1016/j.jhydrol.2014.08.004>

CAPÍTULO 2**AVALIAÇÃO DA DINÂMICA ESPACIAL E TEMPORAL DE PRODUTOS GLOBAIS
DE PRECIPITAÇÃO POR SENSORIAMENTO REMOTO**

Esse capítulo foi publicado no periódico Water. O artigo apresentado nesse capítulo faz uma avaliação da dinâmica espacial e temporal de produtos globais de P por sensoriamento remoto (P_{sr}), em região do Brasil central com alta densidade de pluviômetros. A importância deste estudo no contexto da Tese de doutorado consiste em gerar conhecimento relacionado ao uso de produtos de P_{sr} , visando contribuir com o monitoramento ambiental de recursos hídricos no bioma Cerrado. Além disso, os dados de P_{sr} avaliados nesse capítulo serão utilizados posteriormente no estudo apresentado no capítulo 4, o qual avaliou a integração de dados de sensoriamento remoto com modelo hidrológico.

Salles, L.A.; Satgé, F.; Roig, H.L.; Almeida, T.; Olivetti, D.; Ferrreira, W. Seasonal Effect on Spatial and Temporal Consistency of the New GPM-Based IMERG-v5 and GSMP-v7 Satellite Precipitation Estimates in Brazil's Central Plateau Region. Water, 11, 668, 2019. Doi: <https://doi.org/10.3390/w11040668>



Article

Seasonal Effect on Spatial and Temporal Consistency of the New GPM-Based IMERG-v5 and GSMAp-v7 Satellite Precipitation Estimates in Brazil's Central Plateau Region

Leandro Salles ^{1,2,*}, Frédéric Satgé ³, Henrique Roig ¹, Tati Almeida ¹, Diogo Olivetti ¹ and Welber Ferreira ^{1,4}

¹ Instituto de Geociências (IG/UnB), Universidade de Brasília, CEP: 70910-900, Brasília-DF, Brazil; roig@unb.br (H.R.); tati_almeida@unb.br (T.A.); di_olivetti@hotmail.com (D.O.); welber.fa@gmail.com (W.F.)

² Instituto Brasília Ambiental de Recursos Hídricos do Distrito Federal (IBRAM/DF), SEPN 511-Bloco C-Edifício Bittar-CEP: 70.750-543 Brasília-DF, Brazil

³ IRD, UMR 228 Espace-Dev, Maison de la télédétection, 500 rue JF Breton, 34093 Montpellier CEDEX 5, France; frederic.satge@ird.fr

⁴ Agência Reguladora de Águas, Energia e Saneamento do Distrito Federal (ADASA/DF), Saa Estação Rodoviária de Brasília - Ala Norte, CEP: 70.631-900 Brasília-DF, Brazil

* Correspondence: leandro.almeida.salles@gmail.com; Tel.: +55-61-3214-5647

Received: 28 February 2019; Accepted: 20 March 2019; Published: 31 March 2019



Abstract: This study assesses the performance of the new Global Precipitation Measurement (GPM)-based satellite precipitation estimates (SPEs) datasets in the Brazilian Central Plateau and compares it with the previous Tropical Rainfall Measurement Mission (TRMM)-era datasets. To do so, the Integrated Multi-satellitE Retrievals for GPM (IMERG)-v5 and the Global Satellite Mapping of Precipitation (GSMAp)-v7 were evaluated at their original 0.1° spatial resolution and for a 0.25° grid for comparison with TRMM Multi-satellite Precipitation Analysis (TMPA). The assessment was made on an annual, monthly, and daily basis for both wet and dry seasons. Overall, IMERG presents the best annual and monthly results. In both time steps, IMERG's precipitation estimations present bias with lower magnitudes and smaller root-mean-square error. However, GSMAp performs slightly better for the daily time step based on categorical and quantitative statistical analysis. Both IMERG and GSMAp estimates are seasonally influenced, with the highest difficulty in estimating precipitation occurring during the dry season. Additionally, the study indicates that GPM-based SPEs products are capable of continuing TRMM-based precipitation monitoring with similar or even better accuracy than obtained previously with the widely used TMPA product.

Keywords: IMERG; GSMAp; GPM; TMPA; TRMM; Satellite precipitation; Cerrado biome

1. Introduction

Precipitation is a key component of the water cycle, which is facing unprecedented changes related to both climate change and human growth population. Climate change redistributes precipitation's seasonality [1] and intensity [2], threatening the six-fold increase in water extraction observed in the 20th century in response to the increasing world population, food needs, and economics level (vision, water council, 2000). In this context, The World Meteorological Organization (WMO) defines precipitation as an Essential Climate Variable (ECV) to understand and adapt to these ongoing changes. In a general way, precipitation information obtained from point gauges measurement is spatialized to follow precipitation in time and space. However, in relation to (i)—the access difficulty (forest, desert, mountainous), and/or to (ii)—political, social, and economic issues, the gauges network is often too sparse and unevenly distributed to adequately follow precipitation in space and time [3,4]. It could be even more marked over tropical regions due to high spatial and temporal precipitation variability.

In this context, with an almost global coverage, remote sensing data provide relevant information to overcome these obstacles. Since the first meteorological satellite, Television and Infra-Red Observation Satellite (TIROS), launched in April 1960, a large number of sensors have been developed and used to monitor the precipitation from space [5]. They fall into two main categories: visible and infrared (VIS/IR) sensors available from geostationary (GEO) and low-earth orbiting (LEO) satellites; and passive microwave sensors (PMW) available from LEO satellites [6]. VIS/IR-based precipitation estimates use the relation between cloud-top temperature and the probability and intensity of precipitation, whereas PMW-based precipitation estimates use a more direct method related to the precipitation-sized particle. Although PMW-based precipitation estimates are a more accurate source of precipitation than VIS/IR-based estimates, the spatial and temporal coverage of LEO limits their application [7]. Indeed, a short-term precipitation event can be lost by the PMWs sensors as a result of the irregular and limited overpass of LEO [8]. VIS/IR sensors on GEO satellites can overcome this limitation since they provide high-temporal-resolution global data. In this context, much research has been conducted seeking the development of algorithms to combine both PMW and VIS/IR observations to provide operational satellite precipitation estimates (SPEs) [5–7].

These efforts were initiated after the Tropical Rainfall Measurement Mission (TRMM) was launched, in 1997. TRMM is an international project of the National Aeronautics and Space Administration (NASA) and Japan Aerospace Exploration Agency (JAXA), from which a first generation of SPEs products was developed. TRMM-based SPEs include the TRMM Multi-Satellite Precipitation Analysis (TMPA) [9], the Climate Prediction Center Morphing technique

(CMORPH) [10], the Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks (PERSIANN) [11], and the Global Satellite Mapping of Precipitation (GSMP) [12].

To ensure continuity of the TRMM mission, the Global Precipitation Measurement (GPM) mission's Core Observatory was deployed in February 2014, with new technologies and improved global coverage as a result of opportunities from existing satellite programs and new partners obtained from bilateral agreements with either NASA or JAXA [13]. From the GPM project, a second generation of SPEs was made available to ensure continuity in precipitation monitoring started by the TRMM-based SPEs. GPM-based SPEs includes the integrated multi-satellite retrievals for GPM (IMERG) developed by NASA [14,15] and a new GSMP version developed by JAXA [12]. If the TRMM-based SPEs have proved effective in precipitation estimation over the world, as reviewed by [16,17], GPM-based SPEs' reliability is being currently assessed and discussed by the scientific community. In the last 5 years, successive versions of the GPM-based SPEs were released. Up to date, three IMERG versions (IMERG-v3, -v4 and -v5) and two GSMP versions (GSMP-v6 and -v7) are available. In this context, timely studies reporting on the reliability of the successive released versions have been made available by the scientific community to contribute to the enhancement of the quality of the successively released versions.

First studies focused on the first GPM-based SPEs, IMERG version (IMERG-v3), to report on its potential improvement in precipitation estimate in comparison to its TRMM-based SPEs predecessors. A first attempt was made at the global scale by comparing IMERG-v3 with its predecessor TMPA-v7 at the monthly time step to highlight the difference in both datasets according to surfaces and precipitations rates [18]. Since then, different studies have assessed IMERG-v3's reliability at more local scales in different regions. For example, in India, IMERG-v3 shows notable improvement in comparison to TMPA-v7 to capture heavy rainfall [19] and to represent the mean monsoon rainfall and its variability [20]. In China, IMERG-v3 is more accurate than TMPA-v7 at monthly [21], sub-daily, and daily scales [22] and therefore represents a better option for hydrological applications [23]. More generally, an overall improvement from TRMM-based SPEs to IMERG-v3 were also highlighted in Singapore [24], Iran [25], Bolivia [26], United Arab Emirates [27], Tibet [28], East Africa [29], Continental United State (CONUS) [30], Korea, and Japan [31].

The second released IMERG version (IMERG-v4) was compared to its previous version (IMERG-v3) to highlight potential improvement on precipitation estimates accuracy. Interestingly, IMERG-v4 did not exhibit the anticipated improvement when compared to

IMERG-v3 in China [32,33] and Pakistan [34] with higher bias, lower Correlation Coefficient and RootMean Square Error. Still IMERG-v4 provides better precipitation estimates than TRMM-based SPE in Malaysia [35] and Pakistan [36]. More recently, the last released IMERG version (IMERG-v5) was compared with its former versions IMERG-v4 and -v3 in China [37] and Pakistan [34]. Both studies show a clear improvement from IMERG-v3 and -v4 to IMERG-v5. Other studies compared IMERG-v5 to TRMM-based SPEs. For example, in China, IMERG-v5 provides more reliable daily precipitation estimates than TMPA-v7 [38,39] with a general superiority of IMERG-v5 for extreme rainfall event monitoring [40] and hydrological utility [41]. With an overall performance improvement, IMERG-v5 was found a suitable replacement for TMPA-v7 in Myanmar [42], Brazil [43], and CONUS [44]. It is worth mentioning that even if IMERG-v5 globally provides more accurate precipitation estimates than the TRMM-based SPEs, the opposite can be observed at the very local scale. For example, in Pakistan, at the grid-cell scale, TMPA-v7 and CMORPH-BLD provided more accurate monthly precipitation estimates than IMERG-v5 [45]. Similarly, the other GPM-based SPEs (GSMAp-v7) also provided better precipitation estimates than IMERG-v5. However, only a few studies have compared GSMAp-v7 to IMERG-v5. To our knowledge, GSMAp-v7's reliability was only assessed and compared to IMERG-v5 in Myanmar [42], Tibet [46], Pakistan [45], Brazil [43], and CONUS [44]. Therefore, there is a need to report on the latest released GPM-based SPEs versions to understand their reliability and potential complementarity.

In the described context, this study aims to evaluate the performance of the latest GPM-based IMERG-v5 and GSMAp-v7 SPEs, for the first time, over the Brazilian Central Plateau region. The assessment was made by comparing their estimates with measured data from precipitation gauges at annual, monthly, and daily scales for both wet and dry seasons, respectively. The TRMM-based TMPA-v7 dataset for a common period of data availability is also considered to assess the potential improvement of IMERG-v5 and GSMAp-v7 compared to TMPA-v7. This timely study aims to accompany the transition from TRMM to GPM-based SPE products and is expected to provide relevant information to ongoing GPM precipitation estimate algorithms and to researchers when selecting the most reliable SPEs for their studies.

2. Data and Methodology

2.1. Study Area

The study area is situated in the Brazilian Central Plateau, located between latitudes 15.5° S and 16.1°S and longitudes 47.3°W and 48.5° W, where three South American river basins originate: São Francisco, Tocantins, and Paraná (Figure 1a). The region presents a mean slope value of 5.2°

(9.3%), with elevations ranging from 667 to 1356 m a.s.l. (Figure 1b). The study area is located in the Cerrado biome, which is exceeded in terms of area only by the Amazon and is composed of a mosaic of grass fields, savanna, and forest vegetation formations [47,48]. Recently, the Cerrado is the Brazilian region with the most important beef production, and has experienced the main expansion in total cropland area over the last two decades [49]. If the actual scenario of large-scale agriculture expansion remains, projections indicate that around 30% of the Cerrado's remaining natural vegetation is likely to be cleared in the next three decades as a consequence of limited legal protection and market pressure [50]. The climate is tropical, with a dry winter season from May to September and a rainy summer season in the remaining months, which accounts for more than 90% of average annual precipitation (Figure 1c).

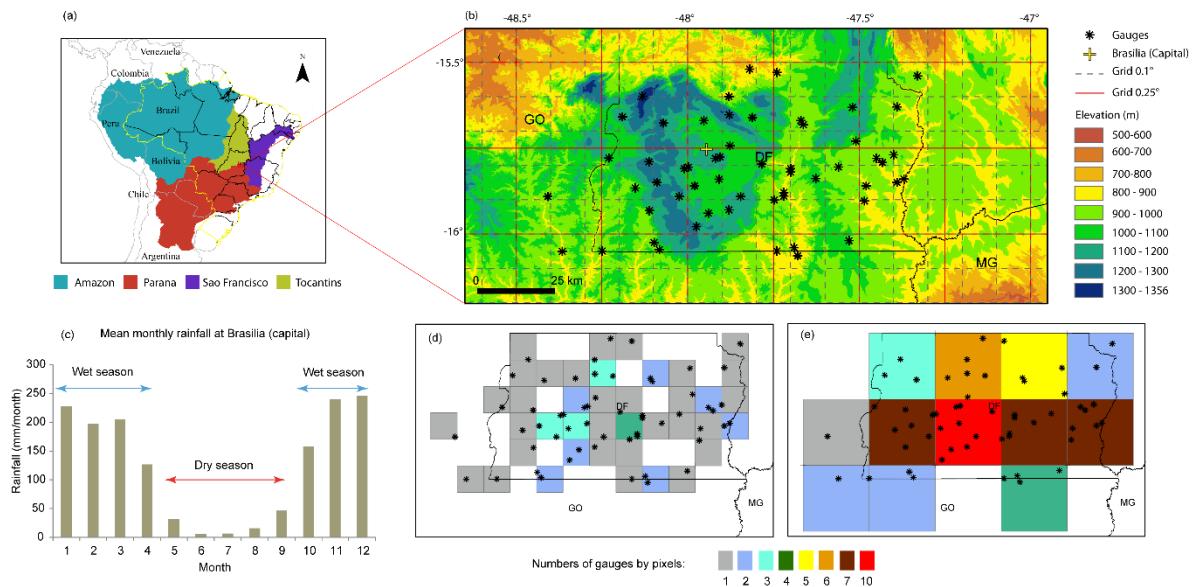


Figure 1. Study area: location within four important hydrographic regions (a); rain gauges and elevation map (b); average monthly precipitation between 1963 and 2016 for Brasilia's rain gauge (c); number of gauges by grid-cell for the 0.1° grid (d); and number of gauges by grid-cell for the 0.25° grid (e).

2.2. Precipitation Data

2.2.1. Integrated Multi-satellitE Retrievals for Global Precipitation Measurement (IMERG)

IMERG is a 0.1° spatial-resolution product available at 30 min time intervals, with spatial coverage between 60° N and 60° S. IMERG is produced by NASA using concepts and components from previous algorithms: TMPA, CMORPH, and PERSIANN. Precipitation estimates from available LEO satellites' PMW sensors are assembled, gridded, and

intercalibrated, then combined with data from GEO IR sensors using the Morphing-Kalman Filter, CMORPH-KF, Lagrangian time interpolation scheme, and the PERSIANN Cloud Classification System (PERSIANN-CCS) to produce half-hourly estimates [14].

There are three stage level available IMERG datasets: the early-run, providing data approximately five hours after observation time; the late-run, with approximately 16 h delay from observation time; and the final-run, which uses monthly precipitation data from the Global Precipitation Climatology Centre (GPCC) to perform a final adjustment [14]. The IMERG datasets are currently at version 5. In this study, only IMERG final-run version 5 (called IMERG hereafter) is considered, as it is the latest version. Early- and late-run versions were not considered, as they consist of intermediate step with an overall low efficiency due to the absence of the gauge's adjustment. Data were downloaded from the internet (<ftp://arthurhou.pps.eosdis.nasa.gov/gpmdata/>).

2.2.2. Global Satellite Mapping of Precipitation (GSMaP)

The GSMAp project was established in 2002 by the Japan Science and Technology Agency (JST) under the Core Research for Evolutional Science and Technology (CREST). Today, the activities are implemented under the Japanese Precipitation Measuring Mission (PMM) Science Team, which is a joint science team between TRMM and its successor mission, GPM [51].

The GSMAp Project has produced different SPE products from PMW, and has merged IR and PMW datasets [12,52]. This study used the 0.1° spatial-resolution GSMAp product available at one-hour time interval, with coverage between 60° N and 60° S, and gauge-adjusted with the Climate Prediction Center (CPC) global rain gauge daily database. This dataset uses an approach similar to CMORPH, where a moving vector derived from two successive IR images is used to propagate rainy areas from microwave radiometry. GSMAp focuses on the relationship between precipitation strength and IR brightness temperature, and a Kalman filter is then applied to the precipitation rate to update the rate on the IR brightness temperature [12]. Currently, the GSMAp gauge-adjusted product is in its seventh version, and will be called GSMAp hereafter. GSMAp data were downloaded from the internet (<https://www.gportal.jaxa.jp/gp>).

2.2.3. Tropical Rainfall Measurement Mission Multi-Satellite Precipitation Analysis (TMPA)

The TMPA was developed by NASA [53,54] and has been widely assessed in many regions [35–38]. TMPA was developed to assemble precipitation estimates from different satellite systems with land-surface precipitation gauges in order to provide the best satellite estimate [53]. The

TMPA products are produced in four stages: combination and calibration of PMW precipitation estimates using the Goddard Profiling Algorithm (GPROF); IR precipitation estimates are created using the merged PMW data; the PMW and IR are combined; and rain gauge data are rescaled, calibrated, and used [24,53].

TMPA has a 0.25° spatial resolution over 50° N and 50° S, and is available at three-hour and monthly time steps, which are called 3B42 and 3B43, respectively. TMPA 3B42 has a real-time and an adjusted dataset using gauge-based data from the GPCC and the Climate Assessment and Monitoring System (CAMS) developed by the CPC. This study adopted the TMPA 3B42-v7 adjusted, available on the internet (<https://mirador.gsfc.nasa.gov/>), hereafter called TMPA.

2.2.4. Rain Gauges

A total of 56 rain gauges with daily records for the period from 12 March 2014 to 30 November 2016 were made available by different institutions which are responsible for quality assessment before making it available to users (Agência Reguladora de Águas, Energia e Saneamento do Distrito Federal (ADASA), Agência Nacional de Águas (ANA), Companhia de Saneamento Ambiental do Distrito Federal (CAESB), Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), and Instituto Nacional de Meteorologia (INMET)). The rain gauge network extends over approximately 6000 km² and the stations are distributed on forty 0.1° grid-cells and on twelve 0.25° grid-cells (Figure 1d,e).

2.3. Method

2.3.1. Pre-processing

In order to compare IMERG and GSMAp with TMPA on a common period of data availability (12 March 2014 to 29 November 2016), it was necessary to aggregate IMERG and GSMAp values from their initial 0.1° grid to TMPA's 0.25° grid scale [21]. First, both IMERG and GSMAp were resampled from their 0.1° grid resolution into a 0.05° resolution dataset, using the nearest neighbor method. Then, from this 0.05° grid, an average precipitation value was calculated for each set of 5×5 grid-cells which were within the overlapping 0.25° grid [26]. Together, these two steps provided 0.25° grids for IMERG and GSMAp. This produced five different SPE datasets for the analysis: IMERG (0.10°), GSMAp (0.10°), TMPA (0.25°), IMERG (0.25°), and GSMAp (0.25°). The 0.10° IMERG and GSMAp grids were used to assess the impacts of the spatial resolution improvement provided by GPM datasets, while the other grids were used to compare GPM-based with TRMM-based SPE products. In order to compare the SPEs with the in situ precipitation dataset, it was also necessary for them all to have the same temporal

resolution. The precipitation values from IMERG, GSMP, and TMPA, which were taken every 30 min, one hour, and three hours, respectively, were converted into daily (from 12Z to 12Z), monthly, and yearly time steps.

Finally, since the number of precipitation gauges inside the same grid-cell varied from one to four on the 0.1° grid (Figure 1d), and from one to ten on the 0.25° grid (Figure 1e), the analysis also required processing the in situ precipitation dataset before comparing it with the SPEs. An average precipitation time-series was generated from each set of gauges within each grid-cell with more than one precipitation gauge inside. It is worth mentioning that the number of gauges can impact the results, due to the localized nature of rainfall measurements obtained by rain gauges and to the localized precipitation events that can occur. The influence of gauge density will be addressed in the discussion section.

2.3.2. Comparison Methodology

According to the considered time step (annual, monthly, daily), different methods were used to compare the SPEs with the observed gauge values and to analyze the difference between them. For the monthly and daily time step assessments, two types of datasets were generated to assess the SPEs potential. The first dataset (hereafter called Mean Regional) consists of an average daily and monthly time series obtained by taking the mean of the time series records of all the grid-cells including at least one gauge. The resulting series count was 994 daily and 32 monthly values for both the 0.1° and 0.25° grid scale. The second dataset (hereafter called Mean Spatial) consists of records available from all the grid-cells including at least one gauge in a single series for both daily and monthly time steps. The resulting series counts were 34,799 daily and 1065 monthly values for the 0.1° grid scale and 11,782 daily and 375 monthly values for the 0.25° grid scale. The consideration of both Mean Spatial and Mean Regional datasets aims to assess the potential of SPEs at different spatial scales. The Mean Regional series comparisons will provide insight into the potential of SPEs at the regional scale, whereas the Mean Spatial series comparisons will provide feedback on the spatial consistency of SPEs over the considered region. Finally, both datasets (Mean Regional and Mean Spatial) were split in two according to the dry and wet season to observe the response of the SPEs to the climatic seasonality.

2.3.2.1. Annual Comparison

For the annual time step assessment, the 2015 annual precipitation maps were derived from the gauges and SPEs for the 0.1° and 0.25° grid to visually compare precipitation spatial distribution from all considered datasets (gauges and SPEs). Then, the 2015 annual precipitation obtained

from all considered SPEs at all the grid-cells including at least one gauge were compared to the values obtained from the gauges. The comparison used the correlation coefficient (CC), the percent root-mean-square error (%RMSE), and the percent bias (%B) (see Equations (1)–(3)):

$$CC = \frac{\sum_{i=1}^N (SPE_i - \bar{SPE})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (SPE_i - \bar{SPE})^2} \sqrt{\sum_{i=1}^N (P_i - \bar{P})^2}} \quad (1)$$

$$RMSE(\%) = \frac{\sqrt{\frac{\sum_{i=1}^N (SPE_i - P_i)^2}{N}}}{\frac{\sum_{i=1}^N P_i}{N}} \times 100 \quad (2)$$

$$BIAS(\%) = \frac{\sum_{i=1}^N (SPE_i - P_i)}{\sum_{i=1}^N P_i} \times 100 \quad (3)$$

where N is the number of values, P is the in situ observed precipitation, \bar{P} is the average P for the considered period, SPE is the precipitation estimate of the considered SPEs, and \bar{SPE} is the average of the values of the SPE parameters for the considered period.

2.3.2.2. Monthly Comparison

The monthly time step analysis used the CC, %RMSE, and %B Equations (1)–(3) for both the Mean Regional and the Mean Spatial datasets. Previous studies assessing SPEs (e.g., [26,39–41,55]) have used the following reference values to define acceptable monthly results: $CC \geq 0.7\%$; $RMSE \leq 50\%$; and %B between -10% to 10%. In order to facilitate the SPEs potential inter-comparison, results are also presented in the form of a Taylor diagram [56]. The Taylor diagram shows the standard deviation (STD), CC, and the centered RMSE (RMSEc) values Equation (4) normalized (divided) by the reference STD.

$$RMSEc(\%) = \frac{\sqrt{\frac{\sum_{i=1}^N \{(SPE_i - \bar{SPE}) - (P_i - \bar{P})\}^2}{N}}}{\frac{\sum_{i=1}^N P_i}{N}} \times 100 \quad (4)$$

In the Taylor diagram, the reference is presented by a black dot where the STD and the CC are equal to 1 and the RMSEc is equal to 0. Therefore, the closer the SPEs' statistics are to the reference values, the closer their estimates are to the observed precipitation values. Additionally,

for all considered SPEs, the CC, %RMSE, and %B are computed for all the grid-cells including at least one gauge. This aims to provide more details in the statistical score obtained from the Mean Regional datasets. The monthly analysis is performed for each dataset (Mean Regional and Mean Spatial) considering the whole period and the dry and wet season separately.

2.3.2.3. Daily Comparison

The daily time step analysis also used the CC, %RMSE, and %B Equations (1)–(3) for both the Mean Regional and the Mean Spatial datasets. Results are presented in the form of a Taylor diagram to facilitate the SPEs potential inter-comparison. Additionally, SPEs were also evaluated based on categorical statistics considering precipitation events as discrete values with only two possible cases (rainy day or not). Four cases are possible: (a) both SPEs and rain gauge register a precipitation event; (b) only the SPEs reports precipitation; (c) only the rain gauge registers precipitation; and (d) precipitation is not reported on either SPEs or rain gauge. After dividing data into these four classes, it was possible to calculate the probability of detection (POD), the false alarm ratio (FAR), the Critical Success Index (CSI), and the bias (B) using the following equations:

$$POD = \frac{a}{(a + c)} \quad (5)$$

$$FAR = \frac{b}{(a+b)} \quad (6)$$

$$CSI = \frac{a}{(a + b + c)} \quad (7)$$

$$B = \frac{(a + b)}{(a + c)} \quad (8)$$

POD, FAR, and CSI vary from 0 to 1. For POD, 1 is the perfect score and indicates the SPEs' capacity to correctly detect precipitation within the study area. CSI also has a perfect score of 1, which represents the ratio between rain events correctly detected by the SPEs and the total rain events reported by the SPEs and the rain gauges. FAR has 0 as a perfect score, and is an indicator of how much the SPEs wrongly report precipitation when it does not occur. The success ratio ($SR = 1 - FAR$) can be derived from FAR, having 1 as a perfect score. Different to POD, FAR, and CSI, B does not vary from 0 to 1. Rather, this index takes 1 as a reference value. If B is higher than 1, it indicates overestimation of the number of rain events within the SPEs product in the studied period, while values lower than 1 indicate underestimation.

A synthesis diagram was also prepared to facilitate the comparison between the categorical statistics of all considered SPEs. The performance diagram [57] builds a response surface from the geometric relationship between the POD, CSI, SR, and B, where the results of each assessed SPEs scenario are plotted. This type of analysis has been conducted in previous studies [26,58], and considerably helps to interpret the global performance of the results. The daily analysis is done for each dataset (Mean Regional and Mean Spatial) considering the whole period and the dry and wet season separately.

3. Results

3.1. Annual Analysis

Figure 2a presents the 2015 annual precipitation maps registered by the SPEs and the gauges. According to the gauge observations, the study area presents a marked west–east gradient, with the highest (lowest) precipitation occurring over the western (eastern) part (Figure 2a). Annual precipitation ranges from 800 to 1500 mm. Despite an overall underestimation of precipitation, with %B close to -20%, GSMAp (0.1° and 0.25°) captured the gradient (Figure 2a,b).

On the other hand, IMERG had difficulties identifying the gradient, presenting smaller annual precipitation variability over the study area when compared to GSMAp, with annual precipitation values between 1000 and 1400 mm. TMPA also had difficulties identifying the local gradient and registered even smaller spatial variability, with annual values ranging between 1100 and 1300 mm, resulting in worse statistics when compared to the precipitation gauges. Moreover, the CC results presented statistical significance for all evaluated SPEs ($p\text{-value} < 0.01$), except for TMPA, in Figure 2.

Despite the SPEs respective ability to represent the regional precipitation pattern, Figure 2 allows an inter-comparison of the potential of SPEs to estimate the annual precipitation amount. When comparing the GPM-based amount. Indeed, in the Taylor diagram (Figure 2c), GSMAp and IMERG for the 0.25° grid are closer to the reference dot than TMPA, which locates farther from the reference dot than all the considered SPEs and resolutions. Interestingly, passing from 0.1° to 0.25° resolution enhances the quality of IMERG's and GSMAp's annual precipitation estimates with a slightly increase (decrease) of the CC (%RMSE). This could be because the lower resolution tends to smooth the annual precipitation and thus to produce better results.

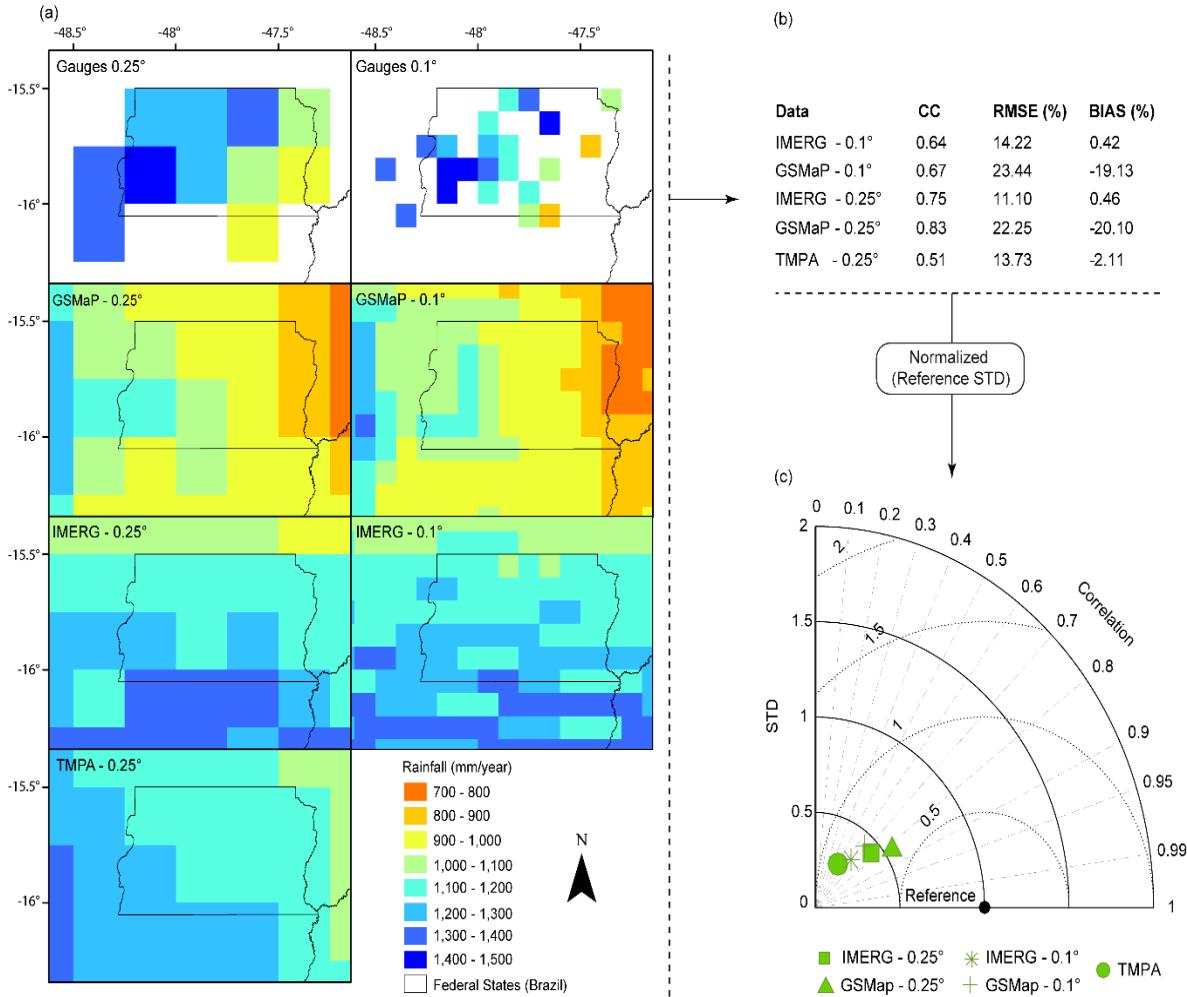


Figure 2. 2015 mean spatial annual precipitation registered by satellite precipitation estimates (SPEs) and gauges (a) and accuracy expressed in statistical metrics; (b) summarized in the form of a Taylor diagram with values normalized by the reference standard deviation (STD); (c). IMERG: Integrated Multi-satellitE Retrievals for Global Precipitation Measurement; GSMap: Global Satellite Mapping of Precipitation; TMPA: Tropical Rainfall Measurement Mission (TRMM) Multi-satellite Precipitation Analysis; RMSE: root-mean-square error.

3.2. Monthly Analysis

Figure 3 shows the potential of SPEs for reproducing monthly mean regional precipitation for the inter-seasonal and for both the dry and wet seasons. The SPEs are able to capture the seasonal cycle from April 2014 to November 2016 with marked dry (from May to September) and wet (from October to April) seasons, following the reference's monthly seasonal tendency (Figure 3a,b).

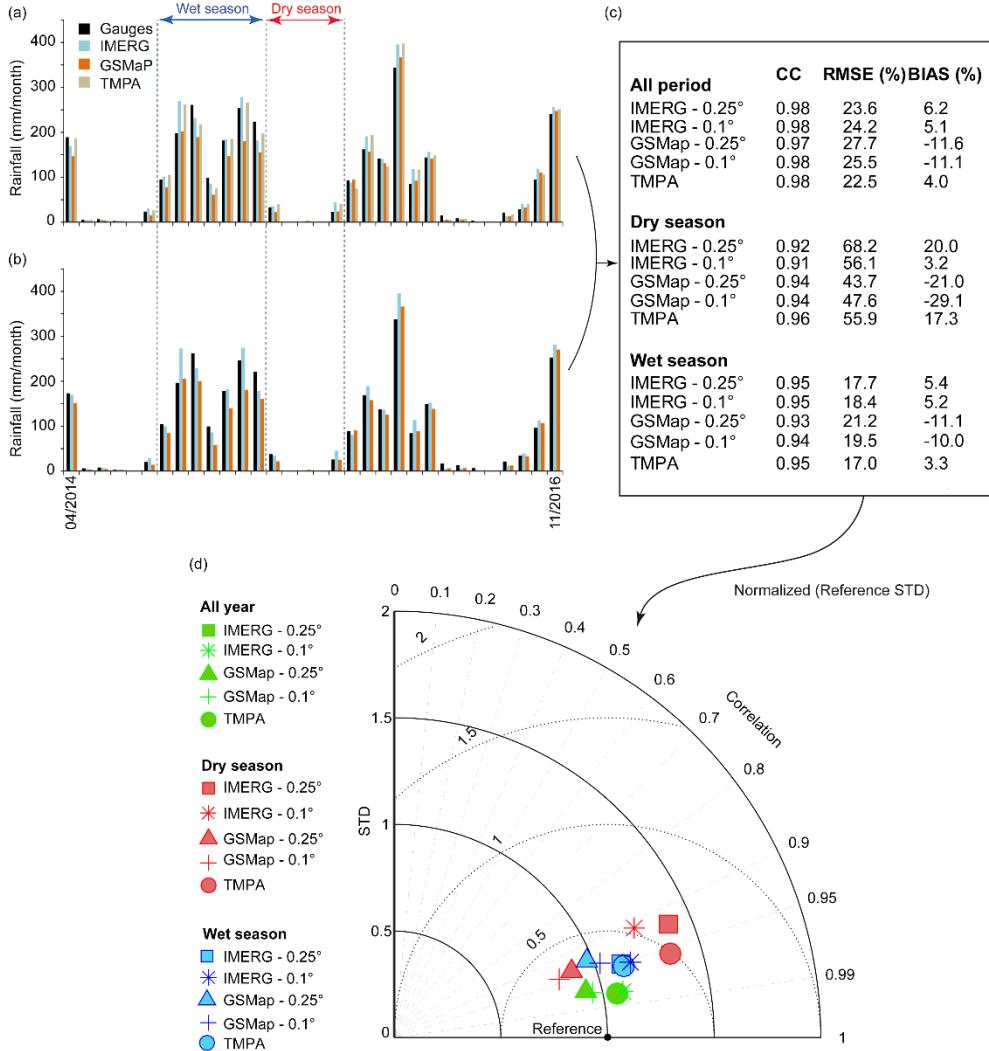


Figure 3. Mean regional monthly precipitation: values from the 0.25° (a) and 0.1° (b) grids; statistical results (c) and the Taylor diagram (d).

Figure 3c presents the mean regional monthly CC, %RMSE, and %B for all considered SPEs, and Figure 3d presents the Taylor diagram, which is intended to facilitate the inter-comparison of SPE potential. The CC values presented in Figure 3 were statistically significant ($p\text{-value} < 0.01$) for all considered SPEs and scenarios. In the inter-seasonal analysis, all SPEs performed better than during both wet and dry seasons. Indeed, in the Taylor diagram, all SPEs' relative positions are closer to the reference dot for the inter-seasonal dataset. Concerning inter-seasonal evaluation, all values, except the %B for GSMap (0.1° and 0.25° grids), are within the established quality threshold ($\text{CC} \geq 0.7$; $\% \text{RMSE} < 50\%$ and $-10\% < \% \text{B} < 10\%$). As observed for the annual time step, GSMap tends to underestimate the precipitation amount, with a %B of approximately

-10% for both 0.1° and 0.25° spatial resolution. Overall, the new GPM-based SPEs presented similar statistics to TRMM-based SPEs in the inter-seasonal analysis, especially IMERG. This can be visually checked in the Taylor diagram, in which all SPEs present very close relative position to the reference dot (Figure 3d). Aggregating IMERG and GSMap datasets from 0.1° to 0.25° slightly improved their accuracy, with lower %RMSE and %B for both SPEs.

During the dry season, all SPEs achieved the established quality threshold for CC (CC 0.7), with CC systematically superior to 0.9 and the highest value obtained for TMPA (CC = 0.96). Regarding the %RMSE, only GSMap achieved the established quality threshold (%RMSE < 50). However, the %RMSE values of IMERG (0.1°) and TMPA (%RMSE = 56%) are very close. With a %B value of 3.2, only IMERG (0.1°) achieved the acceptable quality threshold (-10 < %B < 10%). TMPA and IMERG (0.25°) overestimate the regional monthly precipitation amount, whereas GSMap (0.1° and 0.25°) underestimates the regional monthly precipitation (Figure 3). Despite a significant precipitation underestimation for GSMap 0.1° and 0.25° , with %B of -29.1% and -21%, respectively, GSMap can capture monthly regional precipitation more accurately during the dry season. Indeed, as observed in the Taylor diagram, GSMap is closer to the reference dot than all other considered SPEs. On the contrary, IMERG is the least efficient SPE, having the farthest position from the dot reference in the Taylor diagram. It is worth mentioning that aggregating from 0.1° to 0.25° increased (decreased) GSMap's (IMERG's) %RMSE and %B.

During the wet season, all considered SPEs present CC, %RMSE, and %B values that are within the established quality threshold (CC ≥ 0.7 ; %RMSE < 50%; and -10% < %B < 10%) with CC values systematically superior to 0.92 and %RMSE values systematically inferior to 22%. The %B of GSMap (0.25°) was the only exception (%B = 11.1%), confirming the tendency of GSMap to underestimate monthly regional precipitation amounts, as observed for the inter-seasonal and the dry season. Despite the %B statistics, all SPEs performed similarly, as illustrated in the Taylor diagram, where their positions relative to the reference dot are very close (Figure 3d). Finally, SPEs performed better during the wet season than during the dry season. As illustrated in Figure 3d, SPEs are closer to the reference dot for the wet season than for the dry season.

Figure 4 presents the spatial variability of monthly statistics within the study area for the inter-seasonal temporal scale in the form of %RMSE, %B, and CC for IMERG, GSMap, and TMPA. It is worth mentioning that only the 0.25° spatial resolution was considered, as similar results were obtained for the 0.1° and 0.25° resolutions for the previous annual and mean monthly regional assessments. It is possible to notice that most of the assessed grid-cells present %RMSE

< 50%, achieving the established quality threshold. TMPA and IMERG present the same %RMSE pattern, whereas GSMAp presents two additional grid-cells with %RMSE between 50 and 75%. Regarding the %B, TMPA (GSMAp) is the SPE with the highest (lowest) proportion of grid-cell, with %B within the established threshold (-10% < %B < 10%). IMERG and TMPA present a similar spatial distribution of %B, with some grid-cells overestimating the reference. On the other hand, GSMAp underestimated precipitation, with negative %B over most of the considered grid-cells. Regarding the CC, all SPEs systematically present values within the defined quality threshold (CC > 0.7). All CC values presented statistical significance (p-value < 0.01) in Figure 4c,d). IMERG and TMPA presented the same CC pattern over the region, with CC superior to 0.8 over all of the considered region.

Figure 4d shows the SPEs' statistics based on the Mean Spatial dataset in the form of the Taylor diagram. It aims to summarize observations from Figure 4a–c to quantify the SPEs' potential to reproduce monthly precipitation in space for the inter-seasonal, dry, and wet seasons. With relative position closer to the reference dot, all SPEs performed better at the inter-seasonal temporal scale than on a seasonal basis. At the inter-seasonal scale, the new GPM-based SPEs present similar statistics to the TRMM-based SPEs. All three SPEs presented satisfactory statistical scores, with %RMSE, %B, and CC within the defined quality threshold except for GSMAp, which slightly underestimates the precipitation amount (%B = -11.5). Considering the seasonal scale (wet and dry seasons), all SPEs are more efficient during the wet season than during the dry season. From the wet to the dry season, %RMSE is more than three times greater for all SPEs, %B is twice as large for GSMAp and four times as large for both IMERG and TMPA, while a similar decrease in CC is observed for all SPEs. Consequently, none of the considered SPEs presents an %RMSE or %B value within the established quality threshold.

For all the considered temporal scales (inter-seasonal, wet season, dry season), the new GPM-based SPEs presented similar statistics to TRMM-based SPEs, especially IMERG. Indeed, the positions of IMERG and TMPA in the Taylor diagram are very close, and they both present similar %B values. In the Taylor diagram, GSMAp is systematically slightly farther to the reference dot than IMERG and TMPA, highlighting an overall lower ability to represent mean monthly precipitation in space. The main difference between GSMAp and both IMERG and TMPA occurs in terms of %B, with GSMAp underestimating precipitation amount.

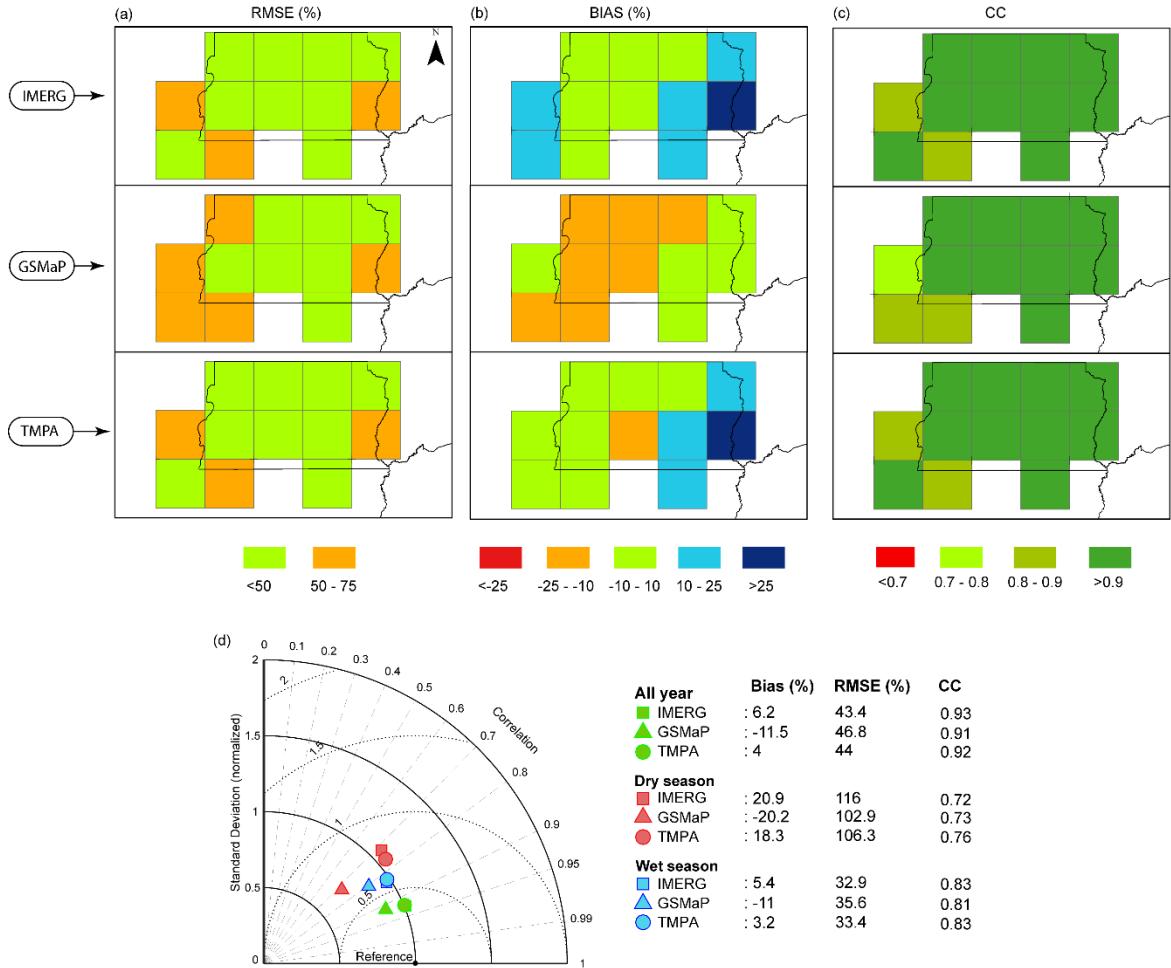


Figure 4. Study area: local percent root-mean-square error (%RMSE) (a), percent bias (%B) (b), and correlation coefficient (CC); (c) for IMERG, GSMap, and TMPA for the inter-seasonal scale, and Taylor diagram using the Mean Monthly datasets (d).

3.3. Daily Analysis

The daily analysis results are illustrated in Figure 5. The daily quantitative results are summarized in the form of a Taylor diagram for both Mean Regional (Figure 5a) and Mean Spatial (Figure 5c) precipitation datasets. The daily contingency assessment is summarized in the form of a performance diagram for both Mean Regional (Figure 5b) and Mean Spatial (Figure 5d) precipitation datasets.

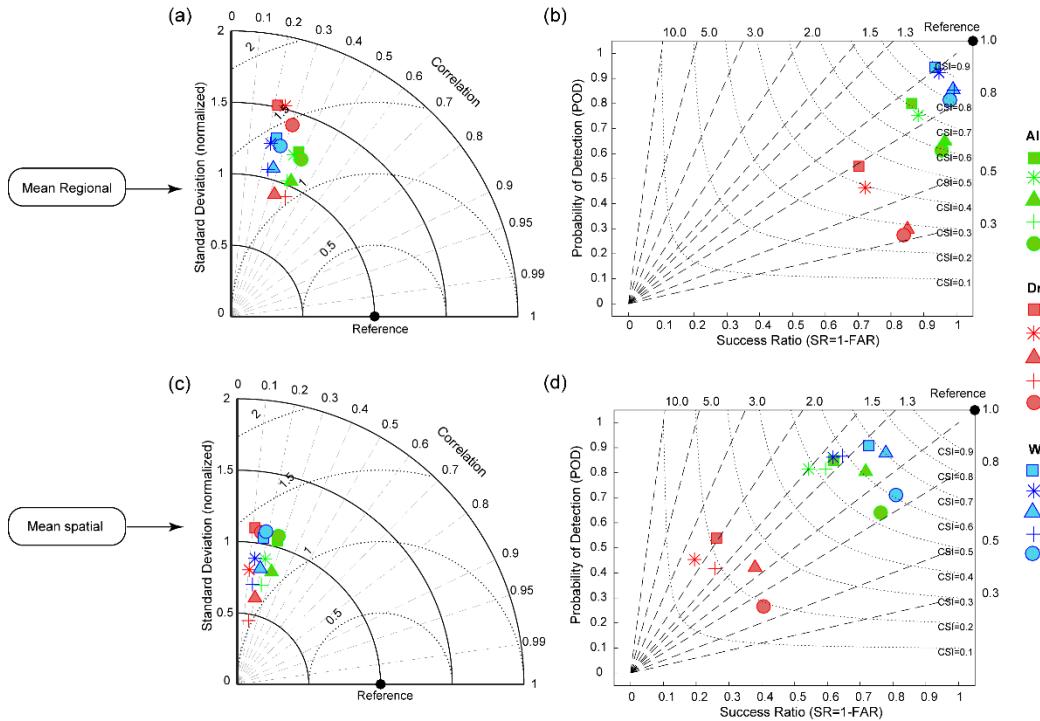


Figure 5. Mean Regional dataset daily Taylor (a) and performance; (b) diagrams, and Mean Spatial dataset Taylor; (c) and performance; (d) diagrams for: IMERG (0.1°); GSMap (0.1°); IMERG (0.25°); GSMap (0.25°); and TMPA.

The Taylor diagram shows an overall low performance for all SPEs and both Mean Regional (Figure 5a) and Mean Spatial (Figure 5c) precipitation datasets. Indeed, all SPEs registered very low CC values, which were systematically inferior to 0.4 and 0.5 for the Mean Regional and Mean Spatial datasets, respectively. All CC values presented statistical significance ($p\text{-value} < 0.01$) in Figure 5a,c). Aggregation from 0.1° to 0.25° did not significantly improve the considered statistical metrics. Still, as observed previously in the monthly assessment, the wet season presents better statistics than the dry season and the best results are obtained for the inter-seasonal temporal scale. IMERG presents similar statistics to TMPA, with close positions on the Taylor diagram (Figure 5a,c), and GSMap appears as the most effective SPE, with closer position to the reference dot on the Taylor diagram for all considered temporal scales (inter-seasonal, wet, and dry seasons).

Different to the daily quantitative statistical results, whose performance was unsatisfactory, as reported in the Taylor diagram (Figure 5a,c), all SPEs present a good ability to detect daily precipitation events (Figure 5b,d). The statistical scores are represented in the form of a performance diagram, in which geometric relationships between POD, SR, B, and CSI facilitate the intercomparisons between the SPEs. The closer the SPEs are to the right-hand top corner

black dot, the higher is the SPEs' potential to detect daily precipitation events. Overall, IMERG presented the best statistical scores according to the performance diagram for the Mean Regional dataset assessment (Figure 5b), while GSMAp presented the best results considering the Mean Spatial dataset (Figure 5d).

The ability of SPEs for detecting precipitation events is seasonally dependent. Indeed, for both datasets (Mean Regional and Mean Spatial), the best scores in the performance diagram are reached during the wet period, whereas the lowest scores are reached during the dry season. On the other hand, intermediate scores are reached for the inter-seasonal scale. Interestingly, aggregating IMERG and GSMAp from the 0.1° grid to the 0.25° grid yielded better results considering the Mean Spatial dataset, whereas no significant changes were observed considering the Mean Regional dataset. Comparing IMERG and GSMAp with TMPA for the 0.25° grid shows an improvement in the ability of SPEs to detect precipitation events from the TRMM-based SPEs to the GPM-based algorithms. Indeed, IMERG and GSMAp are systematically located closer to the reference dot on the performance diagram than TMPA.

4. Discussion

In the present study, the potential of the last-released GPM-based SPEs, IMERG and GSMAp, was compared to the widely used TRMM-based TMPA SPEs. The analysis was performed considering different time steps (annual, monthly, and daily) and considering the potential seasonal effect over their precipitation estimates.

For the monthly time step, the consideration of fixed quality-threshold values highlighted the ability of SPEs to correctly capture monthly regional precipitation pattern in space and time. However, high CC values with unsatisfactory %B can occur independently of the considered SPEs, which is in line with previous studies [24,26,59]. According to our results, a bias correction of approximately 10% is recommended before using GSMAp to follow monthly precipitation amounts. The negative bias of GSMAp supports the results of a previous study over Bolivia where GSMAp-v6 presented a %B of approximately -22.4% [26]. The lowest %B value in the present study (-10%) may be the result of the improvement of the gauge calibration applied to produce the considered GSMAp-v7.

However, the inter-comparison exercise between SPEs conducted over distinct regions remains challenging and should be considered with caution. Indeed, due to the difference in spatial scale between areal (SPEs grid-cell) and point (gauges) measurement, potential conclusions using rain gauges as reference data are influenced by the gauges' locations and distribution density [26,60].

Precipitation events estimated by the SPEs may not be detected by the gauges, as it might rain in other location within the grid-cell area [26,55]. Therefore, part of the variability in the ability of SPEs to predict precipitation from one study to another could be attributed to the distribution density and location of the gauges used as references. In this study, data from the 56 rain gauges were aggregated into twelve 0.25° grid-cells (mean of 4.7 gauges per 0.25° grid-cell) with one grid-cell using up to 10 stations to calculate the reference average precipitation, whereas the 56 gauges were aggregated into forty 0.1° grid-cells joining a maximum of four gauges within a grid-cell (mean of 1.4 gauges per 0.1° grid-cell) (Figure 1d,e). In this context, the gauges managed to better capture the precipitation variability for the coarser grid (0.25°) than for the finer grid (0.1°). Therefore, the aggregation from 0.1° to 0.25° slightly enhanced the quality of SPEs from IMERG and GSMAp for both monthly and daily time steps, confirming previous results [26]. To provide more insight on the conclusion reliability regarding SPEs' sensitivity to the rain gauges density, Figure 6 shows the statistical score (RMSE normalized) obtained in function of the gauge number used as reference to compare with the SPEs at the 0.25° grid-cell scale. For both daily and monthly time step, the SPEs accuracy increase with the number of gauges used as reference (Figure 6a,b). For example, at the daily time step, highest (1) and lowest (0) RMSE values are obtained for grid-cells counting with 1 and 10 gauges, respectively, for both IMERG and GSMAp (Figure 6a). Similarly, at the monthly time scale and for all SPEs, higher normalized RMSE is obtained when only one gauge is used as reference (Figure 6b). Therefore, different conclusion on SPEs' reliability should be drawn when using more or less dense rain gauges network as reference.

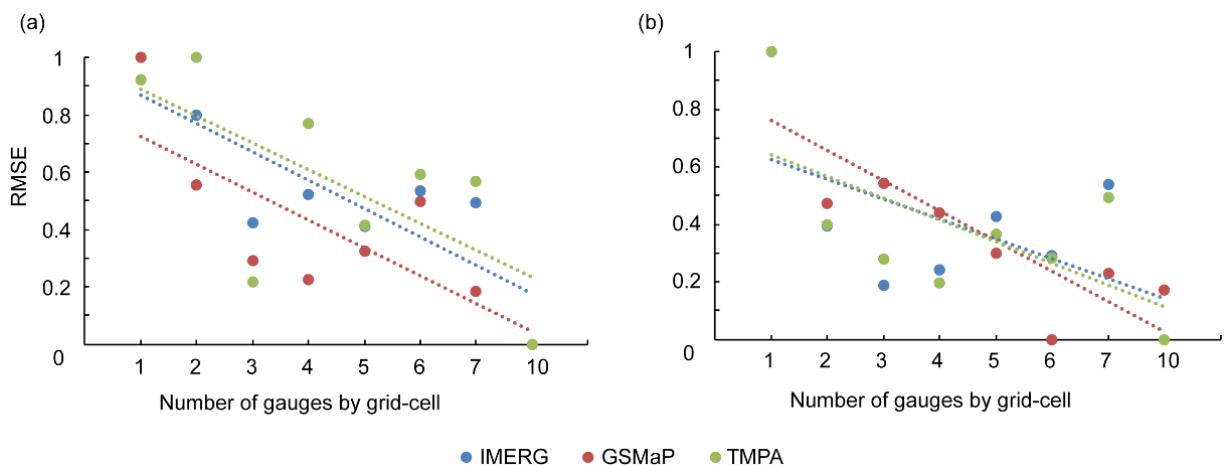


Figure 6. Gauges number influence onto the SPEs accuracy expressed in term of normalized RMSE between 0 and 1. The analysis is applied for the 0.25° grid-cells scale at both daily (a) and monthly (b) time step. Dotted line shows the linear trends.

It is worth mentioning that part of the variability observed in Figure 6 could also be attributed (i) to the gauges distribution into the considered grid-cells and (ii) to the consideration of different grid-cells for the different gauge number threshold (Figure 1). Therefore, Figure 6 illustrates the potential influence of gauge density into the SPEs' reliability conclusion and more studies should be developed to clearly state on gauge density influence.

To avoid any influence of the gauge density and/or distribution on the conclusion regarding the SPEs' reliability, the SPEs could be used as forcing data in hydrological modeling. Indeed, comparing simulated streamflow using SPEs as forcing data with observed streamflow aims to enhance the quality of spatial representativeness between the assessed SPEs and the reference used [34].

Additionally, the different dataset, metrics, and time scale used from one study to another complicate the inter-comparison exercise between SPEs conducted over distinct regions. Actually, as shown in the present study, the conclusions regarding the potential of SPEs differ according to the considered dataset (Mean Regional or Mean Spatial). For both the monthly and daily time steps, the SPEs appear to be globally more accurate when considering the Mean Regional dataset compared to the Mean Spatial dataset. Secondly, as observed for the daily time step, the conclusions regarding the potential of SPEs vary according to the considered metrics: quantitative (Taylor diagram) or categorical (performance diagram). SPEs were able to correctly detect daily precipitation events (categorical metrics) but failed to retrieve daily precipitation amounts (quantitative metrics). Finally, the consideration of different time scales (inter-seasonal, wet, and dry season) reveals a strong seasonal influence on the potential of SPEs, with SPEs performing better during the wet season than during the dry season for both monthly and daily time steps. This finding is in line with previous studies reporting on the influence of season on the potential of SPEs [24,26,58,61]. Evaluated independently, the time scale may influence the conclusion regarding the potential of the SPEs. For the above-detailed reasons, the use of variable datasets, metrics, and time scales should introduce important discrepancy on the conclusion regarding the potential of SPEs obtained from one study to another. Therefore, studies on the potential of SPEs to predict precipitation for a determined region should not be used to determine the performance of SPEs for another region, and the assessment of potential of SPEs proves to be an essential step before their use in impact studies.

Finally, according to the presented results, the SPEs appear to be unsuitable for following the monthly precipitation dynamic during the dry season. However, this observation has to be weighted. Indeed, the mean monthly precipitation values for the dry season are very low (Figure 3). Therefore, a minimum error in precipitation estimates will automatically induce very large

%RMSE and %B. Actually, even if large %RMSE and %B are observed for the dry season, these errors are insignificant regarding the total annual precipitation input over the Brazilian Central Plateau, where the dry months contribute less than 15% of the annual total precipitation. The relatively high and satisfactory CC values (>0.7) obtained by all the considered SPEs mean that the SPEs correctly capture the monthly precipitation dynamics, even during the dry season. Interestingly, during the dry season, higher distribution is observed in both the Taylor and performance diagrams, meaning that SPEs' sensitivity to low precipitation amounts or low number of precipitation events (dry season) differs more than to high precipitation amounts or large number of precipitation events (wet season). According to this study, GSMAp is the most adapted SPE to follow daily and monthly precipitation dynamics during the dry seasons over the Brazil Central Plateau region. However, as discussed before, a bias correction is strongly recommended.

5. Conclusions

This study evaluated the performance of the new GPM-based SPEs in the Brazilian Central Plateau region, using data from precipitation gauges as reference. The assessment compared IMERG and GSMAp at their original 0.1° spatial resolution and used an adjusted/refitted 0.25° grid to compare them with TMPA on an annual, monthly, and daily basis. The major conclusions are:

- Generally, GPM-based SPEs products (IMERG, GSMAp) are able to ensure precipitation monitoring with similar or even better accuracy than that obtained previously with TRMM-based TMPA products in the Brazilian Central Plateau.
- IMERG presents the best annual and monthly results in nearly all metrics used in the analysis for all considered temporal scales (inter-seasonal, wet, and dry season).
- GSMAp precipitation estimations presented negative bias for monthly and annual precipitation amounts for all considered time scales (inter-seasonal, wet, and dry season). A bias correction of approximately 10% is recommended for monthly time step.
- For the daily time step, all SPEs correctly detected precipitation events but considerably failed in the quantification of daily precipitation amount. Among the considered SPEs, GSMAp presented the highest ability for detecting and quantification of daily precipitation events.

- Despite the differences between IMERG and GSMAp, their results indicate an improvement in detecting precipitation events from TRMM-based SPEs to GPM-based SPEs.
- The potential of all SPEs presented a strong seasonal variability. For both the daily and monthly time steps, all SPEs performed better during the wet season than during the dry season. The new GPM-based SPEs, IMERG and GSMAp, still have difficulty in estimating precipitation in the dry period, when precipitation events are generally less intense, of lower volume, and more sparsely distributed across the territory. Among the considered SPEs, GSMAp presents the highest ability for monthly and daily precipitation monitoring during the dry season.

More generally, this study also shows that the SPEs' reliability conclusion is sensitive to the density of the rain gauges used as reference. Indeed, more optimist/pessimist conclusions on SPEs' reliability should be drawn if considering denser/scarcer gauge network. Similarly, SPEs' reliability conclusions depend on the considered indicator. Different conclusions on SPEs' reliability can be drawn according to the considered assessment. In this line, future study should focus on the impacts of modeling sensitivity to various SPEs to assess their reliability in a more applicative context. However, for the time being, only four years of data are available for IMERG and GSMAp, which compromises robust calibration/validation steps for impact models.

Author Contributions: Conceptualization, L.S., F.S. and H.R.; Data curation, L.S., F.S., D.O. and W.F.; Formal analysis, L.S., F.S. and H.R.; Funding acquisition, T.A.; Investigation, L.S. and F.S.; Methodology, L.S., F.S. and H.R.; Project administration, L.S.; Resources, H.R., T.A., D.O. and W.F.; Software, H.R.; Supervision, H.R.; Validation, H.R. and T.A.; Visualization, L.S.; Writing—original draft, L.S. and F.S.; Writing—review and editing, L.S., F.S. and H.R.

Funding: This research received no external funding.

Acknowledgments: We thank ADASA, ANA, CAESB, and INMET for providing the rain gauge data.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Saeed, F.; Bethke, I.; Fischer, E.; Legutke, S.; Shiogama, H.; Stone, D.A.; Schleussner, C.-P. Robust changes in tropical rainy season length at 1.5 °C and 2 °C. *Environ. Res. Lett.* **2018**, *13*, 1–12. [CrossRef]

2. Fischer, E.M.; Knutti, R. Anthropogenic contribution to global occurrence of heavy-precipitation and high-temperature extremes. *Nat. Clim. Chang.* **2015**, *5*, 560. [CrossRef]
3. Li, J.D.; Heap, A. Spatial Interpolation Methods: A Review for Environmental Scientists; Geoscience Australia: Camberra, Australia, 2008; ISBN 9781921498282.
4. Scheel, M.L.M.; Rohrer, M.; Huggel, C.; Santos Villar, D.; Silvestre, E.; Huffman, G.J. Evaluation of TRMM Multi-satellite Precipitation Analysis (TMPA) performance in the Central Andes region and its dependency on spatial and temporal resolution. *Hydrol. Earth Syst. Sci.* **2011**, *15*, 2649–2663. [CrossRef]
5. Sun, Q.; Miao, C.; Duan, Q.; Ashouri, H.; Sorooshian, S.; Hsu, K.-L. A review of global precipitation data sets: data, sources, estimation, and intercomparisons. *Rev. Geophys.* **2018**, *56*, 79–107. [CrossRef]
6. Levizzani, V.; Amorati, R.; Meneguzzo, F. A review of satellite-based rainfall estimation methods; ISAC-CNR: Bologna, Italy, 2002.
7. Kidd, C.; Levizzani, V. Status of satellite precipitation retrievals. *Hydrol. Earth Syst. Sci.* **2011**, *15*, 1109–1116. [CrossRef]
8. Tian, Y.; Peters-Lidard, C.D.; Eylander, J.B.; Joyce, R.J.; Huffman, G.J.; Adler, R.F.; Hsu, K.-L.; Turk, F.J.; Garcia, M.; Zeng, J. Component analysis of errors in satellite-based precipitation estimates. *J. Geophys. Res.* **2009**, *114*, D24101. [CrossRef]
9. Huffman, G.J.; Adler, R.F.; Bolvin, D.T.; Nelkin, E.J. The TRMM Multi-satellite Precipitation Analysis (TMPA). *Satell. Rainfall Appl. Surf. Hydrol.* **2010**, *3*–22.
10. Joyce, R.J.; Janowiak, J.E.; Arkin, P.A.; Xie, P. CMORPH: A Method that Produces Global Precipitation Estimates from Passive Microwave and Infrared Data at High Spatial and Temporal Resolution. *J. Hydrometeorol.* **2004**, *5*, 487–503. [CrossRef]
11. Sorooshian, S.; Hsu, K.-L.; Gao, X.; Gupta, H.V.; Imam, B.; Braithwaite, D. Evaluation of PERSIANN System Satellite-Based Estimates of Tropical Rainfall. *Bull. Am. Meteorol. Soc.* **2000**, *81*, 2035–2046. [CrossRef]
12. Ushio, T.; Sasashige, K.; Kubota, T.; Shige, S.; Okamoto, K.; Aonashi, K.; Inoue, T.; Takahashi, N.; Iguchi, T.; Kachi, M.; et al. A Kalman Filter Approach to the Global Satellite Mapping of Precipitation (GSMap) from Combined Passive Microwave and Infrared Radiometric Data. *J. Meteorol. Soc. Japan* **2009**, *87*, 137–151. [CrossRef]
13. Hou, A.R.; Kakar, R.K.; Neeck, S.; Azarbarzin, A.A.; Kummerow, C.D.; Kojima, M.; Oki, R.; Nakamura, K.; Iguchi, T. The global precipitation measurement mission. *Bull. Am. Meteorol. Soc.* **2014**, *95*, 701–722. [CrossRef]

14. Huffman, G.J.; Bolvin, D.T.; Braithwaite, D.; Hsu, K.; Joyce, R.; Kidd, C.; Nelkin, E.J.; Xie, P. Algorithm Theoretical Basis Document (ATBD) Version 4.5: NASA Global Precipitation Measurement (GPM) Integrated Multi-satellitE Retrievals for GPM (IMERG); NASA: Greenbelt, MD, USA, 2015.
15. Huffman, G.; Bolvin, D.; Braithwaite, D.; Hsu, K.; Joyce, R.; Kidd, C.; Nelkin, E.J.; Sorooshian, J.T.; Xie, P. Algorithm Theoretical Basis Document (ATBD) Version 5.2: NASA Global Precipitation Measurement (GPM) Integrated Multi-satellitE Retrievals for GPM (IMERG); NASA: Greenbelt, MD, USA, 2018.
16. Maggioni, V.; Meyers, P.C.; Robinson, M.D. A Review of Merged High-Resolution Satellite Precipitation Product Accuracy during the Tropical Rainfall Measuring Mission (TRMM) Era. *J. Hydrometeorol.* **2016**, *17*, 1101–1117. [CrossRef]
17. Sun, W.; Ma, J.; Yang, G. Statistical and Hydrological Evaluations of Multi-Satellite Precipitation Products over Fujiang River Basin in Humid Southeast China. *Remote Sens.* **2018**, *10*, 1898. [CrossRef]
18. Liu, Z. Comparison of Integrated Multisatellite Retrievals for GPM (IMERG) and TRMM Multisatellite Precipitation Analysis (TMPA) Monthly Precipitation Products: Initial Results. *J. Hydrometeorol.* **2016**, *17*, 777–790. [CrossRef]
19. Prakash, S.; Mitra, A.K.; Pai, D.S.; AghaKouchak, A. From TRMM to GPM: How well can heavy rainfall be detected from space? *Adv. Water Resour.* **2016**, *88*, 1–7. [CrossRef]
20. Prakash, S.; Mitra, A.K.; AghaKouchak, A.; Liu, Z.; Norouzi, H.; Pai, D.S. A preliminary assessment of GPM-based multi-satellite precipitation estimates over a monsoon dominated region. *J. Hydrol.* **2018**, *556*, 865–876. [CrossRef]
21. Chen, F.; Li, X. Evaluation of IMERG and TRMM 3B43 monthly precipitation products over Mainland China. *Remote Sens.* **2016**, *8*, 472. [CrossRef]
22. Tang, G.; Ma, Y.; Long, D.; Zhong, L.; Hong, Y. Evaluation of GPM Day-1 IMERG and TMPA Version-7 legacy products over Mainland China at multiple spatiotemporal scales. *J. Hydrol.* **2016**, *533*, 152–167. [CrossRef]
23. Wang, Z.; Zhong, R.; Lai, C.; Chen, J. Evaluation of the GPM IMERG satellite-based precipitation products and the hydrological utility. *Atmos. Res.* **2017**, *196*, 151–163. [CrossRef]
24. Tan, M.L.; Duan, Z. Assessment of GPM and TRMM precipitation products over Singapore. *Remote Sens.* **2017**, *9*, 720. [CrossRef]
25. Sharifi, E.; Steinacker, R.; Saghafian, B. Assessment of GPM-IMERG and Other Precipitation Products against Gauge Data under Different Topographic and Climatic Conditions in Iran: Preliminary Results. *Remote Sens.* **2016**, *8*, 135. [CrossRef]

26. Satgé, F.; Xavier, A.; Zolá, R.; Hussain, Y.; Timouk, F.; Garnier, J.; Bonnet, M.-P. Comparative Assessments of the Latest GPM Mission's Spatially Enhanced Satellite Rainfall Products over the Main Bolivian Watersheds. *Remote Sens.* **2017**, *9*, 369. [CrossRef]
27. Mahmoud, M.T.; Hamouda, M.A.; Mostafa, M. Spatiotemporal evaluation of the GPM satellite precipitation products over the United Arab Emirates. *Atmos. Res.* **2019**, *219*, 200–212. [CrossRef]
28. Xu, R.; Tian, F.; Yang, L.; Hu, H.; Lu, H.; Hou, A. Ground validation of GPM IMERG and TRMM 3B42v7 rainfall products over southern Tibetan Plateau based on high-density rain gauge network. *J. Geophys. Res. Atmos.* **2017**, *122*, 910–924. [CrossRef]
29. Sahlu, D.; Nikolopoulos, A.I.; Moges, S.A.; Anagnostou, E.N.; Hailu, D. First Evaluation of the Day-1 IMERG over the Upper Blue Nile Basin. *J. Hydrometeorol.* **2016**, *17*, 2875–2882. [CrossRef]
30. Tan, J.; Petersen, W.A.; Kirstetter, P.-E.; Tian, Y. Performance of IMERG as a Function of Spatiotemporal Scale. *J. Hydrometeorol.* **2017**, *18*, 307–319. [CrossRef] [PubMed]
31. Kim, K.; Park, J.; Baik, J.; Choi, M. Evaluation of topographical and seasonal feature using GPM IMERG and TRMM 3B42 over Far-East Asia. *Atmos. Res.* **2017**, *187*, 95–105. [CrossRef]
32. Wei, G.; Lü, H.; Crow, W.T.; Zhu, Y.; Wang, J.; Su, J. Evaluation of satellite-based precipitation products from IMERG V04A and V03D, CMORPH and TMPA with gauged rainfall in three climatologic zones in China. *Remote Sens.* **2018**, *10*, 30. [CrossRef]
33. Zhao, H.; Yang, S.; You, S.; Huang, Y.; Wang, Q.; Zhou, Q. Comprehensive evaluation of two successive V3 and V4 IMERG final run precipitation products over Mainland China. *Remote Sens.* **2018**, *10*, 34. [CrossRef]
34. Satgé, F.; Ruelland, D.; Bonnet, M.; Molina, J.; Pillco, R. Consistency of satellite-based precipitation products in space and over time compared with gauge observations and snow-hydrological modelling in the Lake Titicaca region. *Hydrol. Earth Syst. Sci.* **2019**, *23*, 595–619. [CrossRef]
35. Tan, M.L.; Santo, H. Comparison of GPM IMERG, TMPA 3B42 and PERSIANN-CDR satellite precipitation products over Malaysia. *Atmos. Res.* **2018**, *202*, 63–76. [CrossRef]
36. Anjum, M.N.; Ding, Y.; Shangguan, D.; Ahmad, I.; Ijaz, M.W.; Farid, H.U.; Yagoub, Y.E.; Zaman, M.; Adnan, M. Performance evaluation of latest integrated multi-satellite retrievals for Global Precipitation Measurement (IMERG) over the northern highlands of Pakistan. *Atmos. Res.* **2018**, *205*, 134–146. [CrossRef]

37. Wang, C.; Tang, G.; Han, Z.; Guo, X.; Hong, Y. Global intercomparison and regional evaluation of GPM IMERG Version-03, Version-04 and its latest Version-05 precipitation products: Similarity, difference and improvements. *J. Hydrol.* **2018**, *564*, 342–356. [CrossRef]
38. Jiang, S.; Ren, L.; Xu, C.; Yong, B.; Yuan, F.; Liu, Y.; Yang, X. Statistical and hydrological evaluation of the latest Integrated Multi-satellitE Retrievals for GPM (IMERG) over a midlatitude humid basin in South China. *Atmos. Res.* **2018**, *214*, 418–429. [CrossRef]
39. Chen, C.; Chen, Q.; Duan, Z. Multiscale Comparative Evaluation of the GPM IMERG v5 and TRMM 3B42 v7 Precipitation Products from 2015 to 2017 over a Climate Transition Area of China. *Remote Sens.* **2017**, *944*. [CrossRef]
40. Fang, J.; Yang, W.; Luan, Y.; Du, J.; Lin, A.; Zhao, L. Evaluation of the TRMM 3B42 and GPM IMERG products for extreme precipitation analysis over China. *Atmos. Res.* **2019**, *223*, 24–38. [CrossRef]
41. Yuan, F.; Wang, B.; Shi, C.; Cui, W.; Zhao, C.; Liu, Y.; Ren, L.; Zhang, L.; Zhu, Y.; Chen, T.; et al. Evaluation of hydrological utility of IMERG Final run V05 and TMPA 3B42V7 satellite precipitation products in the Yellow River source region, China. *J. Hydrol.* **2018**, *567*, 696–711. [CrossRef]
42. Yuan, F.; Zhang, L.; Min, K.; Soe, W.; Ren, L.; Zhao, C. Applications of TRMM- and GPM-Era Multiple-Satellite Precipitation Products for Flood Simulations at Sub-Daily Scales in a Sparsely Gauged Watershed in Myanmar. *Remote Sens.* **2019**, *11*, 140. [CrossRef]
43. Rozante, R.; Id, D.A.V.; Chiquetto, B. Evaluation of TRMM/ PM Blended Daily Products over Brazil. *Remote Sens.* **2018**, *10*, 882. [CrossRef]
44. Beck, H.E.; Pan, M.; Roy, T.; Weedon, G.P.; Pappenberger, F.; Van Dijk, A.I.J.M.; Huffman, G.J.; Adler, R.F.; Wood, E.F. Daily evaluation of 26 precipitation datasets using Stage-IV gauge-radar data for the CONUS. *Hydrol. Earth Syst. Sci.* **2019**, *23*, 207–224. [CrossRef]
45. Satgé, F.; Hussain, Y.; Bonnet, M.-P.; Hussain, B.; Martinez-Carvajal, H.; Akhter, G.; Uagoda, R. Benefits of the Successive GPM Based Satellite Precipitation Estimates IMERG–V03, –V04, –V05 and GSMP–V06, –V07 Over Diverse Geomorphic and Meteorological Regions of Pakistan. *Remote Sens.* **2018**, *10*, 1373. [CrossRef]
46. Lu, D.; Yong, B. Evaluation and Hydrological Utility of the Latest GPM IMERG V5 and GSMP V7 Precipitation Products over the Tibetan Plateau. *Remote Sens.* **2018**, *10*, 2022. [CrossRef]
47. Ratter, J.A.; Ribeiro, J.F.; Bridgewater, S. The Brazilian Cerrado Vegetation and Threats to its Biodiversity. *Ann. Bot.* **1997**, *80*, 223–230. [CrossRef]

48. Ribeiro, J.F.; Walter, B.M.T. Fitofisionomias do bioma Cerrado. In *Cerrado: ambiente e flora*; Sano, S.M., Almeida, S.P., Eds.; EMBRAPA-CPAC: Planaltina, Brazil, 1998; p. 556.
49. Lapola, D.M.; Martinelli, L.A.; Peres, C.A.; Ometto, J.P.H.B.; Ferreira, M.E.; Nobre, C.A.; Aguiar, A.P.D.; Bustamante, M.M.C.; Cardoso, M.F.; Costa, M.H.; et al. Pervasive transition of the Brazilian land-use system. *Nat. Clim. Chang.* **2014**, *4*, 27–35. [CrossRef]
50. Feltran-Barbieri, R.; Crouzeilles, R.; Strassburg, B.B.N.; Brooks, T.; Feltran-barbieri, R.; Iribarrem, A.; Crouzeilles, R.; Loyola, R.; Latawiec, A.E.; Filho, F.J.B.O.; et al. Moment of truth for the Cerrado hotspot. *Nat. Ecol. Evol.* **2017**, *1*, 3.
51. GsMap. Global Satellite Mapping of Precipitation (GSMaP) for GPM. Available online: https://www.eorc.jaxa.jp/GPM/doc/algorithm/GSMaPforGPM_20140902_E.pdf (accessed on 10 July 2018).
52. Kubota, T.; Shige, S.; Hashizume, H.; Aonashi, K.; Takahashi, N.; Seto, S.; Hirose, M.; Takayabu, Y.N.; Ushio, T.; Nakagawa, K.; et al. Global Precipitation Map Using Satellite-Borne Microwave Radiometers by the GSMAp Project: Production and Validation. *IEEE Trans. Geosci. Remote Sens.* **2007**, *45*, 2259–2275. [CrossRef]
53. Huffman, G.J.; Bolvin, D.T.; Nelkin, E.J.; Wolff, D.B.; Adler, R.F.; Gu, G.; Hong, Y.; Bowman, K.P.; Stocker, E.F. The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-Global, Multiyear, Combined-Sensor Precipitation Estimates at Fine Scales. *J. Hydrometeorol.* **2007**, *8*, 38–55. [CrossRef]
54. Huffman, G.J.; Bolvin, D.T. TRMM and Other Data Precipitation Data Set Documentation; NASA: Greenbelt, MD, USA, 2015.
55. Hussain, Y.; Satgé, F.; Hussain, M.B. Performance of CMORPH, TMPA, and PERSIANN rainfall datasets over plain, mountainous, and glacial regions of Pakistan. *Theor. Appl. Climatol.* **2018**, *131*, 1119–1132. [CrossRef]
56. Taylor, K.E. Summarizing multiple aspects of model performance in a single diagram. *J. Geophys. Res.* **2001**, *106*, 7183–7192. [CrossRef]
57. Roebber, P.J. Visualizing Multiple Measures of Forecast Quality. *Weather Forecast.* **2009**, *24*, 601–608. [CrossRef]
58. Oliveira, R.; Maggioni, V.; Vila, D.; Morales, C. Characteristics and Diurnal Cycle of GPM Rainfall Estimates over the Central Amazon Region. *Remote Sens.* **2016**, *8*, 20. [CrossRef]
59. Yuan, F.; Zhang, L.; Win, K.; Ren, L.; Zhao, C.; Zhu, Y.; Jiang, S.; Liu, Y. Assessment of GPM and TRMM Multi-Satellite Precipitation Products in Streamflow Simulations in a Data-Sparse Mountainous Watershed in Myanmar. *Remote Sens.* **2017**, *9*, 302. [CrossRef]

60. Tang, G.; Behrangi, A.; Long, D.; Li, C.; Hong, Y. Accounting for spatiotemporal errors of gauges: A critical step to evaluate gridded precipitation products. *J. Hydrol.* **2018**, *559*, 294–306. [CrossRef]
61. Ning, S.; Wang, J.; Jin, J.; Ishidaira, H. Assessment of the Latest GPM-Era High-Resolution Satellite Precipitation Products by Comparison with Observation Gauge Data over the Chinese Mainland. *Water* **2016**, *8*, 481. [CrossRef]

CAPÍTULO 3**SENSORIAMENTO REMOTO PARA AVALIAR O IMPACTO DA
EVAPOTRANSPIRAÇÃO REAL NA UMIDADE DO SOLO EM DIFERENTES
CAMADAS AO LONGO DO PERFIL EM DIFERENTES COBERTURAS**

O artigo apresentado nesse capítulo faz uma avaliação do impacto da evapotranspiração real (ET_r) na umidade do solo em diferentes camadas ao longo do perfil em área de pastagem, reflorestamento e vegetação nativa no bioma Cerrado. A importância deste estudo no contexto da Tese de doutorado consiste em gerar conhecimento relacionado à ET_r e ao uso de água por culturas agrícolas, florestais e pela vegetação nativa utilizando o sensoriamento remoto como ferramenta de análise, visando contribuir com o monitoramento ambiental e com manejo da água e do solo no bioma Cerrado.

Salles, L.A.; Senay, G; Lima, J.E.F.W.; Roig, H.L.; Neumann, M.R.B.; Malta, E.A. Remote sensing to evaluate the impacts of actual evapotranspiration on soil moisture dynamics through the rooting zone in areas with pasture, forest plantation and native vegetation at the Brazilian Cerrado.

REMOTE SENSING TO EVALUATE THE IMPACTS OF ACTUAL EVAPOTRANSPIRATION ON SOIL MOISTURE DYNAMICS THROUGH THE ROOTING ZONE IN AREAS WITH PASTURE, FOREST PLANTATION AND NATIVE VEGETATION AT THE BRAZILIAN CERRADO

ABSTRACT

This study aims to evaluate the impacts of actual evapotranspiration (ET_a) on soil moisture dynamics through the rooting zone in three different sites at the Brazilian Cerrado region using remote sensing and ground-based measurements. The analysis applied the Operational Simplified Energy Balance (SSEBop) model in Landsat 7 and Landsat 8 images to calculate the ET_a and the FAO 56 guidelines for computing crop water requirements to estimate crop evapotranspiration (ET_c) from soil moisture samples collected in the rooting zone. The samples were obtained in six depths up to 3.0m at three different sites: pasture, forest plantation and native vegetation. Then, it was assessed how the ET_a correlates to the ET_c which was estimated both locally, in each soil layer, and globally, from average soil moisture values. This study also evaluated the differences between ET_a and ET_c , which was simulated in each soil layer during the dry season. The results show that the area with native vegetation presented higher rates of ET_a followed by the areas with forest plantation and pasture. However, the area with native vegetation kept high magnitudes of ET_a through the dry season without reducing significantly the soil moisture up to 3.0m, while a significative impact was observed up to 0.5m and 1.0m at the pasture and the forest plantation, respectively. Moreover, the results also show that the ET_a can be validated with ET_c measurements, being also an alternative to ungauged basins and for monitoring multiple consumptive uses.

Keywords: Evapotranspiration; remote sensing; SSEBop; soil moisture; soil layers; Cerrado biome

1. Introduction

Evapotranspiration (ET) is an important process in the environment being directly related to the hydrologic cycle and to the energy balance, playing a major role in the exchange of mass and energy between the soil-water-vegetation system and the atmosphere. Among the major water budget components, the ET is the most difficult to measure directly since it is a gaseous state (Senay *et al.*, 2016). At a field scale, ET can be measured using Bowen ratio, eddy covariance, and lysimeters systems which are limited to homogeneous areas, without advective climatic

conditions (Gowda *et al.*, 2008). Remote sensing can help overcome these limitations providing calculation of ET over wide areas with mixed landscape types (Glenn *et al.*, 2010). In this context, several modeling approaches to estimate actual evapotranspiration (ET_a) using remote sensing data were developed over the last decades (Kalma *et al.*, 2008; Gowda *et al.*, 2008; Glenn *et al.*, 2010).

Among these methods there are those which use land-surface temperature derived from thermal infrared (TIR) imagery as principal variable, and are based on the surface energy balance method. The physical basis of the energy-based land-surface models used to estimate ET has made them subject to intense research in the hydrological, atmospheric and remote sensing communities (Overgaard *et al.*, 2005). They include the Surface Energy Balance Index (SEBI) (Menenti and Choudhury, 1993), Two Source Model (TSM) (Norman *et al.*, 1995), Surface Energy Balance Algorithm for Land (SEBAL) (Bastiaanssen *et al.*, 1998), Surface Energy Balance System (SEBS) (Su, 2002), Atmosphere-Land Exchange Inverse (ALEXI) (Anderson *et al.*, 2007), Mapping Evapotranspiration at high Resolution with Internalized Calibration (METRIC) (Allen *et al.*, 2007), Simplified Surface Energy Balance (SSEB) (Senay *et al.*, 2007) and the Operational Simplified Energy Balance (SSEBop) (Senay *et al.*, 2013). Methods based on the surface energy balance and other remote sensing ET models are comprehensively summarized for readers in previous review papers (e.g. Kalma *et al.*, 2008; Gowda *et al.*, 2008; Glenn *et al.*, 2010).

While some ET models were developed with high complexity solving the different hydrological mechanism and processes, others have simplified structures, bringing benefits for operational application over large areas (Ji *et al.*, 2019). SSEBop is an example of a simple but robust method which was developed under assumptions that facilitated parameterization required in previous models (e.g. SSEB, SEBAL and METRIC), using predefined boundary conditions for hot and cold reference pixels in operational applications over large areas and under different hydro-climatic conditions (Senay *et al.*, 2013). Since SSEBop's first application in Senay *et al.* (2013), the model has been successfully evaluated under different consumptive uses, at both field and watershed scales and in multiple temporal resolutions (e.g. Singh *et al.*, 2014; Chen *et al.*, 2016; Senay *et al.*, 2016; Singh and Senay, 2016; Alemayehu *et al.*, 2017; Senay *et al.*, 2017; Senay, 2018, Ji *et al.*, 2019; Lopes *et al.*, 2019; Paula *et al.*, 2019; Schauer and Senay, 2019). Most of these studies were developed in the United States of America but there has also been interest of using SSEBop in other regions of the world. For instance, two recent papers evaluated SSEBop in Brazil. Lopes *et al.* (2019) evaluated the performance of SSEBop in irrigated areas planted with wheat, while Paula *et al.* (2019) assessed soybean and bean crops at the Brazilian Cerrado region. Furthermore, Brazil's National Water Agency (Agência Nacional de Águas (ANA)) has

just released SSEBop-BR which is an application for monitoring ET_a in irrigated areas using the Earth Engine platform in the Brazilian territory (Brazil, 2020).

Despite the inherent interest to evaluate the performance of remote sensing ET models in irrigated areas, knowledge of how ET_a varies in different physiognomies of native vegetation and in other non-irrigated activities, such as pasture and forest plantations, is also relevant to provide an integrated management of water resources with land use and occupation. A great deal of effort has been made in this direction over the last decades. For instance, Lima *et al.* (2001) assessed the ET_a of a small watershed under natural conditions of the Brazilian Cerrado biome from the water budget perspective, while Quesada *et al.* (2004), Oliveira *et al.* (2005) and Quesada *et al.* (2008) investigated relations between soil water dynamics and ET in different physiognomies of the Cerrado. Moreover, the energy balance has been assessed in areas with eucalyptus (Cabral *et al.*, 2010), pasture (Meirelles *et al.*, 2011) and cerrado (Giambelluca *et al.*, 2009; Cabral *et al.*, 2015) using Eddy covariance systems. Furthermore, other studies such as Silva *et al.* (2015) and Oliveira *et al.* (2018) used SEBAL and METRIC to assess the ET_a dynamics in areas with native vegetation and with agricultural activities, respectively.

In a similar way, the present analysis also aims at using remote sensing to understand how ET impacts the environment in tropical regions. Most of the studies that used the above-mentioned remote sensing ET models had their performance evaluated from measurements made by either Bowen ratio or Eddy covariance systems (e.g. Silva *et al.*, 2015; Oliveira *et al.*, 2018; Lopes *et al.*, 2019; Paula *et al.*, 2019). However, these systems require investments that are not usually available, especially in development regions and over multiple land use. This ends up demanding other alternatives to evaluate ET_a from remote sensing in ungauged regions, such as models based on soil moisture measurements. In addition, the association of ET_a from remote sensing with soil moisture measurements through the profile can enhance knowledge about ET and soil water dynamics in tropical regions. Therefore, an approach that uses remote sensing together with ground-based measurements from areas with native vegetation, pasture and forest plantation is proposed to validate ET models and to evaluate the relationships between ET_a and soil moisture dynamics through the rooting zone. As known so far, the performance of SSEBop has not been assessed in these types of land covers in Brazil, therefore this analysis offers an opportunity to accomplish this intent, considering the applicability of SSEBop over large continental areas and in multiple hydro-climatic conditions. Besides that, this study proposes an alternative to use remote sensing ET models in ungauged basins, thus being of great importance to provide an integrated management of water resources with land use and occupation.

In this context, the objective of the present study consists in using remote sensing to analyze the relationships between ET_a and soil moisture dynamics through the rooting zone (0-3m) in two non-irrigated areas (pasture and forest plantation) and in a forest physiognomy from the Cerrado biome, in Brazil's Central Plateau region. The seasonal behavior of ET_a is analyzed in order to understand its impacts on soil moisture during the dry season. Furthermore, the study also assesses the applicability of the ET model based on ground-based soil moisture measurements to validate the ET_a from remote sensing model.

2. Data

2.1. Study area

The study area is located in the central region of the Cerrado Biome, in the Federal District, Brazil (Figure 1). More specifically, the study was developed at the Cerrados Agricultural Research Center, which belongs to the Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA Cerrados) and is located in Planaltina (15°35'30"S e 47°42'30"W), Federal District, Brazil. The study sites are composed by the following land covers: pasture, forest plantation and a forest physiognomy of Cerrado biome (Figure 1a). The site with pasture is formed by *Brachiaria* sp., while the site with forest plantation was planted with *Eucalyptus* sp. under a system that integrates crop-livestock-forest. In turn, the site with native vegetation is classified as *Cerradão* and is situated at EMBRAPA Cerrados' *Cerradão* Ecological Reserve.

The EMBRAPA Cerrados is situated at the São Bartolomeu river basin, which is located in the upper part of the Paraná river basin (Figure 1b). Two other important South American river basins make frontier in this region: São Francisco and Tocantins-Araguaia. The climate is classified as Aw (Köppen classification), which is a tropical climate with two well defined seasons: a dry winter from May to September and a rainy summer in the remaining months (Figure 1d). The rainy season accounts for more than 90% of average annual precipitation (~1,500 mm).

The study area is located in the Cerrado biome (Figure 1c), in the Brazilian Central Plateau region. The Cerrado biome has approximately $2 \cdot 10^6 \text{ km}^2$, which represents ~23% of the Brazilian territory. It is exceeded in terms of area only by the Amazon and is composed of a mosaic of grass fields, savanna, and forest vegetation formations (Ratter *et al.*, 1997; Ribeiro and Walter, 1997), with more than 12,000 vascular plants (Mendonça *et al.*, 2008). However, the Brazilian Cerrado was listed as a biodiversity hotspot where exceptional concentrations of endemic species are undergoing exceptional loss of habitat (Myers *et al.*, 2000). In 2013, 43.4% of the Cerrado was converted by some type of anthropic activity (Sano *et al.*, 2019). By contrast, the Cerrado is at the front line of crop and livestock production when compared to other biomes, and there is

still a productivity gap between the most efficient and average producers, implying that production might well be further boosted (Rada, 2013). Soybean, which is extensively produced in the Cerrado, plays a major role in Brazil's grain production (Brazil, 2017), making the country the second-largest global producer over the last years, according to the Food and Agricultural Organization (FAO) (<http://faostat.fao.org/>).

All three study sites are located in areas with Ferralsols (Figure 1e), which is an important soil class to the Cerrado biome covering more than 50% its area (Reatto *et al.*, 1998). These soils play an important role on groundwater recharge due to its intrinsic characteristics which allow the development of important porous aquifers and recharge areas for fractured aquifers (Campos *et al.*, 2006). In general, most of the porous aquifers within the Federal District region are homogeneous, have great lateral extension and thickness between 15 and 25m (Campos, 2004). Furthermore, the samples from each study site were collected near the same contour line (Figure 1e) in order to assure the same hydrogeologic context.

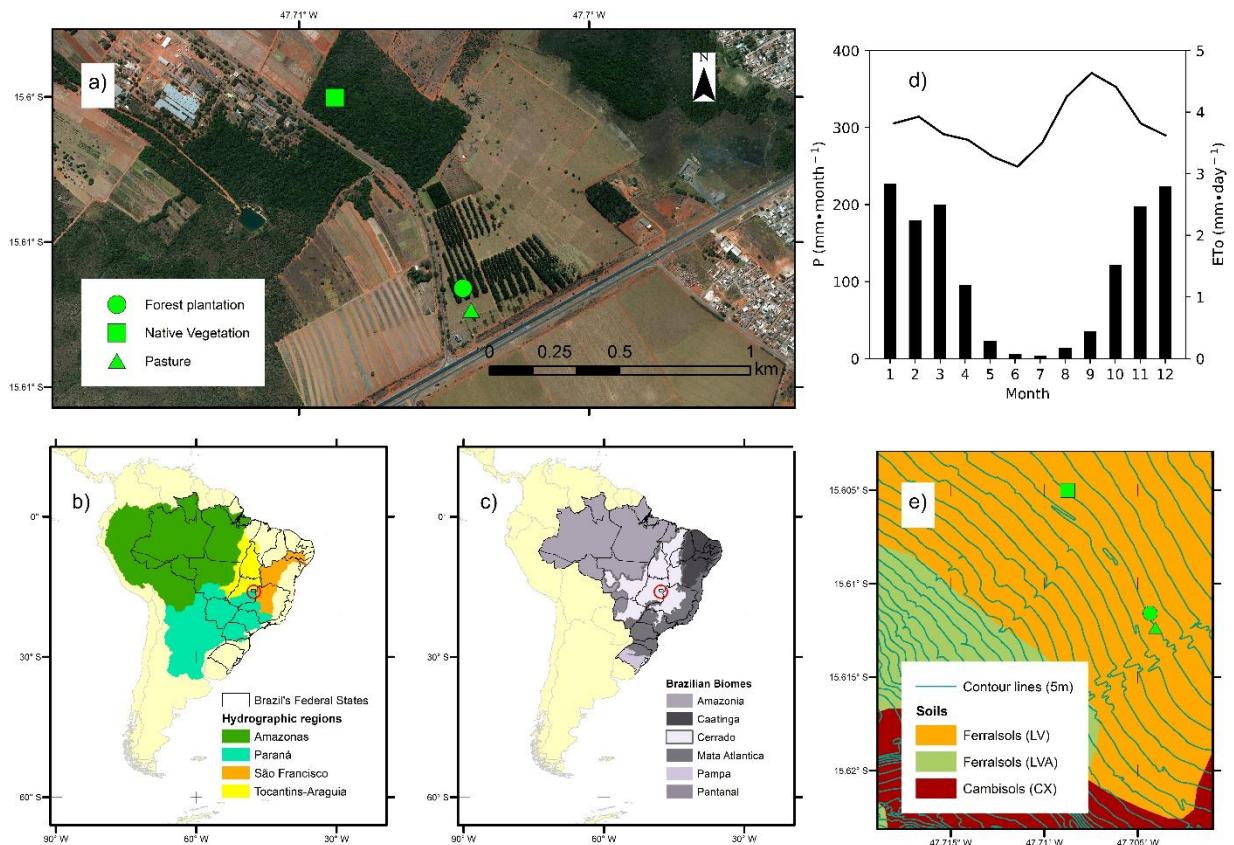


Figure 1: Location map of the study area.

2.2. Input datasets

Forty-six Landsat 7 and Landsat 8 images were download (Path 221, Row 71) from the Tier 1 collection, between 10/28/2014 and 01/11/2016. The thermal band (band 6 in Landsat 7 and band 10 in Landsat 8) was used to compute the land surface temperature (T_s), while the red and the near-infrared bands were used to calculate the Normalized Difference Vegetation Index (NDVI). Other remote sensing modeling inputs includes the SRTM digital elevation model and a gridded meteorological dataset from Xavier *et al.* (2016). The meteorological data is derived from the interpolation of the data collected by the Brazilian national weather stations network into 0.25° grid from January 1981 to July 2017. It includes the maximum air temperature (T_a) and the Penman-Montheith reference evapotranspiration (ET_o) that is needed for model parametrization.

2.3. Ground-based validation datasets

The ground-based validation datasets were collected between October 2014 and April 2016, in three different sites in EMBRAPA Cerrados (Figure 1) and were shared by EMBRAPA Cerrados` Hydrometric Laboratory for this research. In each study area, core soil samples were collected with an auger, in order to obtain soil moisture data through the profile in the rooting zone (0-3m). The data were collected in each site with an average interval of 15 days, at six different soil depths: 0.25m; 0.75m; 1.25m; 1.75m; 2.25m; and 2.75m. At the forest plantation, the samples were collected in the center of the zone planted with trees within the integrated system, where their canopy significantly shaded out other plants, and their roots dominated the soil profile. On the other two sites, the area was homogeneously covered by the pasture and the native vegetation simplifying the data collection procedure.

The soil moisture was derived from the samples using the gravimetric water content approach, by measuring the difference between the sample's weight before and after oven-drying them at 110°C for 24hrs. In order to derive the soil moisture data into a soil water stress coefficient through the modeling approach applied in the present study, other soil physical proprieties were necessary besides the soil water content. Soil bulk density data were used to transform the gravimetric water content in volumetric content. The soil's field capacity and permanent wilting point were generated from the soil water retention curve and were used to determine the soil water stress coefficient (k_s). All these ground-based soil measurements were made in EMBRAPA-Cerrados and were shared with this research (Lima, 2010).

2.4. Other ancillary datasets

In situ ET_a data from irrigated fields collected near the EMBRAPA Cerrados and within the same Landsat image (Path 221, Row 71) were also used to assess the results from the remote sensing modeling approach. These point-scale validation datasets were collected by Paula *et al.* (2019) between November/2014 and February/2016, with Bowen ratio meteorological stations. This period corresponds to the same period which the ground-based validation datasets were sampled in EMBRAPA Cerrados. Two areas were planted with soybeans in the warm (wet) season and the other area was planted with beans during the dry season. In Paula *et al.* (2019), SSEBop was applied using Landsat images and displayed good agreement with the Bowen ratio data. However, it was decided to evaluate again the performance of SSEBop with the current inputs, since there were some differences in the model's parametrization. For instance, this study used the gridded meteorological dataset (Xavier *et al.*, 2016) while previous studies used point data from the Brazilian National Institute of Meteorology (Instituto Nacional de Meteorologia - INMET). The intention in this assessment was to provide an independent evaluation of the ET_a from SSEBop, before evaluating the integration of the remote sensing model with the ET derived from the soil moisture modeling approach.

3. Methodology

3.1. The SSEBop modeling approach

The Operational Simplified Energy Balance (SSEBop) model was developed with a modeling approach which allowed to compute ET_a in a simple way over continental areas, proposing, for a given grid-cell, a predefined reference value (dT) to the difference between the limiting conditions of hot ("dry") and cold ("wet") (Senay *et al.*, 2013). Senay *et al.* (2018) demonstrated that the Satellite Psychrometric Approach (SPA), which creates a "surface" psychrometric constant that is unique to a location and day-of-year, explains the SSEBop model more effectively rather than the energy balance principle because SSEBop does not solve all terms of the surface energy balance such as sensible and ground-heat fluxes. Nevertheless, the setup remained practically the same in Senay (2018), only substituting the clear-sky condition by a solution based on an average-sky net radiation energy balance. In the presented study, both SSEBop clear-sky (Senay *et al.*, 2013) and average-sky (Senay, 2018) conditions were initially assessed in order to evaluate their behavior in the study area. Senay *et al.* (2017) proposed a new method to compute a unique *c* factor for every image, based on a set of constraints and statistical analysis that establish the well-watered vegetated grid-cells per-image. This was necessary to

obtain a parametrization which considered the dynamics for each image instead of capturing seasonality or spatial pattern of ET variation through a median reference characterization, which was used in previous studies (Senay, 2017). Despite the brief overview on the SSEBop setup presently presented, readers can refer to Senay *et al.* (2013) for full details on the model parameters and to Senay *et al.* (2017) and Senay (2018) to have more details on the statistical c-factor and average-sky propositions, respectively.

The SSEBop model computes daily total actual evapotranspiration (ET_a) as a product of ET fractions generated from land surface temperature and reference ET (ET_o), using Eq.1:

$$ET_a = ET_o * k * ET_f \quad (1)$$

where ET_o is the grass reference ET for a location, k is the coefficient to scale the ET_o to the maximum of ET for an aerodynamically rougher crop such as alfalfa; and ET_f is the ET fraction. In this study, k was defined as 1.25 (Senay *et al.*, 2013, Senay *et al.*, 2017). The ET_f is calculated using Eq. 2:

$$ET_f = \frac{T_h - T_s}{dT} = \frac{(T_c + dT) - T_s}{dT} = 1 - \frac{T_s - T_c}{dT} \quad (2)$$

where T_s (K) is the satellite-observed land surface temperature of the grid-cell; T_c (K) is the estimated T_s at the idealized “cold/wet” boundary; dT is a pre-defined temperature difference between T_h and T_c for each grid-cell; and T_h (K) is the estimated T_s at the idealized “hot/dry” boundary limit and is obtained by adding dT (K) to T_c (K), as presented in Eq. 2 ($T_h = T_c + dT$). T_h is proposed for a bare, dry soil where ET is assumed to be zero and sensible heat is assumed to be maximum (Senay *et al.*, 2013, Singh *et al.*, 2014, Senay *et al.*, 2016, Senay *et al.*, 2017, Senay, 2018). The dT values are unique for each grid-cell and day of the year, calculated under clear-sky (Senay, 2013) or under an average-sky (Senay, 2018) condition.

The cold/wet limiting condition, T_c , is calculated from the maximum air temperature (T_a) based on the assumption that T_a is equal to T_c for well-watered vegetated grid-cells, where all the available energy is used for latent heat flux. In order to follow this assumption, Senay *et al.* (2013) recommends a correction coefficient (c factor) which defines the T_c boundary as a fraction of T_a , as presented in Eq. 3:

$$T_c = c * T_a \quad (3)$$

where c is the c factor that relates T_a to T_s on a well-watered, fully transpiring vegetation surface; and T_a (K) is the corresponding daily maximum air temperature. The c factor is calculated dynamically on a per-image basis (Senay *et al.*, 2017), using Eq. (4):

$$c = \frac{T_{s_cold}}{T_a} \quad (4)$$

where T_{s_cold} (K) is the satellite-based T_s at the well-watered vegetated grid-cell. Senay *et al.* (2017) established a set of constraints to define T_{s_cold} in Eq. (4) through an automated process of determining a statistical c factor for each image. This creates an initial c factor called T_{corr} which is then masked by the following conditions, which were adapted from Senay *et al.* (2017): 1) $0.8 \leq NDVI \leq 1$; 2) $T_s > 270$ K; 3) the difference between T_a and T_s (T_{diff}) greater than 0 and smaller or equal to 10K; 4) at least 50 cloud-free pixels that meet the above parameter requirements. Finally, the c factor was determined from the resulting T_{corr} distribution using Eq. 5:

$$c = T_{corr_mean} \quad (5)$$

where T_{corr_mean} is the spatial mean of T_{corr} in the image which satisfy the criteria above, in order to automatically calibrate the c factor for the wettest and greenest locations. Senay *et al.* (2017) propose using the mean of T_{corr} minus two standard deviations of T_{corr} grid-cells ($c = T_{corr_mean} - 2SD$). However, the parametrization led us to use the mean of T_{corr} selected in the image which satisfies the criteria above to automatically calibrate the c factor.

3.2. Landsat 7 and 8 data processing

Landsat 7 and Landsat 8 images were used to compute ET_a with the SSEBop model. The land surface temperature (T_s) values were derived from Landsat 7 and Landsat 8 thermal bands, which correspond to the Enhanced Thematic Mapper Plus (ETM+) band 6 (VCID 1) and to the Thermal Infrared Sensor (TIRS) band 10, respectively. The present study followed the methods to process Landsat images for ET_a as proposed in previous studies (Singh *et al.*, 2014; Senay *et al.*, 2016; Senay *et al.*, 2017; Senay *et al.*, 2018). They include commonly used calibration procedures and atmospheric correction techniques having calculation steps for: 1) spectral radiance conversion to the at-sensor brightness temperature; 2) atmospheric absorption and re-emission value; 3) surface emissivity; and 4) land surface temperature (Senay *et al.*, 2016). The T_s values were computed using a modified equation (Allen *et al.*, 2007), with Eq. 6:

$$T_s = \frac{K_2}{\ln\left(\frac{\varepsilon_{NB} * K_1}{R_c} + 1\right)} \quad (6)$$

where K_1 and K_2 are prelaunch calibration constants; ε_{NB} is the narrow band emissivity computed with a NDVI-based algorithm proposed by Sobrino *et al.* (2004); and R_c is the corrected thermal radiance, using assumptions reported in Allen *et al.* (2007) of the algorithm given by Wukelic *et al.* (1989). The consistency of Eq. 6 in space and time is more important than getting the absolute magnitude correct, since the T_s is applied as a relative ET_f between the “cold/wet” (T_c) and the “hot/dry” (T_h) boundary limits (Senay *et al.*, 2016). The quality assessment band was used to select only clear grid-cells to calculate the c factor.

Because of the rainy season, most of the images downloaded between October and April presented cloud contamination which brought problems to the parameterization of the remote sensing modeling approach and were removed from the analysis, after evaluating each image individually and using the quality band as selecting criteria.

Therefore, most of the remote sensing data used in this assessment refer to the 2015 dry season from May and September (73.7%). Despite the presence of clouds, the analysis still maintained some images from the rainy season in order to also evaluate the ET_a in this period. The evaluation was firstly made with the quality band and followed by an individual image by image analysis of the results reducing the 46 initial images to 29 and then to 19, respectively. Singh *et al.* (2014) suggested 10 to 12 images to represent the annual hydrological behavior in the Colorado river basin after cloud filtering.

3.3. The soil moisture modeling approach

The guidelines for computing crop water requirements (FAO 56) (Allen *et al.*, 1998) with the single crop coefficient approach was used to estimate ET from the soil moisture data. This method gives the crop ET (ET_c) as the product of the reference ET (ET_o) with a crop coefficient (k_c), which relates the plants growing season to the amount of ET in standard conditions, and a water stress coefficient (k_s) that describes the effect of water stress on crop transpiration (Allen *et al.*, 1998). The crop ET from the single crop coefficient approach is given by Eq. 7:

$$ET_c = ET_o * k_c * k_s \quad (7)$$

where ET_c is the crop ET ($\text{mm}\cdot\text{day}^{-1}$); ET_o ($\text{mm}\cdot\text{day}^{-1}$) is the grass reference ET for a location; k_c is the crop coefficient; and k_s is the soil water stress coefficient. The ET_o is calculated with the Penman-Monteith equation. Since the soil was covered at the three sites during the study period and the single crop coefficient integrates both crop transpiration and soil evaporation into a single crop coefficient, the soil evaporation coefficient was not considered. The use of a constant k_c value was decided for each land cover to assess the sensitivity of the remote sensing ET_a results to the water stress coefficient variation. Thus, a k_c equal to 1.0 was used for the three land covers that were evaluated in this study (pasture, native vegetation and forest plantation). This made the variable derived from the soil moisture samples the principal source of variability in the ET_c. The soil water stress coefficient (k_s) was calculated from Bernardo *et al.* (1995), using Eq. 8:

$$k_s = \frac{\ln((SWC_V - WP) + 1)}{\ln((FC - WP) + 1)} = \frac{\ln(SWC_A + 1)}{\ln(SWC_T + 1)} \quad (8)$$

where SWC_V (mm) is the volumetric soil water content; WP (mm) is the soil moisture at the wilting point; FC (mm) is the soil moisture at the field capacity; SWC_A (mm) is the available soil

water content ($\text{SWC}_A = \text{SWC}_V - \text{WP}$) in the profile; SWC_{TA} (mm) is the total amount of soil water content available for plants in the soil profile ($\text{SWC}_T = \text{FC} - \text{WP}$). The k_s values were generated from the soil moisture data presented in section 2.3., for the three land covers evaluated in this study.

To assess the correlations between the ET derived from the available water content through the soil's profile with the ET_a generated from the remote sensing model (SSEBop), a k_s coefficient was calculated from each soil sample (0.25m; 0.75m; 1.25m; 1,75m; 2.25m; and 2.75m depths) collected through time. This produced k_s values that corresponded to the following soil layers: 1) 0 to 0.5m; 2) 0.5 to 1.0m; 3) 1.0 to 1.5m; 4) 1.5 to 2.0m; 5) 2.0 to 2.5m; 6) 2.5 to 3.0m. An average k_s value was also generated for the 0 to 1.0m, 0 to 2.0m and 0 to 3.0m soil datasets. Since the soil samples were not collected at the same date as the satellite images, a linear interpolation was done to obtain the k_s daily time series, simulating water stress coefficient values to each corresponding Landsat date used in this study. After generating the k_s time series for each land cover, the ET_c was calculated from Eq. 7 and compared to the remote sensing ET_a from Eq. 1. The analysis was performed in three steps. The first step evaluated locally the relations between the ET_a and the ET_c obtained from the k_s simulated for each 50cm soil layer. At this step, the differences of the ET_o , ET_a and ET_c were also assessed through the 2015 dry season (May to September). Then the second part assessed the global correlation between ET_a and ET_c using the average k_s for the 0 to 1.0m, 0 to 2.0m and 0 to 3.0m soil profiles. The final step consisted in developing a linear model from the results of the two last parts. In the final step, the analysis looked for the 1:1 fit between ET_a and ET_c . Therefore, different k_c values were tested for each site trying to reduce the relative bias (-1% bias < 1%). A different combination of soil layers measurements resulting in different arrays of k_s values was also considered in this step.

4. Results and discussion

4.1. SSEBop's calibration and parametrization results

Figure 2 presents the correlation results between the ET_a values calculated with SSEBop and from the Bowen ratio point-scale validation datasets provided by Paula *et al.* (2019). The CC, R^2 and the RMSE were equal to 0.933 (p-value < 0.05), 0.8697 and 0.611mm, respectively. These results indicate a good agreement between the ET_a from SSEBop and the ground-based ET measurements (Bowen ratio) at the irrigated fields (section 2.4). This assessment provided an independent calibration of the ET_a simulated with the remote sensing modeling approach, before evaluating its relations with the ET derived from the soil moisture dataset. From the different possibilities to setup SSEBop discussed in section 3.1 (clear-sky condition (Senay *et al.*, 2013),

average-sky condition (Senay *et al.*, 2018); $k = 1$ or $k = 1.25$; $\text{NDVI} \geq 0.7$ or $\text{NDVI} \geq 0.8$, etc.), SSEBop's parametrization was selected with the clear-sky condition (Senay *et al.* 2013) and using the coefficient ($k = 1.25$) to scale the ET_o to the maximum of ET for an aerodynamically rougher crop, such as alfalfa.

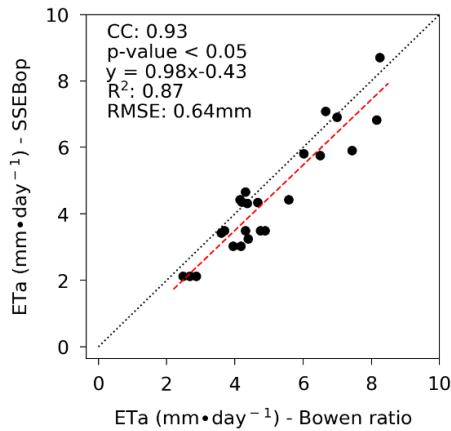


Figure 2: Correlation results between the ET_a values calculated with SSEBop and from the Bowen ratio point-scale validation datasets at irrigated fields.

Comparing the results with Paula *et al.* (2019), which used the same ET point-scale validation datasets but with different inputs to setup the SSEBop model, both studies obtained similar statistical results. However, SSEBop tended to underestimate the ET from the irrigated fields in the present study. In fact, although both studies presented similar CC, R^2 and RMSE, the regression's intercept in Figure 2 was equal to -0.4336, while in Paula *et al.* (2019) it was -0.0254, fitting better over the 1:1 line. These differences should occur due to model parametrization. The dT values presented slightly lower magnitudes (between 11.3 and 23.0K) compared to theirs (14.0K and 26.6K). In Lopes *et al.* (2019), which assessed SSEBop's performance in irrigated areas near Paula *et al.* (2019) study area, dT values were similar to the present study, ranging from ~10 to 20K in 2017. Their study also used point source climate datasets, rather than the grid source used here. The dT affects the ET_f and consequently the ET_a simulated by SSEBop model. Thus, the use of gridded elevation and meteorological datasets, along with climatological values of T_a to determine dT instead of point-based observations caused these differences between both studies. Despite these issues, the overall performance was considered satisfactory to carry on with the analysis and to investigate how the ET_c derived from soil moisture data collected through the soil rooting zone (0-3m) correlates ET_a estimated by the satellite modeling approach. For more discussions on the behavior of SSEBop in irrigated areas at the Brazilian central Plateau region, please refer to Paula *et al.* (2019) and Lopes *et al.* (2019).

4.2. Local and seasonal relations between remote sensing and soil moisture-based evapotranspiration

Figure 3 presents the box-plot of the ET_a from SSEBop and ET_c derived from the soil moisture dataset evaluated locally (layer by layer) and their behavior during the 2015 dry season (May to September) at the study areas with pasture (a,b), forest plantation (c,d) and native vegetation (e,f). The box-plot analysis at the pasture study area (Figure 3a) reveals that the distribution of ET_c yielded low magnitudes on the first soil layer (0 to 0.5m) when compared to the distribution of ET_c simulated at deeper layers. When the ET_c is evaluated locally at each layer through the dry season (Figure 3b), it is possible to notice a decrescent tendency at the surface layer (0 to 0.5m) reaching the wilting point ($ET_c = 0$) by the middle of the season (August, 2015). The ET_a estimated with SSEBop also presented a tendency of reduction during the dry season, but remained higher than zero ($ET_a > 1.0 \text{ mm} \cdot \text{day}^{-1}$).

Although the ET_c simulated at deeper soil layers begin the dry season close to ET_o , their behavior starts to differ as the season passes by, with the 0.5 to 1.0m soil layer systematically yielding lower values followed by the two layers between 1.0 and 2.0m. Indeed, areas planted with pasture present greater amounts of root biomass near the surface at shallow depths (< 30cm) (Santos *et al.*, 2007; Paciullo *et al.*, 2010; Silva *et al.*, 2014). Besides that, the absence of management practices to maintain the pasture's productivity can affect the root biomass through time (Santos *et al.*, 2007). Furthermore, the seasonality of climate affects root density and relations between shoot and roots in areas with pasture (Paciullo *et al.*, 2010). This provides reasonable explanations to why ET_a is highly correlated to the soil moisture only at the 0 to 0.5m (Figure 4a) soil layer.

The ET_c from the 2.0 to 3.0m soil layers were similar during the dry season following the ET_o values during the whole period. Since $k_c = 1$ was adopted, the closer ET_c is to ET_o means that the $k_s \sim 1$, which indicates that available soil water content was near the field capacity. Thus, the results suggest that the ET_a from the pasture study site strongly affected the available soil water content at the first soil layer but presented small influence on soil moisture at depths > 2.0m. This kind of behavior is expected and has been reported in previous studies. For instance, Santos *et al.* (2004) and Oliveira *et al.* (2005) reported deep soil water storage, due to less water uptake caused by deeper roots during the dry season, in sites with pasture and with a grassland physiognomy of the Cerrado biome (*Campo sujo*), respectively. Therefore, both the remote sensing and the soil moisture modeling approaches produced the expected behavior of the ET at the pasture study area.

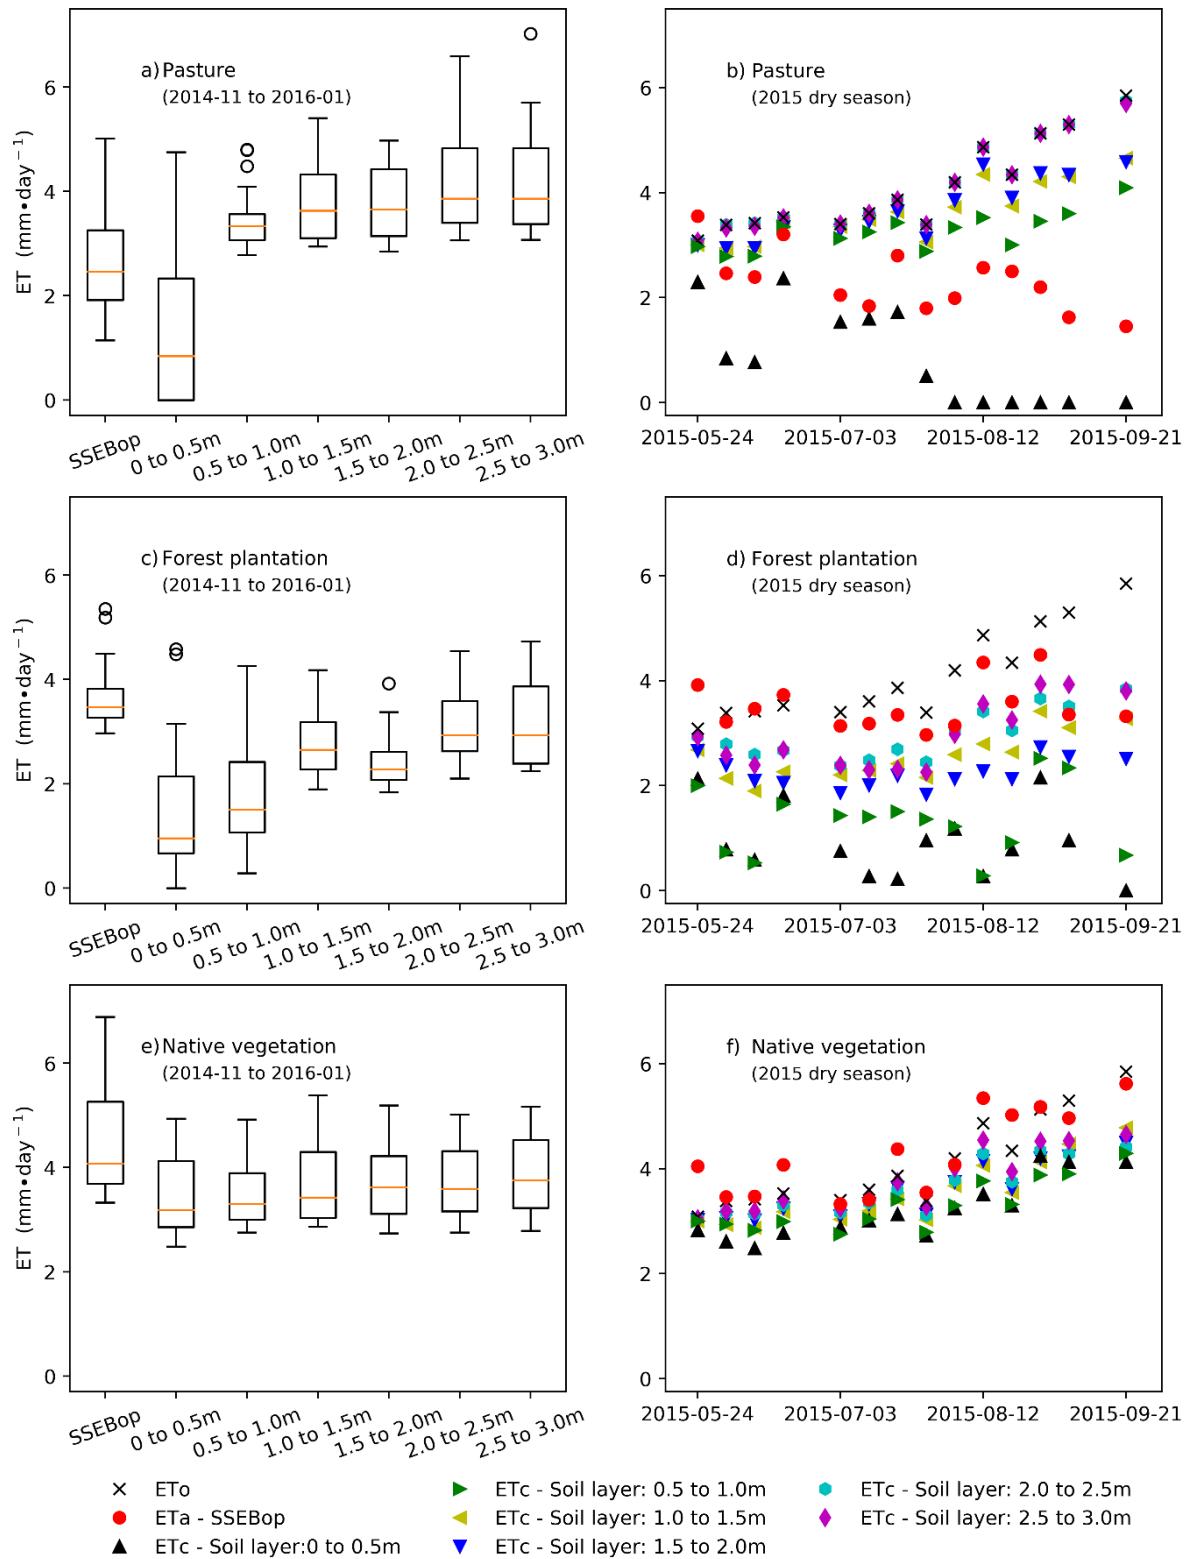


Figure 3: Box-plot of the the ET_a from SSEBop and ET_c derived from the soil moisture dataset evaluated locally and their behavior during the 2015 dry season (May to September) at the study areas with pasture (a,b), forest plantation (c,d) and native vegetation (e,f).

Figure 4 presents the correlations between the ET_c evaluated locally and ET_a at the study area with pasture (a-f), forest plantation (g-l) and native vegetation (m-r). It confirms the first layer (0 to 0.5m) as responsible for most of the ET_a that occurred at the study area with pasture. Indeed, this soil layer (Figure 4a) presented the highest CC (0.9) and R^2 (0.8), the RMSE ($0.48 \text{ mm} \cdot \text{day}^{-1}$) and was the only layer with a significant CC ($p\text{-value} < 0.05$). Despite the significant correlation reported only within the superficial soil layer, the available soil water content on deeper layers also contributed to the ET_a reported by this land cover. This is corroborated by SSEBop overestimating systematically ET_c at the first soil layer.

Considering the results from the forest plantation study area, the distribution of ET_c evaluated locally presented a more heterogenous behavior with the box-plot analysis presenting greater amplitude at the 0 to 0.5m and 0.5 to 1.0m soil layers, compared to deeper layers (Figure 3c). In the 2015 dry season (Figure 3d), SSEBop simulated $ET_a > 2.9 \text{ mm} \cdot \text{day}^{-1}$ during the whole period in this site, while both superficial soil layers (0 to 0.5m and 0.5 to 1.0m) simulated ET_c with lower magnitudes, with the surface soil layer reaching the wilting point at the end of September. Considering the soil layers deeper than 1.0m, they presented ET_c values with similar magnitudes at the beginning of the dry season, but as the season passed by, the magnitude of the ET_c simulated between 1.0 and 2.0m was smaller than the ones between 2.0 and 3.0m, indicating a reduction of the available soil water content between 1.0 and 2.0m depth.

Despite the higher ET_a reported at the forest plantation study site, it did not accompany the tendency of increase observed in the ET_o through the dry season (Figure 1d), neither did the ET_c (Figure 3d). This suggests that although Eucalyptus trees have roots with capacity to withdraw water down to depths of 8–10 m (Laclau *et al.*, 2013; Pinheiro *et al.*, 2016), the forest plantation evaluated in the present study was affected by the variation of available soil water content during the dry season. Indeed, water supply is the key resource determining levels of forest plantation's productivity in Brazil (Stape *et al.*, 2010). Cabral *et al.* (2010) reported that the decline in ecosystem water content and leaf area index (LAI) in areas with eucalyptus led to increased sensible heat fluxes, evaporative demand and decline in canopy conductance, which limited the rates of turbulent fluxes of water vapor to less than 20% of the available energy. Furthermore, Goncalves *et al.* (2008) suggests that water deficit plays a major role to restrict productivity followed by nutrient deficiency and soil depth and strength.

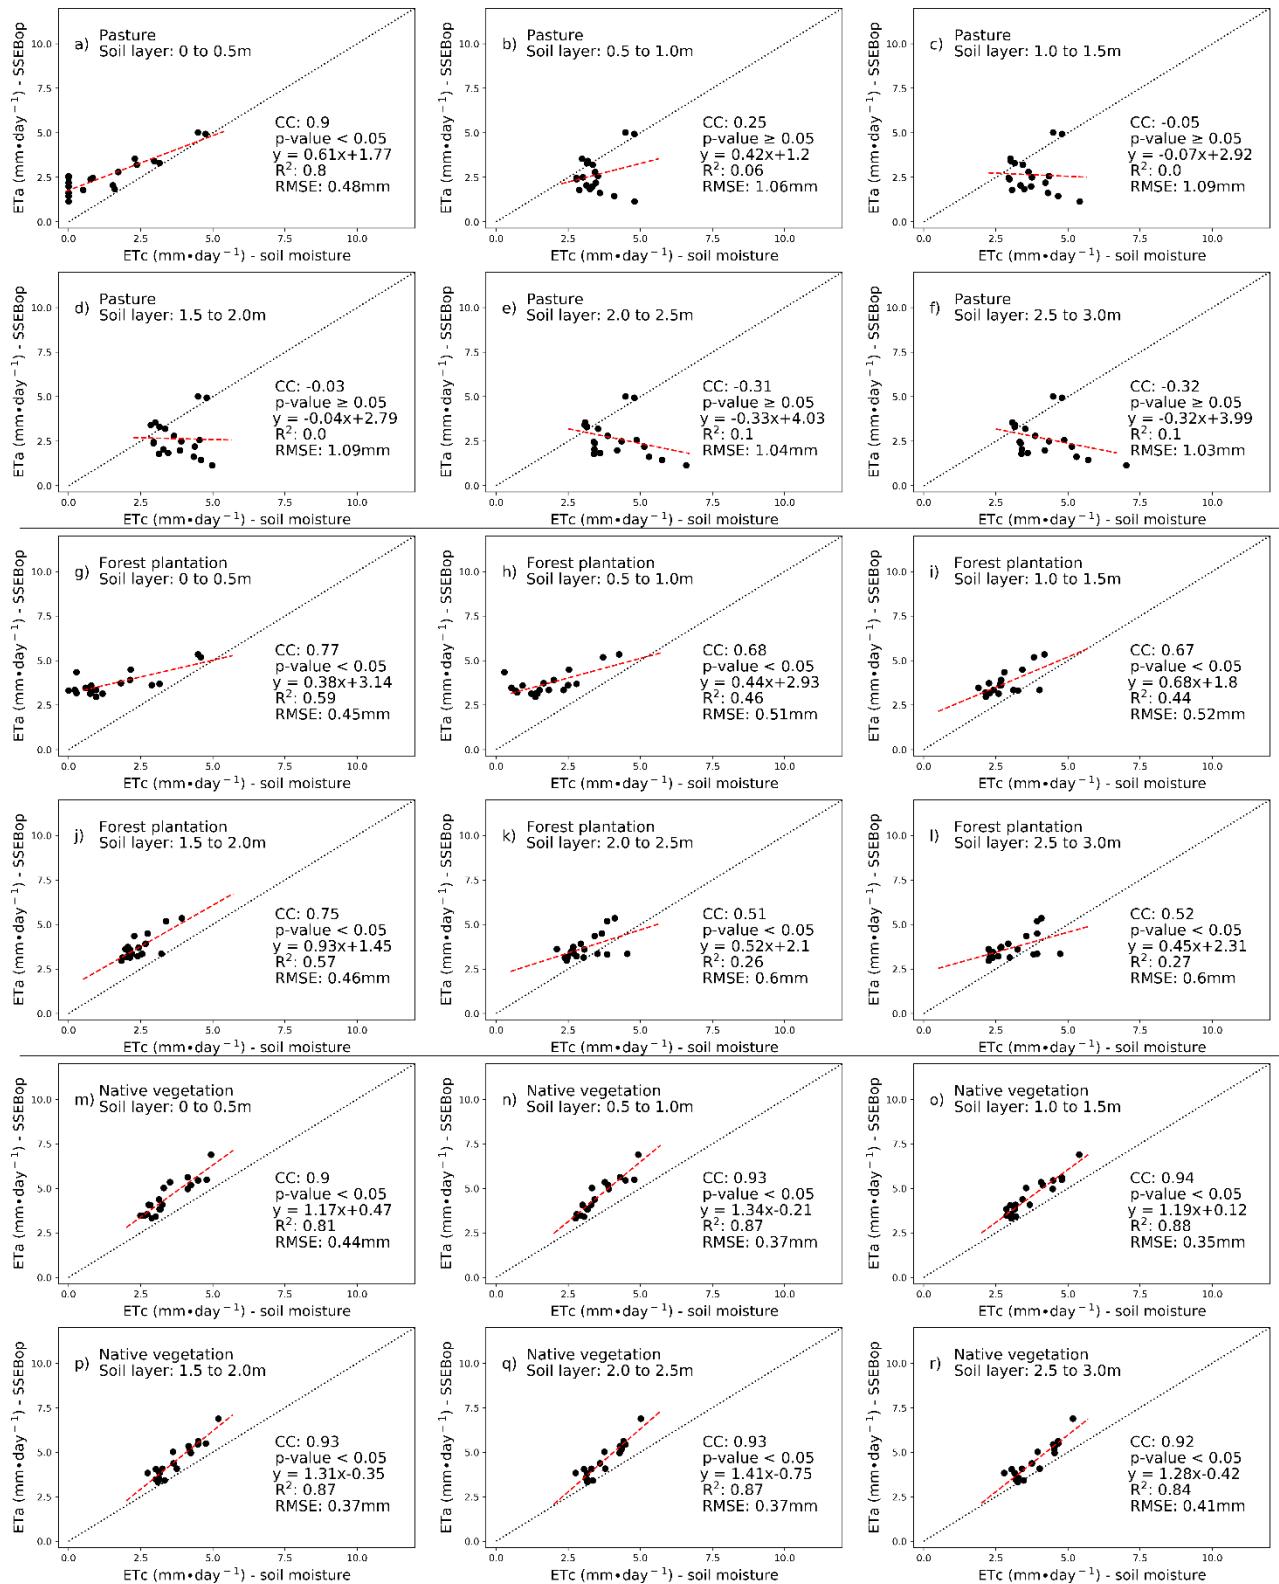


Figure 4: Correlations between the ET derived from the soil moisture dataset and the remote sensing (SSEBop) modeling approach on the study area with pasture (a-f), forest plantation (g-l) and native vegetation (m-r).

Figure 4(g-l) presents the correlations between the ET_a and ET_c at the study area with forest plantation. As reported at the site with pasture, the first layer presented the highest CC (0.77) and R^2 (0.59) and the lowest RMSE ($0.45 \text{ mm} \cdot \text{day}^{-1}$). But at this site, the ET_c reported at the deeper soil layers also presented significant correlation values with the ET_a ($p\text{-value} < 0.05$). The CC, R^2 and RMSE evaluated at the 0.5 to 1.0m were: 0.68; 0.46; and $0.51 \text{ mm} \cdot \text{day}^{-1}$, respectively. Between 1.0 and 2.0m, the evaluated soil layers' CC, R^2 and RMSE results were: 0.67, 0.44 and $0.52 \text{ mm} \cdot \text{day}^{-1}$ (1.0 to 1.5m); and 0.75, 0.57 and $0.46 \text{ mm} \cdot \text{day}^{-1}$ (1.5 to 2.0m), respectively. Finally, at the two deeper layers the CC, R^2 and RMSE results were: 0.51, 0.26 and $0.6 \text{ mm} \cdot \text{day}^{-1}$ (2.0 to 2.5m); and 0.52, 0.27 and $0.6 \text{ mm} \cdot \text{day}^{-1}$ (2.5 to 3.0m), respectively. Besides these significative correlations, it is possible to notice that the statistics tended to get worst as deeper soil layers were assessed. The 1.5 to 2.0m was the exception with a slightly superior correlation compared to the two superior soil layers.

Differently from study sites with pasture and forest plantation, Figure 3e shows similar box plots at the area with native vegetation for both the distribution of ET_a (SSEBop) and ET_c assessed in all soil layers locally. Indeed, the ET_c from all soil layers also behaved homogenously during the dry season of the year (Figure 3f), with $ET_c > 2.4 \text{ mm} \cdot \text{day}^{-1}$, and also following the ET_o tendency (Figure 1d) during the whole period. Since $k_c = 1$ was also adopted for the native vegetation in this analysis, it indicates that the available soil water content was near the field capacity through the soil profile despite the lack of precipitation events in the period. SSEBop also presented high magnitudes of ET during the dry season, with $ET_a > 3.3 \text{ mm} \cdot \text{day}^{-1}$. Although leaf water potential of adult shrubs and trees of the woody plants from the Cerrado biome decreases in the dry season, it is still higher than the soil water potential of upper soil layers allowing root water uptake from the woody plants during this period of the year (Franco, 2002).

Figure 4(m-r) shows the correlations between the ET_a and ET_c at the native vegetation study area. As observed in the area with forest plantation the ET_c from all soil layers presented significative correlation values with ET_a ($p\text{-value} < 0.05$). However, the 0 to 0.5m soil layer presented slightly inferior statistics compared to all other deeper soil layers, with CC, R^2 and RMSE equal to: 0.9, 0.81, and $0.44 \text{ mm} \cdot \text{day}^{-1}$, respectively. The results improved at the 0.5 to 1.0m soil layer (CC = 0.93, $R^2 = 0.87$ and RMSE = $0.37 \text{ mm} \cdot \text{day}^{-1}$), but the best local result was reported at the 1.0 to 1.5m soil layer (CC = 0.94, $R^2 = 0.88$ and RMSE = $0.35 \text{ mm} \cdot \text{day}^{-1}$). The results of the soil layers evaluated between 1.5 and 2.5m were similar (CC = 0.93, $R^2 = 0.87$ and RMSE = $0.37 \text{ mm} \cdot \text{day}^{-1}$) differing only at the regression's coefficients. Finally, the CC, R^2 and RMSE results at deepest layer (2.5 to 3.0m) were equal to: 0.92, 0.84 and $0.41 \text{ mm} \cdot \text{day}^{-1}$, respectively.

Figure 5 provides the T_s with the T_c and T_h boundary conditions (a), and the ET_f values from SSEBop (b) at the study areas with native vegetation, forest plantation and pasture during the dry season. Figure 5a shows the site with pasture with T_s systematically superior to the observed at the sites with native vegetation and forest plantation. The native vegetation and forest plantation presented similar T_s at the beginning of the dry season, but by the end of the period they behaved differently with the native vegetation presenting lower temperatures. Furthermore, Figure 5b shows the site with pasture with ET_f values systematically inferior to the ones reported at the areas with native vegetation and forest plantation, presenting a strong tendency of reduction through the dry season, decreasing from 0.92 (05/24/2015) to 0.2 (09/21/2015). At the area with forest plantation, the ET_f reduced from 1.02 to 0.45, while at the native vegetation study site, it reduced from 1.05 to 0.77, and thus indicating that the forest plantation was more sensitive to the lack of precipitation and the variation of soil moisture through the period than the native vegetation, as reported previously.

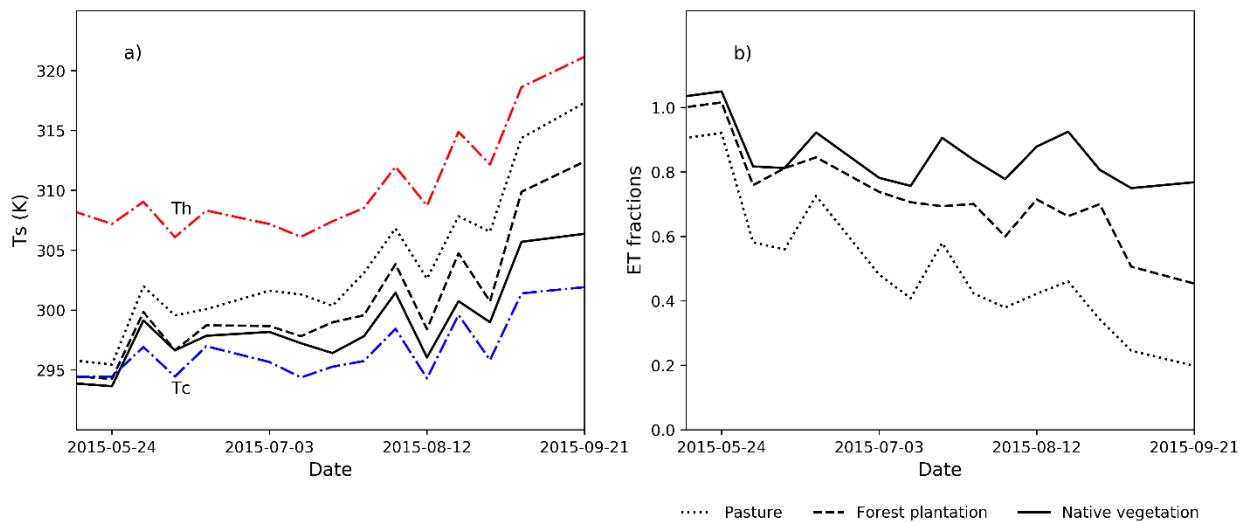


Figure 5: T_s (a) and ET_f (b) results from the remote sensing (SSEBop) modeling approach at the study areas with native vegetation, forest plantation and pasture during the 2015 dry season (after linear interpolation).

4.3. Global relations between remote sensing and soil moisture-based evapotranspiration

Figure 6 presents the correlations between ET_a and ET_c derived from the average soil moisture datasets (0 to 1.0m, 0 to 2.0m, and 0 to 3.0m) at the study area with pasture (a-c), forest plantation (d-f) and native vegetation (g-i). The ET_a reported at the area with pasture presented high correlation with the ET_c from the 0 to 1.0m average soil moisture data ($CC = 0.82$, $R^2 = 0.67$, $RMSE = 0.62 \text{ mm}\cdot\text{day}^{-1}$). The correlations tended to reduce when data from deeper layers were

considered (0 to 2.0m and 0 to 3.0m). This followed the tendency reported previously assessing the ET_c locally at this study site.

All three scenarios evaluated in Figure 6 (0 to 1.0m, 0 to 2.0m, 0 to 3.0m) presented significative correlations ($p\text{-value} < 0.05$) between ET_a and ET_c in the areas with forest plantation (Figure 6d-f) and native vegetation (Figure 6g-i). The best result reported at the forest plantation site occurred with the 0 to 2.0m average soil moisture dataset, where CC, R^2 , and RMSE were equal to: 0.74, 0.55 and $0.47 \text{ mm}\cdot\text{day}^{-1}$. As observed in the area with pasture, the deeper soil layers contributed to reduce the systematic underestimation of ET_a reported by soil moisture modeling approach, specially at the dry season, when the ET_c magnitudes decreased and the available soil water content reached the wilting point. The area with native vegetation presented similar results with high CC (0.95) and R^2 (> 0.9) values and lower RMSE ($\leq 0.32 \text{ mm}\cdot\text{day}^{-1}$) in the three scenarios.

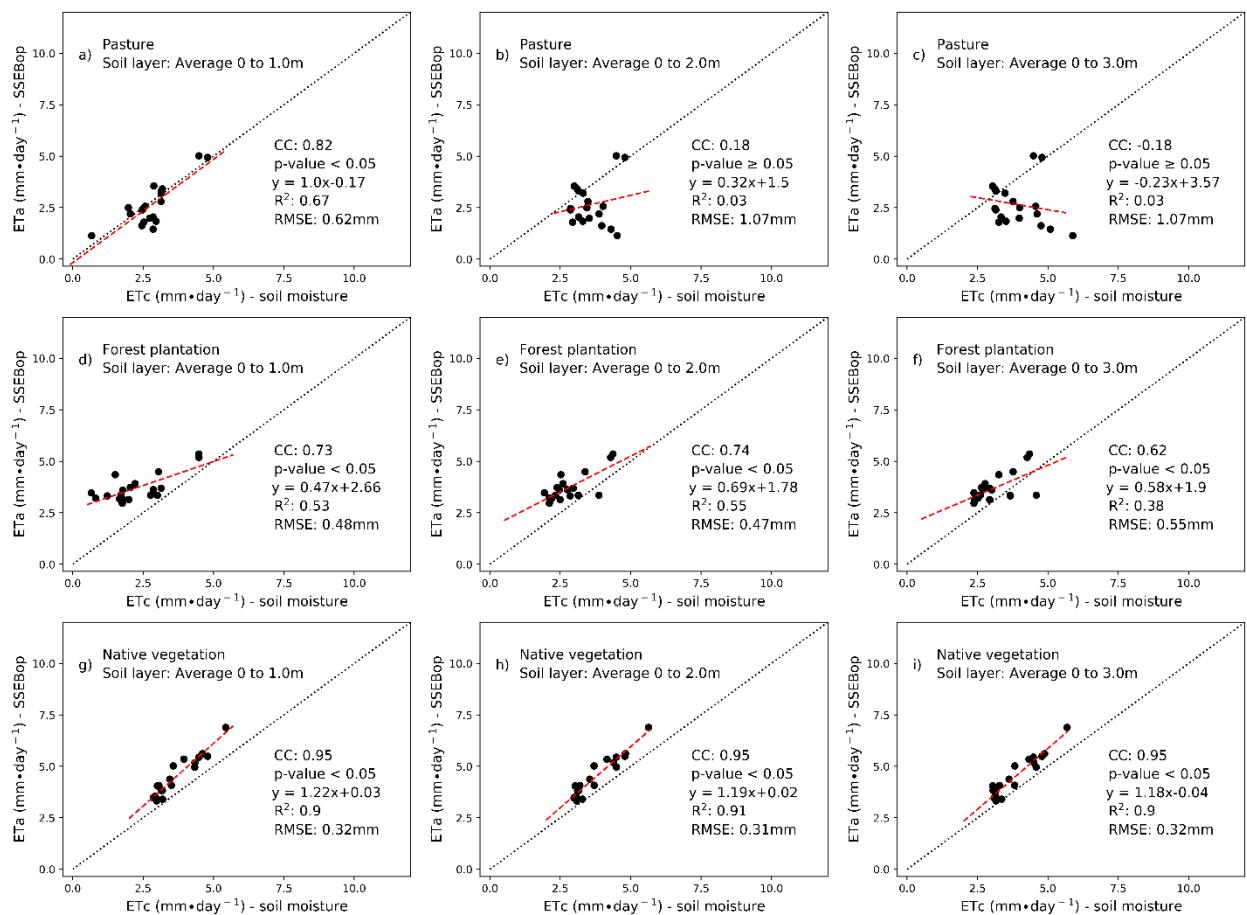


Figure 6: Correlations between the ET derived from the average soil moisture datasets (0 to 1.0m, 0 to 2.0m, and 0 to 3.0m) and the remote sensing (SSEBop) modeling approach at the study area with pasture (a-c), forest plantation (d-f) and native vegetation (g-i).

Figure 7 presents the scatter plot between ET_a and ET_c joining the three datasets and the median ET_a of the study area. The CC, R^2 and RMSE were equal to 0.91 ($p\text{-value} < 0.05$), 0.83 and 0.5 $\text{mm}\cdot\text{day}^{-1}$, respectively. The k_s values from the 0 to 1.0m were used for the pasture and native vegetation, while the k_s values from the 1.5 to 2.0 m soil layers were used for the area with forest plantation. Concerning the k_c applied for each site, the initial value for the pasture site reduced slightly ($k_c = 0.95$), once there was a good fit between ET_a and ET_c (Figure 6a). A higher value was proposed for the native vegetation ($k_c = 1.22$) and for the forest plantation ($k_c = 1.52$). These k_c values seem reasonable when the ET_a and ET_o are compared in Figure 3. At the pasture site, Figure 3b shows ET_a near ET_o at the beginning of the dry season, which results in $k_c \sim 1$. Investigating a site with pasture in the beginning of the rainy season, Meirelles *et al.* (2011) obtained k_c values initially ranging from 0.61 to 0.79 and then presenting posterior increase ranging from 0.89 and 1.28, a few days later after the LAI shifted up from 0.4 to 1.1.

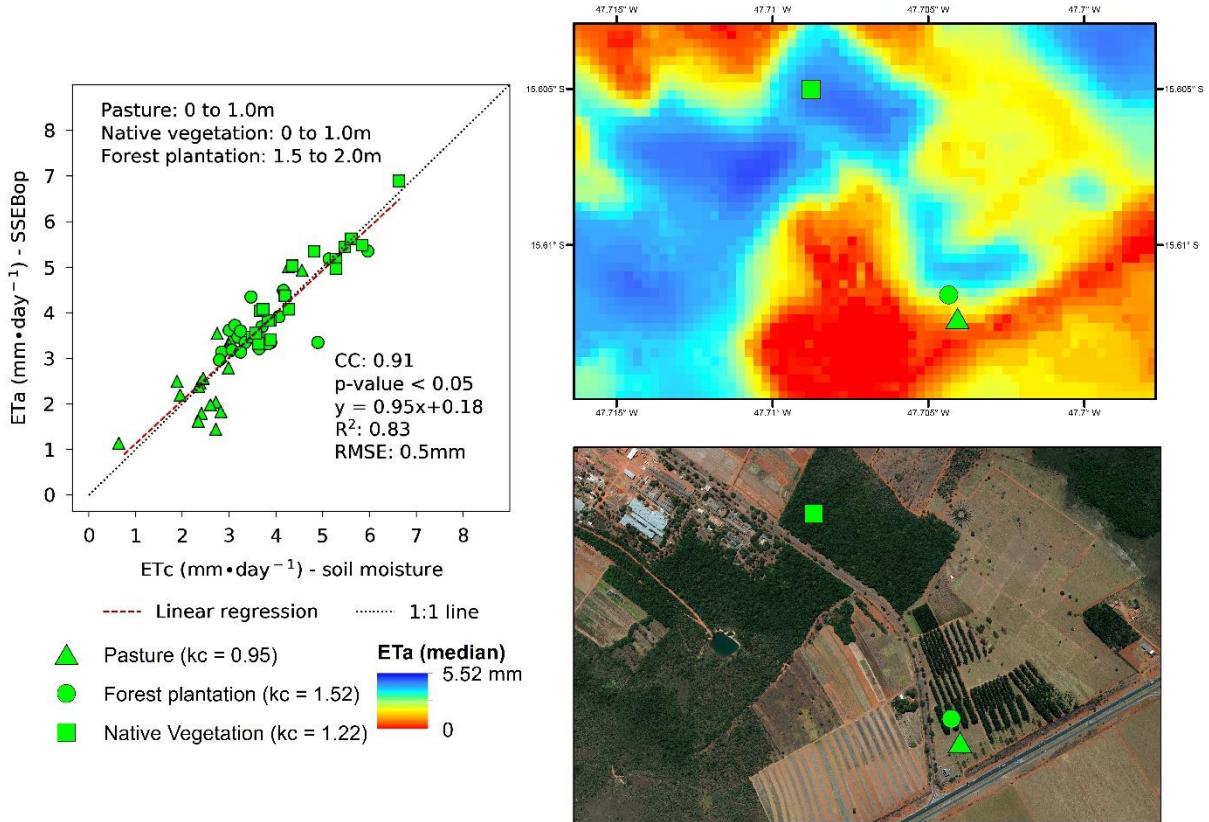


Figure 7: Scatter plot between the ET_a and the ET_c joining the three datasets and the median ET_a of the study area.

Furthermore, the k_c proposed for the native vegetation also appears to be adequate. In Figure 3f, $ET_a > ET_o$ in many Landsat dates, which results in $k_c > 1$. On the other hand, the k_c proposed for the forest plantation seems higher than the expected, especially when ET_a and ET_o are compared

in Figure 3d by the end of the dry season. Alves *et al.* (2013) proposed k_c equal to 0.70 and 0.82 for eucalyptus plantations during initial growth and mid-season stages, respectively. However, they discuss that the mid-season stage k_c could be higher than the reported. Indeed, Pakparvar *et al.* (2013) reported dates with $k_c > 1.0$ in areas with different density of eucalyptus in Iran, with peaks reaching 1.6 for very dense sites. These extreme k_c values were attributed to local or regional advection, rather than to overestimation of ET_a . In fact, advection may impact the energy-balance closure (Lu *et al.*, 2013) and has been pointed as an important factor influencing annual variation in crop water requirements at irrigated fields in the Cerrado (Luchiari Jr. *et al.*, 1997). However, since $ET_a < ET_o$ at the end of the dry season at the forest plantation site, the high k_c seems to be a consequence of the differences between the low ET_c and higher ET_a , rather than local or region advection at this site. Despite these issues concerning the k_c , especially for the forest plantation, the performance of the global model was considered satisfactory to establish relations between the ET derived from the ground-based and the remote sensing measurements at the three study sites.

The results show the site with native vegetation presenting higher rates of ET_a , followed by the forest plantation and by the pasture with smallest rates. Assessing the impacts of sugar-cane expansion on local climate in Brazil, Loarie *et al.* (2011) presented an ET reduction trend in land use change from native vegetation to pasture and other agricultural sites. Silva *et al.* (2015) also reported that the conversion of native vegetation to sugarcane altered significantly the energy and water budgets, presenting a ~30% reduction of ET in the study period. However, their results showed that the conversion of natural areas to eucalyptus plantations presented relatively small changes to the energy and water budgets.

When it comes to understanding how trees from the Cerrado biome uses the available soil water content through the rooting zone and to explain why the ET_f and ET_a remained in higher levels during the dry season, previous studies have demonstrated that they are adapted to reach soil water in different depths through the profile. Jackson *et al.* (1999) reported both evergreen and deciduous species from the Cerrado extracting either soil water primarily in upper soil layers (above 2m) or from deeper sources (below 2m). Interestingly most of the species evaluated by these authors had their occurrence reported by Parron *et al.* (1998) at the *Cerradão* Ecological Reserve. The *Cerradão* is a forest formation and exhibit species that belong to both savanna and forest physiognomies with a floristic predominance of species from the savanna environment (Ribeiro and Walter, 1997). Forest species are adapted to more competitive light environments presenting more leaf area and stem biomass, instead of root biomass, in which savanna species invest (Hoffman and Franco, 2003).

Investigations of plant biomass allocation and carbon stocks have shown the existence of sites with root:shoot ratios > 1 , with higher below-ground biomass (Castro and Kauffman, 1998; Lilienfein *et al.*, 2001; Hoffman and Franco, 2003), but have also revealed root:shot < 1 within the same physiognomies (Ribeiro *et al.*, 2011; Durigan *et al.*, 2012). Smaller root:shoot ratio could be a response to lower light and higher soil water availability, and/or to less frequent fires (Durigan *et al.*, 2012). In this context, the physiognomy evaluated in the study area is composed by species extremely adapted to the local environment and climate which corroborates the results found in this research. It also provides reasonable explanations to the ET_a being highly correlated to the ET_c up to 3m depth.

Noteworthy that T_s in the native vegetation was systematically greater than T_c from June to the end of September (Figure 5a), which made the ET_f remain lower than the one reported in well-watered, fully transpiring vegetation surfaces. This indicates that the native vegetation was submitted to a certain level of stress during the period which reduced the ET_a . In a general way, the stomatal conductance plays a major role in water flow for the Cerrado woody plants' transpiration process, where closure during the night curtails transpiration and allows plant rehydration according to the available water content, while during the day it minimizes the effects of increases in the evaporative demand of the atmosphere as a force driving transpiration (Franco, 2002). Previous studies have also demonstrated that the Cerrado's vegetation can transport water via roots from moist deep soil layers to the upper dryer layers of the soil profile, a process that is referred as hydraulic lift (e.g. Scholz *et al.*, 2002; Moreira *et al.*, 2003; Scholz *et al.*, 2008; Scholz *et al.*, 2010). In trees, it is associated to deciduous and brevidecidous species that have dimorphic roots system with both shallow and tap roots rather than to evergreen species with monomorphic root systems (Scholz *et al.*, 2008). Furthermore, in terms of rooting patterns cerrado trees present a wide range of rooting habits from shallow-rooted to deep-rooted species (Franco, 2009). In fact, the ET_f reduced but remained relatively constant through the following dry months of the year (Figure 5b). Consequently, the ET_a reported at the native vegetation study site remained at higher levels and followed the tendency of increase observed in the ET_o (Figure 1d) through the dry season (Figure 3f). This can explain the ET_a from remote sensing yielding higher levels at the native vegetation during the dry season, when compared to the other two study areas.

The results demonstrate different soil moisture dynamics through the soil profile in each site resulting in different ET_a behavior through the dry season. The ET_a from the native vegetation and the forest plantation presented relations to the variation of the available soil water content up to 3.0m, while in the area with pasture, the ET_a was related principally to the soil moisture up to 1.0m, having subtle influence from deeper layers. In Santos *et al.* (2004), the soil water extraction

by a pasture site was particularly marked at 0.1m depth during the dry season, but the systematic differences reported between the wet and dry seasons below 0.8m depth suggest that lower depths were a significant source of plant water sometime during the dry period between May and September. Although root biomass is usually reported with a significant distribution at shallow depths and in greater amounts near the surface, it is also reported in deeper layers (< 1.0m) in areas of pasture submitted to different management practices (Santos *et al.*, 2007; Paciullo *et al.*, 2010). This provides reasonable explanations to the ET_a being highly correlated to the soil moisture at the 0 to 0.5m (Figure 4a) and the 0 to 1.0m (Figure 6a) soil layers.

Although the variability of ET_a at the forest plantation and on the native vegetation presented similar magnitudes, as reported by Silva *et al.* (2015), and presented significative relations to ET_c through the different soil layers, the results indicate that the impact of ET_a on soil moisture differed between them. As reported previously, both the pasture's and the forest plantation's ET_a impacted significantly soil moisture up to 0.5m and 1.0m, respectively. Interestingly all soil layers evaluated at the native vegetation site presented ET_c with high magnitudes through the entire dry season (Figure 3f). Since ET_c was driven by the soil moisture dataset, this indicates that the native vegetation kept high rates of ET_a without reducing significantly the soil moisture up to 3.0m. Scholz *et al.* (2010) reported that hydraulic lift replaced 23% of the ecosystem evapotranspiration at the peak of the dry season in a site of cerrado with high tree density near the study area. Therefore, hydraulic lift is expected to play an important role in the Cerrado's vegetation and provides a reasonable explanation to the relations between ET_c and ET_a through the soil profile presently reported.

The fact that at the pasture study site the soil moisture remained close to the field capacity in layers deeper than 2.0m in contrast with the higher ET_a reported in areas with native vegetation brings the discussion concerning water yield in watersheds. In one direction a recently published global review on hydrological responses to forest change across multiple spatial scales has shown that there is an increase in annual runoff associated with forest cover loss and that in water-limited watersheds the annual runoff is more sensitive to deforestation than energy-limited basins (Zhang *et al.* 2017). However, this type of conclusion is not supported by all studies in the literature, which argue for the opposite: planting additional forests should raise downstream water availability and intensify the hydrologic cycle (Ellison *et al.*, 2011). They argue that looking from the demand to the supplying side of the debate of the forest cover-water yield, the ET produced from forests and wetlands are one of the principal drivers of precipitation, since they play a pivotal role in supplying the atmospheric moisture that becomes precipitation in the hydrologic cycle on larger regional and global context (Ellison *et al.*, 2011). Besides being

intimately linked to rainfall, water availability and to the movement of water through moisture transportation in continental areas, forests influence not only local and global temperature as well as heat flow, but also regulate water supplies (Ellison *et al.*, 2017).

Concerning the influence on local and global temperature and heat flow, the results shows T_s systematically superior in the area with pasture followed by the area with forest plantation during the dry season. Other studies have also reported an increase of the albedo and T_s followed by the reduction of ET where natural areas were converted into pasture and agricultural lands in Brazil (Loarie *et al.* 2011; Lathuilliere *et al.*, 2012; Silva *et al.*, 2015). Furthermore, when the hydrological processes are considered in relation to the regulation of water supplies, it is necessary to evaluate the relations between ET_a and other hydrological processes, such as infiltration and groundwater recharge, in different land use and soil management. The results show that differently from the pasture and forest plantation sites, the native vegetation kept high rates of ET_a without reducing significantly soil available water content in the 3.0m soil profile. Consequently, this should affect other hydrological processes such as infiltration and groundwater recharge. Indeed, infiltration capacity increases after afforestation or planting trees (Ilstedt *et al.*, 2007). Moreover, previous studies in the Cerrado region have shown that agriculture and its management practices can affect negatively soil physical properties such as: saturated hydraulic conductivity; amount of organic matter; soil water storage capacity; and porosity (Figueiredo *et al.*, 2008; Figueiredo *et al.*, 2009; Rocha *et al.*, 2008; Fontana *et al.*, 2016).

In this direction, Krishnaswamy *et al.* (2013) presented catchments with a higher proportion of forest cover upstream maintaining flow longer into the dry season. They argue that their results support the ‘infiltration-evapotranspiration trade-off’ hypothesis in which differences in infiltration between land-cover rather than ET determines the differences in groundwater recharge, low flows and dry-season flow. This is relevant considering that, dry season flows and groundwater recharge play a major role in the regulation of water supplies in tropical regions, rather than total annual streamflow (Ellison *et al.*, 2017). Furthermore, Ilstedt *et al.* (2016) proposed that there is an intermediate tree cover, where the hydrological benefits gained from more tree cover outweigh their extra water use and maximize groundwater recharge in seasonally dry tropics. Comparing groundwater recharge in different physiognomies of the Cerrado biome, Oliveira *et al.* (2017) presented a decreasing trend with the increase of the vegetation’s density. However, they found similar groundwater recharge rates between the physiognomies with values around $300 \text{ mm} \cdot \text{year}^{-1}$ and ranging from 29.7 to 25.8% of the annual precipitation. Other studies, such as Quesada *et al.* (2008) and Cabral *et al.* (2015), showed that areas with cerrado *sensu*

stricto presented similar mean water uptake values in dry and wet years. Cabral *et al.* (2015) point out that this behavior results in higher groundwater recharge in wet years. In contrast, Lucas and Wendland (2016) report 8, 16, 19, and 26% of groundwater recharge in terms of annual precipitation in sites with forest plantation, citrus, sugarcane and pasture, respectively. Considering that researches in Lucas and Wendland (2016) and Oliveira *et al.* (2017) were undertaken in the same region and with similar hydrogeological conditions, the differences between their results also illustrate the existence of trade-offs between ET_a and infiltration that increase water yield in areas with the Cerrado's native vegetation. In this context, the results from the present study also demonstrate important trade-offs between ET_a and soil water dynamics in areas with native vegetation when compared to the areas with pasture and forest plantation, that should be considered in applicative contexts concerning an integrated management of water resources with land use and occupation.

Finally, considering the uncertainties within the present analysis, they include: (i) cloud contamination, (ii) the interpolation method applied to the soil moisture dataset and (iii) the soil layer evaluated for each site. Cloud contamination is a typical problem for remote sensing methods and was a concern in previous studies with SSEBop (e.g., Senay *et al.*, 2013, Singh *et al.*, 2014, Senay *et al.*, 2016, Senay *et al.*, 2017, Senay *et al.*, 2018, Paula *et al.*, 2019, Lopes *et al.*, 2019). Although Landsat images have a quality band, clouds can still be a source of error. In SSEBop's application, it can affect the T_s _cold selection and consequently the determination of ET_f. Another source of uncertainty as pointed out above refers to the interpolation method applied to the soil moisture dataset. Since the samples were not collected at the same dates of the Landsat images, the interpolation may have also contributed to the differences between ET_a and ET_c. Furthermore, the third source of uncertainty listed here refers to the soil layer evaluated. Depending on the land cover and the soil layer that is evaluated, different conclusions can be drawn, which require caution before making any generalization. For instance, the forest plantation kept high levels of ET_a despite the reductions reported with ET_c in the first two soil layers. The pasture study site presented higher ET_c in deeper layers while ET_a reduced, during the dry season. Despite the sources of uncertainties that can influence negatively the present assessment, the results reported in this research were considered satisfactory.

5. Conclusions

This study evaluated how the evapotranspiration derived from soil moisture data (ET_c) collected through the soil rooting zone (0-3m) correlates to the actual evapotranspiration (ET_a) estimated by satellite data in the Brazilian Cerrado. It also assessed the applicability of the ground-based

method, which was driven by soil moisture measurements, to validate the ET_a estimated on three different land covers (pasture, forest plantation, and native vegetation). The major conclusions are:

- The area with native vegetation presented higher rates of ET_a followed by the areas with forest plantation and pasture land covers.
- The ET_a from areas with native vegetation and forest plantation is influenced by the available water content up to 3.0m, while in areas with pasture the ET_a is directly influenced only up to 0.5m, having subtle influence from the soil moisture available on deeper layers.
- Both forest plantation and native vegetation kept high rates of ET_a during the dry season, but their impacts on soil moisture observed in the rooting zone differed, especially in the superficial layers (up to 1.0m).
- The area with native vegetation kept high ET_a through the season without reducing significantly the soil moisture up to 3.0m.
- Although the soil moisture reduced significantly at the superficial soil layer (0 to 0.5m) in the area with pasture, there was no correlation between the ET_a and the ET_c in deeper layers.

More generally, this study also shows that the ET_a can be validated with ET measurements derived from models that use the available water content measured through the rooting zone. This is important for regions where flux towers with Eddy covariance and Bowen ratio systems are unavailable and for ungauged basins. However, these ET models based on soil moisture data require information on the soil's physical properties, and the ET_a's reliability conclusion is sensitive both to the soil depth used as a reference and to the land cover which is being assessed. Indeed, more optimist/pessimist conclusions on ET_a's reliability should be drawn if considering deeper/shallower soil layers according to each land cover and soil class. In this line, future studies should analyze the sensitivity of ET_a to soil moisture dynamics in other physiognomies of native vegetation and in multiple land use and soil classes. Other important issues to investigate in future studies are the usage of remote sensing ET_a data with finer resolutions and in applicative contexts.

6. References

Alemayehu, T.; Griensven, A.; Senay, G. B.; Bauwens, W. Evapotranspiration Mapping in a Heterogeneous Landscape Using Remote Sensing and Global Weather Datasets: Application to the Mara Basin, East Africa. *Remote Sensing*, 9, 2017, 390. Doi: <https://doi.org/10.3390/rs9040390>

Allen, R. G.; Pereira, L. S.; Raes, D.; Smith, M. Crop evapotranspiration: guidelines for computing crop water requirements. In: Irrigation and Drainage Paper 56, FAO, Rome, Italy, 1998.

Allen, R. G.; Tasumi, M.; Trezza, R. Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC) – Model. *Journal of Irrigation and Drainage Engineering*, 133, 2007, 380–394. Doi: [https://doi.org/10.1061/\(ASCE\)0733-9437\(2007\)133:4\(380\)](https://doi.org/10.1061/(ASCE)0733-9437(2007)133:4(380))

Alves, M. E. B.; Mantovani, E. C.; Sediyama, G. C.; Neves, J. C. L. Estimate of the crop coefficient for Eucalyptus cultivated under irrigation during initial growth. *Cerne*, 19(2), 2013, 247–253. Doi: <http://dx.doi.org/10.1590/S0104-77602013000200008>

Anderson, M. C., Norman, J. M., Mecikalski, J. R., Otkin, J. A., & Kustas, W. P. A climatological study of evapotranspiration and moisture stress across the continental United States based on thermal remote sensing: 1. Model formulation. *Journal of Geophysical Research-Atmospheres*, 112, 2007, 1984–2012. Doi: <http://dx.doi.org/10.1029/2006JD007506>

Bastiaanssen, W.; Menenti, M.; Feddes, R.; Holtslag, A. A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. *Journal of Hydrology*, 212, 1998, 198–212. Doi: [https://doi.org/10.1016/S0022-1694\(98\)00253-4](https://doi.org/10.1016/S0022-1694(98)00253-4)

Bernardo, S. Manual de irrigação (Irrigation manual). Viçosa: UFV, Imprensa Universitária, 6^a ed., 1995. 657p

Brazil. Agência Nacional de Águas (ANA). Estimativas de evapotranspiração real por sensoriamento remoto no Brasil. Brasilia: ANA, 2020, 41p.

Brazil. Instituto Brasileiro de Geografia e Estatística (IBGE). 2017. Levantamento sistemático produção agrícola – Pesquisa mensal de previsão e acompanhamento das safras agrícolas no ano civil, 1–83. Vol. 30. Rio de Janeiro: IBGE.

Bonan, G. B. Forests and Climate Change: Forcings, Feedbacks, and the Climate Benefits of Forests. *Science*, 320, 2008, 1444–1449. Doi: <http://dx.doi.org/10.1126/science.1155121>

Castro, E. A. de; Kauffman, J. B. Ecosystem structure in the Brazilian Cerrado: a vegetation gradient of aboveground biomass, root mass and consumption by fire. *Journal of Tropical Ecology*, 14, 1998, 263–283. Doi: <https://doi.org/10.1017/S0266467498000212>

Cabral, O. M. R.; Rocha, H. R. da; Gash, J. H.; Freitas, H. C.; Ligo, M. A.V. Water and energy fluxes from a woodland savanna (cerrado) in southeast Brazil. *Journal of Hydrology: Regional Studies*, 4, 2015, 22–40. Doi: <https://doi.org/10.1016/j.ejrh.2015.04.010>

Cabral, O. M. R.; Rocha, H. R.; Gash, J. H. C.; Ligo, M. A. V.; Freitas, H. C.; Tatsch, J. D. The energy and water balance of a Eucalyptus plantation in southeast Brazil. *Journal of Hydrology*, 388, 2010, 208–216. Doi: <https://doi.org/10.1016/j.jhydrol.2010.04.041>

Chen, M.; Senay, G. B.; Singh, R. K.; Verdin J. P. Uncertainty analysis of the Operational Simplified Surface Energy Balance (SSEBop) model at multiple flux tower sites. *Journal of Hydrology* 536, 2016, 384–399. Doi: <http://dx.doi.org/10.1016/j.jhydrol.2016.02.026>

Campos, J. E. G. Hidrogeologia do Distrito Federal: Bases para a gestão dos recursos hídricos subterrâneos (Hydrogeology of the Federal District: Bases for groundwater resources management). *Brazilian Journal of Geology*, 34(1), 2004, 41–48.

Campos, J. E. G.; Monteiro, C. F.; & Rodrigues, L. N. Geologia e Zoneamento Hidrogeológico da Bacia do Rio Preto, DF/GO/MG (Geology and Hydrogeological Zoning of the Rio Preto Basin, DF/GO/MG). Planaltina, DF: Embrapa Cerrados, 2006, 54. ISSN: 1517- 5111:172.

Durigan, G.; Melo, A. C.G.; Brewer, J. S. The root to shoot ratio of trees from open- and closed-canopy cerrado in south-eastern Brazil. *Plant Ecology & Diversity*, iFirst, 2012, 1–11. Doi: <http://dx.doi.org/10.1080/17550874.2012.691564>

Ellison, D.; Futter, M. N.; Bishop, K. On the forest cover–water yield debate: from demand- to supply-side thinking. *Global Change Biology*, 2017. Doi: <http://dx.doi.org/10.1111/j.1365-2486.2011.02589.x>

Ellison, D.; Morris, C. E.; Locatelli, B.; Sheil, D.; Cohen J.; Murdiyarso, D.; Gutierrez, V.; Noordwijk, M. van; Creed, I. F.; Pokorny, J.; Gaveau, D.; Spracklen, D. V.; Tobella, A. B.; Ilstedt, U.; Teuling, A. J.; Gebrehiwot, S. G.; Sands, D. C.; Muys, B.; Verbist, B.; Springgay, E.; Sugandi, Y.; Sullivan, C. A. Trees, forests and water: Cool insights for a hot world. *Global Environmental Change*, 43, 2017, 51–61. Doi: <http://dx.doi.org/10.1016/j.gloenvcha.2017.01.002>

Figueiredo, C. C.; Ramos, M. L. G.; & Tostes, R. Propriedades físicas e matéria orgânica de um latossolo vermelho sob sistemas de manejo e cerrado nativo (Physical properties and organic matter in a red latosol under management systems and native cerrado). *Bioscience Journal*, 24(3), 2008, 24–30. Retrieved from <http://www.seer.ufu.br/index.php/biosciencejournal/article/view/6749>

Figueiredo, C. C.; Santos, G. G.; Pereira, S.; Nascimento, J. L.; Alves, J., Jr. Propriedades físico-hídricas em Latossolo do Cerrado sob diferentes sistemas de manejo (Physico-hydric properties of Cerrado Latosol under different management systems). *Revista Brasileira Engenharia Agrícola Ambiente*, 13(2), 2009, 146–151. Doi: <http://dx.doi.org/10.1590/S1415-43662009000200006>

Fontana, A.; Teixeira, W. G.; Balieiro, F. C.; Moura, T. P. A.; Menezes, A. R.; Santana, C. I. Características e atributos de Latossolos sob diferentes usos na região Oeste do Estado da Bahia (Characteristics and attributes of Oxisols under different land uses in the western region of the state of Bahia, Brazil). *Pesquisa Agropecuária Brasileira*, 51(9), 2016, 1457–1465. Doi: <http://dx.doi.org/10.1590/S0100-204X2016000900044>.

Franco, A. C. Ecophysiology of Woody Plants. In Oliveira, P. S.; Marquis, R. J. The cerrados of Brazil: ecology and natural history of a neotropical savanna. Columbia University Press, 2002, 398 pp.

Franco, A. C. Tree functional strategies in Brazilian savannas. In Barrera, E; Smith, W. K. Perspectives in Biophysical Plant Ecophysiology: A Tribute to Park S. Nobel. Universidad Nacional Autónoma de México, 2009, 400 pp.

Giambelluca, T. W.; Scholz, F. G.; Bucci, S. J.; Meinzer, F. C.; Goldstein, G.; Hoffmann, W. A.; Franco, A. C.; Buchert, M. P. Evapotranspiration and energy balance of Brazilian savannas with contrasting tree density. *Agricultural and Forest Meteorology*, 149, 2009, 1365–1376. Doi: <http://dx.doi.org/10.1016/j.agrformet.2009.03.006>

Glenn, E. P.; Nagler, P. L.; Huete, A. R. Vegetation Index Methods for Estimating Evapotranspiration by Remote Sensing. *Surveys in Geophysics*, 31, 2010, 531-555. Doi: <http://dx.doi.org/10.1007/s10712-010-9102-2>

Gonçalves, J. L. M.; Stape, J. L.; Laclau, J-P.; Bouillet, J-P.; Ranger, J. Assessing the effects of early silvicultural management on long-term site productivity of fast-growing eucalypt plantations: the Brazilian experience. *Southern Forests*, 70(2), 2008. Doi: <http://dx.doi.org/10.2989/SOUTH.FOR.2008.70.2.6.534>

Gowda, P. H.; Chavez, J. L.; Colaizzi, P. D.; Evett, S. R.; Howell, T. A.; Tolk, J. A. ET mapping for agricultural water management: present status and challenges. *Irrigation Science*, 26, 2008, 223–237. Doi: <http://dx.doi.org/10.1007/s00271-007-0088-6>

Hoffmann, W. A.; Franco, A. C. Comparative growth analysis of tropical forest and savanna woody plants using phylogenetically independent contrasts. *Journal of Ecology*, 2003, 91, 475–484.

Ilstedt, U.; Malmer, A.; Verbeeten, E.; Murdiyarso, D. The effect of afforestation on water infiltration in the tropics: A systematic review and meta-analysis. *Forest Ecology and Management*, 251, 2007, 45–51. Doi: <http://dx.doi.org/10.1016/j.foreco.2007.06.014>

Ilstedt, U.; Tobella, A. B.; Bazié, H. R.; Bayala, J.; Verbeeten, E.; Nyberg, G.; Sanou, J.; Benegas, L.; Murdiyarso, D.; Laudon, H.; Sheil, D.; Malmer, A. Intermediate tree cover can maximize groundwater recharge in the seasonally dry tropics. *Scientific Reports*, 6, 21930, 2016. Doi: <http://dx.doi.org/10.1038/srep21930>

Jackson, P. C.; Meinzer, F. C.; Bustamante, M.; Goldstein, G.; Franco, A.; Rundel, P. W.; Caldas, L.; Igler, E.; Causin, F. Partitioning of soil water among tree species in a Brazilian Cerrado ecosystem. *Tree Physiology*, 19, 1999, 717–724. Doi: <http://dx.doi.org/10.1093/treephys/19.11.717>

Ji, L.; Senay, G. B. Velpuri, N. M.; Kagone, Evaluating the Temperature Difference Parameter in the SSEBop Model with Satellite-Observed Land Surface Temperature Data. *Remote Sensing*, 2019, 11, 1947. Doi: <https://doi.org/10.3390/rs11161947>

Kalma, J. D.; McVicar, T. R.; McCabe, M. F. Estimating Land Surface Evaporation: A Review of Methods Using Remotely Sensed Surface Temperature Data. *Surveys in Geophysics*, 29, 2008, 421-469. Doi: <http://dx.doi.org/10.1007/s10712-008-9037-z>

Krishnaswamy, J.; Bonell, M.; Venkatesh, B.; Purandara, B. K.; Rakesh, K. N.; Lele, S.; Kiran, M. C.; Reddy, V.; Badiger, S. The groundwater recharge response and hydrologic services of

tropical humid forest ecosystems to use and reforestation: Support for the “infiltration-evapotranspiration trade-off hypothesis”. *Journal of Hydrology*, 498, 2013, 191–209. Doi: <http://dx.doi.org/10.1016/j.jhydrol.2013.06.034>

Laclau, J. P.; Silva, E. A.; Lambais, G. R.; Bernoux, M.; Maire, G.; Stape, J. L.; Bouillet, J. P.; Gonçalves, J. L. M.; Jourdan, C.; Nouvellon, Y. Dynamics of soil exploration by fine roots down to a depth of 10m throughout the entire rotation in *Eucalyptus grandis* plantations. *Frontiers in Plant Science*, 4, 2013. Doi: <http://dx.doi.org/10.3389/fpls.2013.00243>

Lathuilliere, M. J.; Johnson, M. S.; Donner, S. D. Water use by terrestrial ecosystems: temporal variability in rainforest and agricultural contributions to evapotranspiration in Mato Grosso, Brazil. *Environmental Research Letters*, 7, 024024, 2012, 1–18. Doi: <https://doi.org/10.1088/1748-9326/7/2/024024>

Lilienfein, J.; Wilcke1, W.; Zimmermann, R.; Gerstberger, P.; Araujo, G. M.; Zech, W. Nutrient storage in soil and biomass of native Brazilian Cerrado. *Journal of Plant Nutrition and Soil Science*, 164, 2001, 487–495. Doi: [https://doi.org/10.1002/1522-2624\(200110\)164:5<487::AID-JPLN487>3.0.CO;2-I](https://doi.org/10.1002/1522-2624(200110)164:5<487::AID-JPLN487>3.0.CO;2-I)

Lima, J. E. F. W.; Silva, C. L.; Oliveira, C. A. S. Comparação da evapotranspiração real simulada e observada em uma bacia hidrográfica em condições naturais de cerrado (Comparation of simulated and measured data of actual evapotranspiration of a watershed with natural Brazilian savannah conditions), *Revista Brasileira de Engenharia Agrícola e Ambiental*, 5(1), 2001, 33–41. Doi: <https://doi.org/10.1590/S1415-43662001000100007>

Lima, J. E. F. W. Modelagem numérica do fluxo da água no solo e do escoamento de base em uma bacia experimental em área agrícola no Cerrado (Numerical modeling of water flux and baseflow in an experimental agricultural area in the Cerrado). [Doctorate] Brasília: Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, 2010.

Loarie, S. R.; Lobell, D. B.; Asner, G. P.; Mu, Q.; Field, C. B. Direct impacts on local climate of sugar-cane expansion in Brazil. *Nature Climate Change*, 1, 2011, 105–109. Doi: <https://doi.org/10.1038/NCLIMATE1067>

Lopes, J. D.; Rodrigues, L. N.; Imbuzeiro, H. M. A.; Pruski, F. F. Performance of SSEBop model for estimating wheat actual evapotranspiration in the Brazilian Savannah region. *International Journal of Remote Sensing*, 2019, 1-18. Doi: <https://doi.org/10.1080/01431161.2019.1597304>

Lu, J.; Li, Z-L.; Tang, R.; Tang, B-H.; Wu, H.; Yang, F.; Labed, J.; Zhou, G. Evaluating the SEBS-estimated evaporative fraction from MODIS data for a complex underlying surface. *Hydrological Processes*, 27, 2013, 3139–3149. Doi: <https://doi.org/10.1002/hyp.9440>

Lucas, M.; Wendland, E. Recharge estimates for various land uses in the Guarani Aquifer System outcrop area. *Hydrological Sciences Journal*, 61(7), 2016, 1253–1262. Doi: <https://doi.org/10.1080/02626667.2015.1031760>

Luchiari-Jr, A.; Riha, S. J.; Gomide, R.L. Energy balance in irrigated wheat in the Cerrados region of central Brazil. *Scientia Agricola*, 54, 1997, 78–88. Doi: <http://dx.doi.org/10.1590/S0103-90161997000300011>

Mendonça, R.C.; Felfili, J.M.; Walter, B.M.T.; Silva Júnior, M.C.; Rezende, A.V.; Filgueiras, T.S., Nogueira, P.E. & Fagg, C.W. Flora vascular do Bioma Cerrado: checklist com 12.356 espécies. In: S.M. Sano, S.P. Almeida, J.F. Ribeiro (eds.). Cerrado: ecologia e flora. Brasília, Embrapa Cerrados, 2008, p. 423-1279.

Menenti, M.; Choudhury, B. J. Parameterization of land surface evaporation by means of location dependent potential evaporation and surface temperature range. In H. J. Bolle, R. A. Feddes, & J. D. Kalma (Eds.), Exchange process at the land surface for a range of space and time scales, publication no. 212 (pp. 561–568). UK: International Association of Hydrological Sciences.

Meirelles, M. L.; Franco, A. C.; Farias, S. E. M.; Bracho, R. Evapotranspiration and plant-atmospheric coupling in a Brachiaria brizantha pasture in the Brazilian savannah region. *Grass and Forage Science*, 66, 2011, 206–213. Doi: <https://doi.org/10.1111/j.1365-2494.2010.00777.x>

Moreira, M. Z.; Scholz, F. G.; Bucci, S. J.; Sternberg, L. S.; Goldstein, G.; Meinzer, F. C.; Franco, A. C. Hydraulic lift in a Neotropical savanna. *Functional Ecology* 17, 2003, 573–581. Doi: <https://doi.org/10.1046/j.1365-2435.2003.00770.x>

Norman, J. M.; Kustas, W. P.; Humes, K. S. Source approach for estimating soil and vegetation energy fluxes in observations of directional radiometric surface temperature. *Agricultural and Forest Meteorology*, 77, 1995, 263–293. Doi: [http://dx.doi.org/10.1016/0168-1923\(95\)02265-Y](http://dx.doi.org/10.1016/0168-1923(95)02265-Y).

Oliveira, P. T. S.; Leite, M. B.; Mattos, T.; Nearing, M. A.; Scott, R. L.; Xavier, R. O.; Matos, D. M. S.; Wendland, E. Groundwater recharge decrease with increased vegetation density in the Brazilian cerrado. *Ecohydrology*, 10, 2017, 1-8. Doi: <https://doi.org/10.1002/eco.1759>

Oliveira, R. S.; Bezerra, L.; Davidson, E. A.; Pinto, F.; Klink, C. A.; Nepstad, D. C.; Moreira, A. Deep root function in soil water dynamics in cerrado savannas of central Brazil. *Functional Ecology*, 19, 2005, 574-581. Doi: <https://doi.org/10.1111/j.1365-2435.2005.01003.x>

Oliveira, B. S.; Moraes, E. C.; Carrasco-Benavides, M.; Bertani, G.; Mataveli, G. A. V. Improved Albedo Estimates Implemented in the METRIC Model for Modeling Energy Balance Fluxes and Evapotranspiration over Agricultural and Natural Areas in the Brazilian Cerrado. *Remote Sensing*, 10, 2018, 1181. Doi: <https://doi.org/10.3390/rs10081181>

Overgaard, J.; Rosbjerg, D.; Butts, M. B. Land-surface modelling in hydrological perspective. *Biogeosciences Discussions*, 2, 2005, 1815–1848. Doi: <https://doi.org/10.5194/bg-3-229-2006>

Pakparvar, M.; Cornelis, W.; Pereira, L. S.; Gabriels, D.; Hosseini Marandi, H.; Edraki, M.; Kowsar, S. A. Remote sensing estimation of actual evapotranspiration and crop coefficients for a multiple land use arid landscape of southern Iran with limited available data. *Journal of Hydroinformatics*, 16(6), 2014, 1441–1460. Doi: <https://doi.org/10.2166/hydro.2014.140>

Parron, L. M.; Sousa-Silva, J. C.; Camargo, A. J. A. de. Reservas ecológicas da Embrapa Cerrados: Caracterização e zoneamento. Planaltina: EMBRAPA-CPAC, 1998. 80p. (EMBRAPA CPAC Documentos, 73).

Paula, A. C. P. de; Silva, C. L. da; Rodrigues, L.N.; Scherer-Warren, M. Performance of the SSEBop model in the estimation of the actual evapotranspiration of soybean and bean crops.

Pesquisa Agropecuária Brasileira, 54, e00739, 2019. Doi: <https://doi.org/10.1590/S1678-3921.pab2019.v54.00739>

Paciullo, D. S. C.; Castro, C. R. T.; Gomide, C. A. M.; Fernandes, P. B.; Rocha, W. S. D.; Müller, M. D.; Rossiello, R. O. P. Soil bulk density and biomass partitioning of *Brachiaria decumbens* in a silvopastoral system. *Scientia Agricola*, 67, 5, 2010, 598-603. Doi: <https://doi.org/10.1590/S0103-90162010000500014>

Pinheiro, R. C.; Deus Jr, J. C.; Nouvellon, Y.; Campoe, O. C.; Stape, J. L.; Aló, L. L.; Guerrini, I. A.; Jourdan, C. Laclau, J. P. A fast exploration of very deep soil layers by Eucalyptus seedlings and clones in Brazil. *Forest Ecology and Management*, 366, 2016, 143–152. Doi: <http://dx.doi.org/10.1016/j.foreco.2016.02.012>

Quesada, C. A.; Miranda, A. C.; Hodnett, M. G.; Santos, A. J. B.; Miranda, H. S.; Breyer, L. M. *Ecological Applications*, 14(4), 2004, 33-41.

Quesada, C. A.; Hodnett, M. G.; Breyer, L. M.; Santos, A. J. B.; Andrade, S.; Miranda, H. S.; Miranda, A. C.; Lloyd J. Seasonal variations in soil water in two woodland savannas of central Brazil with different fire history. *Tree Physiology*, 28, 2008, 405–415. Doi: <https://doi.org/10.1093/treephys/28.3.405>

Reatto, A.; Correia, J. R.; & Spera, S. T. Solos do bioma cerrado: Aspectos pedológicos (soils of the cerrado biome: Pedological aspects). In S. M. Sano, & S. P. Almeida (Eds.). *Cerrado: Ambiente e flora*. Planaltina: EMBRAPA-CPAC, 1998, pp. 556.

Rada, N. Assessing Brazil's Cerrado agricultural miracle. *Food Policy*, 38, 2013, 146-155. Doi: <http://dx.doi.org/10.1016/j.foodpol.2012.11.002>

Ratter, J. A.; Ribeiro, J. F.; Bridgewater, S. The Brazilian Cerrado Vegetation and Threats to its Biodiversity. *Annals of Botany*, 80, 1997, 223–230. Doi: <https://doi.org/10.1006/anbo.1997.0469>

Ribeiro, J.F.; Walter, B.M.T. Fitofisionomias do bioma Cerrado. In *Cerrado: ambiente e flora*; Sano, S.M.; Almeida, S.P. EMBRAPA-CPAC: Planaltina, Brazil, 1998, p. 556.

Ribeiro, S. C.; Fehrman, L.; Soares, C. P. B.; Jacovine, L. A. G.; Kleinn, C.; Gaspar, R. de O. Above- and belowground biomass in a Brazilian Cerrado. *Forest Ecology and Management*, 262, 2011, 491–499. Doi: <https://doi.org/10.1016/j.foreco.2011.04.017>

Rocha, O. M.; Ramos, M. L. G.; Veiga, A. D.; Guerra, A. F.; Bartholo, G. F.; Rodrigues, G. C.; Silva, J. E. Chemical and hydrophysical attributes of an Oxisol under coffee intercropped with brachiaria in the Cerrado. *Pesquisa Agropecuária Brasileira*, 51(9), 2016, 1476–1483. Doi: <http://dx.doi.org/10.1590/S0100-204X2016000900046>

Sano, E. E.; Rosa, R.; Scaramuzza, C. A. de M.; Adami, M.; Bolfe, E. L.; Coutinho, A. C.; Esquerdo, J. C. D. M.; Maurano, L. E. P.; Narvaes, I. da S.; Oliveira Filho, F. J. B. de; Silva, E. B. da; Victoria, D. de C.; Ferreira, L. G.; Brito, J. L. S.; Bayma, A. P.; Oliveira, G. H. de; Bayma-Silva, G. Land use dynamics in the Brazilian Cerrado in the period from 2002 to 2013. *Pesquisa Agropecuária Brasileira*, 54, e00138, 2019. Doi: <https://doi.org/10.1590/S1678-3921.pab2019.v54.00138>

Santos, A. J. B.; Quesada, C. A.; Silva, G. T.; Maia, J. F.; Miranda, H. S.; Miranda, A. C.; Lloyd, J. High rates of net ecosystem carbon assimilation by Brachiaria pasture in the Brazilian Cerrado. *Global Change Biology*, 10, 2004, 877–885. Doi: <https://doi.org/10.1111/j.1529-8817.2003.00777.x>

Santos, R. S. M.; Oliveira, I. P.; Morais, R. F.; Urquiaga, S. C.; Boddey, R. M.; Alves, B. J. R. Componentes da parte aérea e raízes de pastagens de *Brachiaria* spp. em diferentes idades após a reforma, como indicadores de produtividade em ambiente de Cerrado (Aboveground and total root biomass components of *Brachiaria* pastures in different ages after renovation as a production indicator under savanna vegetation). *Pesquisa Agropecuaria Tropical*, 37, 2, 2007, 119-124.

Schauer, M.; Senay, G. B. Characterizing Crop Water Use Dynamics in the Central Valley of California Using Landsat-Derived Evapotranspiration. *Remote Sensing*, 11, 2019, 1782. Doi: <https://doi.org/10.3390/rs11151782>

Scholz, F. G.; Bucci, S. J.; Goldstein, G.; Meinzer, F. C.; Franco, A. C. Hydraulic redistribution of soil water by Neotropical savanna trees. *Tree Physiology* 22, 2002, 603–612. Doi: <https://doi.org/10.1093/treephys/22.9.603>

Scholz, F. G.; Bucci, S. J.; Hoffmann, W. A.; Meinzer, F. C.; Goldstein, G. Hydraulic lift in a Neotropical savanna: Experimental manipulation and model simulations. *Agricultural and Forest Meteorology*, 150, 2010, 629–639. Doi: <https://doi.org/10.1016/j.agrformet.2010.02.001>

Scholz, F. G.; Bucci, S. J.; Goldstein, G.; Moreira, M. Z.; Meinzer, F. C.; Domec, J.-C.; Villalobos-Veja, R.; Franco, A. C.; Miralles-Wilhelm, F. Biophysical and life-history determinants of hydraulic lift in Neotropical savanna trees. *Functional Ecology*, 22, 2008, 773–786. Doi: <https://doi.org/10.1111/j.1365-2435.2008.01452.x>

Senay, G. B. Satellite psychrometric formulation of the Operational Simplified Surface Energy Balance (SSEBOP) model for quantifying and mapping evapotranspiration. *Applied Engineering in Agriculture*, 34(3), 2018, 555-566. Doi: <https://doi.org/10.13031/aea.12614>

Senay, G. B.; Bohms, S.; Singh, R. K.; Gowda, P. H.; Velpuri, N. M.; Alemu, H.; Verdin, J. P. Operational Evapotranspiration Mapping Using Remote Sensing and Weather Datasets: A New Parameterization for the SSEB Approach. *Journal of the American Water Resources Association (JAWRA)* 49(3), 2013, 577-591. Doi: <https://doi.org/10.1111/jawr.12057>

Senay, G. B., Budde, M., Verdin, J. P., & Melesse, A. M. A coupled remote sensing and simplified surface energy balance approach to estimate actual evapotranspiration from irrigated fields. *Sensors*, 7, 2007, 979–1000. Doi: <https://doi.org/10.3390/s7060979>

Senay, G. B.; Friedrichs, M.; Singh, R. K.; Velpuri, N. M. Evaluating Landsat 8 evapotranspiration for water use mapping in the Colorado River Basin. *Remote Sensing of Environment*, 185, 2016, 171–185. Doi: <http://dx.doi.org/10.1016/j.rse.2015.12.043>

Senay, G. B.; Schauer, M.; Friedrichs, M.; Velpuri, N. M.; Singh, R. K. Satellite-based water use dynamics using historical Landsat data (1984–2014) in the southwestern United States. *Remote Sensing of Environment*, 202, 2017, 98-112. Doi: <https://doi.org/10.1016/j.rse.2017.05.005>

Silva, R. A. B.; Lima, J. R. S.; Antonino, A. C. D.; Gondim, P. S. S.; Souza, E. S.; Barros-Jr, G. Balanço hídrico em neossolo regolítico cultivado com Braquiária - Brachiaria decumbens Stapf (Water balance in regosols cultivated with signal grass - Brachiaria decumbens Stapf). Revista Brasileira de Ciência do Solo, 38, 2014, 147-157. Doi: <http://dx.doi.org/10.1590/S0100-06832014000100014>

Silva, B. B. da; Wilcox, B. P.; Silva, V. de P. R. da; Montenegro, S. M. G. L.; Oliveira, L. M. M. de. Changes to the energy budget and evapotranspiration following conversion of tropical savannas to agricultural lands in São Paulo State, Brazil. Ecohydrology, 8, 2015, 1272–1283. Doi: <https://doi.org/10.1002/eco.1580>

Singh, R. K.; Senay, G. B. Comparison of Four Different Energy Balance Models for Estimating Evapotranspiration in the Midwestern United States. Water, 8, 2016, 9. Doi: <https://doi.org/10.3390/w8010009>

Singh, R. K.; Senay, G. B.; Velpuri, N. M.; Bohms, S.; Scott, R. L.; Verdin, J. P. Actual Evapotranspiration (Water Use) Assessment of the Colorado River Basin at the Landsat Resolution Using the Operational Simplified Surface Energy Balance Model. Remote sensing, 6, 233-256, 2014. Doi: <https://doi.org/10.3390/rs6010233>

Sobrino, J. A.; Jiménez-Muñoz, J. C.; Paolini, L. Land surface temperature retrieval from LANDSAT TM 5. Remote Sensing of Environment, 90, 2004, 434–440. Doi: <https://doi.org/10.1016/j.rse.2004.02.003>

Soares, J. V.; Almeida, A. C. Modeling the water balance and soil water fluxes in a fast growing Eucalyptus plantation in Brazil. Journal of Hydrology, 253, 2001, 130–147. Doi: [https://doi.org/10.1016/S0022-1694\(01\)00477-2](https://doi.org/10.1016/S0022-1694(01)00477-2)

Stape, J. L.; Binkley, D.; Ryan, M. G.; Fonseca, S.; Loos, R. A.; Takahashi, E. N.; Silva, C. R.; Silva, S. R.; Hakamada, R. E.; Ferreira, J. M. de A.; Lima, A. M. N.; Gava, J. L.; Leite, F. P.; Andrade, H. B.; Alves, J. M.; Silva, G. G. C.; Azevedo, M. R. The Brazil Eucalyptus Potential Productivity Project: Influence of water, nutrients and stand uniformity on wood production. Forest Ecology and Management, 259, 2010, 1684–1694. Doi: <https://doi.org/10.1016/j.foreco.2010.01.012>

Su, Z. The Surface Energy Balance System (SEBS) for estimation of turbulent heat fluxes. Hydrology and Earth System Sciences Discussions, 6(1), 2002, 85–100. Doi: <https://doi.org/10.5194/hess-6-85-2002>

Wukelic, G.; Gibbons, D.; Martucci, L.; Foote, H. Radiometric calibration of Landsat Thematic Mapper thermal band. Remote Sensing of Environment, 28, 1989, 339–347. Doi: [https://doi.org/10.1016/0034-4257\(89\)90125-9](https://doi.org/10.1016/0034-4257(89)90125-9)

Xavier, A. C.; King, C. W.; Scanlon, B. R. Daily gridded meteorological variables in Brazil (1980–2013). International Journal of Climatology, 36, 2016, 2644–2659. Doi: <https://doi.org/10.1002/joc.4518>

Zhang, M.; Liu, N.; Harper, R.; Li, Q.; Liu K.; Wei X.; Ning, D.; Hou, Y.; Liu, S. A global review on hydrological responses to forest change across multiple spatial scales: Importance of scale,

climate, forest type and hydrological regime. *Journal of Hydrology*, 546, 2017, 44–59. Doi: <http://dx.doi.org/10.1016/j.jhydrol.2016.12.040>

CAPÍTULO 4**SIMULAÇÃO HIDROLÓGICA UTILIZANDO DADOS DE EVAPOTRANSPIRAÇÃO REAL E PRECIPITAÇÃO OBTIDOS POR SENSORIAMENTO REMOTO EM BACIA HIDROGRÁFICA DO BIOMA CERRADO.**

O artigo apresentado neste capítulo faz uma avaliação do uso de produtos globais de P_{sr} e de ET_r gerados a partir de dados obtidos por sensoriamento remoto, no modelo de simulação hidrológica *Soil and Water Assessment Tool* (SWAT). A importância deste estudo no contexto da Tese de doutorado consiste em dar sequência aos artigos desenvolvidos nos capítulos anteriores e verificar como dados obtidos por sensoriamento remoto podem contribuir nas simulações de vazões e outras variáveis hidrológicas em bacias hidrográficas agrícolas no bioma Cerrado.

Salles, L.A.; Roig, H.L.; Senay, G.; Satgé, F.; Lima, J.E.F.W.; Neumann, M.R.B.; Conti, L.C.; Malta, E.A.; Neves, G.B.; Ferrreira, W. Integração de modelo chuva-vazão com produtos globais de evapotranspiração real e de precipitação obtidos por sensoriamento remoto em bacia hidrográfica do bioma cerrado.

INTEGRAÇÃO DE MODELO CHUVA-VAZÃO COM PRODUTOS GLOBAIS DE EVAPOTRANSPIRAÇÃO REAL E DE PRECIPITAÇÃO OBTIDOS POR SENSORIAMENTO REMOTO EM BACIA HIDROGRÁFICA DO BIOMA CERRADO.

Resumo

O objetivo deste estudo foi avaliar o uso de estimativas de evapotranspiração real (ET_r) e de precipitação (P) feitas através de dados obtidos por sensoriamento remoto em modelo hidrológico para a simulação de vazões (Q) e ET_r na Bacia Hidrográfica do Reservatório de Queimado (BHRQ), no bioma Cerrado. As estimativas de ET_r foram obtidas de um produto global que utiliza o *Operational Simplified Surface Energy Balance* (SSEBop), a partir de dados do *Moderate resolution Imaging Spectroradiometer* (MODIS). Já as estimativas de P por sensoriamento remoto (P_{sr}) foram obtidas por meio de produtos globais derivados do *Tropical Rainfall Measuring Mission* (TRMM) (*TRMM Multi-satellite Precipitation Analysis* (TMPA) – 3B42) e do *Global Precipitation Measurement* (GPM) (*Integrated Multi-satellitE Retrievals for GPM* (IMERG) e o *Global Satellite Mapping of Precipitation* (GSMaP)). As estimativas de ET_r e de P_{sr} foram utilizadas no modelo chuva-vazão *Soil and Water Assessment Tool* (SWAT) para simular Q e ET_r em quatro sub-bacias da BHRQ. De modo geral, os produtos de P_{sr} e ET_r utilizados em conjunto com o modelo hidrológico, foram capazes de fornecer dados que contribuíram com a simulação de Q e ET_r na BHRQ. No entanto, os resultados não foram satisfatórios em todos os cenários avaliados, de modo que qualquer generalização deve ser evitada. Em relação aos dados de P_{sr} , a nova geração de produtos obtidos a partir de dados da missão GPM (IMERG e GSMAp) foi capaz de garantir a continuidade no fornecimento de dados de P para simulação de Q com modelo hidrológico no Brasil central de forma semelhante ou até mesmo melhor do que o obtido anteriormente com o principal produto da geração TRMM. O IMERG apresentou melhores resultados na maior parte dos cenários avaliados. Em relação ao uso de dados do SSEBop em conjunto com o modelo hidrológico, ficou demonstrada a sua importância na calibração do modelo SWAT para a simulação de Q e ET_r . Por fim, os produtos de P_{sr} e ET_r avaliados no presente estudo se mostraram ser uma importante fonte de dados para gestão dos recursos hídricos, uma vez que disponibilizam séries temporais de P e ET_r em todo o território brasileiro, o qual possui muitos locais que carecem de dados hidrológicos.

Palavras-chave: GPM, TRMM, SSEBop, SWAT, IMERG, GSMAp, TMPA

1. Introdução

O uso de geotecnologias se tornou de extrema importância para o monitoramento de processos hidrológicos, sendo mundialmente empregado no manejo e conservação da água e do solo em bacias hidrográficas. O *Soil and Water Assessment Tool* (SWAT) é um exemplo de modelo hidrológico que vem sendo amplamente utilizado para essa finalidade (e.g. ABBASPOUR *et al.*, 2015; CASTRO *et al.*, 2016; FRANCO & BONUMÁ, 2017; HERMAN *et al.*, 2018; DENG *et al.*, 2019; LUO *et al.*, 2019; TANG *et al.*, 2019; TAN & YANG, 2020; TRIANA *et al.*, 2020), simulando os fenômenos físicos do ciclo hidrológico existentes em uma bacia hidrográfica associados ao uso do solo, como o escoamento superficial e subterrâneo, a produção de sedimentos e a qualidade da água (SRINIVASAN & ARNOLD, 1994). No Brasil, Bressiani *et al.* (2015) identificaram mais de 100 estudos que utilizaram o SWAT, no período entre 1999 e 2015. Muitos desses estudos foram conduzidos no bioma Cerrado (e.g. SARMENTO, 2010; STRAUCH *et al.*, 2012; STRAUCH; VOLK, 2013; STRAUCH *et al.*, 2013; FERRIGO, 2014; SALLES *et al.*, 2015; CASTRO *et al.*, 2016; TÁVORA, 2017; ARAÚJO, 2018), o qual vem passando por grandes transformações da paisagem devido ao avanço da agricultura nos últimos anos, e cuja sazonalidade do clima com estação seca e chuvosa bem definidas, associada ao crescimento populacional e ao aumento da demanda por práticas agrícolas de irrigação, tem proporcionado problemas relacionados a disponibilidade hídrica em muitas regiões.

Mesmo com os resultados satisfatórios obtidos com o modelo SWAT no Brasil, o processo de calibração pode esconder problemas significantes, como a representação inadequada das características da vegetação e de culturas agrícolas, bem como de outros dados de entrada (BRESSIANI *et al.*, 2015). De fato, a aquisição das variáveis de entrada, a estrutura do modelo (equações e simplificações utilizadas para representar o sistema), e a estimativa dos parâmetros estão entre as principais fontes de incertezas envolvidas em estudos hidrológicos (TUCCI, 1998).

Nesse cenário, algumas iniciativas foram feitas nos últimos anos para melhorar a base física das simulações hidrológicas em regiões de clima tropical. Por exemplo, Strauch *et al.* (2012) avaliaram as incertezas nas simulações de vazões decorrentes do uso de diferentes dados de precipitação (P) e concluíram que, apesar de o uso de dados pontuais coletados dentro da bacia hidrográfica estudada fornecer resultados satisfatórios, a integração desses dados com dados distribuídos espacialmente reduz as incertezas nos dados de saída, sendo uma opção para melhorar a modelagem. Strauch & Volk (2013), por sua vez, propuseram alteração do código do SWAT com uma função logística de declínio do Índice de Área Foliar (IAF), para melhorar a representação da senescência das folhas da vegetação nativa de regiões tropicais no processo de

modelagem. Além disso, esses autores adaptaram o SWAT para representar de forma apropriada as condições hidrológicas esperadas em ambientes tropicais, onde o teor de umidade no solo é o fator limitante para o crescimento das plantas.

Nesse contexto de soluções para a modelagem hidrológica no Brasil, também foi proposto uma base de dados de solos para a aplicação do modelo SWAT em bacias hidrográficas do bioma Cerrado, visando melhorar a base física do modelo na representação das propriedades físicas dos solos de regiões tropicais (LIMA *et al.*, 2013). Em Salles *et al.* (2015), ficou demonstrado que esse banco de dados de solos proposto por Lima *et al.* (2013) traz benefícios em relação à representação do balanço hídrico na condição inicial do modelo, sendo de grande importância para bacias não monitoradas. Também podemos citar o estudo de Franco & Bonumá (2017) que avaliou melhorias nas simulações do modelo SWAT utilizando séries temporais de evapotranspiração real (ET_r) por sensoriamento remoto. Esse estudo demonstrou que, comparada com a calibração convencional conduzida apenas com dados de vazão (Q), a calibração multi-varável ($ET + Q$) apresentou melhor desempenho da simulação de Q. No entanto, os autores também concluem que a estratégia de calibração utilizada não foi capaz de evidenciar diminuição nas incertezas envolvidas nas estimativas de Q.

Apesar de todo esforço em propor melhorias no processo de simulação hidrológica em bacias hidrográficas brasileiras, ainda há muito para ser avaliado, uma vez que as geotecnologias estão em constante desenvolvimento, com novas ferramentas para análise. Por exemplo, o estudo de Strauch *et al.* (2012) utilizou dados do *Tropical Rainfall Measuring Mission Multi-satellite Precipitation Analysis* (TMPA) (HUFFMAN *et al.*, 2007), que é um produto de precipitação por sensoriamento remoto (P_{sr}) desenvolvido no âmbito da missão *Tropical Rainfall Measuring Mission* (TRMM), a qual chegou ao fim e foi substituída pela missão *Global Precipitation Measurement* (GPM) (HOU *et al.*, 2014), com os seus respectivos produtos que estimam P_{sr} : o *Global Satellite Mapping of Precipitation* (GSMP) (KUBOTA *et al.*, 2007; USHIO *et al.*, 2009); e o *Integrated multi-satellite retrievals for Global Precipitation Measurement* (IMERG) (HUFFMANN *et al.*, 2015). Diversos estudos comparam a transição da era TRMM para a geração GPM no Brasil e no mundo (e.g. TANG *et al.*, 2016; SHARIFI *et al.*, 2016; SATGÉ *et al.*, 2017; ROZANTE *et al.* 2018; SALLES *et al.*, 2019) mostrando, na maior parte dos casos, melhorias nas estimativas de P_{sr} . Especificamente na mesma região que será avaliada no presente estudo, Salles *et al.* (2019) demonstraram que a nova geração de produtos de P_{sr} obtidos a partir de dados da missão GPM (IMERG e GSMP) é capaz de garantir a continuidade no monitoramento da precipitação no Brasil central de forma semelhante ou até mesmo melhor do que o obtido anteriormente com produtos da geração TRMM. Além disso, esses autores

concluem que apesar das diferenças observadas entre o IMERG e o GSMAp, os resultados indicam melhorias na detecção de eventos de P, assim como na determinação de sua magnitude, entre os produtos obtidos nas gerações TRMM e GPM. No entanto, o desempenho dos produtos de satélites que estimam a precipitação pode ser insatisfatório e requer cuidado quando aplicados para modelagem hidrológica e para gestão da água (KARIMI & BASTIAANSSEN, 2015; JIANG & WANG, 2019). Nesse contexto, mostra-se oportuno avaliar o uso dessa nova geração de dados de P_{sr} (IMERG e o GSMAp) em simulações hidrológicas em comparação com os dados de algoritmos desenvolvidos anteriormente (TMPA) e com dados de pluviômetros.

De forma similar, existem diversos modelos que estimam a ET_r por sensoriamento remoto que podem ser testados em simulações com modelos hidrológicos. Entre eles, podemos destacar: o *Surface Energy Balance for Land* (SEBAL) (BASTIAANSSEN *et al.*, 1998), o *Mapping Evapotranspiration with Internalized Calibration* (METRIC) (ALLEN *et al.*, 2007); o *Surface Energy Balance System* (SEBS) (SU, 2002); o *Atmosphere-Land Exchange Inverse* (ALEXI) (ANDERSON *et al.*, 2007), e o *Simplified Surface Energy Balance Approach* (SSEBop) (SENAY *et al.*, 2013). O uso de metodologias que estimam a ET_r com dados obtidos por sensoriamento remoto pode contribuir para a redução de incertezas em modelos hidrológicos distribuídos que empregam metodologias tradicionais para o cálculo da ET_r (BASTIAANSSEN *et al.*, 2010). No entanto, a integração dessas estimativas em modelos hidrológicos ainda é um desafio para a comunidade científica, sendo, muitas vezes, subutilizada (KARIMI & BASTIAANSSEN, 2015), devido ao fato de a ET_r não ser constante e à dificuldade de se mensurar essa variável ao longo do tempo (JIANG & WANG, 2019).

Em Franco e Bonumá (2017) foram utilizados dados de ET_r gerados pelo METRIC que, apesar de ser um modelo de ET_r por sensoriamento remoto utilizado em diversas aplicações pelo mundo (e.g. SCHERER-WARREN, 2012; CARRILLO-ROJAS, *et al.*, 2016; KILIC *et al.*, 2016; SINGH & SENAY, 2016; OLIVEIRA *et al.*, 2018), ele requer condições hidro-climáticas homogêneas, o que dificulta o seu uso em áreas extensas (SENAY *et al.*, 2013). Além disso, modelos que estimam o balanço de energia na superfície, como o METRIC, podem ser complexos na parametrização (GOWDA *et al.*, 2008; SINGH & SENAY, 2016). Em sentido oposto, o modelo SSEBop foi desenvolvido com simplificações que possibilitaram o seu uso em escala continental (e.g. SENAY *et al.*, 2013; SENAY *et al.*, 2017; BRASIL, 2020) e que, atualmente, possui aplicações utilizando imagens MODIS e Landsat que estão disponíveis gratuitamente na internet (HUNTINGTON *et al.*, 2017; BRASIL, 2020), o que facilita o seu uso em estudos de simulação hidrológica no Brasil. Desde a sua formulação, o SSEBop foi validado em diferentes estudos (e.g. SINGH *et al.*, 2014; CHEN *et al.*, 2016; SINGH & SENAY, 2016;

ALEMAYEHU *et al.*, 2017; SENAY *et al.*, 2017; JI *et al.*, 2019), inclusive apresentando bons resultados ($R^2 > 0,8$) em áreas irrigadas situadas na mesma região do Brasil Central que será avaliada no presente estudo (MALTA, 2019; LOPES *et al.*, 2019; PAULA *et al.*, 2019). O SSEBop também foi validado em áreas de pastagem, reflorestamento e em fitofisionomia do bioma Cerrado na mesma região do Brasil Central, ampliando o número de classes de cobertura/uso do solo nas quais esse modelo pode ser utilizado para o monitoramento de ET_r (SALLES *et al.*, 2020). Ademais, séries temporais de ET_r estimadas com o SSEBop podem proporcionar um bom fechamento do balanço hídrico anual em bacias hidrográficas em múltiplas regiões hidro-climáticas (SALLES *et al.*, 2018). Desse modo, também se mostra oportuno avaliar as simulações do SWAT em conjunto com dados de ET_r do modelo SSEBop.

Nesse contexto, o objetivo do presente estudo consiste em avaliar o uso de dados de P e ET_r obtidos por sensoriamento remoto em simulações hidrológicas com o SWAT. Foram avaliados o uso dos produtos TMPA, IMERG e GSMAp de P_{sr} nas simulações de Q_{dia} e $Q_{mês}$, observando o potencial de a missão GPM substituir a TRMM no fornecimento de dados de chuva para simulações hidrológicas em bacias hidrográficas no Brasil. Além disso, foram avaliados o uso de séries temporais de ET_r simuladas com o modelo SSEBop na calibração automática dos parâmetros do SWAT para a simulação de Q e ET_r pelo modelo hidrológico. Por fim, também foram analisadas as incertezas observadas na estimativa dos parâmetros do modelo chuva-vazão ao longo do processo de calibração Q e ET_r nos diferentes cenários que utilizaram os produtos globais obtidos por sensoriamento remoto.

2. Materiais e Métodos

2.1 Área de Estudo

Para a realização dos testes, foi escolhida a Bacia Hidrográfica do Reservatório de Queimado (BHRQ), Figura 1, que está situada no Planalto Central do Brasil, no Bioma Cerrado, e que possui área de drenagem de aproximadamente 3647,86 km². A BHRQ é situada na cabeceira da Bacia Hidrográfica do Rio Preto, que tem suas nascentes no município de Formosa (GO) e deságua no rio Paracatu (MG), um dos principais afluentes do rio São Francisco.

O clima da região é tropical do tipo Aw, segundo a classificação de Köppen, com duas estações bem definidas: verão, quente e chuvoso; e inverno, frio e seco (CAMPOS *et al.*, 2006). Em relação à precipitação mensal, o período chuvoso é bem marcado entre os meses de outubro e abril, com as maiores médias entre 1978 e 2005 registradas no mês de dezembro na estação do Instituto Nacional de Meteorologia em Formosa (15°32'00"S e 47°20'00"W) igual a 280mm, enquanto a estiagem ocorre entre maio e setembro (CAMPOS *et al.*, 2006).

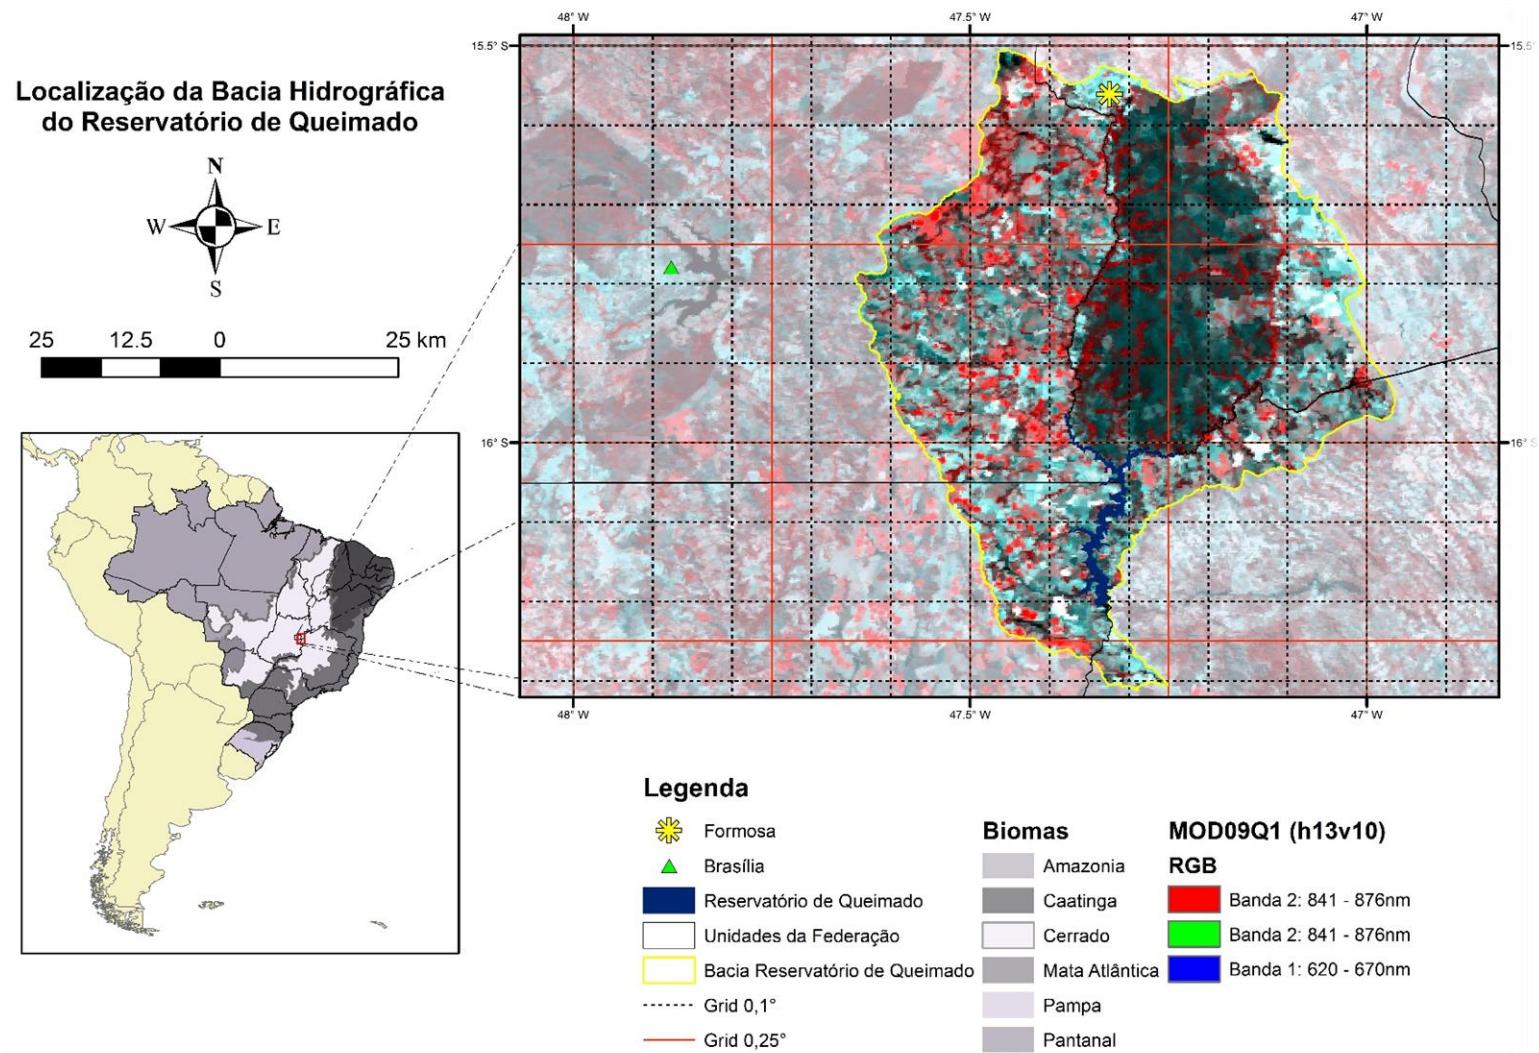


Figura 1: Bacia Hidrográfica do Reservatório de Queimado

Existe uma tríplice fronteira estadual entre o Distrito Federal (DF), Goiás (GO) e Minas Gerais (MG) dentro da BHRQ, sendo uma região estratégica para o Distrito Federal e parte da Região Integrada de Desenvolvimento do Distrito Federal e Entorno (RIDE). Existe conflito pelo uso da água entre não irrigantes, irrigantes, e a usina hidrelétrica de Queimado (Carneiro *et al.*, 2007). A Usina Hidrelétrica de Queimado teve o início de suas obras em 2000 e entrou em operação em 2004. Tem a capacidade de gerar até 105 MW, distribuídos em três unidades geradoras de energia com potência unitária de 35 MW (CEMIG, 2006).

A BHRQ é uma bacia predominantemente agrícola, com trechos também cobertos por vegetação nativa e por uma pequena área urbana ($\sim 30 \text{ km}^2$), representada pela cidade de Formosa (GO), a qual tem uma população de ~ 120 mil habitantes (Figura 1). Em termos geomorfológicos, a BHRQ é caracterizada por chapadas intermediárias, situadas em cotas acima de 800m, cobertas por Latossolos, Cambissolos e Argissolos, desenvolvidos sobre rochas pelítico-carbonatadas, pouco resistentes ao intemperismo, atribuídas ao Grupo Bambuí (CAMPOS *et al.*, 2006).

2.2 Aspectos gerais do SWAT

O modelo *Soil and Water Assessment Tool* (SWAT) foi desenvolvido pelo *Agricultural Research Service* (ARS/USDA) dos Estados Unidos, com o objetivo de analisar os impactos gerados pela alteração do uso e manejo do solo em bacias hidrográficas complexas, e que possuem diferentes combinações de uso, manejo e tipo de solos (NEITSCH *et al.*, 2011).

O objetivo com o desenvolvimento do modelo SWAT foi prever o impacto do manejo do uso do solo nos recursos hídricos, na produção de sedimentos em bacias não monitoradas (ARNOLD *et al.*, 1998). O modelo foi integrado com o Sistema de Informações Geográficas para facilmente extrair os dados de entrada para modelar bacias hidrográficas, distribuir espacialmente os parâmetros para permitir simulações contínuas em um intervalo de tempo, em nível de grandes bacias hidrográficas (SRINIVASAN & ARNOLD, 1994).

O modelo SWAT é um modelo de parâmetros distribuídos espacialmente e contínuo em um intervalo de tempo que simula os fenômenos físicos do ciclo hidrológico existentes em uma bacia hidrográfica associados ao uso do solo, como o escoamento superficial e subterrâneo, produção de sedimentos e qualidade da água (SRINIVASAN & ARNOLD, 1994). Na prática, não existem modelos totalmente distribuídos, pois discretizações são feitas, de forma que o modelo distribuído se torna concentrado em uma pequena sub-divisão (TUCCI, 1998). Assim, o modelo SWAT é semi-distribuído, sendo capaz de considerar a variabilidade espacial e temporal dos tipos e usos do solo, das feições topográficas e dos parâmetros climatológicos nas sub-bacias (SARMENTO, 2010).

Independentemente do tipo de estudo realizado com o SWAT, seu funcionamento será sempre em função do balanço hídrico existente na bacia hidrográfica. Nesse sentido, a simulação dos processos hidrológicos pelo modelo requer a subdivisão dos dados em duas partes. A primeira parte controla quantitativamente a fase terrestre do ciclo hidrológico, calculando-se a evapotranspiração real e potencial, o escoamento superficial, o deslocamento da água pelas camadas do solo, o fluxo de base, os níveis de erosão, entre outros. A segunda parte está voltada para o movimento da água, sedimentos, pesticidas, nutrientes, entre outros, e pelas redes de drenagem, até o exutório da bacia (NEITSCH *et al.*, 2011).

A quantificação da fase terrestre do ciclo hidrológico é calculada a partir da equação do balanço hídrico:

$$SW_t = SW_0 + \sum_{i=1}^t (P_{dia} - Q_{sup} - ET_r - w_s - Q_{subt}) \quad (1)$$

em que SW_t é a quantidade final de água existente no solo (mm H₂O), SW_0 é a quantidade inicial de água existente no solo no dia i (mm H₂O), t é o tempo (dias), P_{dia} é quantidade de chuva no dia i (mm H₂O), Q_{sup} é o escoamento superficial no dia i (mm H₂O), ET_r é a evapotranspiração no dia i (mm H₂O), w_s é a quantidade de água que entra na zona-vadosa no dia i (mm H₂O), e Q_{subt} é o escoamento de base (mm H₂O).

2.3. Base de dados

Os principais dados de entrada para a modelagem hidrológica na BHRQ estão sumarizados na Tabela 1 e apresentados na Figura 2. Esses dados são disponibilizados pelas entidades responsáveis nos seus respectivos sites e podem ser obtidos gratuitamente (Tabela 1).

Tabela 1: Resumo dos dados de entrada para a modelagem.

Dado	Tipo de dado	Fonte/Site
SRTM	Modelo Digital de Elevação	https://earthexplorer.usgs.gov/
ZEE RIDE	Mapa de solos	Brasil, 2003
MapBiomass	Mapa de uso do solo	http://mapbiomas.org
Estações meteorológicas	Precipitação, Umidade relativa, Temperatura (mínima e máxima), Insolação	http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep
Dados Hidroweb	Precipitação e Vazão	http://www.snirh.gov.br/hidroweb
TMPA-3B42	Precipitação	https://mirador.gsfc.nasa.gov/
IMERG	Precipitação	ftp://arthurhou.pps.eosdis.nasa.gov/gpmdata/
GSMaP	Precipitação	https://www.gportal.jaxa.jp/gp
SSEBop	Evapotranspiração real	https://app.climateengine.org/

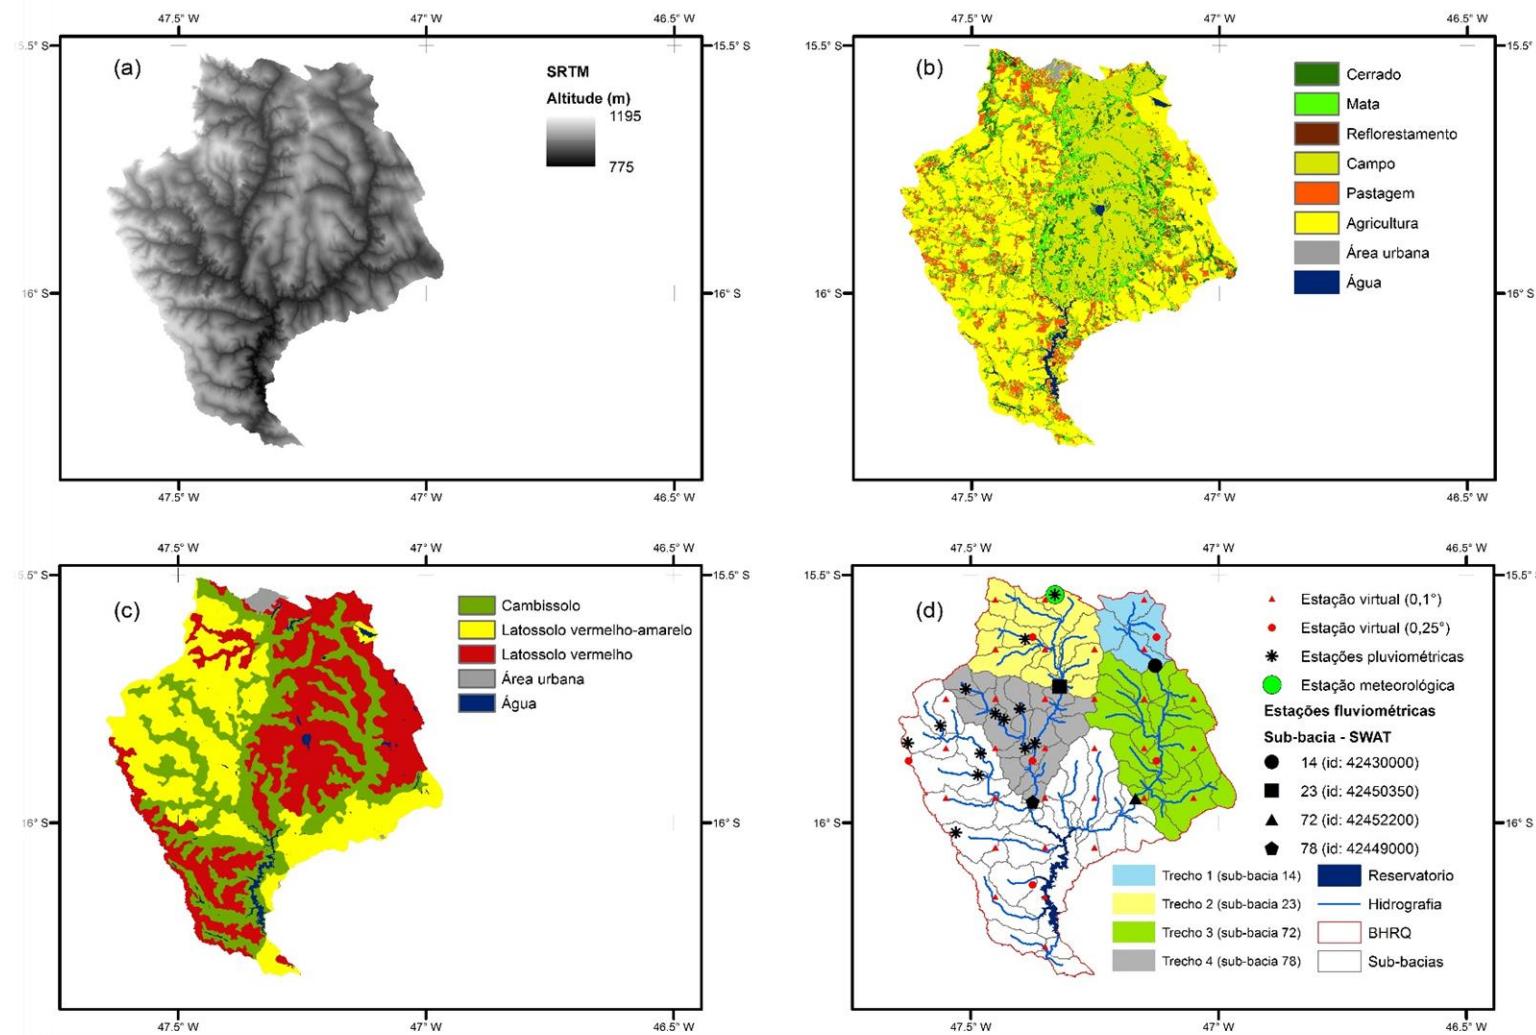


Figura 2: Dados de entrada do modelo hidrológico na Bacia Hidrográfica do Reservatório de Queimado

O modelo digital de elevação da BHRQ (Figura 2a) utilizado foi o SRTM (*Shuttle Radar Topography Mission*) com resolução espacial de aproximadamente 30m (1 arco-segundo) e pode ser baixado no site do USGS (<https://earthexplorer.usgs.gov/>).

O mapa de uso e ocupação do solo do ano de 2010 (Figura 2b) foi extraído do banco de dados do projeto MapBiomas, na versão 3.2. O Projeto MapBiomas é uma iniciativa multi-institucional para geração de mapas anuais de cobertura e uso do solo de todo o território brasileiro para a série histórica 1985-2019 a partir da classificação pixel a pixel de imagens da série Landsat 5,7 e 8 (SPAROVEK et al., 2019). Todo processo é feito com algoritmos de aprendizagem de máquina (*machine learning*) por intermédio da plataforma Google Earth Engine. A descrição completa do projeto encontra-se em <http://mapbiomas.org>. Os dados são disponibilizados na plataforma do Earth Engine da google (<https://code.earthengine.google.com>) a partir de uma coleção pública (asset: projects/mapbiomas-workspace/MOSAICOS/workspace-c3).

Para realizar a simulação hidrológica, foi necessária a compatibilização desse mapa de uso do solo do MapBiomas com o banco de dados do modelo SWAT. A Figura 2(b) apresenta o mapa de uso e ocupação do solo da BHRQ após a integração com banco de dados do modelo SWAT. Por fim, o mapa de uso e ocupação do solo da BHRQ utilizado na simulação hidrológica possui as seguintes classes: Mata de Galeria (9,58%); Cerrado (9,54%); Campo (27,04%); Reflorestamento (0,25%); Pastagem (9,01%); Agricultura (42,91%); Urbano (0,53%); e Córpos d'água (1,14%).

O mapa de solos utilizado na simulação hidrológica com o SWAT (Figura 2c) foi elaborado para a Fase I do Zoneamento Ecológico-Econômico da Região Integrada de Desenvolvimento do Distrito Federal e Entorno (RIDE), na escala de 1:250,000, a partir da compatibilização de mapas de solos existentes e informações auxiliares obtidas por sensoriamento remoto e por trabalhos de campo (BRASIL, 2003). O mapa de solos da BHRQ tem as seguintes classes: Cambissolo (31,6%), Latossolo Vermelho (31,4%), e Latossolo Vermelho-Amarelo (34,5%), com o restante da área (~2,5%) sendo ocupada pelas classes Água e Urbano. Os parâmetros relacionados às propriedades físicas dos solos como, porosidade, condutividade hidráulica entre outros, foram extraídos do banco de dados proposto em Lima *et al.*, (2013) para solos do bioma Cerrado. Esse banco foi desenvolvido com dados coletados na Bacia Experimental do ribeirão Jardim, uma sub-bacia da BHRQ. Também foi utilizado o banco de dados para aplicações do SWAT no bioma Cerrado proposto no contexto da pesquisa desenvolvida por Ferrigo (2014).

Além dos dados mencionados acima, o SWAT necessita de séries históricas de chuva e das condições climáticas (temperatura mínima e máxima, umidade relativa e velocidade do vento), os quais foram obtidos no site do INMET (<http://www.inmet.gov.br>). A Figura 2d apresenta a localização das estações pluviométricas, das estações virtuais com os dados de P_{sr} , da estação meteorológica e das estações de monitoramento de vazão localizadas dentro da BHRQ. Em relação aos dados meteorológicos, serão utilizados os dados de temperatura mínima e máxima, umidade relativa e velocidade do vento, da estação convencional de Formosa. A estação meteorológica de Formosa fornece a quantidade de horas de insolação por dia. Desse modo, a radiação solar foi calculada de acordo com o método exposto no documento FAO-56 (ALLEN *et al.*, 1998). Existem 13 estações pluviométricas instaladas dentro da BHRQ. Por fim, foram utilizadas 4 estações de monitoramento de vazão (Q).

2.4 Dados de precipitação por sensoriamento remoto

Para atingir os objetivos estabelecidos para o presente estudo foram realizadas simulações hidrológicas do modelo SWAT com os seguintes produtos que estimam a P por sensoriamento remoto: IMERG, GSMAp e TMPA – 3B42. Vale lembrar que o TMPA – 3B42 foi desenvolvido no âmbito da missão TRMM, a qual foi substituída em 2014 pela missão GPM que, por sua vez, possui novos produtos P_{sr} : IMERG e o GSMAp. Esses três produtos de P_{sr} foram validados anteriormente em Salles *et al.* (2019) com dados de P coletados *in situ* na mesma região da BHRQ.

A Figura 1 apresenta os grids $0,1^\circ$ e $0,25^\circ$ dos produtos de P_{sr} utilizados no presente estudo (IMERG, GSMAp e TMPA), enquanto a Figura 2d apresenta a localização das estações virtuais que armazenam os dados de P_{sr} . Segue uma breve descrição dos produtos P por sensoriamento remoto que foram utilizados no presente estudo.

2.4.1 Tropical Rainfall Measuring Mission Multi-Satellite Precipitation Analysis (TMPA)

O algoritmo TMPA foi desenvolvido pela NASA (HUFFAMAN *et al.*, 2007; HUFFMAN; BOLVIN, 2015) para integrar dados de P obtidos por diferentes satélites com dados de estações pluviométricas, com o objetivo de fornecer o melhor dado de P estimado por sensoriamento remoto (HUFFAMAN *et al.*, 2007). O TMPA possui uma resolução espacial de $0,25^\circ$, com cobertura entre 50°N e 50°S , e está disponível na resolução temporal de 3 horas e 30 dias (mensal), os quais são denominados TMPA 3B42 e 3B43, respectivamente. O produto TMPA – 3B42 possui uma versão

real time, e outra versão na qual as estimativas de P são calibradas utilizando dados da rede de estações do Global Precipitation Climatology Centre (GPCC) e do *Climate Assessment and Monitoring System* (CAMS) desenvolvido pelo CPC. Até o momento, o algoritmo do TMPA já passou por três atualizações principais, na V5, V6 e V7 as quais foram lançadas em 2005, 2009 e 2012, respectivamente (CHEN; LI, 2016). O presente estudo utilizou o produto TMPA – 3B42, versão 7. Os dados estão disponíveis gratuitamente na internet (<https://mirador.gsfc.nasa.gov/>). Considerando a resolução espacial de 0,25°, foram extraídos 6 pixels do produto TMPA dentro da BHRQ para a análise.

2.4.2 Integrated Multi-satellitE Retrievals for Global Precipitation Measurement (IMERG)

O IMERG foi desenvolvido pela NASA para unir, calibrar e interpolar dados provenientes de diversos sensores passivo de micro-ondas (PMW) e no Infravermelho (IR) em órbita terrestre (HUFFMAN *et al.*, 2015).

O IMERG utiliza conceitos e componentes que foram elaborados ao longo do tempo no desenvolvimento da primeira geração de algoritmos desenvolvidos no âmbito da missão TRMM como: o TMPA (HUFFMAN *et al.*, 2007); o *Climate Prediction Center morphing method* (CMORPH) (JOYCE *et al.*, 2004); e o *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks* (PERSIANN) (HSU *et al.*, 1997; SOROOSHIAN *et al.*, 2000; HONG *et al.*, 2004).

O IMERG possui uma resolução espacial de 0,1° e está disponível na resolução temporal de 30 minutos, com cobertura entre 60°N e 60°S. Os dados do IMERG são disponibilizados com três níveis de processamentos: o *Early-run*, que é fornecido 5 horas após o horário observado; o *Late-run*, que é disponibilizado após 16 horas; e o *Final-run* que utiliza os dados de P mensal da rede de estações do *Global Precipitation Climatology Centre's* (GPCC), para o ajuste final dos dados (HUFFMAN *et al.*, 2015).

No presente estudo utilizamos a versão 5 do produto *Final-run* do IMERG que pode ser obtido na internet (<ftp://arthurhou.pps.eosdis.nasa.gov/gpdata/>). Considerando a resolução espacial de 0,10°, foram extraídos 31 pixels do produto IMERG dentro da BHRQ para a análise. Considerando que o TMPA possui uma resolução de 0,25°, também foi avaliado o uso de dados do IMERG nesta resolução, os quais foram obtidos em Salles *et al.* (2019).

2.4.3 Global Satellite Mapping of Precipitation (GSMap)

O Projeto GsMap foi criado em 2002 pela agência Japonesa *Japan Science and Technology* (JST), no âmbito da *Core Research for Evolutional Science and Technology* (CREST). Atualmente, as atividades são implementadas por uma equipe de cientistas que cuida das missões TRMM e GPM, pertencentes à *Japanese Precipitation Measuring Mission (PMM) Science Team* (GSMAP, 2014). O projeto GsMap disponibiliza produtos que estimam a P utilizando dados coletados por sensoriamento remoto, provenientes de sensores PMW e da combinação entre dados IR e dados PMW (KUBOTA *et al.*, 2007; USHIO *et al.*, 2009), assim como o TMPA e o IMERG. O GsMap possui o produto GsMap *gauge-adjusted*, que possui correção das estimativas de P utilizando dados da rede de pluviômetros do CPC, e que será utilizado neste projeto. Esse produto do GsMap possui resolução espacial de 0,1° e está disponível na resolução temporal de 1 hora. No presente estudo utilizamos a versão 7 do produto GsMap *gauge-adjusted*, que pode ser baixada na internet (<https://www.gportal.jaxa.jp/gp>). Considerando a resolução espacial de 0,10°, foram extraídos 31 pixels do produto IMERG dentro da BHRQ para a análise. Assim como feito com os dados do IMERG, o GSMap também foi avaliado na resolução espacial de 0.25°, os quais foram obtidos em Salles *et al.* (2019), com o objetivo de comparar com os resultados do TMPA.

2.5 Dados de evapotranspiração real por sensoriamento remoto

Os dados de ET_r por sensoriamento remoto utilizados no presente estudo foram gerados pelo modelo SSEBop, cuja implementação pode ser sumarizada nas seguintes etapas (SENAY *et al.*, 2013):

1. Seleção e aquisição das imagens de satélite contendo a banda termal (T_s) da área de estudo (satélites / sensores);
2. Obtenção de série histórica de Temperatura do ar (T_a) da área de estudo, podendo ser obtida de estação meteorológica ou por sensoriamento remoto;
3. Estabelecimento da correção do fator que relaciona o T_s do pixel frio com a T_a, sob condições de céu aberto, nos pixels com vegetação vigorosa (NDVI > 0.8);
4. Desenvolvimento do dT, sob condições de céu aberto, para cada localidade e cada período do ano, utilizando a equação do balanço de energia e a resistência

aerodinâmica (r_{ah}), para o fluxo de calor proveniente do solo exposto e de superfície seca (dado espacial);

5. Cálculo da ET de referência (ET_o) para o período referente a imagem utilizada;
6. Cálculo da ET_r .

O SSEBop calcula a Evapotranspiração real (ET_r) a partir da equação:

$$ET_r = ET_f \cdot k \cdot ET_o \quad (2)$$

em que ET_f consiste na fração evaporativa, ET_o é a ET de referência na localidade, e k é um coeficiente utilizado para ajustar a escala da ET_o para um nível máximo de ET em uma cultura com menos aerodinâmica. Desde a sua publicação em Senay *et al.* (2013), algumas alterações já foram propostas para implementação do SSEBop (Senay *et al.*, 2017; Senay, 2018). No entanto, essas alterações não alteram os princípios listados anteriormente.

Considerando o interesse em utilizar dados de ET_r por sensoriamento remoto de fácil acesso, os dados do SSEBop empregados no presente estudo foram obtidos na plataforma *Climate Engine* (HUNTINGTON *et al.*, 2017) que fornece dados de sensoriamento remoto pela internet (<https://app.climateengine.org/>). O *Climate Engine* foi elaborado por uma equipe multidisciplinar de cientistas cujos principais parceiros são a *National Aeronautics and Space Administration* (NASA), Google *Earth Engine* e o *United States Geological Survey* (USGS). O serviço disponibiliza uma série de produtos oriundos de processamentos digitais de imagens, dentre os quais, a ET_r obtida por meio do modelo SSEBop. Na prática, o *Climate Engine* torna públicas imagens com a ET_r estimada pelo SSEBop desde 2003 até a presente data. Para o presente estudo, foi utilizado o produto com resolução espacial de 1km e temporal de 10 dias, disponível na plataforma.

Após o download de todos os dados, foram extraídas 4 séries temporais de ET_r do SSEBop para cada trecho da BHRQ avaliado. A Figura 2d também apresenta os 4 trechos nas quais foram extraídas series de ET_r do modelo SSEBop na BHRQ. Esses trechos correspondem a área de drenagem de cada uma das 4 estações de monitoramento de Q avaliadas nesse estudo, menos a área de drenagem do trecho a montante. Portanto, dois trechos correspondem a área de drenagem das sub-bacias 14 e 23, e dois trechos correspondem a área de drenagem restante das sub-bacias 72 e 78. Desse modo, cada uma das quatro sub-bacias obteve um resultado independente de calibração. Esses dados foram avaliados do ponto de vista do fechamento do balanço hídrico anual

em diversas sub-bacias do rio São Francisco, mostrando um bom potencial do produto para análise no nível de bacia (SALLES *et al.*, 2018 - ANEXO I da Tese).

2.6 Configuração do SWAT (pré-processamento)

Em relação à etapa de pré-processamento em ambiente SIG (ArcSWAT), a qual produz as tabelas necessárias para realizar a simulação hidrológica com o modelo SWAT, foram definidas 102 sub-bacias na etapa de delineamento da BHRQ. Foram estabelecidas três classes de declividade (0 a 6,5%, 6,5 a 15%; e > 15%) a partir dos dados do SRTM. A integração dos mapas de declividade, de solos e de uso/cobertura do solo resultou em 3748 unidades de resposta hidrológicas (HRU, sigla em inglês). Além disso, foram estabelecidos o método Curva-Número (*US Department of Agriculture, Soil Conservation Service Curve Number* (SCS-CN), 1972) para o cálculo do escoamento superficial, assim como o método Penman-Monteith para determinação da ETo (ALLEN *et al.*, 1998).

2.7 Análise de incertezas e calibração do modelo SWAT

A calibração de modelos hidrológicos pode ser conduzida tanto de forma automática, utilizando algoritmos de otimização e/ou técnicas de análise de incertezas, quanto de forma manual (BEVEN, 2001; MORIASI *et al.*, 2007). Testes que determinam o grau de incerteza que permanecem no modelo também são recomendados no uso de procedimentos automáticos de calibração (YAPO *et al.*, 1996). Nesse contexto, foi utilizado o software SWAT-CUP que realiza calibração automática e análise de incertezas do modelo SWAT por diferentes métodos (ABBASPOUR, *et al.*, 2007; ABBASPOUR, 2015). Os cenários utilizados para avaliar o uso dos produtos globais de P e ET_r por sensoriamento remoto serão apresentados no item 2.9, a seguir.

A análise foi conduzida pelo *Sequential Uncertainty Fitting* (SUFI-2) (ABBASPOUR *et al.*, 2004; ABBASPOUR *et al.*, 2007), o qual tem sido amplamente aplicado em estudos utilizando o SWAT no Brasil (e.g. STRAUCH *et al.*, 2012; STRAUCH *et al.*, 2013; FRANCO & BONUMÁ, 2017). Para execução do SUFI-2, foram estabelecidas 5 iterações com 500 simulações cada, otimizando a função objetivo NS (item 2.8 a seguir). As iterações foram conduzidas com apoio de software que foi desenvolvido em python no Laboratório de Sensoriamento Remoto e Análise Espacial da Universidade de Brasília por Ferreira (2019) e que realiza processamento em paralelo do projeto criado no SWATCUP. Além das funções objetivo listadas anteriormente para avaliar a

qualidade dos resultados obtidos nas simulações (NS, PBIAS, e RSR), também foram utilizados o p-fator e o r-fator, os quais são calculados após cada iteração realizada com SUFI-2 e que buscam medir as incertezas na estimativa dos parâmetros.

A Tabela 3 apresenta os parâmetros utilizados na calibração do modelo. A forma utilizada para alterar os parâmetros varia de acordo com as características de cada parâmetro do modelo (VAN GRIENSVEN; BAUWENS, 2003; VAN GRIENSVEN *et al.*, 2006). No presente estudo utilizou-se o método da multiplicação e o método da substituição direta para definir os limites inferiores e superiores dos parâmetros a partir de um valor inicial em cada iteração.

Tabela 3: Parâmetros, método de alteração do valor e intervalo de variação aplicados na primeira iteração que foram utilizados na calibração do modelo.

Parâmetro	Mínimo	Máximo	Parâmetro	Mínimo	Máximo
ALPHA_BF ¹	0	1	SOL_AWC ²	-0,5	0,5
DEEPST ¹	0	25	SOL_BD ²	-0,5	0,5
GW_DELAY ¹	0	450	SOL_K ²	-0,5	0,5
GW_REVAP ¹	0,02	0,2	SOL_Z ²	-0,5	0,5
GWHT ¹	0	25	SOL_ZMX ²	0	1
GWQMN ¹	0	5000	CH_W1 ¹	3	6
RCHRG_DP ¹	0	1	BIOMIX ¹	0,5	1
REVAPMN ¹	0	500	ALAI_MIN ¹	0,5	0,99
SHALLST ¹	1000	5000	BIO_E ¹	10	90
HRU_SLP ²	-0,5	0,5	BLAI ¹	5	7
OV_N ²	-1	1	DLAI ¹	0,8	1
SLSUBBSN ²	-0,5	0,5	FRGRW1 ¹	0,1	0,2
EPCO ¹	0	1	FRGRW2 ¹	0,21	0,4
ESCO ¹	0	1	GSI ¹	0	5
CN2 ²	-0,5	0,5	LAIMX1 ¹	0,1	0,2
ALPHA_BNK ¹	0	1	LAIMX2 ¹	0,21	0,4
CH_K2 ¹	0	25	RDMX ¹	1	3
CH_N2 ¹	0,025	0,15	VPDFR ¹	1,5	6
ANION_EXCL ²	0,1	1			

¹Substituição direta; ²Multiplicação

Em relação aos parâmetros do banco de dados de solos, optou-se realizar a calibração automática por grupo hidrológico (A, B, C, D) e por camadas (até 3) para cada tipo de solo. A única exceção foi a densidade do solo (SOL_BD) que foi calibrada apenas na camada superficial (1). Além disso, a calibração foi conduzida por partes, de modo que inicialmente foram calibradas as duas sub-bacias situadas a montante na BHRQ (14 e 23), para depois calibrar apenas o trecho

mais a jusante das sub-bacias 72 e 78. Desse modo, cada uma das quatro sub-bacias obteve um resultado independente de calibração de Q e ET_r.

2.8 Avaliação da simulação hidrológica

A avaliação da qualidade dos resultados obtidos pelo modelo foi feita por meio de métodos propostos por Moriasi *et al.* (2007). Foram calculados o coeficiente Nash & Sutcliffe (NS) (NASH & SUTCLIFFE, 1970), o percentual de tendência (PBIAS), e a razão entre o erro padrão médio e o desvio padrão das observações (RSR). O NS é dado pela seguinte equação:

$$\text{NS} = 1 - \frac{\sum_{i=1}^n (Q_{\text{obs}} - Q_{\text{sim}})^2}{\sum_{i=1}^n (Q_{\text{obs}} - Q_{\text{obs,médio}})^2} \quad (3)$$

onde Q_{obs} é o evento observado; Q_{sim} é o evento simulado pelo modelo; $Q_{\text{obs,médio}}$ é a média do evento observado no período simulado; e n é o número de eventos.

O percentual de tendência (PBIAS) e o erro padrão médio normalizado (RSR) são calculados pelas equações a seguir, em que, quanto mais próximo de zero, melhores são os resultados:

$$\text{PBIAS}(\%) = \frac{\sum_{i=1}^n (Q_{\text{obs}} - Q_{\text{sim}})}{\sum_{i=1}^n Q_{\text{obs}}} \quad (4)$$

$$\text{RSR} = \frac{\text{EPM}}{\text{desvpad}Q_{\text{obs}}} = \frac{\sqrt{\sum_{i=1}^n (Q_{\text{obs}} - Q_{\text{sim}})^2}}{\sqrt{\sum_{i=1}^n (Q_{\text{obs}} - Q_{\text{obs,médio}})^2}} \quad (5)$$

Os resultados dos índices de qualidade da simulação de vazões (NS, RSR e do PBIAS) foram classificados de acordo com critério sugerido por Moriasi *et al.* (2007), amplamente utilizado na comunidade científica. Os critérios estabelecidos por Moriasi *et al.* (2007) foram originalmente propostos para a simulação da vazão média mensal ($Q_{\text{mês}}$). Optou-se por utilizar os mesmos critérios para as simulações de Q_{dia} e $Q_{\text{mês}}$. Além disso, essa referência também foi utilizada para avaliar a qualidade da ET_r mensal simulada com o modelo SWAT. A Tabela 2 apresenta os critérios de classificação dos resultados dos índices de qualidade da simulação de Q e ET_r.

Tabela 2: Critério de classificação dos resultados dos índices de qualidade da simulação de Q e ET_r.

Classificação	RSR	NS	PBIAS (%)
Muito bom	$0,00 \leq RSR \leq 0,50$	$0,75 < NS \leq 1,00$	$PBIAS < \pm 10$
Bom	$0,50 < RSR \leq 0,60$	$0,65 < NS \leq 0,75$	$\pm 10 \leq PBIAS < \pm 15$
Satisfatório	$0,60 < RSR \leq 0,70$	$0,50 < NS \leq 0,65$	$\pm 15 \leq PBIAS < \pm 25$
Insatisfatório	$RSR > 0,70$	$NS \leq 0,50$	$PBIAS \geq \pm 25$

Fonte: Moriasi *et al.* (2007)

A avaliação das incertezas decorrentes da estimativa dos parâmetros foi feita utilizando o p-fator e o r-fator, os quais são obtidos pelo SUFI-2 para cada iteração executada. O p-fator é um índice que varia de 0 a 1 e refere-se às incertezas preditas em 95% das simulações (95PPU), avaliando-se a percentagem em que os dados observados estão inseridos entre 2,5% e 97,5% da distribuição acumulada da variável de saída avaliada na amostragem. Portanto, p-fator igual a 1 indica que 100% dos dados observados estão contidos na faixa de incerteza calculada. O r-fator, por sua vez, refere-se a largura média da faixa de incerteza que contempla o 95PPU, normalizada pelo desvio padrão do dado observado. Nesse caso, quanto menor o r-fator, menores são as incertezas calculadas na estimativa dos parâmetros. No entanto, um menor r-fator é obtido reduzindo o p-fator, de modo que se faz necessário encontrar um ponto de equilíbrio entre os dois. De forma geral, Abbaspour *et al.* (2015) recomenda p-fator > 0.7 e r-fator < 1.5 para análise de vazões. Desse modo, a melhor iteração selecionada na calibração do modelo correspondeu àquela cujos valores do p-fator e r-fator se aproximaram de 1.

2.9 Cenários de integração do modelo SWAT com dados obtidos por sensoriamento remoto

Os cenários propostos para a avaliação do uso do modelo SWAT com dados de sensoriamento remoto são apresentados na Figura 3. A análise foi realizada em duas etapas independentes. Na primeira etapa, os dados de P_{sr} e P_{obs} foram utilizados como entrada no modelo SWAT, enquanto na segunda parte do estudo foi avaliado o uso da ET_r estimada pelo modelo SSEBop na calibração e na validação de Q e ET_r simuladas pelo modelo hidrológico. A Tabela 4 apresenta o resumo dos cenários utilizados para avaliar o uso de dados de precipitação e evapotranspiração por sensoriamento remoto em conjunto com o modelo SWAT nas simulações de Q e ET_r em cada trecho da BHRQ.

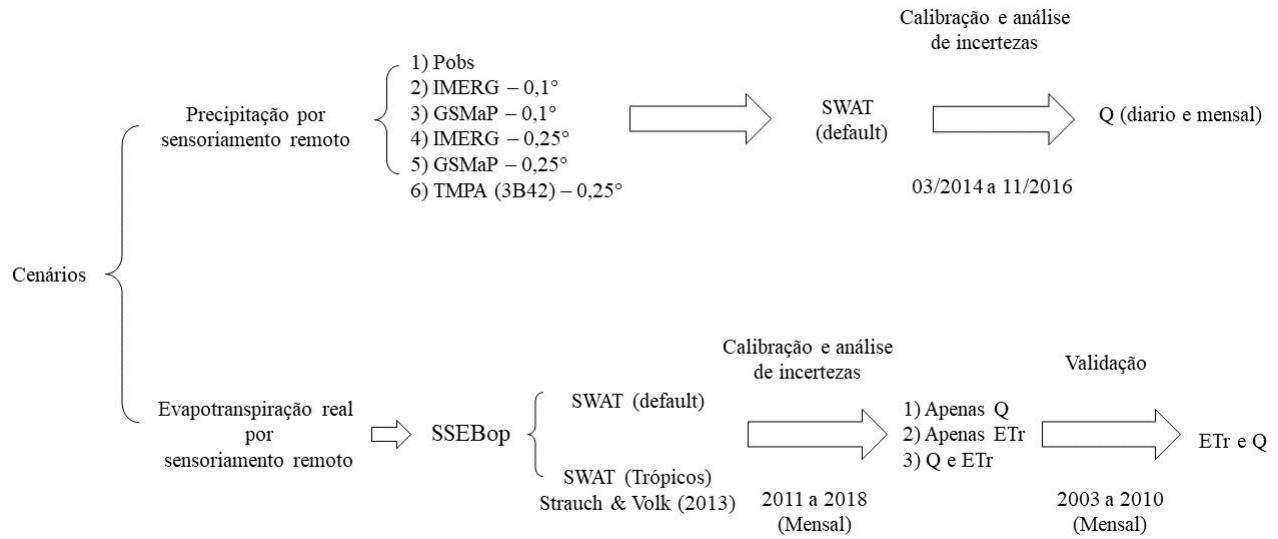


Figura 3: Cenários utilizados para avaliar o uso do modelo SWAT com os dados de sensoriamento remoto.

Tabela 4: Resumo dos cenários utilizados para avaliar o uso de dados de precipitação e evapotranspiração por sensoriamento remoto em conjunto com o modelo SWAT nas simulações de Q e ET_r em cada trecho da BHRQ.

Trecho	Sub-bacia SWAT	Período de operação	Calibração Parte 1 (Q)	Calibração Parte 2 (Q e ET _r)	Validação Parte 2 (Q)	Validação Parte 2 (ET _r)
1	14	09/2009 a 12/2018	03/2014 a 11/2016	01/2011 a 12/2018	09/2009 a 12/2010	01/2003 a 12/2010
		01/2003 a 12/2018	03/2014 a 11/2016	01/2011 a 12/2018	01/2003 a 12/2010	01/2003 a 12/2010
2	23	07/2006 a 12/2018	03/2014 a 11/2016	01/2011 a 12/2018	07/2006 a 12/2010	01/2003 a 12/2010
		12/2018	11/2016	12/2018	12/2010	12/2010
3	72	04/2005 a 12/2018	03/2014 a 11/2016	01/2011 a 12/2018	04/2005 a 12/2010	01/2003 a 12/2010
		12/2018	11/2016	12/2018	12/2010	12/2010
4	78	04/2005 a 12/2018	03/2014 a 11/2016	01/2011 a 12/2018	04/2005 a 12/2010	01/2003 a 12/2010
		12/2018	11/2016	12/2018	12/2010	12/2010

Na primeira etapa do estudo, foram utilizados dados diários do IMERG, GSMAp e TMPA (P_{sr}), assim como dados da rede de monitoramento pluviométrico (P_{obs}). As simulações hidrológicas com os produtos de P_{sr} foram feitas no período entre 03/2014 e 11/2016, com um período de 4 anos de aquecimento. O período utilizado na simulação do modelo SWAT corresponde ao mesmo período no qual Salles *et al.*, (2019) avaliou o uso do IMERG, GSMAp e TMPA na mesma região em que se localiza a BHRQ. No entanto, como esse período é curto do ponto de vista hidrológico, optou-se por utilizar a série inteira apenas para calibração do modelo.

Nesse contexto, avaliaram-se apenas as incertezas na estimativa dos parâmetros do modelo utilizando o IMERG, o GSMAp, o TMPA e os dados dos pluviômetros. A análise foi feita comparando as séries de Q diária (Q_{dia}) e de Q média mensal ($Q_{mês}$), simuladas e observadas. Os dados do IMERG e do GSMAp foram utilizados na sua resolução original $0,1^{\circ}$ e na resolução de $0,25^{\circ}$ para fins de comparação com os dados do TMPA, conforme descrito anteriormente.

Os parâmetros utilizados na calibração do SWAT na primeira etapa do estudo foram: ALPHA_BF; DEEPST; GW_DELAY; GW_REVAP; GWHT; GWQMN; RCHRG_DP; REVAPMN; SHALLST; HRU_SLP; OV_N; SLSUBBSN; EPCO; ESCO; CN2; ALPHA_BNK; CH_K; CH_N; ANION_EXCL; SOL_AWC; SOL_BD; SOL_K; SOL_Z; SOL_ZMX.

Na segunda etapa da pesquisa, foi avaliado o uso da ET_r estimada pelo modelo SSEBop na calibração das vazões simuladas pelo modelo. Desse modo, a análise foi feita comparando tanto a Q média mensal ($Q_{mês}$) simulada e observada, quanto a ET_r mensal simulada pelo SSEBop e pelo SWAT para cada uma das 4 sub-bacias da BHRQ avaliadas no presente estudo. A calibração do modelo foi conduzida nos seguintes cenários utilizando: apenas ET_r (SSEBop); apenas $Q_{mês}$; e concomitantemente $Q_{mês}$ e ET_r (SSEBop). Além disso, foram avaliados o modelo SWAT na sua versão default, a qual está disponível na internet, assim como o modelo na versão proposta por Strauch & Volk (2013), a qual foi disponibilizada pelo autor. A versão default será denominada SWAT enquanto a outra, SWAT (Trópicos), agora em diante.

Nesta etapa, as simulações foram feitas no período entre 01/01/2003 e 31/12/2018, com 12 anos de aquecimento tanto para a calibração quanto para a validação do modelo. Em virtude da disponibilidade de dados de Q, optou-se por realizar a validação entre 2003 e 2010 e calibração do modelo entre 2011 e 2018. Desse modo, as quatro sub-bacias avaliadas tiveram o mesmo período de calibração, porém intervalos diferentes de validação, uma vez que as estações de monitoramento tiveram suas atividades iniciadas em períodos distintos. Todas as simulações desta etapa foram feitas utilizando os dados de P dos pluviômetros (P_{obs}). A calibração do modelo na segunda etapa do presente estudo foi conduzida utilizando os mesmos parâmetros listados na etapa anterior acrescidos dos seguintes: CH_W1; BIOMIX; ALAI_MIN; BIO_E; BLAI; DLAI; FRGRW1; FRGRW2; GSI; LAIMX1; LAIMX2; RDMX; VPDFR.

Por fim, vale mencionar que foi desenvolvida uma rotina de programação em python para calcular a ET_r média para todas as sub-bacias contidas na área que estava sendo calibrada no SWATCUP. Desse modo, após a extração do dado de ET_r simulado pelo modelo hidrológico na

etapa de processamento “SUFI2_run.bat” e antes da execução da etapa “SUFI2_post.bat” do SWATCUP para todas as sub-bacias contidas no trecho que estava sendo calibrado, foram obtidas uma única série temporal de ET_r média do SWAT para cada uma das 500 simulações realizadas por iteração, para fins de comparação com a ET_r do modelo SSEBop. Esse procedimento foi adotado em virtude da série temporal de ET_r do SSEBop ter sido extraída para cada trecho da BHRQ avaliado, o qual é correspondente a área de drenagem da estação de monitoramento de Q em questão, menos a área do trecho a montante (Figura 2d), conforme explicado anteriormente.

3. Resultados e Discussões

3.1. Simulações com dados de precipitação por sensoriamento remoto

A seguir são apresentados os resultados obtidos na etapa que avaliou a simulação de Q pelo modelo SWAT com séries temporais de P_{sr} do TMPA, IMERG e GSMap (Figura 3). Importante recordar que a calibração dos parâmetros do SWAT buscou otimizar a função objetivo NS na simulação de Q_{dia} e Q_{mês} com o algoritmo SUFI-2, em todos os cenários avaliados. Além disso, também foram avaliadas as incertezas decorrentes da estimativa dos parâmetros do SWAT para a simulação de Q_{dia} e Q_{mês}.

3.1.1. Análise de incertezas e calibração do modelo SWAT na simulação da vazão diária utilizando dados de precipitação por sensoriamento remoto

A relação entre o p-fator e o r-fator obtidos na análise de incertezas e na calibração dos parâmetros do modelo SWAT simulando Q_{dia} com dados de P_{obs} e P_{sr} é apresentada nas Figuras 4a, b, c e d para as sub-bacias 14, 23, 72 e 78, respectivamente. Em todos os cenários avaliados buscou-se otimizar a função objetivo NS com o algoritmo SUFI-2. Em todas as quatro sub-bacias da BHRQ avaliadas, a simulação de Q_{dia} pelo SWAT com dados de P_{obs} apresentou níveis de incertezas satisfatórios (p-fator > 0,7 e r-fator < 1,5) em ao menos uma iteração, conforme sugerido por Abbaspour *et al.* (2015).

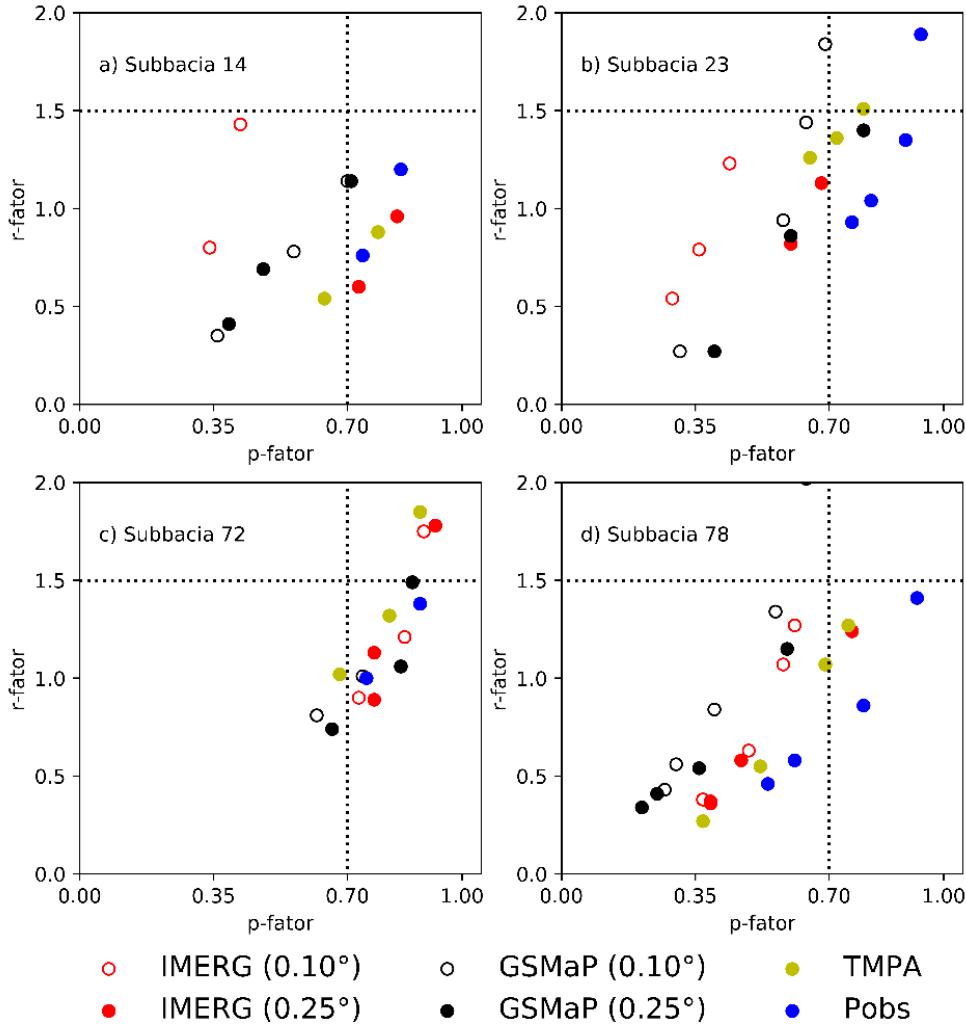


Figura 4: Relação entre o p-fator e o r-fator obtidos na análise de incertezas e na calibração dos parâmetros do modelo SWAT simulando Q_{dia} com dados de P_{obs} e P por sensoriamento remoto nas sub-bacias 14 (a), 23 (b), 72 (c) e 78 (d).

A Figura 5 apresenta o melhor NS e os respectivos RSR e o PBIAS obtidos em cada iteração da calibração dos parâmetros do modelo SWAT para simulações de Q_{dia} com dados de P_{obs} e P_{sr} nas sub-bacias 14 (a-c), 23 (d-f), 72 (g-i) e 78 (j-l). As melhores simulações de Q_{dia} com o modelo SWAT ocorreram nas sub-bacias 23 e 78. Observa-se que essas sub-bacias apresentaram NS, RSR em níveis satisfatórios ($NS > 0.5$; $RSR < 0.7$) enquanto as sub-bacias 14 e 72 não conseguiram atingir os critérios estabelecidos para a análise. Diferentemente do NS e do RSR, observa-se que a calibração dos parâmetros do modelo reduziu o PBIAS para níveis adequados em todas as quatro sub-bacias ($-25\% \leq PBIAS \leq 25\%$).

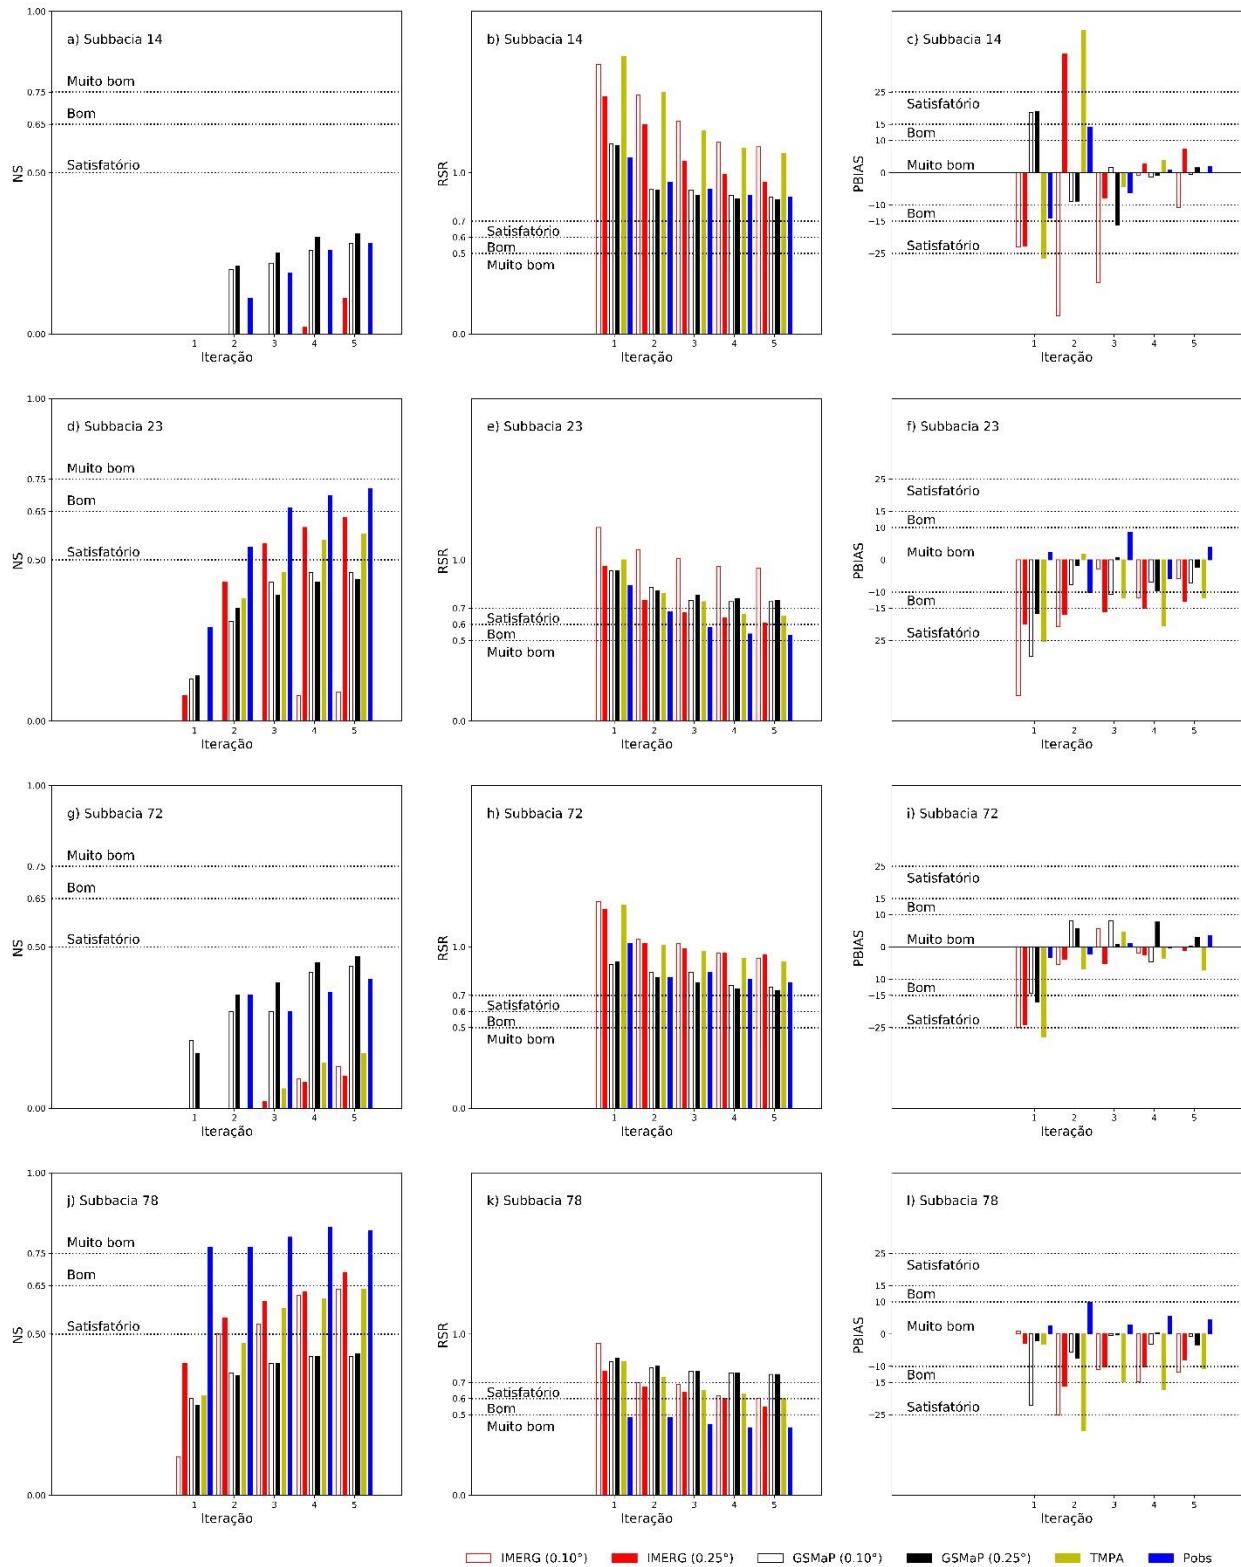


Figura 5: Melhor NS e os respectivos RSR e PBIAS obtidos em cada iteração da calibração dos parâmetros do modelo SWAT para simulações de Q_{dia} com dados de P_{obs} e P_{sr} nas sub-bacias 14 (a-c), 23 (d-f), 72 (g-i) e 78 (j-l).

Apesar de as simulações de Q_{dia} utilizando P_{obs} terem apresentado níveis de incertezas satisfatórios nas estimativas dos parâmetros nas quatro sub-bacias, apenas as sub-bacias 23 e 78 apresentaram resultados de PBIAS e RSR adequados. Nessas sub-bacias, as simulações de Q_{dia} apresentou NS e RSR classificados como bom e como muito bom, respectivamente (Figuras 5 d,e,j,k). Importante observar que a rede de pluviômetros está localizada no lado oeste da BHRQ onde estão as sub-bacias 23 e 78 (Figura 2d), o que pode ter contribuído para melhores resultados de NS e RSR nas simulações de Q_{dia} . O PBIAS reduziu ao longo das iterações com P_{obs} nas quatro sub-bacias avaliadas, sendo classificado como muito bom.

Avaliando-se os resultados de Q_{dia} utilizando o IMERG – 0,1°, o NS e o RSR foram respectivamente classificados como satisfatório e bom apenas na sub-bacia 78 enquanto nas demais sub-bacias o desempenho não atingiu o critério mínimo estabelecido. O GSMAp – 0,1° não apresentou NS e RSR satisfatório em nenhuma das quatro sub-bacias avaliadas. O IMERG – 0,25°, por sua vez, apresentou resultados de NS e RSR classificados como satisfatório e bom nas sub-bacias 23 e 78, respectivamente, enquanto o GSMAp – 0,25° não apresentou resultados de NS e RSR satisfatórios em nenhum cenário.

Assim como o IMERG – 0,25°, o TMPA também apresentou resultados satisfatórios de NS e RSR nas sub-bacias 23 e 78. No entanto, os resultados de NS e RSR obtidos nas simulações do SWAT com dados do TMPA foram piores do que os obtidos com o IMERG – 0,25° nessas sub-bacias.

3.1.2. Análise de incertezas e calibração do modelo SWAT na simulação da vazão média mensal utilizando dados de precipitação por sensoriamento remoto

A Figura 6 apresenta a relação entre o p-fator e o r-fator obtidos na análise de incertezas e na calibração dos parâmetros do modelo SWAT simulando $Q_{mês}$ com dados de P_{obs} e P_{sr} nas sub-bacias 14 (a), 23 (b), 72 (c) e 78 (d). Mais uma vez, todos os cenários avaliados otimizaram a função objetivo NS com o algoritmo SUFI-2. Assim como os resultados anteriores avaliados na escala de tempo diária, a simulação de $Q_{mês}$ pelo modelo SWAT utilizando P_{obs} apresentou níveis de incertezas satisfatórios, conforme sugerido em Abbaspour *et al.* (2015), em todas as quatro sub-bacias da BHRQ que foram avaliadas.

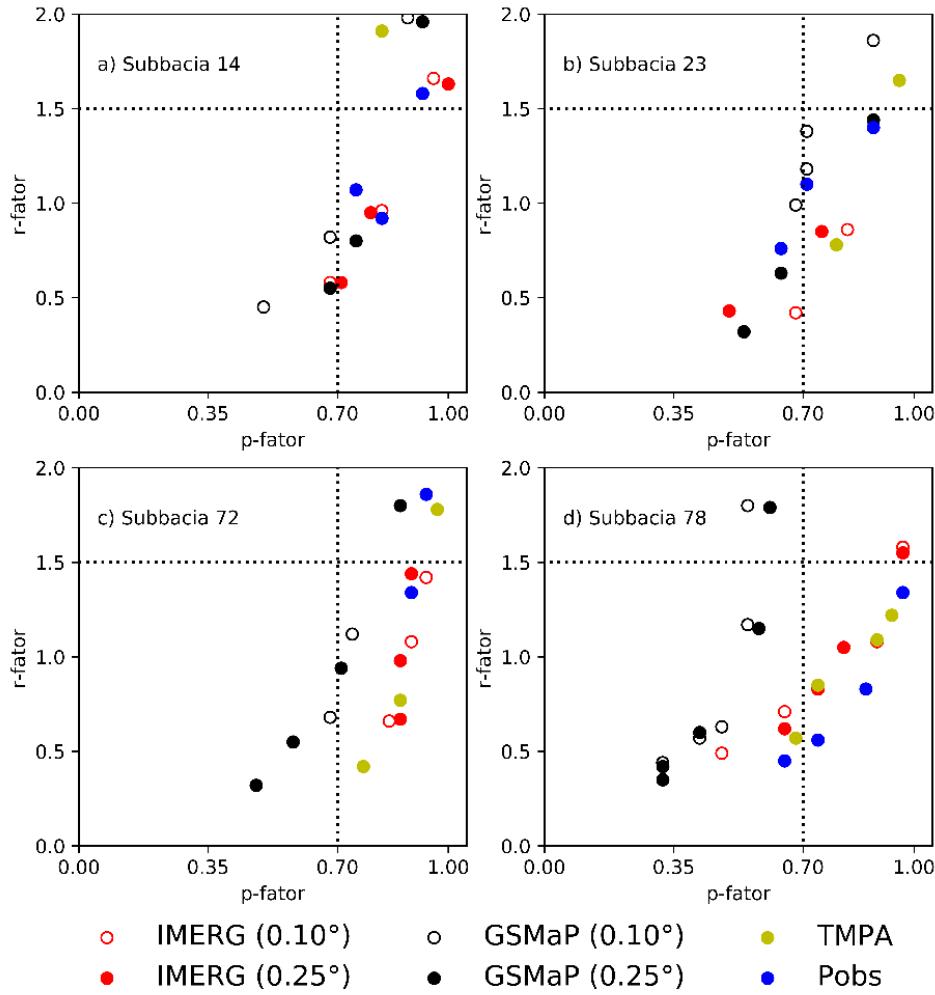


Figura 6: Relação entre o p-fator e o r-fator em diferentes iterações utilizando dados mensais de P_{obs} e P_{sr} nas sub-bacias 14 (a), 23 (b), 72 (c) e 78 (d).

Novamente os níveis de incertezas nas simulações $Q_{\text{mês}}$ foram insatisfatórios em alguns cenários simulados com P_{sr} . No entanto, os resultados foram consideravelmente melhores do que o obtido com os dados diários. Observa-se que, na escala mensal, o IMERG – 0,1° obteve um bom desempenho nas sub-bacias 14, 23 e 72. O mesmo ocorreu com o GSMAp – 0,1° nas sub-bacias 23 e 72. Comparando o IMERG – 0,25° e o GSMAp – 0,25° com o TMPA, os produtos da geração GPM apresentaram menores níveis de incertezas nas simulações de $Q_{\text{mês}}$, assim como observado anteriormente com Q_{dia} . É possível observar nas Figura 4 e 6 que o IMERG e o GSMAp tiveram mais iterações dentro da faixa sugerida por Abbaspour *et al.* (2015) como ideal para a estimativa de Q , com $p\text{-fator} > 0,7$ e $r\text{-fator} < 1,5$.

A Figura 7 apresenta o melhor NS e os respectivos RSR e o PBIAS obtidos em cada iteração da calibração dos parâmetros do modelo SWAT para simulações de $Q_{mês}$ com dados de P_{obs} e P_{sr} nas sub-bacias 14 (a-c), 23 (d-f), 72 (g-i) e 78 (j-l). O bom desempenho observado na análise de incertezas se estendeu à avaliação da qualidade das simulações de $Q_{mês}$ pelo modelo SWAT, de modo que todos os cenários avaliados apresentaram resultados ao menos classificados como satisfatórios ($NS > 0,5$; $RSR < 0,7$; $-25\% \leq PBIAS \leq 25\%$). Além disso, observa-se que, de modo similar aos resultados obtidos nas simulações de vazões na escala diária, o PBIAS atingiu níveis considerados como muito bom em todos os cenários avaliados.

Com exceção da sub-bacia 14, cujo NS e RSR foram classificados como bom, as demais sub-bacias apresentaram $NS > 0,75$ (muito bom) e $RSR < 0,5$ (muito bom) quando o SWAT foi simulado com P_{obs} . Já as simulações com o IMERG – $0,1^\circ$ obtiveram resultados de NS e RSR classificados como muito bom em todas as quatro sub-bacias, indicando um bom potencial desse produto de P_{sr} para simulações de $Q_{mês}$ em bacias agrícolas no bioma Cerrado.

Os resultados do IMERG foram similares ao obtido com P_{obs} tanto nas sub-bacias 23 e 78, que possuem alta densidade de pluviômetros, quanto nas sub-bacias 14 e 72 que não possuem pluviômetros (Figura 2d), o que indica o potencial do uso desse produto de P_{sr} em áreas não monitoradas, principalmente para simulações na escala mensal. Apesar de ter apresentado resultados piores, as simulações do SWAT com o GSMAp – $0,1^\circ$ também tiveram resultados de NS e o RSR satisfatórios para as simulações de $Q_{mês}$.

De forma similar, o IMERG – $0,25^\circ$ apresentou resultados de NS e RSR classificados como muito bom nas quatro sub-bacias. O TMPA também apresentou excelentes resultados e muito próximos ao do IMERG – $0,25^\circ$, com o NS e RSR classificados como muito bom em quase todas as sub-bacias. Já o GSMAp – $0,25^\circ$ apresentou resultados de NS e RSR considerados satisfatórios em todos os cenários, porém bem inferior aos outros produtos de P_{sr} .

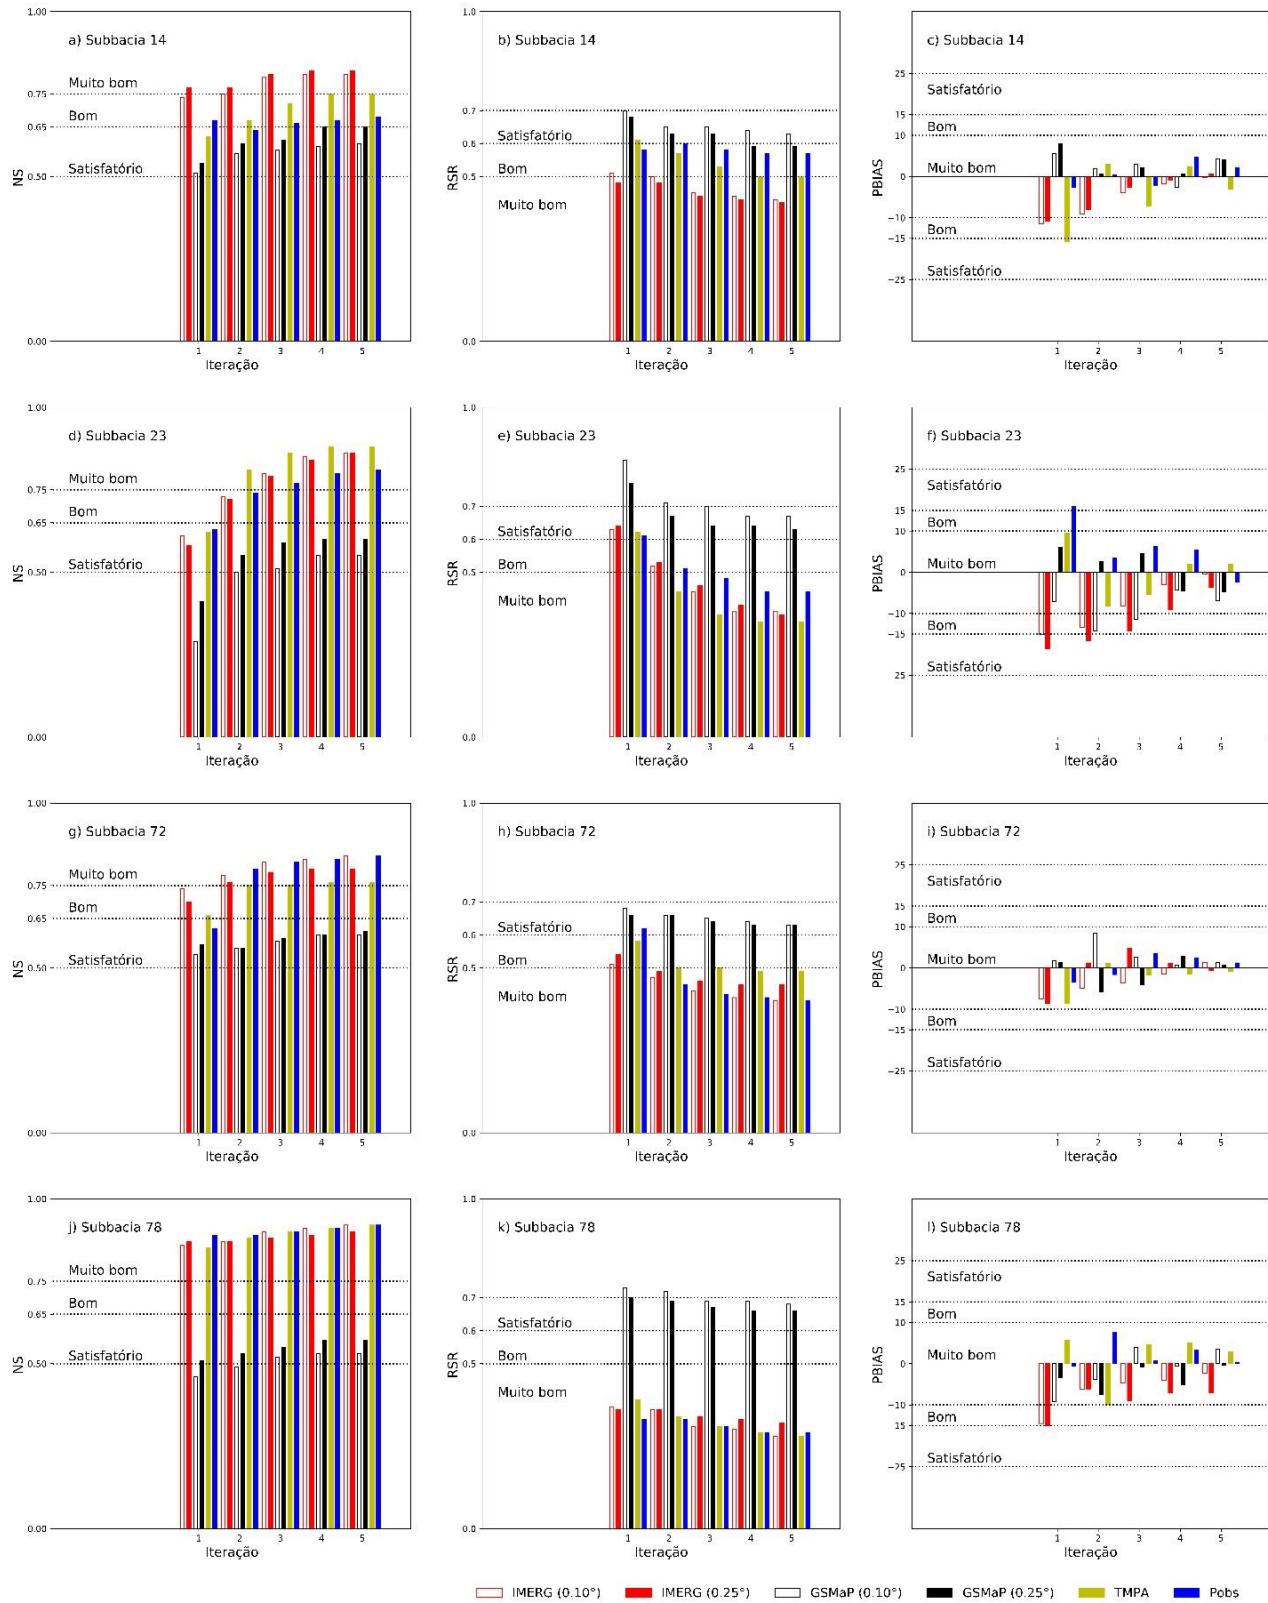


Figura 7: Melhores NS, PBIAS e RSR obtidos na calibração de vazões em cada iteração utilizando dados mensais de precipitação, nas sub-bacias 14 (a-c), 23 (d-f), 72 (g-i) e 78 (j-l).

Os resultados apresentados indicam que a nova geração de produtos de P_{sr} obtidos a partir de dados da missão GPM (IMERG e GSMAp) foi capaz de garantir a continuidade no fornecimento de dados de P para simulação de Q com modelo hidrológico no Brasil central de forma semelhante ou até mesmo melhor do que o obtido anteriormente com o principal produto da geração TRMM (3B42V7). De forma geral, estudos anteriores que compararam o desempenho de ambas gerações de dados de P_{sr} em simulações hidrológicas também reportaram um desempenho do IMERG similar (GUO *et al.*, 2019; ZHANG *et al.*, 2019) ou até mesmo melhor do que o obtido com o 3B42V7 (TANG *et al.*, 2016; WANG *et al.*, 2017; YUAN *et al.*, 2019). Ademais, os resultados das simulações que utilizaram dados de P_{sr} foram compatíveis com os obtidos nas simulações que utilizaram P_{obs} , demonstrando um bom potencial para o uso tanto em áreas não monitoradas quanto em aplicações conjuntas com dados observados.

No que concerne às simulações de Q_{dia} , tanto os cenários que utilizaram P_{sr} quanto P_{obs} não atingiram os critérios de qualidade estabelecidos em todas as sub-bacias avaliadas. Os resultados das simulações de Q_{dia} com P_{obs} foram melhores do que os obtidos com P_{sr} na maior parte dos casos. Vale observar que o uso dos dados de P_{obs} na simulação de Q_{dia} não atingiu os critérios de qualidade estabelecidos nas sub-bacias que não possuem pluviômetros. No entanto, o mesmo ocorreu com as simulações que utilizaram P_{sr} , o que indica que, além da ausência de pluviômetros nos trechos 1 e 3 da BHRQ, outros fatores, como por exemplo a escala do mapa de solos, podem ter influenciado negativamente as simulações de Q_{dia} pelo SWAT na BHRQ.

Assim como observado no presente estudo, Guo *et al.*, (2019) não reportaram resultados de NS satisfatórios na simulação de Q_{dia} pelo modelo SWAT utilizando dados do IMERG e do TMPA. Esses autores atribuíram ao baixo potencial de detecção da P_{sr} observado no período de seca como um dos fatores que influenciaram os resultados das simulações hidrológicas. Vale observar que Salles *et al.* (2019) também reportaram o IMERG e o TMPA com um potencial de detecção da P_{sr} inferior no período de seca do que o observado no período chuvoso, o que pode ter influenciado os resultados obtidos no presente estudo. Tan *et al.* (2018), por sua vez, obteve resultados satisfatórios de NS na simulação de Q_{dia} pelo modelo SWAT utilizando dados de P_{sr} dos três níveis de processamentos do IMERG (*Early-run*, *Late-run* e *Final-run*). Ademais, Strauch *et al.* (2012) obteve um bom resultado no período de calibração (NS = 0,74) nas simulações de Q_{dia} utilizando dados do TMPA, porém o desempenho foi insatisfatório no período de validação

($NS < 0,5$). Não obstante, foi ressaltada a importância do TMPA para simulações hidrológicas, principalmente em regiões com escassez de dados.

Vale observar que o IMERG – $0,1^\circ$ apresentou resultado satisfatório na simulação de Q_{dia} apenas na sub-bacia 78, enquanto o GSMAp – $0,1^\circ$ apresentou resultados insatisfatórios em todas as sub-bacias. No entanto, as simulações de Q_{dia} com o IMERG – $0,25^\circ$ foram melhores também na sub-bacia 23 e superaram os resultados do TMPA e do GSMAp – $0,25^\circ$. Salles *et al.* (2019) reportaram que a agregação dos dados do IMERG e do GSMAp do grid original ($0,1^\circ$) para o grid $0,25^\circ$ não acarretou perdas na representação da P_{sr} por esses produtos. No mesmo sentido, observa-se que o uso dos dados do IMERG e do GSMAp agregados no grid $0,25^\circ$ também não acarretou prejuízos para as simulações de Q_{dia} com o SWAT, com resultados semelhantes aos observados com o grid $0,1^\circ$ e com bom desempenho nas sub-bacias 23 e 78.

Diferentemente do observado na análise diária, a simulação de $Q_{mês}$ com os dados de P_{sr} e com dados de P_{obs} atingiu os critérios de qualidade estabelecidos em todas as sub-bacias avaliadas. Os dados de P_{sr} do IMERG e do GSMAp tiveram melhor correlação com os dados registrado nos pluviômetros na escala mensal do que nas escalas diária e anual (SALLES *et al.*, 2019). Assim como observado no presente estudo, Tan *et al.* (2018) também obtiveram melhores resultados nas simulações mensais de Q pelo SWAT utilizando dados de P_{sr} dos três níveis de processamentos do IMERG. Ademais, as simulações de $Q_{mês}$ com o IMERG foram melhores do que o obtido com o GSMAp em ambas as resoluções espaciais avaliadas ($0,1^\circ$ e $0,25^\circ$) no presente estudo. Além disso, as simulações de $Q_{mês}$ com o IMERG – $0,25^\circ$ superaram os resultados obtidos com o TMPA na maior parte dos cenários avaliados. Em alguns cenários as simulações de $Q_{mês}$ com dados do IMERG e do TMPA superaram também os resultados obtidos com P_{obs} demonstrando o bom potencial do uso desses dados na simulação hidrológica com dados mensais. Individualmente, o uso de dados mensais da missão GPM terá mais utilidade na medida que houver disponível uma série temporal de dados maior (Tan *et al.*, 2018). No entanto, os resultados obtidos com o TMPA no presente estudo, assim como o reportado em Strauch *et al.* (2012), indicam a possibilidade de se utilizar conjuntamente dados das missões TRMM e GPM em estudos de simulação hidrológica formando uma série temporal que atualmente possui mais de 15 anos. Ademais, resultados melhores podem ser obtidos em função do refinamento das bases de dados e outros dados de entrada no SWAT.

3.2. Simulações com dados de evapotranspiração real por sensoriamento remoto

A seguir são apresentados os resultados obtidos na etapa que avaliou a simulação de Q e ET_r pelo modelo SWAT com séries temporais de ET_r do SSEBop (Figura 3). Importante recordar que, diferentemente da etapa que avaliou o uso dos produtos globais de P_{sr} cuja análise foi feita em relação às simulações de Q_{dia} e Q_{mês}, a avaliação ocorreu apenas na escala mensal para ambas variáveis simuladas com o SWAT (Q e ET_r). Além disso, também foi analisado o uso do SWAT em sua versão *default* e com as modificações proposta por Strauch & Volk (2013), as quais foram denominadas SWAT e SWAT – Trópicos, respectivamente.

3.2.1. Análise de incertezas e calibração do modelo SWAT na simulação da evapotranspiração real e da vazão média mensal

A Figura 8 apresenta a relação entre o p-fator e o r-fator obtidos na iteração selecionada para a validação do SWAT em ambas versões avaliadas (*default* e trópicos). Os resultados de p-fator e do r-fator foram obtidos em três cenários, sendo dois cenários que calibraram individualmente a ET_r e a Q_{mês} (Apenas Q e Apenas ET_r) e o terceiro com as duas variáveis do modelo ao mesmo tempo (Q e ET_r). Em todos os cenários buscou-se estimar o intervalo dos parâmetros, otimizando a função objetivo NS com o algoritmo SUFI-2.

Em relação aos resultados dos cenários que avaliaram individualmente ET_r (Figura 8a) e Q (Figura 8b), os níveis de incertezas das iterações selecionadas para a validação foram satisfatórios, conforme estabelecido no presente estudo, em todas sub-bacias avaliadas. A única ressalva refere-se à calibração da ET_r na bacia 23 que apresentou p-valor < 0,7 em ambas versões do SWAT avaliadas (SWAT e SWAT – Trópicos). No entanto, vale mencionar que essa referência foi sugerida para simulações de Q.

Em relação ao terceiro cenário que otimizou a função objetivo NS e calibrou ET_r e Q ao mesmo tempo, os resultados de ET_r (Figura 8c) e Q (Figura 8d) também tiveram níveis de incertezas satisfatórios, com p-fator e r-fator atendendo os limites estabelecidos para o presente estudo em todas as sub-bacias avaliadas. No entanto, novamente a calibração do trecho referente a bacia 23 teve resultados fora do estabelecido, com o r-fator > 1,5 da simulação de Q.

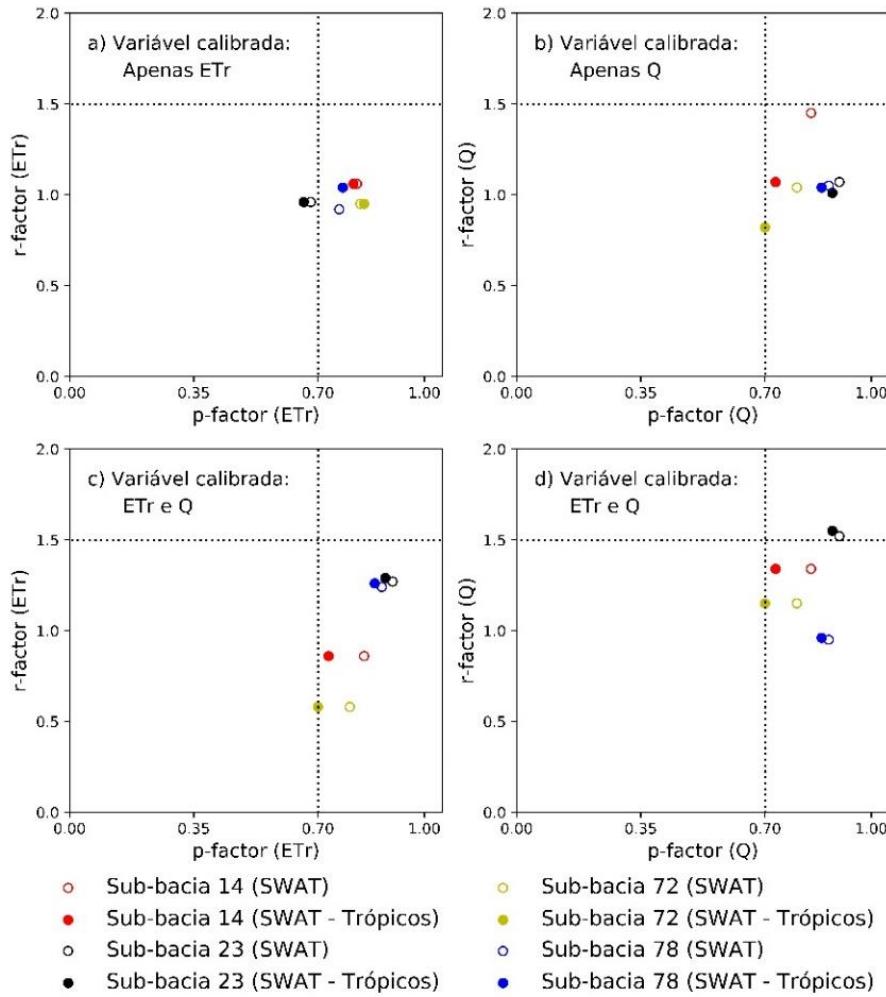


Figura 8: Relação entre o p-fator e o r-fator obtidos na iteração selecionada para a validação do modelo SWAT, avaliando os seguintes cenários de calibração: Apenas ET_r (a); Apenas Q (b); ET_r e Q (c-d).

A Figura 9 apresenta o NS e os respectivos RSR e PBIAS obtidos na melhor simulação da iteração selecionada para a validação do modelo SWAT. No cenário em que foi calibrado apenas a ET_r, a melhor simulação da iteração da etapa de calibração selecionada para a validação do modelo teve NS (Figura 9a) classificado como satisfatório nas sub-bacias 14 e 78 e bom na 72. Seguindo a mesma tendência, o RSR (Figura 9b) foi classificado como bom nas sub-bacias 14 e 72 e satisfatório na sub-bacia 78. Já a sub-bacia 23, apresentou resultados de NS e RSR fora do padrão estabelecido como satisfatório. Vale mencionar que a cidade de Formosa está localizada na sub-bacia 23, o que pode ter influenciado negativamente as estimativas de ET_r do modelo SWAT nessa sub-bacia nos cenários avaliados.

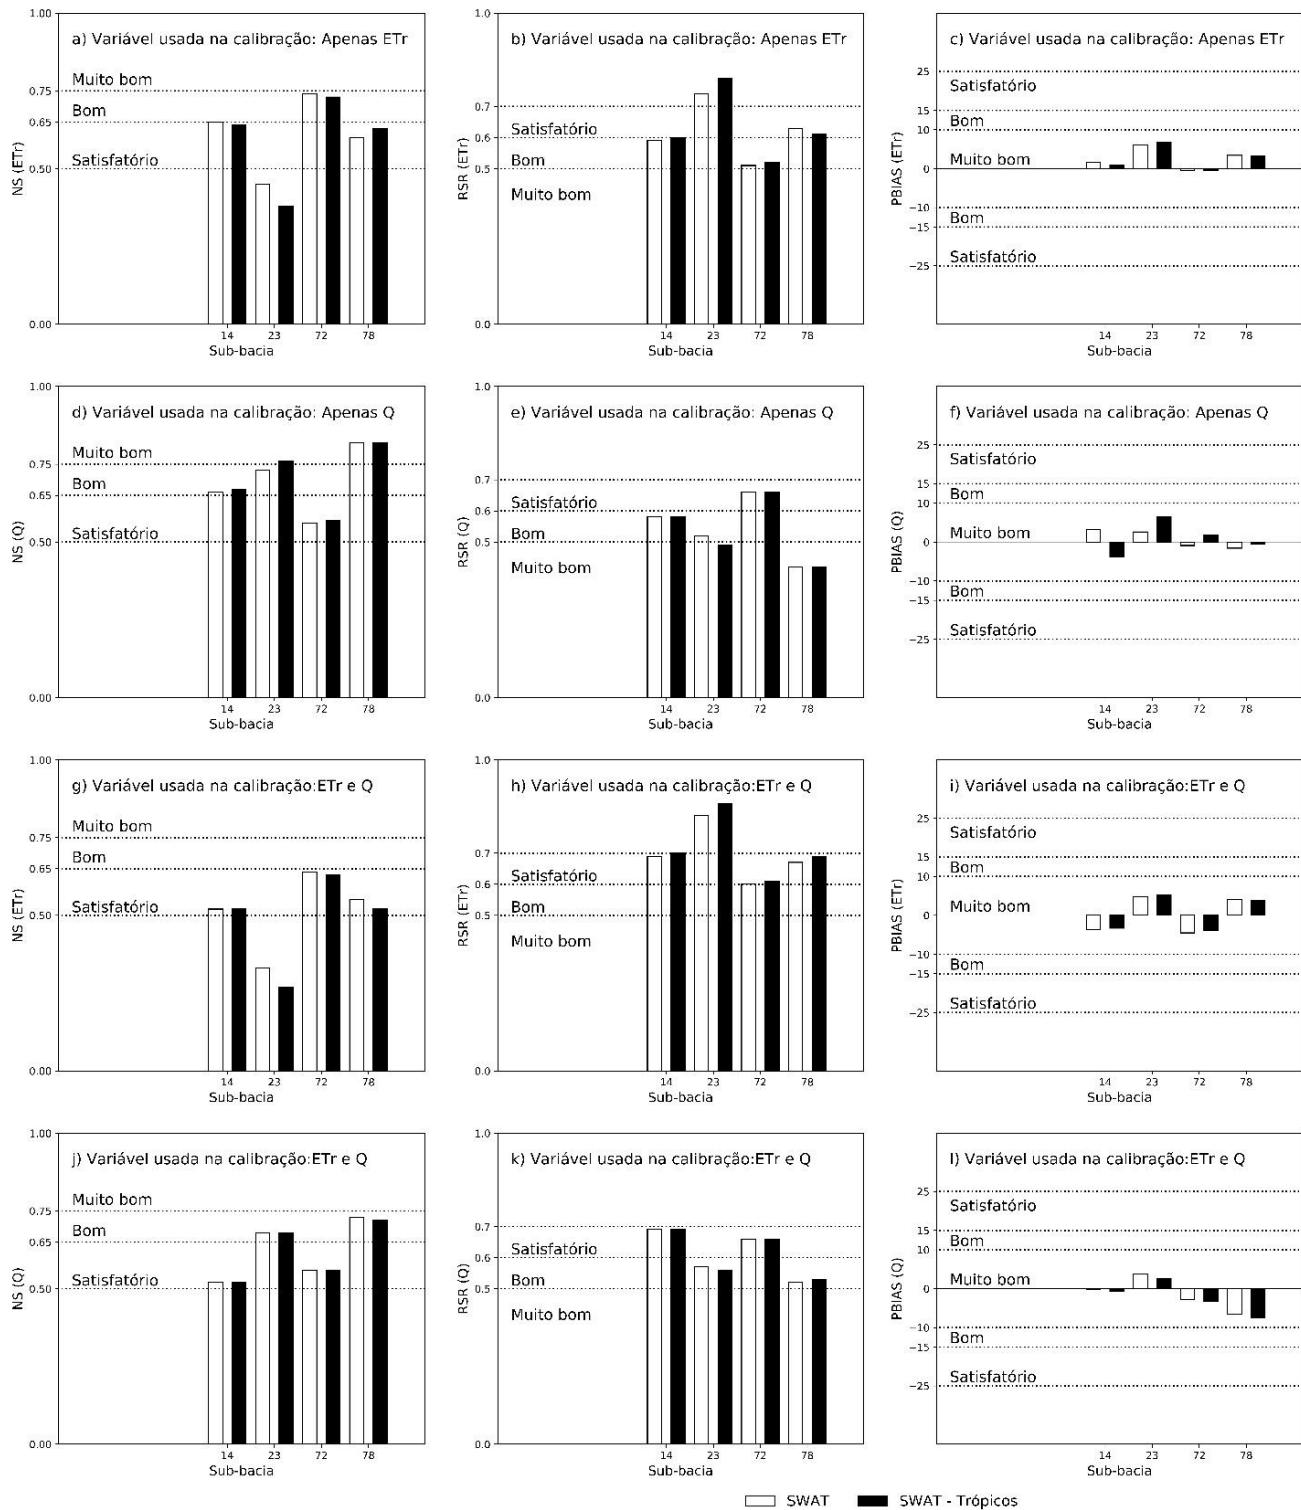


Figura 9: NS e os respectivos RSR e PBIAS obtidos na melhor simulação da iteração selecionada para a validação do modelo SWAT, avaliando os diferentes cenários de calibração que utilizaram dados de ET_r por sensoriamento remoto: Apenas ET_r (a-c); Apenas Q (d-f); ET_r e Q (g-l).

O PBIAS foi baixo e classificado como muito bom em todos as sub-bacias e em ambas as versões do SWAT avaliadas (Figura 9c). O padrão de resultados para os três índices utilizados para avaliar a qualidade das simulações hidrológicas nesse cenário de calibração (Apenas ET_r) foi o mesmo utilizando ambas versões do SWAT (default e Trópicos).

Em relação ao cenário em que foi calibrado apenas a Q (Figura 9d), os resultados de NS atenderam o critério estabelecido por Moriasi *et al.* (2007) e adotado no presente estudo em todas as sub-bacias. As sub-bacias 14 e 23 tiveram NS classificado como bom, utilizando ambas versões do SWAT (default e Trópicos). Na sub-bacia 23 o NS foi classificado como muito bom utilizando SWAT – Trópicos. Nas sub-bacias 72 e 78, os resultados de NS foram classificados como satisfatório e muito bom em ambos os cenários, respectivamente. O RSR (Figura 9e) teve o mesmo padrão descrito para o NS. De modo geral, as sub-bacias 23 e 78 tiveram menores RSR, os quais foram classificados como muito bom. Já o RSR foi maior na sub-bacia 14 seguido pela sub-bacia 72, sendo classificados como bom e satisfatório, respectivamente. O PBIAS (Figura 9f) foi classificado como muito bom em todas as sub-bacias avaliadas. De modo geral, o padrão de resultados para os três índices utilizados para avaliar a qualidade das simulações hidrológicas nesse cenário de calibração (Apenas Q) foi o mesmo utilizando ambas versões do SWAT (default e Trópicos).

No terceiro cenário estabelecido para avaliar o uso dos dados de ET_r por sensoriamento remoto, o qual otimizou a função objetivo NS e calibrou ET_r e Q ao mesmo tempo, os resultados da iteração selecionada para a validação do modelo do melhor NS e o seu RSR e PBIAS para ET_r (Figuras 9g-i) e Q (Figura 9j-l) foram similares aos cenários em que ambas variáveis foram calibradas individualmente. O padrão de resultados para os três índices utilizados para avaliar a qualidade das simulações hidrológicas nesse cenário de calibração (ET_r e Q) foi o mesmo utilizando ambas versões do SWAT (default e Trópicos), tanto nas simulações de ET_r quanto de Q.

Os resultados do NS para ET_r (Figura 9g) foram classificados como satisfatórios nas sub-bacias 14, 72 e 78, enquanto a sub-bacia 23 teve resultados insatisfatórios. Do mesmo modo, os resultados do RSR para ET_r (Figura 9h) foram classificados como satisfatórios nas sub-bacias 14, 72 e 78, enquanto a sub-bacia 23 teve resultados insatisfatórios. Mais uma vez o PBIAS (Figura 9i) não foi um problema em nenhuma sub-bacia e na simulação de ET_r foi classificado como muito bom.

Por fim, os resultados de NS para Q (Figura 9j) no cenário que calibrou ET_r e Q ao mesmo tempo foram classificados como satisfatórios nas sub-bacias 14, e 72 e bom nas sub-bacias 23 e 78. Do mesmo modo, os resultados do RSR para Q (Figura 9k) foram classificados como satisfatórios nas sub-bacias 14, 72, enquanto nas sub-bacias 23 e 78 o RSR foi classificado como bom. O PBIAS (Figura 9i) novamente não foi um problema em nenhuma sub-bacia e na simulação de ET_r foi classificado como muito bom.

Comparando ambas versões do SWAT utilizadas nesse estudo (default e Trópicos) temos que, de modo geral, a Figura 8 indica que ambas versões avaliadas apresentaram r-fator similares nas iterações selecionadas. Porém, o SWAT – Trópicos apresentou p-fator inferior aos resultados obtidos com a versão default em quase todas as sub-bacias, para os três cenários de calibração avaliados. Em relação aos resultados de NS, RSR e PBIAS apresentados na Figura 9, ambas versões avaliadas apresentaram resultados similares nas iterações selecionadas em todas as sub-bacias.

3.2.2. Validação das simulações de evapotranspiração real e da vazão média mensal pelo modelo SWAT

A Figura 10 apresenta as séries temporais de ET_r simuladas pelo modelo SWAT e pelo SSEBop, assim como a faixa com 95PPU obtida na iteração correspondente à etapa de validação nas sub-bacias 14 (a-c), 23 (d-f), 72 (g-i), e 78 (j-l). Esses resultados foram obtidos com a versão default do SWAT. A validação foi executada com as variáveis Q e ET_r em uma única iteração de 500 simulações com o intervalo dos parâmetros estabelecidos em cada um dos três cenários avaliados na etapa de calibração e cujos resultados foram apresentados na seção anterior.

Os resultados da validação da ET_r simulada pelo SWAT na sub-bacia 14 foram insatisfatórios utilizando o intervalo dos parâmetros definidos no cenário que calibrou apenas a Q (Figura 10a). O p-fator foi igual a 0,59, sendo abaixo do critério estabelecido no presente estudo. É possível observar que a faixa de 95PPU apresentou menores magnitudes de ET_r no período da seca em comparação com o SSEBop. O NS (0.46) da melhor simulação e o seu RSR (0.73) também foram classificados como insatisfatórios.

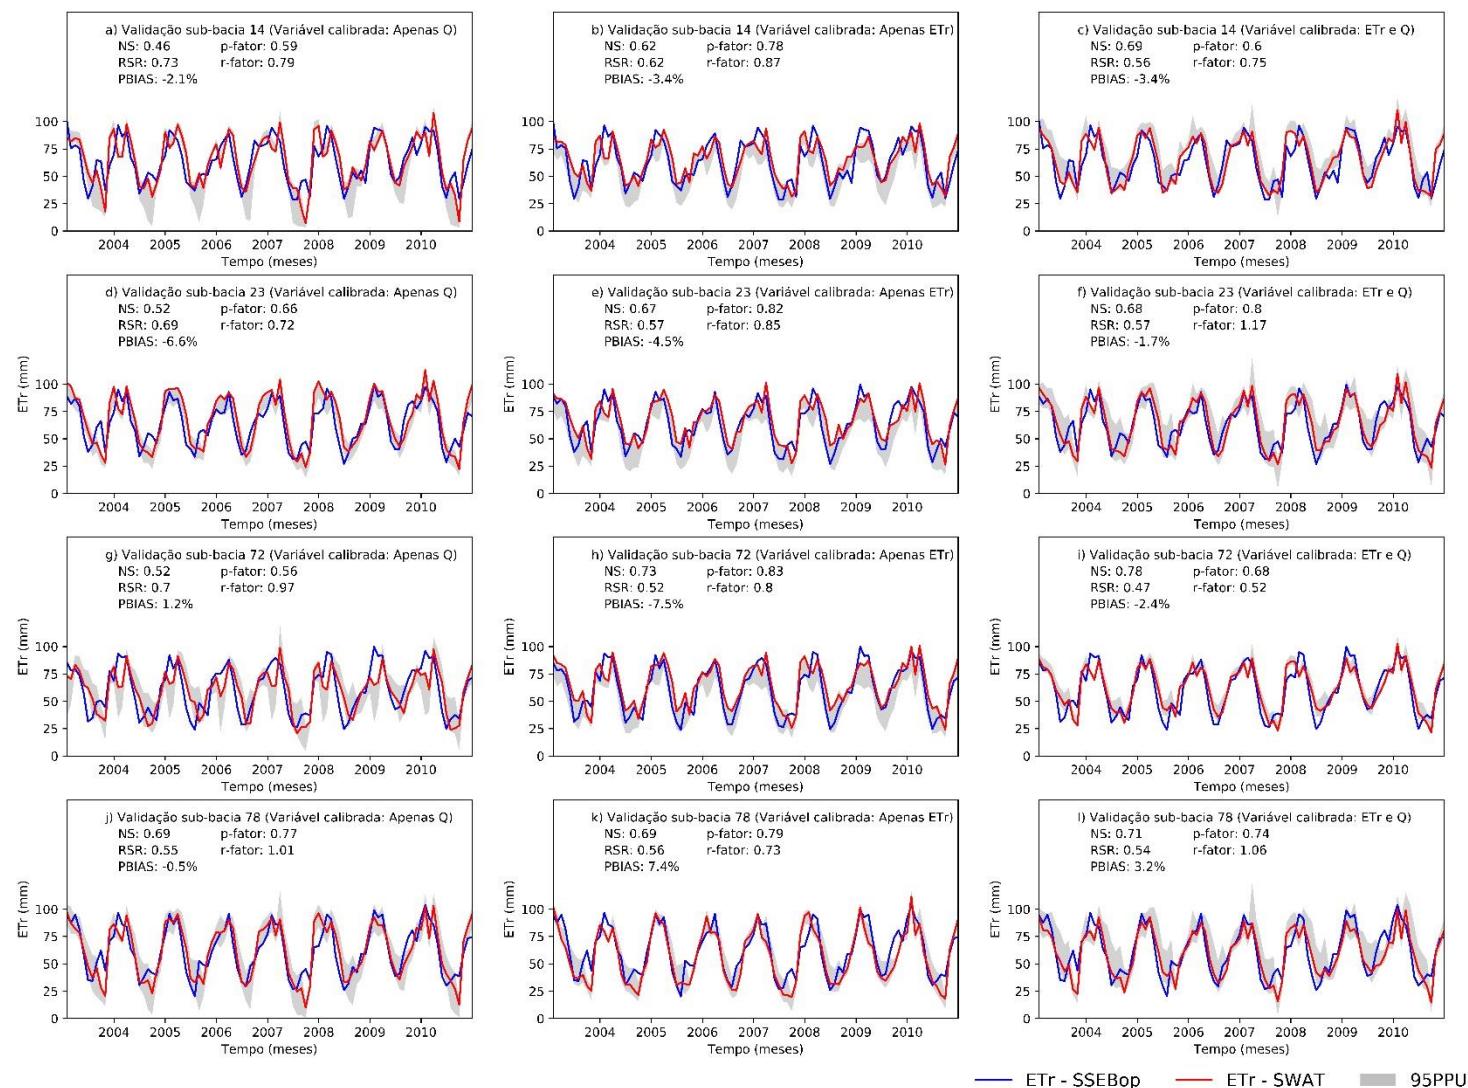


Figura 10: Séries temporais de ET_r simuladas pelo modelo SWAT e pelo SSEBop e a faixa de 95PPU da iteração correspondente à etapa de validação nas sub-bacias 14 (a-c), 23 (d-f), 72 (g-i), e 78 (j-l).

Ainda em relação à sub-bacia 14, a validação da ET_r simulada pelo modelo SWAT no cenário que calibrou essa variável individualmente (Figura 10b) apresentou níveis de incertezas satisfatórios, com p-fator (0,78) e r-fator (0,87) dentro do critério estabelecido. Já o NS (0,62) da melhor simulação dessa iteração e o seu RSR (0,62) foram classificados como satisfatório.

Na validação da ET_r simulada pelo SWAT no cenário em que foram calibrados a Q e a ET_r ao mesmo tempo na sub-bacia 14 (Figura 10c), o p-fator (0,6) não foi satisfatório, tendo a melhor simulação localizada na extremidade inferior do 95PPU. No entanto, esse cenário teve o NS (0,69) e o RSR (0,56) classificados como bom. O PBIAS, por sua vez, foi classificado como muito bom ($-10\% < \text{PBIAS} < 10\%$) em todos os cenários avaliados, assim como o r-fator ($< 1,5$) ficou dentro do critério estabelecido.

Em relação aos resultados da validação da ET_r simulada pelo modelo SWAT na sub-bacia 23 utilizando o intervalo dos parâmetros definidos no cenário que calibrou apenas a Q (Figura 10d), o p-fator foi insatisfatório (0,66) enquanto o NS (0,52) da melhor simulação e o seu RSR (0,69) foram classificados como satisfatórios. A validação da ET_r simulada pelo SWAT nessa sub-bacia, utilizando o intervalo dos parâmetros estabelecidos no cenário que calibrou apenas essa variável (Figura 10e), apresentou menores níveis de incertezas com p-fator e r-fator iguais a 0,82 e 0,85, respectivamente. Os índices de qualidade da melhor simulação também ficaram dentro do esperado, com NS (0,67) e o RSR (0,57) classificados como bom. A validação do intervalo dos parâmetros obtidos no cenário que calibrou Q e ET_r concomitantemente (Figura 10f) também apresentou níveis de incertezas satisfatórios (p-fator = 0,8 e r-fator = 1,17), apesar de alguns picos e vales extremos observados no 95PPU. Nesse cenário, o NS (0,68) da melhor simulação e o seu RSR (0,57) também foram classificados como bom. Já o PBIAS foi classificado como muito bom nos três cenários avaliados na etapa de validação na sub-bacia 23 ($-10\% < \text{PBIAS} < 10\%$).

Assim como o observado nas sub-bacias 14 e 23, os níveis de incertezas obtidos na validação da ET_r simulada pelo modelo SWAT utilizando o intervalo dos parâmetros definidos no cenário que calibrou apenas a Q (Figura 10g) foram insatisfatórios na sub-bacia 72, com p-fator igual a 0,56. Este resultado também pode ser avaliado visualmente no 95PPU onde a ET_r simulada pelo SWAT apresentou queda sistemática nos níveis de ET_r ao longo do período chuvoso. Mesmo assim, o NS (0,52) da melhor simulação e o seu RSR (0,7) foram classificados como satisfatório nesse cenário. A validação da ET_r na sub-bacia 72 utilizando o intervalo dos parâmetros

estabelecidos no cenário que calibrou apenas a própria ET_r (Figura 10h) apresentou os melhores níveis de incertezas com p-fator e r-fator, respectivamente, iguais a 0,83 e 0,8. Nesse cenário, o NS (0,73) da melhor simulação e o RSR (0,52) foram classificados como bom. Já a validação do intervalo dos parâmetros estabelecidos no cenário que calibrou Q e ET_r concomitantemente (Figura 10i) apresentou p-fator igual a 0,68, sendo um pouco abaixo do critério estabelecido. Esse resultado foi consequência do baixo valor obtido para o r-fator (0,52) o qual apresentou uma faixa de 95PPU estreita. No entanto, tanto o NS (0,78) da melhor simulação quanto o seu RSR (0,47) foram classificados como muito bom. O PBIAS calculado na sub-bacia 72 também foi classificado como muito bom na etapa de validação dos três cenários de calibração avaliados (-10% < PBIAS < 10%).

Todos os resultados da sub-bacia 78 obtidos na etapa de validação da ET_r simulada pelo modelo SWAT foram dentro do padrão estabelecido para o presente estudo nos três cenários de calibração avaliados. No cenário que calibrou apenas a Q, o intervalo dos parâmetros (Figura 10j) apresentou níveis de incertezas satisfatórios com o p-fator e o r-fator, respectivamente iguais a 0,77 e 1,01. O NS (0,69) da melhor simulação e o seu RSR (0,55) foram classificados como bom nesse cenário. Esses resultados foram similares ao obtido na validação do cenário que calibrou apenas a ET_r (Figura 10k) cujo p-fator e r-fator foram, respectivamente, iguais 0,79 e 0,73. O NS (0,69) da melhor simulação e o seu RSR (0,56) foram classificados como bom nesse cenário. Os resultados obtidos na validação da ET_r simulada pelo modelo SWAT no cenário que calibrou Q e ET_r concomitantemente (Figura 10l) foram similares aos demais, com o p-fator e o r-fator, respectivamente, iguais a 0,74 e 1,06. O NS (0,71) da melhor simulação e o seu RSR (0,54) foram classificados como bom nesse cenário. Assim como observado anteriormente nas demais sub-bacias, o PBIAS das simulações de Q na sub-bacia 78 foi classificado como muito bom em todos cenários avaliados (-10% < PBIAS < 10%).

A Figura 11 apresenta as séries temporais de Q simuladas pelo modelo SWAT, assim como a faixa com 95PPU obtida na iteração correspondente à etapa de validação nas sub-bacias 14 (a-c), 23 (d-f), 72 (g-i), e 78 (j-l). Os resultados da validação da Q simulada pelo SWAT na sub-bacia 14 utilizando o intervalo dos parâmetros definidos no cenário que calibrou apenas a Q (Figura 11a) foram de acordo com o estabelecido para o presente estudo. O p-fator e o r-fator foram iguais a 1,0 e a 1,2, respectivamente, com 100% dos dados observados contidos na faixa de 95PPU. Nesse cenário o NS (0,74) da melhor simulação e o seu RSR (0,51) e PBIAS (12%) foram classificados

como bom. A validação da Q simulada pelo modelo SWAT na sub-bacia 14 utilizando o intervalo dos parâmetros estabelecidos no cenário que calibrou apenas a ET_r (Figura 11b) teve maiores níveis de incertezas calculadas. O p-fator foi igual a 0,81, sendo dentro dos critérios estabelecidos, porém o r-fator ficou acima do recomendado ($>1,5$). O NS (0,69) da melhor simulação e os seu RSR (0,55) e PBIAS (-12,3%) também foram classificados como bom. A validação da Q simulada pelo SWAT com o intervalo dos parâmetros estabelecidos no cenário que calibrou Q e ET_r concomitantemente na sub-bacia 14 (Figura 11c) apresentou níveis de incertezas satisfatórios com p-fator e r-fator iguais a 0,81 e 1,23, respectivamente. Nesse cenário, o NS (0,89) da melhor simulação e o seu RSR (0,34) e PBIAS (2,4%) foram classificados como muito bom.

Os resultados da validação da Q simulada pelo SWAT na sub-bacia 23 utilizando o intervalo dos parâmetros definidos no cenário que calibrou apenas a Q (Figura 11d) foram de acordo com o estabelecido para o presente estudo. O p-fator e o r-fator foram iguais a 0,9 e a 1,34, respectivamente. Nesse cenário o NS (0,68) da melhor simulação de Q e seu o RSR (0,56) foram classificados como bom, enquanto o PBIAS foi próximo de zero (2,1%), sendo classificado como muito bom. Os resultados da validação da Q simulada pelo SWAT na sub-bacia 23 utilizando o intervalo dos parâmetros estabelecidos no cenário que calibrou apenas a ET_r (Figura 11e) novamente tiveram maiores níveis de incertezas calculadas e foram insatisfatórios, com o p-fator e o r-fator, respectivamente, iguais a 0,23 e 1,48. Observa-se que o 95PPU ficou acima dos valores de Q_{obs} no período avaliado, o que gerou uma forte tendência negativa, com PBIAS igual a -29,4%, o que é insatisfatório. Os dois maiores picos de Q observados no período também foram superestimados pelo SWAT, o que contribuiu também na redução do NS (0,14) da melhor simulação e no aumento do RSR (0,93), os quais também foram classificados como insatisfatório. Os resultados da validação da Q simulada pelo SWAT na sub-bacia 23 utilizando o intervalo dos parâmetros estabelecidos no cenário que calibrou Q e ET_r concomitantemente (Figura 11f) também apresentaram níveis de incertezas acima do recomendado. Apesar do p-fator ter sido igual 0,97, o r-fator igual a 1,9 ficou acima do recomendado, o que gerou uma faixa de 95PPU muito larga. Esses resultados foram reflexo da iteração selecionada na calibração, o que pode ser melhorado pelo uso de um intervalo de menor amplitude dos valores dos parâmetros utilizados. Nesse cenário, os resultados de NS (0,54) da melhor simulação e o seu RSR (0,68) foram classificados como bom, enquanto o PBIAS (2,1%) foi classificado como muito bom.

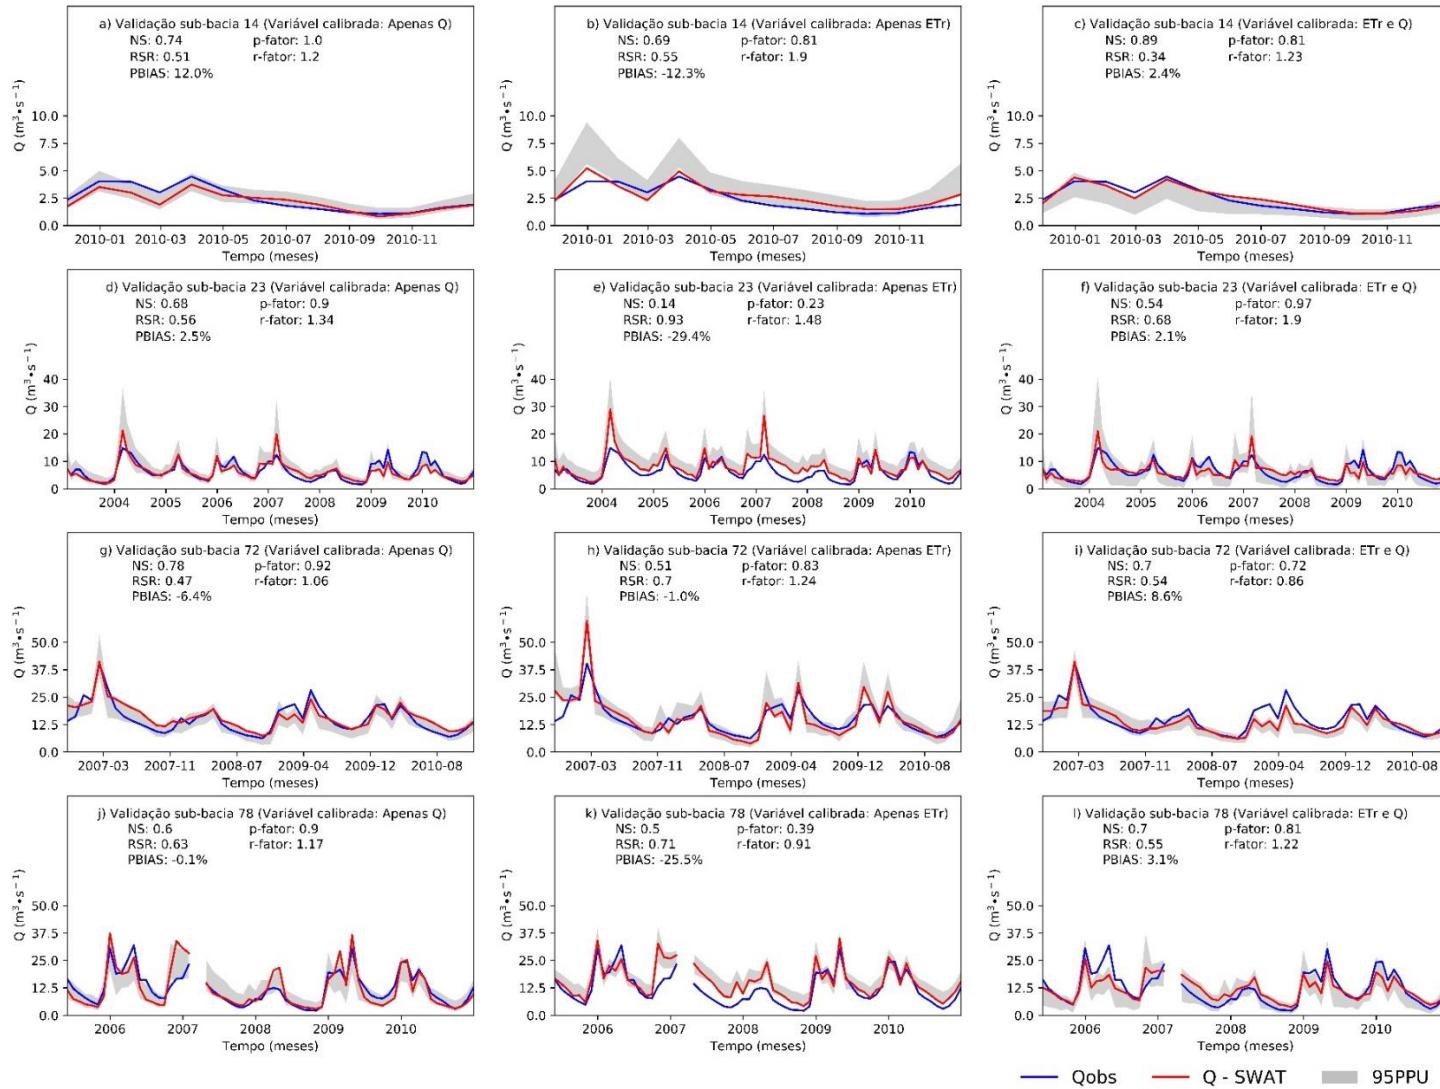


Figura 11: Séries temporais de $Q_{\text{mês}}$ simuladas pelo modelo SWAT e pelo SSEBop e a faixa de 95PPU da iteração correspondente à etapa de validação nas sub-bacias 14 (a-c), 23 (d-f), 72 (g-i), e 78 (j-l).

Os resultados da validação da Q simulada pelo modelo SWAT na sub-bacia 72 utilizando o intervalo dos parâmetros definidos no cenário que calibrou apenas a Q (Figura 11g) seguiram a tendência observada na sub-bacia 14 e foram de acordo com o estabelecido para o presente estudo, com p-fator e r-fator, respectivamente, iguais a 0,92 e a 1,06. Nesse cenário a faixa de 95PPU teve mais de 90% de sobreposição dos dados observados. Além disso, o NS (0,78) da melhor simulação e o seu RSR (0,47) e PBIAS (-6,4%) foram classificados como muito bom. A validação da Q simulada pelo modelo SWAT na sub-bacia 23 utilizando o intervalo dos parâmetros estabelecidos no cenário que calibrou apenas a ET_r (Figura 11h) teve maiores incertezas calculadas do que o outro cenário. Porém, os resultados atenderam os critérios estabelecidos, com p-fator e o r-fator, respectivamente, iguais a 0,83 e 1,24. O NS (0,51) da melhor simulação e o seu RSR (0,7) foram classificados como satisfatórios para a simulação de Q, enquanto o PBIAS (-1,0%) foi muito bom. Os resultados da validação da Q simulada pelo modelo SWAT na sub-bacia 23 utilizando o intervalo dos parâmetros estabelecidos no cenário que calibrou Q e ET_r concomitantemente (Figura 11i) também apresentaram níveis de incertezas dentro do limite recomendado, com p-fator e r-fator iguais a 0,72 e 0,86, respectivamente. Nesse cenário, o NS (0,7) da melhor simulação e o seu RSR (0,54) foram classificados como bom, enquanto o PBIAS (8,6%) foi classificado como muito bom.

A validação da Q simulada pelo SWAT na sub-bacia 78 utilizando o intervalo dos parâmetros definidos no cenário que calibrou apenas essa variável (Figura 11h) apresentou níveis de incertezas satisfatórios, com o p-fator e o r-fator, respectivamente, iguais a 0,9 e a 1,17. Nesse cenário o NS (0,6) da melhor simulação e o seu RSR (0,63) foram classificados como satisfatório, enquanto o PBIAS (-0,1%) foi classificado como muito bom. A validação da Q simulada pelo modelo SWAT na sub-bacia 78 utilizando o intervalo dos parâmetros estabelecidos no cenário que calibrou apenas a ET_r (Figura 11k) tiveram maiores níveis de incertezas calculadas. Apesar de uma boa faixa de 95PPU (r-fator = 0,91), o p-fator (0,39) foi insatisfatório. O NS da melhor simulação (0,5) e o seu RSR (0,71) e PBIAS (-25,5%) também não atenderam os critérios estabelecidos nesse cenário. Por fim, os resultados da validação da Q simulada pelo modelo SWAT na sub-bacia 78 utilizando o intervalo dos parâmetros estabelecidos no cenário que calibrou Q e ET_r concomitantemente (Figura 11l) também apresentaram níveis de incertezas dentro do limite recomendado, com p-fator e r-fator, respectivamente, iguais a 0,81 e 1,22. Nesse cenário, o NS (0,7) da melhor simulação e o seu RSR (0,55) foram classificados como bom, enquanto o PBIAS (3,1%) foi classificado como muito bom.

Os resultados demonstram que a estratégia de calibração que utilizou os dados de ET_r por sensoriamento remoto não foi capaz de evidenciar diminuição nas incertezas envolvidas nas estimativas da vazão em todos os cenários avaliados. Mesmo assim, os resultados obtidos na simulação de Q e ET_r pelo modelo SWAT no presente estudo demonstram a importância do uso de séries temporais de ET_r geradas com dados obtidos por sensoriamento remoto em modelos hidrológicos. De modo geral, a validação das simulações de ET_r pelo modelo SWAT (Figura 10) com os parâmetros obtidos no cenário que calibrou apenas a variável ET_r obteve melhores índices de qualidade da simulação e menores níveis de incertezas nas estimativas dos parâmetros do que o observado na validação das simulações de ET_r com o intervalo dos parâmetros gerados com a calibração de apenas Q. Immerzeel *et al.*, (2008) também obtiveram ganhos na simulação de ET_r pelo modelo SWAT calibrando o modelo com dados estimados pelo modelo SEBAL. Do mesmo modo, Herman *et al.* (2018) também reportaram bons resultados na simulação de ET_r utilizando dados do SSEBop e do ALEXI. Avaliando especificamente as unidades hidrológicas com vegetação nativa em sua área de estudo, Strauch & Volk (2013) também reportaram resultados satisfatórios de ET_r simulados pelo SWAT em comparação com dados do MODIS (MOD16A2) nas classes campo e cerrado, enquanto que, na Mata de Galeria, o modelo subestimou a ET_r em diversos momentos do período simulado. Apesar desse comportamento observado nas unidades hidrológicas com Mata de Galeria, os autores consideraram as simulações de ET_r satisfatórias diante do método proposto.

Diferentemente desses estudos, Franco e Bonumá (2017) reportaram resultados insatisfatórios comparando a ET_r simulada pelo modelo SWAT com dados do METRIC tanto no período de calibração quanto no período de validação. Segundo Herman *et al.* (2018), utilizando a estratégia adequada de calibração, a simulação de mais de uma variável pelo modelo SWAT pode melhorar. De fato, a estratégia de otimização do NS pelo SUFI-2 no cenário que calibrou em conjunto Q e ET_r utilizada no presente estudo conseguiu atingir níveis de incertezas adequados e boa qualidade nas simulações de Q e ET_r na maior parte das sub-bacias avaliadas. No presente estudo (Tabela 3) foram utilizados parâmetros que são relacionados ao desenvolvimento foliar e a outros processos ligados à ET, os quais também foram empregados em Strauch & Volk (2013), além dos parâmetros usualmente utilizados em estudos com o modelo SWAT. O uso desses parâmetros relacionados ao desenvolvimento foliar e a outros processos ligados à ET pode ter contribuído positivamente na calibração do modelo, sendo uma explicação razoável para os resultados obtidos em comparação com Franco e Bonumá (2017). Além disso, o presente estudo avaliou a ET_r por trecho (Figura 2d) o qual inclui diversas sub-bacias e que pode também ter influenciado positivamente os resultados, principalmente no cenário que

calibrou em conjunto Q e ET_r. A avaliação por trecho também é razoável, considerando a resolução espacial do MODIS na banda termal e os dados do SSEBop utilizados no presente estudo.

Observa-se que as simulações de Q e ET_r pelo modelo SWAT atenderam os critérios de qualidade estabelecidos na maior parte dos cenários avaliados, apesar de não ter reduzido os níveis de incertezas na estimativa dos parâmetros em todos os casos. A seleção de outra iteração para realizar a etapa de validação de Q e ET_r pode melhorar os níveis de incertezas na estimativa dos parâmetros nos casos em que os níveis não foram satisfatórios. No entanto, devem ser observadas as relações entre o p-fator e o r-fator, assim como o desempenho da simulação para avaliar os ganhos/perdas dessa alteração.

Ademais, outras estratégias de calibração devem ser testadas, visando melhores resultados em todas as sub-bacias avaliadas, conforme observado por Herman *et al.* (2018). Nesse sentido, o presente estudo apresenta metodologias que podem ser aperfeiçoadas e outras alternativas que podem ser testadas em estudos posteriores visando melhores resultados. Por exemplo, em relação ao método de calibração utilizado, a otimização do NS pelo SUFI-2 pode ser alterada pela função KGE, a qual permite a calibração multi-objetivo, principalmente em cenários que calibraram Q e ET_r ao mesmo. A calibração multi-objetivo também poderá incluir outras variáveis simuladas pelo modelo SWAT e que são disponibilizadas após o processamento de dados obtidos por sensoriamento remoto como o IAF. Essa variável foi calibrada anteriormente com sucesso em Strauch & Volk (2013) utilizando dados do MODIS (MOD15A2). Outras estratégias de calibração do modelo também podem ser recomendadas como alterar o número de parâmetros utilizados no processo, o intervalo de variação de cada parâmetro, o número de iterações e simulações utilizadas. Além disso, há outros algoritmos de calibração que podem ser testados no próprio SWATCUP.

Outro ponto que pode ser melhorado em futuras aplicações refere-se à escala de dados utilizados no presente estudo. Por exemplo, o mapa de uso do solo não diferencia práticas de irrigação, as quais são comuns na região com diversos pivôs centrais que entraram em operação nos últimos 30 anos. Como as imagens de ET_r do SSEBop são processadas a partir de dados do MODIS, cuja banda com T_s possui resolução espacial de ~1km, o que abrange uma área de 100 ha, essa escala não possibilita a obtenção de pixels puros dentro de áreas irrigadas com facilidade, havendo grande mistura espectral entre os alvos. No entanto, atualmente Brasil (2020) fornece séries temporais de ET_r gerados por imagens LandSat as quais permitem o uso desses dados com modelos hidrológicos e consequentemente avaliações dos níveis de ET_r nos pivôs centrais, em conjunto com as vazões. Além disso, Xavier *et al.*, (2016) disponibilizam séries temporais de

imagens com dados climatológicas no território brasileiro, os quais possibilitam o processamento da série histórica LandSat desde a década de 1980 para simulações de ET_r com o modelo SSEBop, caso seja desejada outra alternativa à Brasil (2020).

Apesar das limitações presente nesse estudo e das metodologias que podem ser aperfeiçoadas, os resultados observados reforçam a importância do uso de séries temporais de P e ET_r obtidas por sensoriamento remoto em estudos com modelos hidrológicos no Brasil.

4. Conclusões

O presente estudo avaliou o uso de produtos globais de precipitação (P) e evapotranspiração real (ET_r) obtidos por sensoriamento remoto na simulação de vazões (Q) e (ET_r) em regiões tropicais utilizando o modelo SWAT. Foram analisadas as incertezas observadas na estimativa dos parâmetros ao longo do processo de calibração e validação de Q e ET_r simuladas pelo modelo chuva-vazão em diferentes cenários, os quais utilizaram dados de P e ET_r obtidos por sensoriamento remoto. De modo geral, os produtos de P e ET_r utilizados em conjunto com o modelo hidrológico foram capazes de fornecer dados que contribuíram com a simulação de Q e ET_r na BHRQ. No entanto, os resultados não foram satisfatórios em todos os cenários avaliados, de modo que qualquer generalização deve ser usada com cautela e com a verificação da qualidade dos dados. Nesse contexto, as principais conclusões são:

- A simulação de Q_{dia} com os dados de P_{sr} e com dados de P_{obs} não atingiram os critérios de qualidade estabelecidos em todas as sub-bacias avaliadas. O IMERG – 0,1° apresentou resultados insatisfatórios na maior parte dos cenários avaliados, enquanto o GSMAp – 0,1° não apresentou resultados satisfatórios. No entanto, o uso dos dados de P_{obs} também não atingiu os critérios de qualidade estabelecidos em todos os cenários avaliados, principalmente nas sub-bacias que não possuem pluviômetros. Apesar disso, os resultados das simulações de Q_{dia} com P_{obs} foi melhor do que o obtido com P_{sr} na maior parte dos casos. As simulações de Q_{dia} com o IMERG – 0,25°, por sua vez, foram melhores e superaram os resultados do TMPA e do GSMAp – 0,25°.
- A simulação de Q_{mês} com os dados de P_{sr} e com dados de P_{obs} atingiram os critérios de qualidade estabelecidos em todas as sub-bacias avaliadas. As simulações de Q_{mês} com o IMERG foram melhores do que o obtido com o GSMAp em ambas as resoluções espaciais avaliadas (0,1° e 0,25°). Além disso, as simulações de Q_{mês} com o IMERG – 0,25° superaram os resultados obtidos com o TMPA na maior parte dos cenários avaliados. Em alguns cenários, as simulações de Q_{mês} com dados do IMERG e do TMPA superaram os

resultados obtidos com P_{obs} , demonstrando o bom potencial do uso desses dados na simulação hidrológica nessa escala temporal.

- A nova geração de produtos de P_{sr} obtidos a partir de dados da missão GPM (IMERG e GSMAp) foi capaz de garantir a continuidade no fornecimento de dados de P para simulação de Q com modelo hidrológico no Brasil central de forma semelhante ou até mesmo melhor do que o obtido anteriormente com produtos da geração TRMM. Além disso, os resultados das simulações que utilizaram dados de P_{sr} foram compatíveis com os obtidos nas simulações que utilizaram P_{obs} . De modo geral, o IMERG – 0,25° apresentou melhores resultados nas simulações de Q_{dia} e $Q_{mês}$ do que o observado com o TMPA. No entanto, os resultados com o TMPA foram melhores do que o observado com o GSMAp – 0,25°.
- Apesar das diferenças observadas entre o IMERG e o GSMAp, ambos os produtos foram capazes de ter simulações de Q dentro dos critérios estabelecidos com níveis satisfatórios. No entanto, o IMERG apresentou melhores resultados na maior parte dos cenários avaliados.
- As séries temporais do modelo SSEBop permitiu a calibração da ET_r simulada pelo modelo SWAT ao nível de sub-bacia nos cenários avaliados. Ambas as versões do SWAT (default e Trópicos) apresentaram simulações de Q e ET_r dentro dos critérios estabelecidos. Os resultados foram similares na maior parte dos cenários avaliados.
- A calibração dos parâmetros apenas para a simulação da Q não garante que o modelo SWAT também simule a ET_r de forma adequada. Do mesmo modo, a calibração dos parâmetros apenas para a simulação de ET_r não produziu simulações de Q em níveis satisfatórios em parte dos cenários avaliados.
- A calibração dos parâmetros para a simulação de Q e ET_r ao mesmo tempo apresentou níveis de incertezas semelhantes ao cenário no qual Q e ET_r foram calibrados individualmente. Além disso, a qualidade das simulações também foi semelhante ao observado quando Q e ET_r foram calibrados individualmente. No entanto, o fato de ter duas variáveis hidrológicas sendo simuladas conforme o padrão estabelecido possibilita melhor representação do ciclo hidrológico pelo modelo chuva-vazão.

Por fim, os produtos de P_{sr} e ET_r avaliados no presente estudo se mostraram ser uma importante fonte de dados para gestão dos recursos hídricos, uma vez que disponibilizam séries

temporais de P e ET_r em todo o território brasileiro, em muitos locais que carecem de dados hidrológicos.

Referências bibliográficas

- Abbaspour, K.C., Johnson, C., van Genuchten, M.T. Estimating uncertain flow and transport parameters using a sequential uncertainty fitting procedure. *Vadose Zone Journal*, 3, 1340–1352, 2004.
- Abbaspour, K.C., Yang, J., Maximov, I., Siber, R., Bogner, K., Mieleitner, J., Zobrist, J., Srinivasan, R. Modelling hydrology and water quality in the pre-alpine/alpine Thur watershed using SWAT. *Journal of Hydrology*, 333, 413–430, 2007.
- Abbaspour, K.C.; Rouholahnejad, E.; Vaghefi, S.; Srinivasan, R.; Yang, H.; Kløve, B. 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, 2015.
- Alemayehu, T.; Griensven, A.; Senay, G. B.; Bauwens, W. Evapotranspiration Mapping in a Heterogeneous Landscape Using Remote Sensing and Global Weather Datasets: Application to the Mara Basin, East Africa. *Remote Sensing*, 9, 2017, 390. Doi: <https://doi.org/10.3390/rs9040390>
- Allen, R. G.; Pereira, L. S.; Raes, D.; Smith, M. Crop evapotranspiration: guidelines for computing crop water requirements. In: *Irrigation and Drainage Paper 56*, FAO, Rome, Italy, 1998.
- Allen, R. G.; Tasumi, M.; Trezza, R. Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC) – Model. *Journal of Irrigation and Drainage Engineering*, 133, 380–394, 2007. Doi: [https://doi.org/10.1061/\(ASCE\)0733-9437\(2007\)133:4\(380\)](https://doi.org/10.1061/(ASCE)0733-9437(2007)133:4(380)).
- Anderson, M. C., Norman, J. M., Mecikalski, J. R., Otkin, J. A., & Kustas, W. P. A climatological study of evapotranspiration and moisture stress across the continental United States based on thermal remote sensing: 1. Model formulation. *Journal of Geophysical Research-Atmospheres*, 112, 1984–2012, 2007. Doi: <http://dx.doi.org/10.1029/2006JD007506ASCE>. Criteria for evaluation of watershed models. *Journal of Irrigation and Drainage Engineering*, v. 119, n. 3, p. 429–442, 1993.
- Araújo, D. L. Avaliação dos impactos da exploração de águas subterrâneas na bacia do Ribeirão Rodeador por meio de simulação integrada entre os modelos SWAT e MODFLOW. Dissertação de Mestrado em Tecnologia Ambiental e Recursos Hídricos, Publicação PTARH. DM 213/2018, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 186p. 2018.
- Arnold, J. G.; Srinivasan, R.; Muttiah, R.S.; Williams, J. R. Large area hydrologic modeling and assessment part I: model development. *Journal of the American Water Resources Association*, 34, 1, 73–89, 1998. Doi: <https://doi.org/10.1111/j.1752-1688.1998.tb05961.x>
- Bastiaanssen, W.; Menenti, M.; Feddes, R.; Holtslag, A. A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. *Journal of Hydrology*, 212, 198–212, 1998.

Bastiaanssen, W. G. M.; Thoreson, B.; Clark, B.; Davids, G. Discussion of “Application of SEBAL Model for Mapping Evapotranspiration and Estimating Surface Energy Fluxes in South-Central Nebraska” by Ramesh K. Singh, Ayse Irmak, Suat Irmak, and Derrel L. Martin. *Journal of Irrigation and Drainage Engineering*, 136, 4, 282–283, 2010. Doi: [https://doi.org/10.1061/\(ASCE\)0733-9437\(2008\)134:3\(273\)](https://doi.org/10.1061/(ASCE)0733-9437(2008)134:3(273))

Beven, K.J. Rainfall-runoff modelling: The primer. Chichester: John Wiley & Sons Ltda. 360p. 2001.

Brasil. Zoneamento ecológico-econômico da região integrada de desenvolvimento do Distrito Federal e entorno: fase I. Rio de Janeiro: CPRM, EMBRAPA, MI/SCO, 2003.

Brasil. ANA, Agência Nacional de Águas. Estimativas de evapotranspiração real por sensoriamento remoto no Brasil. Brasilia: ANA, 41p, 2020.

Bressiani, D.A.; Gassman, P.W.; Fernandes, J.G.; Garbossa, L.H.P.; Srinivasan, R.; Bonumá, N.B.; Mendiondo, E.M. A review of soil and water assessment tool (SWAT) applications in Brazil: Challenges and prospects. *International Journal of Agricultural and Biological Engineering*, v. 8, n. 3, p. 1–27, 2015.

Campos, J.E.G.; Monteiro, C.F.; Rodrigues, L.N. Geologia e Zoneamento Hidrogeológico da Bacia do Rio Preto, DF/GO/MG. Planaltina, DF: Embrapa Cerrados, 2006, 54. ISSN: 1517-5111:172.

Carneiro, P.J.R.; Maldaner, V.I.; Alves, P.F.; Queirós, I.A.; Mauriz, T.V.; Pacheco, R.F. Evolução do uso da água na bacia do rio Preto no Distrito Federal. *Espaço & Geografia*, v. 10, n. 2, p. 325–353, 2007.

Carrillo-Rojas, G.; Silva, B.; Córdova, M.; Cáceres, R.; Bendix, J. Dynamic Mapping of Evapotranspiration Using an Energy Balance-Based Model over an Andean Páramo Catchment of Southern Ecuador. *Remote Sensing*, 8, 160, 2016. Doi: <https://doi.org/10.3390/rs8020160>

Castro, K.B.; Roig, H.L.; Lima, J.E.F.W.; Ferrigo, S. Aplicação de série temporal mínima para simulação de vazões em bacia experimental do Cerrado. *Revista Brasileira de Cartografia (online)*, v. 68, p. 1497-1513, 2016.

Chen, F.; Li, X. Evaluation ofIMERG and TRMM 3B43 monthly precipitation products over Mainland China. *Remote Sensing*, 2016, 8, 472. Doi: <https://doi.org/10.3390/rs8060472>

Chen, M.; Senay, G. B.; Singh, R. K.; Verdin J. P. Uncertainty analysis of the Operational Simplified Surface Energy Balance (SSEBop) model at multiple flux tower sites. *Journal of Hydrology* 536, 2016, 384–399. Doi: <http://dx.doi.org/10.1016/j.jhydrol.2016.02.026>

Deng, P.; Zhang, M.; Bing, J.; Jia, J.; Zhang, D. Evaluation of the GSMP_Gauge products using rain gauge observations and SWAT model in the Upper Hanjiang River Basin. *Atmospheric Research* 219, 153–165, 2019. Doi: <https://doi.org/10.1016/j.atmosres.2018.12.032>

Ferrigo, S. Análise de consistência dos parâmetros do modelo SWAT obtidos por calibração automática – Estudo de caso da bacia do lago Descoberto – DF. Dissertação de Mestrado em

Tecnologia Ambiental e Recursos Hídricos, Publicação PTARH.DM-159/14, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 164 p. 2014.

Franco, A.C.L.; Bonumá, N.B. Multi-variable SWAT model calibration with remotely sensed evapotranspiration and observed flow. *Brazilian Journal of Water Resources*, 22(e35), 2017.

GsMap. Global Satellite Mapping of Precipitation (GSMaP) for GPM. Available online: https://www.eorc.jaxa.jp/GPM/doc/algorithm/GSMaPforGPM_20140902_E.pdf (acesso em: 10/07/ 2018).

Gowda, P. H.; Chavez, J. L.; Colaizzi, P. D.; Evett, S. R.; Howell, T. A.; Tolk, J. A. ET mapping for agricultural water management: present status and challenges. *Irrigation Science*, 26, 2008, 223–237. Doi: <http://dx.doi.org/10.1007/s00271-007-0088-6>

Guo, D.; Wang, H.; Zhang, X.; Liu, G. Evaluation and Analysis of Grid Precipitation Fusion Products in Jinsha River Basin Based on China Meteorological Assimilation Datasets for the SWAT Model. *Water*, 11, 2019, 253. Doi: <http://dx.doi.org/10.3390/w11020253>

Herman, M.R.; Nejadhashemi, A.P.; Abouali, M.; Hernandez-Suarez, J.S.; Daneshvar, F.; Zhang, Z.; Anderson, M.C.; Sadeghi, A.M.; Hain, C.R.; Sharifi, A. Evaluating the role of evapotranspiration remote sensing data in improving hydrological modeling predictability. *Journal of Hydrology*, 556, 39-49, 2018. Doi: <https://doi.org/10.1016/j.jhydrol.2017.11.009>

Hong, Y.; Hsu, K.L.; Sorooshian, S.; Gao, X. Precipitation Estimation from Remotely Sensed Imagery Using an Artificial Neural Network Cloud Classification System. *Journal of Applied Meteorology*, v. 43, p. 1834–1852, 2004.

Hou, A.R.; Kakar, R.K.; Neeck, S.; Azarbarzin, A.A.; Kummerow, C.D.; Kojima, M.; Oki, R.; Nakamura, K.; Iguchi, T. The global precipitation measurement mission. *Bulletin of the American Meteorological Society*, 95, 701–722, 2014. Doi: <https://doi.org/10.1175/BAMS-D-13-00164.1>

Hsu, K.L.; Gao, X.; Sorooshian, S.; Gupta, H. V. Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks. *Journal of Applied Meteorology*, v. 36, p. 1176–1190, 1997.

Huffman, G.J.; Bolvin, D.T.; Nelkin, E.J.; Wolff, D.B.; Adler, R.F.; Gu, G.; Hong, Y.; Bowman, K.P.; Stocker, E.F. The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-Global, Multiyear, Combined-Sensor Precipitation Estimates at Fine Scales. *Journal of Hydrometeorology*, 8, 38–55, 2007.

Huffman, G.J.; Bolvin, D.T. TRMM and Other Data Precipitation Data Set Documentation; NASA: Greenbelt, MD, USA, 2015.

Huffman, G.J.; Bolvin, D.T.; Braithwaite, D.; Hsu, K.; Joyce, R.; Kidd, C.; Nelkin, E.J.; Xie, P. Algorithm Theoretical Basis Document (ATBD) Version 4.5: NASA Global Precipitation Measurement (GPM) Integrated Multi-satellitE Retrievals for GPM (IMERG); NASA: Greenbelt, MD, USA, 2015.

Huntington, J., Hegewisch, K., Daudert, B., Morton, C., Abatzoglou, J., McEvoy, D., and T., Erickson. Climate Engine: Cloud Computing of Climate and Remote Sensing Data for Advanced Natural Resource Monitoring and Process Understanding. *Bulletin of the American*

Meteorological Society, 2017. Doi: <http://journals.ametsoc.org/doi/abs/10.1175/BAMS-D-15-00324.1>.

Immerzeel, W.W.; Gaur, A.; Zwart, S.J. Integrating remote sensing and a process-based hydrological model to evaluate water use and productivity in a south Indian catchment. Agricultural Water Management, 95, 11-25, 2008. Doi: <https://doi.org/10.1016/j.agwat.2007.08.006>

Ji, L.; Senay, G. B. Velpuri, N. M.; Kagone, Evaluating the Temperature Difference Parameter in the SSEBop Model with Satellite-Observed Land Surface Temperature Data. Remote Sensing, 2019, 11, 1947. Doi: <https://doi.org/10.3390/rs11161947>

Jiang, D.; Wang, K. The Role of Satellite-Based Remote Sensing in Improving Simulated Streamflow: A Review. Water, 11, 1615, 2019. Doi: <https://doi.org/10.3390/w11081615>
 Joyce, R.J.; Janowiak, J.E.; Arkin, P.A.; Xie, P. CMORPH: A Method that Produces Global Precipitation Estimates from Passive Microwave and Infrared Data at High Spatial and Temporal Resolution. Journal of Hydrometeorology, 5, 487–503, 2004. Doi: [https://doi.org/10.1175/1525-7541\(2004\)005<0487:CAMTPG>2.0.CO;2](https://doi.org/10.1175/1525-7541(2004)005<0487:CAMTPG>2.0.CO;2)

Kubota, T.; Shige, S.; Hashizume, H.; Aonashi, K.; Takahashi, N.; Seto, S.; Hirose, M.; Takayabu, Y.N.; Ushio, T.; Nakagawa, K.; et al. Global Precipitation Map Using Satellite-Borne Microwave Radiometers by the GSMAp Project: Production and Validation. IEEE Transactions on Geoscience and Remote Sensing, 45, 2259–2275, 2007.

Karimi, P.; Bastiaanssen, W. G. M. Spatial evapotranspiration, rainfall and land use data in water accounting - Part 1: Review of the accuracy of the remote sensing data. Hydrology and Earth System Sciences, v. 19, p. 507–532, 2015.

Kilic, A.; Allen, R.; Trezza, R.; Ratcliffe, I.; Kamble. B.; Robison, C.; Ozturk, D. Sensitivity of evapotranspiration retrievals from the METRIC processing algorithm to improved radiometric resolution of Landsat 8 thermal data and to calibration bias in Landsat 7 and 8 surface temperature. Remote Sensing of Environment 185, 198–209, 2016. Doi: <http://dx.doi.org/10.1016/j.rse.2016.07.011>

Lima, J. E. F. W.; Silva, E. M.; Strauch, M.; Lorz, C. Development of a soil database for applying SWAT model in a catchment of the Brazilian Savanna. Proceedings of the SWAT-2013 Conference, Toulouse-FR. p.1-10, 2013.

Lopes, J. D.; Rodrigues, L. N.; Imbuzeiro, H. M. A.; Pruski, F. F. Performance of SSEBop model for estimating wheat actual evapotranspiration in the Brazilian Savannah region. International Journal of Remote Sensing, 2019, 1-18. Doi: <https://doi.org/10.1080/01431161.2019.1597304>

Luo X.; Wu W.; He D.; Li Y.; Ji X. Hydrological Simulation Using TRMM and CHIRPS Precipitation Estimates in the Lower Lancang-Mekong River Basin. Chinese Geographical Science, 29,1, 13–25, 2019. Doi: <https://doi.org/10.1007/s11769-019-1014-6>

Nash, J.E, Sutcliffe, J. V. River flow forecasting through conceptual models Part I - A discussion of principles. Journal of hydrology, v. 10, p. 282–290, 1970.

Malta, E. A. Avaliação do modelo SSEBop na estimativa de evapotranspiração real da cultura do trigo. Dissertação de Mestrado em Geociências Aplicadas, Publicação IG.DM- /19, Instituto de Geociências, Universidade de Brasília, Brasília, DF, 120 p. 2019.

Moriasi, D.N.; Arnold, J.G.; Van Liew, M.W.; Bingner, R.L.; Harmel, R.D.; Veith, T.L. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, v. 50, n. 3, p. 885–900, 2007.

Neitsch, S.; Arnold, J.G.; Kiniry, J.R.; Williams, J. Soil & Water Assessment Tool Theoretical Documentation Version 2009. Texas Water Resources Institute Technical Report No. 406, College Station, TX, pp. 618, 2011.

Oliveira, B. S.; Moraes, E. C.; Carrasco-Benavides, M.; Bertani, G.; Mataveli, G. A. V. Improved Albedo Estimates Implemented in the METRIC Model for Modeling Energy Balance Fluxes and Evapotranspiration over Agricultural and Natural Areas in the Brazilian Cerrado. *Remote Sensing*, 10, 2018, 1181. Doi: <https://doi.org/10.3390/rs10081181>

Paula, A. C. P. de; Silva, C. L. da; Rodrigues, L.N.; Scherer-Warren, M. Performance of the SSEBop model in the estimation of the actual evapotranspiration of soybean and bean crops. *Pesquisa Agropecuária Brasileira*, 54, e00739, 2019. Doi: <https://doi.org/10.1590/S1678-3921.pab2019.v54.00739>

Rozante, R.; Id, D.A.V.; Chiquetto, B. Evaluation of TRMM/GPM Blended Daily Products over Brazil. *Remote Sensing*, 10, 6, 882, 2018. Doi: <https://doi.org/10.3390/rs10060882>

Salles, L.A.; Lima, J.E.F.W.; Chaves, H.M.L.; Ferrigo, S.; Carvalho, H.E.S. Impacts of Using Different Soil Databases on Streamflow Simulation in an Experimental Rural Catchment of the Brazilian Savanna. *Revista Brasileira de Geografia Física*, 8, 1, 187–195, 2015. Doi: <https://doi.org/10.26848/rbgf.v8.1.p187-195>

Salles, L.A.; Satgé, F.; Roig, H.; Almeida, T.; Olivetti, D.; Ferreira, W. Seasonal Effect on Spatial and Temporal Consistency of the New GPM-BasedIMERG-v5 and GSMap-v7 Satellite Precipitation Estimates in Brazil's Central Plateau Region. *Water*, 11, 668, 2019. Doi: <https://doi.org/10.3390/w11040668>

Salles, L. A.; Senay, G. B.; Ojima, D. S.; Roig, H. L.; Malta, E. A.; Conti, L. C.; Neumann, M. R. B.; Rodrigues, L. N.; Galvão, J. L.; Scherer-Warren, M. Remote sensing based estimation of Actual Evapotranspiration time series for rainfall-runoff modeling at an agricultural river basin of the Brazilian Central Plateau region. Development of a soil database for applying SWAT model in a catchment of the Brazilian Savanna. In: *Poster session of the American Geophysical Union (AGU) 2018 Fall Meeting*, Washington D.C. -US, 2018.

Salles, L.A.; Roig, H.; Lima, J.E.F.W.; Senay, G; Ojima, D. S. Remote sensing to evaluate the impacts of actual evapotranspiration on soil moisture dynamics through the rooting zone in areas with pasture, forest plantation and native vegetation at the Brazilian Cerrado. 2020. (Pronto para submeter)

Sarmento, L. Análise de incertezas e avaliação dos fatores influentes no desempenho de modelos de simulação de bacias hidrográficas. Tese de Doutorado em Tecnologia Ambiental e Recursos Hídricos, Publicação PTARH. TD – 07/10, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 241p. 2010.

Satgé, F.; Xavier, A.; Zolá, R.; Hussain, Y.; Timouk, F.; Garnier, J.; Bonnet, M.-P. Comparative Assessments of the Latest GPM Mission's Spatially Enhanced Satellite Rainfall Products over the Main Bolivian Watersheds. *Remote Sensing*, 9, 369, 2017. Doi: <https://doi.org/10.3390/rs9040369>

Scherer-Warren, M. Desmembramento de Estimativas de Evapotranspiração Obtidas por Sensoriamento Remoto nas Componentes de Evaporação e Transpiração Vegetal. *Revista Brasileira de Geografia Física* 02, 361-373, 2012. Doi: <https://doi.org/10.26848/rbgf.v5i2.232806>

Senay, G. B. Satellite psychrometric formulation of the Operational Simplified Surface Energy Balance (SSEBOP) model for quantifying and mapping evapotranspiration. *Applied Engineering in Agriculture*, 34(3), 555-566, 2018. Doi: <https://doi.org/10.13031/aea.12614>

Senay, G. B.; Bohms, S.; Singh, R. K.; Gowda, P. H.; Velpuri, N. M.; Alemu, H.; Verdin, J. P. Operational Evapotranspiration Mapping Using Remote Sensing and Weather Datasets: A New Parameterization for the SSEB Approach. *Journal of the American Water Resources Association (JAWRA)* 49(3), 577-591. Doi: <https://doi.org/10.1111/jawr.12057>

Senay, G. B.; Schauer, M.; Friedrichs, M.; Velpuri, N. M.; Singh, R. K. Satellite-based water use dynamics using historical Landsat data (1984–2014) in the southwestern United States. *Remote Sensing of Environment*, 202, 2017, 98-112. Doi: <https://doi.org/10.1016/j.rse.2017.05.005>

Sharifi, E.; Steinacker, R.; Saghafian, B. Assessment of GPM-IMERG and Other Precipitation Products against Gauge Data under Different Topographic and Climatic Conditions in Iran: Preliminary Results. *Remote Sensing*, 8, 135, 2016. Doi: <https://doi.org/10.3390/rs8020135>

Singh, R. K.; Senay, G. B. Comparison of Four Different Energy Balance Models for Estimating Evapotranspiration in the Midwestern United States. *Water*, 8, 2016, 9. Doi: <https://doi.org/10.3390/w8010009>

Singh, R. K.; Senay, G. B.; Velpuri, N. M.; Bohms, S.; Scott, R. L.; Verdin, J. P. Actual Evapotranspiration (Water Use) Assessment of the Colorado River Basin at the Landsat Resolution Using the Operational Simplified Surface Energy Balance Model. *Remote sensing*, 6, 233-256, 2014. Doi: <https://doi.org/10.3390/rs6010233>

Sorooshian, S.; Hsu, K.-L.; Gao, X.; Gupta, H.V.; Imam, B.; Braithwaite, D. Evaluation of PERSIANN System Satellite-Based Estimates of Tropical Rainfall. *Bulletin of the American Meteorological Society*, 81, 2035–2046, 2000. Doi: [https://doi.org/10.1175/1520-0477\(2000\)081<2035:EOPSSE>2.3.CO;2](https://doi.org/10.1175/1520-0477(2000)081<2035:EOPSSE>2.3.CO;2)

Sparovek, G.; Freitas, F. L. M.; Barreto, A. G. O. P.; Sbitkowski, A. L. Evaluation of the MapBiomas Initiative (2015-2019). 2019.

Srinivasan, R., Arnold, J. G. Integration of a basin-scale water quality model with GIS. *Water Resources Bulletin*, v. 30, n. 3, p. 453–462, 1994. Doi: <https://doi.org/10.1111/j.1752-1688.1994.tb03304.x>

Strauch, M.; Bernhofer, C.; Koide, S.; Volk, M.; Lorz, C.; Makeschin, F. Using precipitation data ensemble for uncertainty analysis in SWAT streamflow simulation. *Journal of Hydrology*, 414–415, 413–424, 2012. Doi: <https://doi.org/10.1016/j.jhydrol.2011.11.014>

Strauch, M.; Lima, J.E.F.W.; Volk, M.; Lorz, C.; Makeschin, F. The impact of Best Management Practices on simulated streamflow and sediment load in a Central Brazilian catchment. *Journal of Environmental Management*, 127, S24–S36, 2013. Doi: <https://doi.org/10.1016/j.jenvman.2013.01.014>

Strauch, M.; Volk, M. SWAT plant growth modification for improved modeling of perennial vegetation in the tropics. *Ecological Modelling*, v. 269, p. 98–112, 2013. Doi: <https://doi.org/10.1016/j.ecolmodel.2013.08.013>

Su, Z. The Surface Energy Balance System (SEBS) for estimation of turbulent heat fluxes. *Hydrology and Earth System Sciences Discussions*, 6, 1, 85–100, 2002. Doi: <https://doi.org/10.5194/hess-6-85-2002>

Tan, M. L.; Yang, X. Effect of rainfall station density, distribution and missing values on SWAT outputs in tropical region. *Journal of Hydrology* 584, 2020. Doi: <https://doi.org/10.1016/j.jhydrol.2020.124660>

Tan, M. L.; Samat, N.; Chan, N. W.; Roy, R. Hydro-Meteorological Assessment of Three GPM Satellite Precipitation Products in the Kelantan River Basin, Malaysia. *Remote Sensing*, 10, 2018, 1011. Doi: <https://doi.org/10.3390/rs10071011>

Tang, G.; Ziyue Zeng, Z; Long, D.; Guo, X. Statistical and Hydrological Comparisons between TRMM and GPM Level-3 Products over a Midlatitude Basin: Is Day-1 IMERG a Good Successor for TMPA 3B42V7? *Journal of Hydrometeorology*, 17, 1, 2016. Doi: <https://doi.org/10.1175/JHM-D-15-0059.1>

Tang, X.; Zhang, J.; Gao, C.; Ruben, G. B.; Wang, G. Assessing the Uncertainties of Four Precipitation Products for Swat Modeling in Mekong River Basin. *Remote Sensing*, 11, 304, 2019. Doi: <https://doi.org/10.3390/rs11030304>

Távora, B.E. Zona Ripária de Cerrado: Processos Hidrossedimentológicos. Tese de Doutorado em Tecnologia Ambiental e Recursos Hídricos, Publicação PTARH.TD019/2017, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 133p. 2017.

Triana, J. S. A.; Chu, M. L.; Guzman, J. A.; Moriasi, D. N. Steiner, J. L. Evaluating the Risks of Groundwater Extraction in an Agricultural Landscape under Different Climate Projections. *Water*, 12, 400, 2020. Doi: <https://doi.org/10.3390/w12020400>

Tucci, C.E.M. Modelos hidrológicos, Ed. Universidade/UFRGS/Associação Brasileira de Recursos Hídricos, Porto Alegre, 668p, 1998.

van Griensven, A.; Bauwens, W. Multiobjective autocalibration for semidistributed water quality models. *Water Resources Research*, 39, 12, 2003. Doi: <https://doi.org/10.1029/2003WR002284>

van Griensven, A.; Meixner, T.; Grunwald, S.; Bishop, T.; Diluzio, M.; Srinivasan, R. A global sensitivity analysis tool for the parameters of multi-variable catchment models. *Journal of Hydrology*, 324, 1, 10–23, 2006. Doi: <https://doi.org/10.1016/j.jhydrol.2005.09.008>

Ushio, T.; Sasashige, K.; Kubota, T.; Shige, S.; Okamoto, K.; Aonashi, K.; Inoue, T.; Takahashi, N.; Iguchi, T.; Kachi, M.; Oki, R.; Morimoto, T.; Kawasaki, Z.-I. A Kalman Filter Approach to the Global Satellite Mapping of Precipitation (GSMaP) from Combined Passive Microwave and Infrared Radiometric Data. *Journal of the Meteorological Society of Japan*, 87, 137–151, 2009. Doi: <https://doi.org/10.2151/jmsj.87A.137>

Wang, Z.; Zhong, R.; Lai, C.; Chen, J. Evaluation of the GPM IMERG satellite-based precipitation products and the hydrological utility. *Atmospheric Research* 196, 2017, 151–163. Doi: <http://dx.doi.org/10.1016/j.atmosres.2017.06.020>

Xavier, A. C.; King, C. W.; Scanlon, B. R. Daily gridded meteorological variables in Brazil (1980–2013). *International Journal of Climatology*, 36, 2016, 2644–2659. Doi: <https://doi.org/10.1002/joc.4518>

Yapo, P.O.; Gupta, H.V.; Sorooshian, S. Automatic calibration of conceptual rainfall-runoff models: sensitivity to calibration data. *Journal of Hydrology*, v. 181, p. 23–48, 1996.

Yuan, F.; Zhang, L.; Soe, K. M. W.; Ren, L.; Zhao, C.; Zhu, Y.; Jiang, S.; Liu, Y. Applications of TRMM- and GPM-Era Multiple-Satellite Precipitation Products for Flood Simulations at Sub-Daily Scales in a Sparsely Gauged Watershed in Myanmar. *Remote Sensing*, 11, 2019, 140. Doi: <https://doi.org/10.3390/rs11020140>

Zhang, Z.; Tian, J.; Huang, Y.; Chen, X.; Chen, S.; Duan, Z. Hydrologic Evaluation of TRMM and GPM IMERG Satellite-Based Precipitation in a Humid Basin of China. *Remote Sensing*, 11, 2019, 431; Doi: <https://doi.org/10.3390/rs11040431>

CAPÍTULO 5

1. Considerações finais

A gestão dos recursos hídricos, em muitas regiões do Brasil e no mundo, carece de séries históricas consistentes de dados hidrológicos, assim como apresenta problemas na parametrização de modelos, na representação de processos hidrológicos e no monitoramento das variáveis hidrológicas. Nesse cenário, o objetivo desta tese de doutorado foi contribuir com o monitoramento ambiental e com a simulação de processos hidrológicos em regiões tropicais, visando à melhoria no diagnóstico e prognóstico da P, da ET_r, e da Q em bacias hidrográficas. Como hipótese norteadora para a pesquisa, foi definido que a determinação da dinâmica espacial e temporal da ET e da P por sensoriamento remoto melhora o monitoramento ambiental assim como o processo de simulação de modelos chuva-vazão na gestão de recursos hídricos em bacias hidrográficas. Essa hipótese foi confirmada por meio dos resultados apresentados nos artigos científicos constantes nos três capítulos anteriores. Além disso, os resultados apresentados nos documentos anexos também estão no contexto geral desta tese e demonstram como o uso de técnicas de análise espacial e sensoriamento remoto pode melhorar o monitoramento ambiental e a simulação de processos hidrológicos em regiões tropicais.

As principais conclusões obtidas são listadas a seguir:

- 1) Em relação ao uso de séries temporais de produtos globais de P obtidos por sensoriamento remoto, que foram analisados no contexto dessa pesquisa para o monitoramento ambiental dessa variável hidrológica, tem-se que:
 - a) A nova geração de produtos de P por sensoriamento remoto obtidos a partir de dados da GPM (IMERG e GSMAp) é capaz de garantir a continuidade no monitoramento de P no Brasil central de forma semelhante ou até mesmo melhor do que o obtido anteriormente com produtos da geração TRMM. Apesar das diferenças observadas entre o IMERG e o GSMAp, os resultados indicam melhorias na detecção de eventos de P, assim como na determinação de sua magnitude, entre os produtos obtidos nas gerações TRMM e GPM.
 - b) O IMERG apresentou os melhores resultados em quase todos os cenários avaliados na escala de tempo mensal e anual, assim como na avaliação feita por estação chuvosa e seca, enquanto o GSMAp subestimou P_{obs} nesses cenários. Considerando a escala de tempo diária, todos os produtos de P_{sr} tiveram um bom desempenho na detecção de eventos de P, porém tiveram problemas em quantificar a P ocorrida. Nesse caso, o GSMAp obteve os melhores resultados.

- c) A qualidade dos produtos de P_{sr} avaliados variou de acordo com as estações seca e chuvosa observada na área de estudo, sendo que os melhores resultados foram obtidos no período chuvoso. Mesmo com melhor resolução espacial, os produtos da geração GPM apresentam dificuldades de estimar a P no período seco, quando os eventos chuvosos são menos frequentes, com menos volume e mais esparsos pelo território. O GSMAp apresentou melhor capacidade para o monitoramento da P ao longo da estação seca.
- d) Os produtos de P_{sr} avaliados no presente estudo se mostraram ser uma importante fonte de dados para gestão dos recursos hídricos, uma vez que disponibilizam séries temporais de P em todo o território brasileiro, em muitos locais que carecem de dados hidrológicos. Apesar do potencial em fornecer dados de P em áreas continentais, o uso de dados de P_{sr} não substitui a rede de pluviômetros, de modo que ambos devem ser utilizados concomitantemente visando otimização dos recursos existentes.

2) Já em relação ao uso de séries temporais de ET_r obtidas por sensoriamento remoto e que foram avaliadas no contexto dessa pesquisa para o monitoramento ambiental dessa variável hidrológica em diferentes usos do solo, tem-se que:

- a) O modelo SSEBop conseguiu estimar ET_r utilizando imagens Landsat de forma satisfatória em áreas de pastagem, reflorestamento e com vegetação nativa. A vegetação nativa apresentou os maiores níveis de ET_r no período avaliado seguido pela área com reflorestamento e depois pela pastagem. Esse resultado amplia o número de classes de cobertura/uso do solo nas quais o modelo SSEBop pode ser utilizado para o monitoramento de ET_r em áreas do bioma Cerrado.
- b) A ET_r estimada pelo modelo SSEBop nas áreas de vegetação nativa e reflorestamento apresentaram relações com a variação da água disponível no solo ao longo de todo o perfil avaliado (até 3.0m), enquanto a área de pastagem apresentou relações significativas apenas com variação da água disponível no solo na superfície (até 1.0m). O teor de umidade reduziu significativamente nas camadas superficiais chegando ao ponto de murcha permanente estabelecido para o solo tanto na área com pastagem quanto na área com reflorestamento.
- c) Apesar da área com vegetação nativa ter apresentado maiores taxas de ET_r ao longo da seca, o seu impacto na variação da água disponível no solo na camada superficial foi menor do que o observado na área de pastagem e de reflorestamento.
- d) Considerando o período de seca, na qual há maior interesse na quantificação do uso consumutivo da água, o monitoramento da ET_r com o modelo SSEBop mostrou-se viável

em diferentes usos do solo na escala temporal de 8 em 8 dias, utilizando dados LandSat 7 e 8.

- e) A ET_r por sensoriamento remoto pode ser validada utilizando a ET de cultura (ET_c), a qual é derivada a partir do teor de umidade do solo. A ET_c é um método mais acessível economicamente para ser aplicado em múltiplos usos do solo em comparação com lisímetros e sistemas que medem o balanço de energia e fluxos de calor latente (*Eddy-Covariance* e Razão de Bowen). No entanto, o uso da ET_c para validação de dados de ET_r por sensoriamento remoto deve ser feito com cautela, avaliando-se a ET_c simulada em diferentes profundidades para se determinar quais são as camadas do solo que realmente estão influenciando a ET_r estimada por sensoriamento remoto.
- f) Além de ser uma importante ferramenta de monitoramento da ET_r em um contexto local avaliado em imagens Landsat em áreas de vegetação nativa, reflorestamento, pastagem e áreas irrigadas, o modelo SSEBop também se mostrou útil para ser utilizado em um contexto regional, na escala de bacia hidrográfica em diferentes regiões brasileiras (ANEXO I).

3) Por fim, em relação ao uso de séries temporais de ET_r e P obtidas por sensoriamento remoto em modelo hidrológico para simulação de Q e ET_r que foram analisados no contexto dessa pesquisa, tem-se que:

- a) De modo geral, os produtos de P e ET_r utilizados em conjunto com o modelo hidrológico foram capazes de fornecer dados que contribuíram com a simulação de Q e ET_r na BHRQ. No entanto, os resultados não foram satisfatórios em todos os cenários avaliados de modo que qualquer generalização deve ser evitada.
- b) A simulação de Q_{dia} com os dados de P_{sr} e com dados de P_{obs} não atingiram os critérios de qualidade estabelecidos em todas as sub-bacias avaliadas. Apesar disso, os resultados das simulações de Q_{dia} com P_{obs} foi melhor do que o obtido com P_{sr} na maior parte dos casos. As sub-bacias onde estão os pluviômetros apresentaram as melhores simulações de Q_{dia} com P_{obs}. Em relação às simulações de Q_{dia} com P_{sr}, o IMERG superou o TMPA e o GSMAp na maior parte dos cenários avaliados.
- c) A simulação de Q_{mês} com os dados de P_{sr} e com dados de P_{obs} atingiram os critérios de qualidade estabelecidos em todas as sub-bacias avaliadas. As simulações de Q_{mês} com o IMERG foram melhores do que o obtido com o GSMAp em ambas as resoluções espaciais avaliadas (0,1° e 0,25°). Além disso, as simulações de Q_{mês} com o IMERG – 0,25° superaram os resultados obtidos com o TMPA na maior parte dos cenários avaliados. Em

alguns cenários, as simulações de $Q_{mês}$ com dados do IMERG e do TMPA superaram os resultados obtidos com P_{obs} , demonstrando o bom potencial do uso desses dados na simulação hidrológica nessa escala temporal.

- d) A nova geração de produtos de P_{sr} obtidos a partir de dados da missão GPM (IMERG e GSMAp) foi capaz de garantir a continuidade no fornecimento de dados de P para simulação de Q com modelo hidrológico no Brasil central de forma semelhante ou até mesmo melhor do que o obtido anteriormente com produtos da geração TRMM. Além disso, os resultados das simulações que utilizaram dados de P_{sr} foram compatíveis com os obtidos nas simulações que utilizaram P_{obs} . De modo geral, o IMERG – 0,25° apresentou melhores resultados nas simulações de Q_{dia} e $Q_{mês}$ do que os observados com o TMPA. No entanto, os resultados com o TMPA foram melhores do que os observados com o GSMAp – 0,25°.
- e) A calibração dos parâmetros para a simulação de Q e ET_r ao mesmo tempo apresentou níveis de incertezas semelhantes ao cenário no qual Q e ET_r foram calibradas individualmente. Além disso, a qualidade das simulações também foi semelhante ao observado quando Q e ET_r foram calibradas individualmente. No entanto, o fato de ter duas variáveis hidrológicas sendo simuladas conforme o padrão estabelecido possibilita melhor representação do ciclo hidrológico pelo modelo chuva-vazão.
- f) Os produtos de P_{sr} e ET_r avaliados no presente estudo se mostraram ser uma importante fonte de dados para gestão dos recursos hídricos, uma vez que disponibilizam séries temporais de P e ET_r em todo o território brasileiro, em muitos locais que carecem de dados hidrológicos. Apesar do potencial em fornecer dados de P em áreas continentais, o uso de dados de P_{sr} não substitui a rede de pluviômetros, de modo que ambos devem ser utilizados concomitantemente visando otimização dos recursos existentes.

2. Próximos passos

Essa pesquisa buscou avaliar e contribuir com o uso de análise espacial e sensoriamento remoto na determinação de processos hidrológicos. Considerando os resultados obtidos nesta tese, existem diferentes caminhos que podem ser trilhados no futuro. Nesse contexto, sugere-se:

- Avaliar outros produtos de P_{sr} como o *Climate Prediction Center Morphing Technique* (CMORPH), *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks* (PERSIANN), *Climate Hazards group Infrared Precipitation with Stations* (CHIRPS) e o *Multi-Source Weighted-Ensemble Precipitation* (MSWEP) tanto em relação à detecção de eventos de P, assim como na determinação de sua magnitude. Além disso, esses produtos de P_{sr} também podem ser avaliados em conjunto com o modelo SWAT. Vale mencionar que o CHIRPS e MSWEP possuem séries temporais de dados de P_{sr} com mais de 30 anos de dados.
- Integrar o uso de dados de ET_r do modelo SSEBop obtidas a partir de imagens Landsat com o modelo SWAT. Com isso, a ET_r poderá ser avaliada ao nível de unidades hidrológicas (HRU) do modelo SWAT, o que certamente irá contribuir significativamente na simulação hidrológica, uma vez que será possível avaliar a ET_r simulada pelo modelo nos diferentes usos do solo. Além disso, essa integração também irá permitir avaliar as simulações de irrigação que são feitas pelo modelo SWAT.
- A realização de estudos utilizando sistemas aéros não tripulados para simular a ET_r , tendo em vista a crescente disponibilidade de drones e sensores que podem ser aerotransportados. Vale mencionar que, ao longo do curso de doutorado, foram obtidos resultados promissores no uso do modelo SSEBop a partir de dados coletados por drones no âmbito de projeto de pesquisa financiado pela Fundação de Apoio à Pesquisa do Distrito Federal (FAP/DF). Desse modo, sugere-se o prosseguimento de pesquisas nesse tema.

ANEXO I

Trabalho apresentado na sessão de posters da *American Geophysical Union (AGU) 2018 Fall Meeting*.


UnB

Remote sensing based estimation of actual Evapotranspiration time series for rainfall-runoff modeling at an agricultural river basin of the Brazilian Central Plateau region.



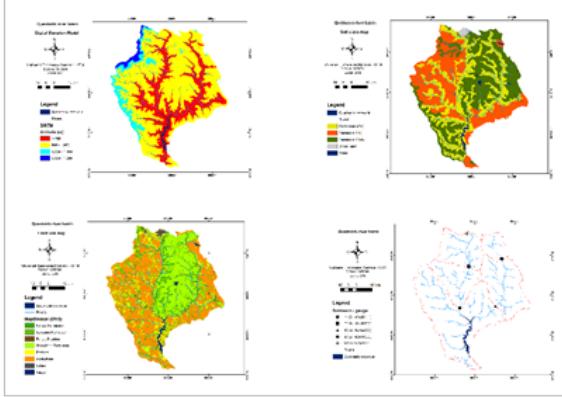
Leandro de Almeida Salles¹, Gabriel B. Senay², Dennis S. Ojima³, Henrique Roig¹, Édio A. Malta¹, Luciano C. Conti¹, Marina R. B. Neumann⁴, Lineu N. Rodrigues⁵, Juliana D. L. Galvão⁶ and Morris Scherer-Warren⁶
(1) University of Brasília, Institute of Geoscience, Brasília, Brazil, (2) U.S. Geological Survey Earth Resources Observation and Science, EROS/ North Central Climate Science Center, Fort Collins, CO, United States, (3) Colorado State University, Natural Resource Ecology Laboratory, Fort Collins, CO, United States, (4) University of Brasília, Faculty of Agronomy and Veterinary Medicine, Brasília, Brazil, (5) Embrapa Cerrados, Planaltina, Brazil, (6) Agência Nacional de Águas - ANA, Brasília, Brazil

INTRODUCTION

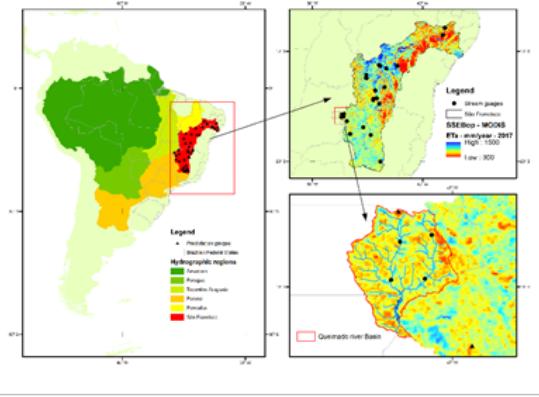
This study aims to assess the application of an Actual Evapotranspiration – ET_a time series, estimated from remote sensing dataset, with rainfall-runoff modeling for water production at an agricultural river basin of the Brazilian Central Plateau region.

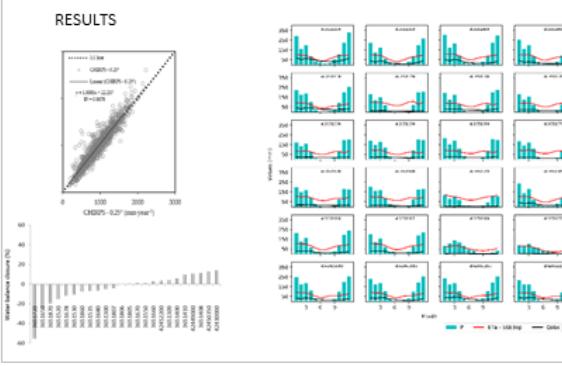
OBJECTIVES

To achieve this goal, the study used an ET_a time series, using the Operational Simplified Surface Energy Balance - SSEBop (Senay *et al.*, 2013), to apply with stream flow simulations from the Soil and Water Assessment Tool – SWAT (Arnold *et al.*, 1998), at the Queimado river basin – QRB.

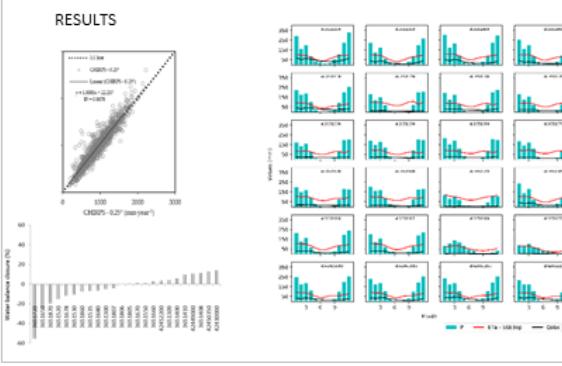


MATERIAL AND METHODS





RESULTS



CONCLUSIONS

- Remote sensing dataset managed to capture the spatial variability of the annual water budget within the studied area.
- SWAT can reach acceptable calibration results without necessarily having good results for ET_a.
- SSEBop demonstrates potential to improve rainfall-runoff modeling with SWAT model by reducing uncertainties provided from ET_a estimation.

NEXT STEPS

Further investigations are still recommended to better comprehend the use of ET_a time series remote sensing datasets along with calibration tools for rainfall run-off modeling in Central Brazil's watersheds.

ACKNOWLEDGMENTS

We thank IBRAM-DF and CAPES for supporting this project (Bolsista da CAPES, Programa de Doutorado Sanduíche no exterior, Process n° 88881.187622/2018-01).

REFERENCES

Arnold, J. G. *et al.* Large area hydrologic modeling and assessment part I: model development. *Journal of the American Water Resources Association*, v. 34, n. 1, p. 73–89, 1998.
 Senay, G. B. *et al.* Operational Evapotranspiration Mapping Using Remote Sensing and Weather Datasets: A New Parameterization for the SSEB Approach. *Journal of the American Water Resources Association*, v. 49, n. 3, p. 577–591, 2013.

ANEXO II

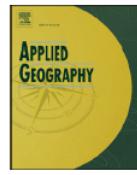
Applied Geography, 2018, 94, 272-281; doi: 10.1016/j.apgeog.2018.02.007

Applied Geography 94 (2018) 272–281



Contents lists available at ScienceDirect

Applied Geography
journal homepage: www.elsevier.com/locate/apgeog



Environmental factors and groundwater behavior in an agricultural experimental basin of the Brazilian central plateau



Leandro de Almeida Salles^{a,c,*}, Jorge Enoch Furquim Werneck Lima^b, Henrique Llacer Roig^c, Juaci Vitória Malaquias^b

^a Instituto Brasília Ambiental – IBRAM, SEPN 511 – Bloco C – Edifício Bittar, CEP: 70.750-543, Brasília – DF, Brazil

^b Empresa Brasileira de Pesquisa Agropecuária, Centro de Pesquisa Agropecuária dos Cerrados – EMBRAPA/CPAC, BR 020, Km 18, Caixa 08223, Brazil

^c Instituto de Geociências, Universidade de Brasília, Campus Universitário Darcy Ribeiro, Asa Norte, CEP: 70910-900, Brasília, DF, Brazil

ARTICLE INFO

Keywords:
Geostatistics
Statistical modeling
Groundwater recharge/water budget
Geographic information system

ABSTRACT

Knowledge of groundwater storage in tropical soils of the Cerrado biome is relevant because of its importance for stream flow regime in Brazil's central plateau, where rivers are perennial during the drought period of the year. The purpose of this study was to: (i) identify environmental variables capable of explaining the amplitude of groundwater variation in points of an agricultural basin in the Cerrado; and (ii) develop a statistical model to simulate the amplitude of water table variation from the chosen variables. The study was developed with monthly data obtained from 35 piezometric wells located at the Upper Jardim experimental river basin (105 km²), collected between 17/02/2004 and 01/10/2012. Two multivariate analysis methodologies were used: (i) Ordinary Least Squares regression (OLS); and (ii) Geographical Weighted Regression (GWR). Groundwater amplitude in the studied period was correlated with independent variables related to soil's physical properties and related to the basin's geomorphology, where six explanatory variables were selected to compose the statistical model. The results indicate that both OLS and GWR methodologies were capable of establishing correlations between the response and the explanatory variables. However, GWR managed to capture local correlations between the explanatory and the dependent variable that were not obtained by the OLS. Despite the complexity of groundwater behavior in tropical soils, this study demonstrates the possibility to estimate with data collected near the surface, how much water is stored in porous aquifers and groundwater behavior in soils of the Brazilian central plateau, being of great use to unmonitored river basins.

1. Introduction

Knowledge of flow and water storage in tropical soils of the Cerrado biome is relevant because of the importance of these hydrological processes for the stream flow regime in this biome. The fact that many rivers in the region are perennial, even with seasonal fluctuations of rainfall throughout the year, where 80% of the precipitation occurs from October to April (Brasil, 1984), corroborates this assertion. According to Lima (2010), based on data collected from small experimental watersheds in the Cerrado biome, base flow represents 90% of streamflow, with the other 10% resulting from runoff generated by some rain events.

Monitoring soil's hydrological processes is not a trivial activity, demanding infrastructure and equipment which, added to the large spatial variability of environment and phenomena, end up discouraging such efforts. In this context, experimental basins are an important

option to collect data and produce knowledge on these hydrological processes and their relationship with the environment. Hydrological models are presented as important assessment tools to help comprehend these complex systems and to simulate these processes, from collected data and information that are easier to obtain.

Several studies have looked for relationships between environmental features that are easy to obtain and groundwater hydrological processes occurring in tropical soils (Campos & Freitas-Silva, 1998; Lousada & Campos, 2005; Almeida, Resende, Rodrigues, & Campos, 2006; Fiori, Campos, & Almeida, 2010; Lima, 2010; Lima, Silva, Strauch, & Lorz, 2013; Gonçalves, Lohe, & Campos, 2015). Different hydrological models have been used in the Cerrado biome to simulate soil water behavior such as Feflow (Lima, 2010), Modflow (Santos, 2012) and SWAT (Minoti, Silva, Lombardi Neto, Koide, & Crestana, 2011; Salles, 2012; Strauch et al., 2012, 2013).

Methodologies of multivariate analysis are also applied in water

* Corresponding author. Instituto Brasília Ambiental – IBRAM, SEPN 511 – Bloco C – Edifício Bittar, CEP: 70.750-543, Brasília – DF, Brazil.
E-mail addresses: leandro.almeida.salles@gmail.com (L.d.A. Salles), jorge.werneck-lima@embrapa.br (J.E.F.W. Lima), roig@unb.br (H.L. Roig), juaci.malaquias@embrapa.br (J.V. Malaquias).

resources management. These methods can be grouped into three classes: Classification, Summarization and spatial relationships analysis (Bierman, Lewis, Ostendorf, & Tanner, 2011). Some of these techniques do not take into account the location of sampling points or the existence of spatial relationships between the measured data, for example, discriminant analysis and principal components analysis, while others seek to understand if spatial relation is significant, such as Geographic Weighting Regression, GWR (Bierman et al., 2011).

GWR has also been used in different types of studies, such as: epidemiology (Gilbert & Chakraborty, 2011; Leyk, Norlund, & Nuckols, 2012); remote sensing (Erdogan, 2010; Bayramov, Buchroithner, & McGurty, 2012; Gao, Huang, Li, & Li, 2012); economy (Himmelberger, Pearsall, & Rakshit, 2009; Breetzke, 2012 ; Deller, 2011; Grubacic, Mack, & Kaylen, 2012); forestry (Kupfer & Farris, 2007); transport (Blainey, 2010; Ibeas, Cordera, Dell'Ollo, & Moura, 2011); and water quality (Mills et al., 2009; Wu & Driscoll, 2009; Harris & Brundson, 2010).

Given the importance of studying flow and water storage in tropical soils of the Cerrado biome and the difficulty to collect data capable of representing groundwater's spatial and temporal variation, in order to identify how much water is stored in porous aquifers, this study looked for relationships between the Upper Jardim experimental river basin's geomorphology and soil's physical properties, with the amplitude of groundwater's variation in the basin, using spatial statistics and geo-processing methodologies.

2. Materials and methods

2.1. Study area

The Upper Jardim experimental river basin is located in the eastern region of the Federal District, between 15.71° and 15.86° S latitudes and 47.55° and 47.64° W longitudes (Fig. 1), in the center of Brazil. The basin has approximately 105 km² drainage area, and can be divided into two sub-basins: the Estanislau's and the Jardim's river basin, with 50 and 55 km², respectively (Lima, 2010). The Jardim's river is a tributary of the Preto's river, which is part of the Paracatu's watershed, an important contributor to the left side of the São Francisco river basin.

The climate in the Upper Jardim river basin has seasonality pattern in rainfall distribution, with two seasons well defined: dry winter, between April and October; and rainy summer in the remaining months of the year, with average annual rainfall ranging from 1,000 mm to 1,700 mm, and more than 80% of the precipitation occurring during this period. According to the classification proposed by Koppen, the prevailing climate in the region is Tropical Savanna (Brasil, 1984).

The Upper Jardim river basin is located in Brasília's rural area. Therefore, agriculture is the principal land use (76.4%), followed by native vegetation (22.4%), which is divided in cerrado savannah (14.9%), and Gallery or Riparian forest (7.5%). The other 1.2% area is occupied by buildings, reservoirs and bare soil (Lima et al., 2007). Crops (soy, beans, cotton, corn and sorghum), citrus, coffee, manioc, vegetables, poultry, pigs and cattle are the main agricultural activities developed in the basin (Lima, 2010). Comparing satellite images from the past 20 years, it is possible to notice that land use has not changed significantly.

According to the semi-detailed survey at 1:50,000 scale produced by Reatto et al. (2000) the soils in the Upper Jardim river basin (Fig. 1) are classified as: Latosol (76.38%); Cambisol (16.68%); Plinthosol (2.54%); Gleysol (2.41%); and Quartzarenic Neosol (2.09%). These soil classes correspond, respectively, to Ferralsols, Cambisols, Plinthosols, Gleysols and Arenosols using the World Reference Base (WRB) for Soil Resources (Food and Agriculture Organisation, 2015). In addition to these types of soils, there are also outcropping rocks (0.24%).

2.2. Ordinary Least Squares regression – OLS

The general model for Ordinary Least Squares, OLS, can be expressed by the following equation:

$$Y_i = \beta_0 + \sum_k \beta_k X_{ik} + \varepsilon_i \quad (1)$$

where Y_i is the value of the dependent variable Y at point i (response variable), β_0 is the point that the regression line intercepts the y -axis, β_k is the slope coefficient of the k^{th} independent variable, X_{ik} is the value of k^{th} independent variable at point i (explanatory variable), and ε_i is the independent random error at point i , with normal distribution, $N(0, \sigma^2)$.

Stepwise regression technique, with backward direction and based on the Akaike information criterion (AIC), was conducted to support the model's selection. The stepwise regression analysis is available in the R-Commander package (Fox, 2005). A final model was selected after evaluating the significance level of each estimated coefficient, and removing those with values above the established criteria (p -value ≤ 0.05).

An important part of the OLS methodology is the residual analysis. This assessment is relevant to evaluate if the linear model's assumptions are been achieved (Souza, 1998). The Residual analysis was conducted with the following procedures which are suggested on the literature (Souza, 1998; Erdogan, 2010; Cardozo, García-Palomares, & Gutiérrez, 2012): F-test to assess the significance of the model; Koenker's studentized Breusch-Pagan statistic, to evaluate the model stationarity; Bonferroni test for outliers analysis; Shapiro-Wilks and Jarque-Bera test to assess the residuals normality; Global Moran's I statistic for auto-correlation analysis. The Variance Inflator Factor, VIF, was also evaluated for each explanatory variable in the selected model.

2.3. Geographically Weighted regression – GWR

Geographically weighted regression, GWR, was conducted to include spatial variability of the variables in the selected statistic model used to correlate environmental factors with the amplitude of water table variation in the Upper Jardim river basin. The general model for GWR can be expressed by the following equation:

$$Y_i = \beta_0(u_i, v_i) + \sum_k \beta_k(u_i, v_i)X_{ik} + \varepsilon_i \quad (2)$$

where (u_i, v_i) is the coordinate of the i^{th} point in space and $\beta_k(u_i, v_i)$ is a realization of the continuous function $\beta_k(u, v)$ at the point i , and ε_i is the independent random error at the point i with normal distribution, $N(0, \sigma^2)$ (Fotheringham, Brunsdon, & Charlton, 2002). It is possible to notice that Equation (2) is a special case of Equation (1), where the parameters do not vary in space (Fotheringham et al., 2002).

The regression's parameters, for each observed point i , can be calculated with the following matrix equation:

$$\hat{\beta}(u_i, v_i) = (X^T W(u_i, v_i) X)^{-1} X^T W(u_i, v_i) Y \quad (3)$$

where $\hat{\beta}$ is the estimate of β , and $W(u_i, v_i)$ is a n by n matrix that the diagonal elements, w_{ii} , are spatial weights for each of the n observed data for regression point i , and the remaining elements of the matrix are zero. Equation (3) resembles OLS estimator with the difference that the GWR has weights which vary according to point i location, while OLS have constant weights (Fotheringham et al., 2002).

This study used the bi-square spatial weighting function with an adaptive spatial kernel. The weights are calculated as follow:

$$w_{ij} = \left\{ 1 - \left(\frac{d_{ij}}{b} \right)^2 \right\}^2 \quad \text{if } d_{ij} < b \quad (4)$$

$$w_{ij} = 0 \quad \text{if } d_{ij} \geq b \quad (5)$$

where i is the point where the regression parameter is been estimated, j

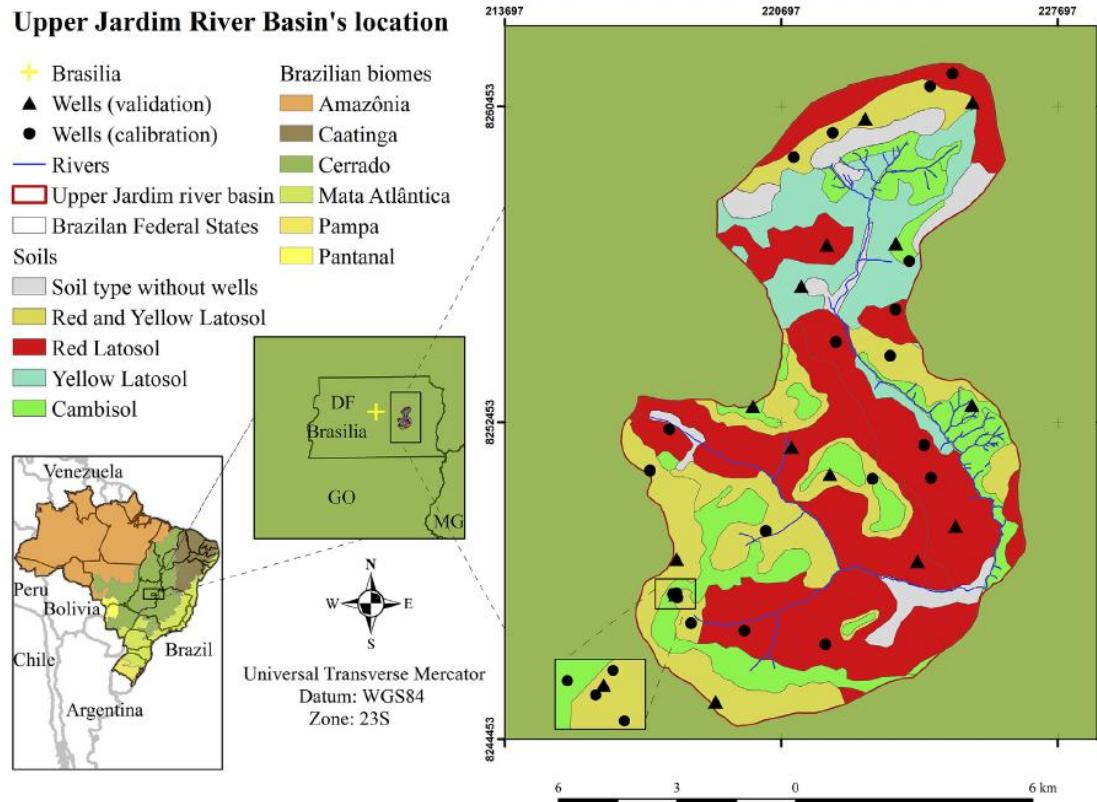


Fig. 1. Location of the 35 piezometric wells used in the development of the study on the Upper Jardim experimental River Basin.

represents a specific point in space where the assessed neighbor to point i is located, d_{ij} is the distance between i and j , w_{ij} is the spatial weight, and b is the bandwidth of the spatial kernel used to search neighbors to point i according to a predefined criteria. It was established an inclusion criteria between 10 and 45% of the n observed neighbors to each regression point (i^{th}) for adaptive spatial kernel's bandwidth. As calibration criterion for the bi-squared weighting function, it was used the minimization of "corrected" Akaike Information Criterion (AICc).

The explanatory variables' estimated coefficients, the local R^2 , and the response variable (registered at piezometric wells and estimated with GWR) were interpolated using Inverse Distance Weighted – IDW algorithm from ArcGIS 10.1, with quadratic power to assess the spatial variability of results. This study used the R statistical computing language and environment (R Development core team., 2012) with the R-Commander package (Fox, 2005). The GWR spatial analysis was made using Spatial Analysis in Macroecology – SAM (Rangel, Diniz-Filho, & Bini, 2010) software.

2.4. Groundwater data

The dependent variable (response variable) used in this study was the amplitude of the water table variation between 17/02/2004 and 01/10/2012, as illustrated in Fig. 2. Data was measured monthly during this period in 35 piezometric wells distributed inside the upper Jardim river basin (Fig. 1). The wells were installed in the following soil classes: Red Latosol (34.29%), Yellow Latosol (2.86%), Red-Yellow Latosol (45.71%) and Cambisol (17.14%).

The hydrological behavior of groundwater in the monitored area is not homogeneous, as illustrated in Fig. 3. The amplitude values of the water table observed in the piezometric wells ranged between 1.85 m

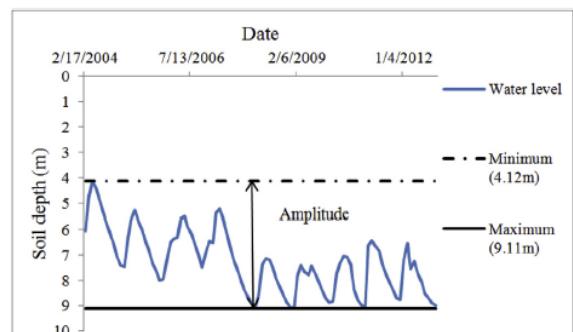


Fig. 2. Illustration of the maximum amplitude of groundwater variation, between 17/02/2004 and 01/10/2012.

and 8.49 m, in the studied period.

Part of the data was randomly selected and used to build the global linear model, to perform the OLS and the GWR, while the other part was used to validate the selected OLS model. Fig. 1 shows the spatial distribution of the 35 piezometric wells used in the analysis, where twenty-one were used to build the OLS and GWR models, and fourteen wells were used to validate the results.

2.5. Environmental variables

Initially, there were available 11 types of independent variables related to soils physical properties, collected up to three different soil

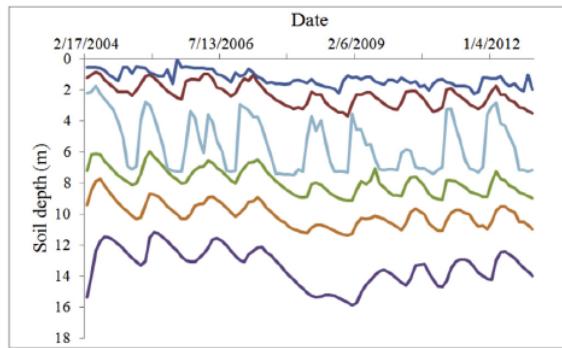


Fig. 3. Illustration of the groundwater behavior observed at the Upper Jardim river basin, between 17/02/2004 and 01/10/2012.

layers, and five independent geomorphology variables: Soil water capacity – CAD ($\text{mm} \cdot \text{mm}^{-1}$); silt – S (%); Clay – A (%); Thin sand – AF (%); Coarse sand – AG (%); Organic matter – TMO (%); Saturated hydraulic conductivity – Ks ($\text{m} \cdot \text{s}^{-1}$); Density of soil particles – dp ($\text{g} \cdot \text{m}^{-3}$); Bulk density – Ds ($\text{g} \cdot \text{m}^{-3}$); Soil porosity – Po ($\text{cm}^3 \cdot \text{cm}^{-3}$); Soil moisture – UmS ($\text{g} \cdot \text{g}^{-1}$); Altitude – Alt (m); Minimum distance to drainage network – Md (m); Distance to the basin's exutory – DBE (m); Direction of the steepest downhill slope – Ov('); and Slope – SLP (%). The soils physical properties were collected by Lima (2010) in the same location where the piezometric wells were installed. Some of the variables were collected at different depths (surface; 15 cm and 60 cm), representing different soil layers in the same location.

The independent variables related to the river basin's geomorphology were taken from a Digital Terrain Model, DTM, with a 5 m spatial resolution, generated from contour lines, elevation points and drainage network, present in the Federal District's Cartographic System (Brasil, 1992), with the *Topo to Raster* algorithm available in ArcGIS 10.1.

The Correlation Coefficient – CC was calculated to assess representative explanatory variables to do the stepwise regression analysis. The CC is calculated as follow:

$$\text{CC} = \frac{\sum_{i=1}^N (V1_i - V1_{\text{av}})(V2_i - V2_{\text{av}})}{\sqrt{\sum_{i=1}^N (V1_i - V1_{\text{av}})^2} \sqrt{\sum_{i=1}^N (V2_i - V2_{\text{av}})^2}}$$

where N is the number of piezometric wells been evaluated (Fig. 1), $V1_i$ and $V2_i$ are the two variables been assessed at the i^{th} piezometric well, and $V1_{\text{av}}$ and $V2_{\text{av}}$ are the average values of each assessed variable.

3. Results

3.1. Selection of the explanatory variables for the stepwise regression

Table 1 present's the CC results between the groundwater response variable (Fig. 2) and the explanatory variables. Correlations ranged from 0.54 to –0.59. The highest positive CC were obtained with Po60 cm (0.54), dp60 cm (0.50), S60 cm (0.39), dp0cm (0.39), and Ks60 cm (0.27) while the highest negative correlations were obtained with Alt (–0.59), DBE (–0.57), Ks15 cm (–0.46), Ds60 cm (–0.34) and A60 cm (–0.27). This analysis helped to select 12 explanatory variables for the stepwise regression, where eleven are related to soil's physical properties and one to geomorphology.

Soil's saturated hydraulic conductivity (Ks) presented CC equal to –0.46 (ks15 cm) and 0.27 (ks60 cm), and data from both soil layers were selected for the stepwise regression analysis. Soil's saturated hydraulic conductivity is a relevant variable for groundwater management (Campos, 2004) and has been used previously for assessment of porous aquifers characteristics in the Cerrado biome (e.g. Campos,

Table 1
CC results between the groundwater response variable and the available explanatory variables.

Explanatory variable	ID	Surface layer	15 cm soil layer	60 cm soil layer
Soil water capacity ($\text{mm} \cdot \text{mm}^{-1}$)	CAD	–	–0.02	–0.04
Silt (%)	S	0.23	0.43	0.39 ^a
Clay (%)	A	–0.09	–0.27	–0.27 ^a
Thin sand (%)	AF	–0.08	–0.10	–0.03
Coarse sand (%)	AG	–0.30	–0.11	–0.06
Organic matter (%)	TMO	–0.21 ^a	0.09	0.12
Soil's saturated hydraulic conductivity ($\text{m} \cdot \text{s}^{-1}$)	Ks	–	–0.46 ^a	0.27 ^a
Density of soil particles ($\text{g} \cdot \text{m}^{-3}$)	dp	0.39 ^a	0.13	0.50 ^a
Bulk density ($\text{g} \cdot \text{m}^{-3}$)	Ds	0.19 ^a	0.08	–0.34 ^a
Soil porosity ($\text{cm}^3 \cdot \text{cm}^{-3}$)	Po	–	–0.01	0.54 ^a
Soil moisture ($\text{g} \cdot \text{g}^{-1}$)	UmS	–	0.20 ^a	0.02
Altitude (m)	Alt	–0.59	–	–
Minimum distance to drainage network (m)	Md	0.04	–	–
Distance to the basin's exutory (m)	DBE	–0.57 ^a	–	–
Direction of the steepest downhill slope (°)	Ov	0.09	–	–
Slope (%)	SLP	–0.09	–	–

^a Selected for stepwise regression analysis.

2004; Campos, Monteiro, & Rodrigues, 2006; Gonçalves et al., 2015).

Bulk density and soil's Porosity are important variables used to assess the impacts of agriculture on soil's physical proprieties. At the surface layers, bulk density and soil's porosity are sensitive to land use and soil's management (Figueiredo, Ramos, & Tostes, 2008; Lisboa, Donegemma, Burak, Passos, & Mendonça, 2016; Souza, Carneiro, & Paulino, 2005). Despite the effects caused by agricultural use at the surface layers, bulk density can remain constant in deeper layers (Souza et al. 2005). Bulk density (Ds) presented CC equal to: 0.19 (Ds0cm); 0.08 (Ds15 cm); –0.34(Ds60 cm). Data from the surface and the 60 cm soil layer were selected for the stepwise regression, since the 15 cm soil layer presented lower CC. Concerning soil's porosity (Po), data from the 60 cm layer was selected for the stepwise regression because it presented CC equal to 0.54, while the CC results at the 15 cm soil layer was very low (0.01).

Although soil quality decreases with the incorporation of native areas for agriculture in the Brazilian Cerrado (Stefanowski, Figueiredo, Santos, & Marchão, 2016), soil's physical proprieties behave differently to land use change. For instance, land use can cause soil's surface layer compaction, which is verified through the reduction of macroporosity, and the increase of microporosity and soil's bulk density (Figueiredo, Santos, Pereira, Nascimento, & Alves, 2009). On the other hand, density of soil's particles and soil's texture are not directly affected by land use and soil's management (Figueiredo et al., 2008; Zaninetti, Moreira, & Moraes, 2016). Density of soil's particles (dp) presented CC equal to: 0.39(dp0cm); 0.13(dp15 cm); and 0.50 (dp60 cm). Data from the surface and from soil's deeper layer (60 cm) were selected for the stepwise regression. Concerning soil's texture, data from the 60 cm soil layer was selected for the stepwise regression. The groundwater response variable presented higher CC with silt (0.39) and clay (–0.27) than it did with thin sand (0.03) and coarse sand (0.06). Therefore, silt (S60 cm) and clay (A60 cm) were selected for stepwise regression analysis.

Soil's water capacity (CAD) presented very low CC, –0.02 (CAD15 cm) and –0.04 (CAD60 cm), and was not selected for the stepwise regression analysis. Soil moisture (UmS) also presented low CC with the groundwater variable at the 60 cm layer (0.02). However, this variable presented a slightly higher CC score (0.20) at the surface layer, which was selected for the stepwise regression analysis. The amount of organic matter (TMO) also presented higher CC with the groundwater

Table 2
Estimated OLS coefficients.

Explanatory variables	Coefficient	RME	t-value	p-value	VIF
A60 cm	0.11	0.04	2.64	$1.94 \cdot 10^{-2}$	5.13
Dp60 cm	6.37	1.74	3.67	$2.50 \cdot 10^{-3}$	1.39
Ds0cm	7.46	2.18	3.42	$4.20 \cdot 10^{-3}$	1.54
Ds60 cm	25.12	8.51	2.95	$1.05 \cdot 10^{-2}$	12.29
Po60 cm	72.31	15.58	4.64	$4.00 \cdot 10^{-4}$	5.23
S60 cm	0.21	0.06	3.40	$4.30 \cdot 10^{-3}$	6.74
(Intercept)	-94.34	20.70	-4.56	$4.47 \cdot 10^{-4}$	—

response variable at the surface layer (-0.21), which was selected for stepwise regression. The amount of organic matter decreases in soil's deeper layers (Figueiredo et al., 2008). Soil's management also affects the amount of organic matter and the soil water storage capacity (Figueiredo et al., 2008).

Finally, concerning the basin's geomorphology, the groundwater response variable presented higher CC with: altitude (alt), -0.59 ; and with the distance between the wells and the basin's exutory (DBE), -0.57 . The CC between these two variables (alt and DBE) was assessed (0.92), and the distance of the wells to basin's exutory ended up being selected for stepwise regression analysis. The other three tested variables related to the basin's geomorphology characteristics had low CC with the groundwater studied variable. The minimum distance of the wells to the drainage network (Md) presented CC equal to 0.04, while slope (SLP) and the direction of the steepest downhill slope (Ov) presented CC equal to -0.09 and 0.09, respectively. Therefore, these three variables were not selected for stepwise regression analysis.

3.2. OLS results

Table 2 shows the estimated OLS coefficients results of the selected model, after stepwise regression analysis and after removing those variables that presented p-value ≥ 0.05 . The analysis selected as explanatory variables: A60 cm, dp60 cm, Ds0cm, Ds60 cm, Po60 cm, S60 cm. The OLS statistics results were: $R^2 = 0.81$, $R^2_{\text{Adjusted}} = 0.73$, AIC = 59.52; and AICc = 71.52.

The model's estimated coefficients indicate positive correlations of the six explanatory variables with the groundwater's maximum amplitude of variation in the studied period. The F-test (p-value = $1.92 \cdot 10^{-4}$) indicates a difference between the explanatory variables, within 1% of significance level. VIF ranged from 1.39 (dp60 cm) to 12.29 (Ds60 cm), remaining slightly larger than the thumb rule suggested by Souza (1998), as a reference for indication of multicollinearity between variables (VIF > 10).

Fig. 4 shows the observed groundwater amplitude and the results of the fitted OLS calibration (A) and validation (B) model. The selected model has six environmental explanatory variables (Table 2) that explain 73% of the amplitude of the water table variation, in the Upper Jardim river basin ($R^2_{\text{Adjusted}} = 0.73$), which represents a good result, since it did not use any hydrologic variable that composes the water balance, such as precipitation, evapotranspiration, and runoff.

Koenker's test to assess stationarity indicates homoscedasticity in the regression's residuals (p-value = 0.57). The Koenker's test determines whether the explanatory variables in the model have a consistent relationship with the dependent variable (Erdogan, 2010). Therefore, the relationship between the explanatory variables (environmental factors) and the response variable (amplitude of water table variation in the studied period), using the coefficients estimated with OLS, remains constant throughout the explanatory variables magnitudes. The results of Jarque-Bera's test (p-value = 0.64) and Shapiro-Wilks' test (p-value = 0.73) indicates that the OLS residuals have a similar behavior to a normal theoretical distribution. The Jarque-Bera's test is used to assess model's bias (Erdogan, 2010) and indicates whether or not the residuals are normally distributed

(Erdogan, 2010; Cardozo et al., 2012).

Fig. 5 (A) shows the relation between the OLS residuals and the estimated groundwater amplitude, while Fig. 5 (B) presents the residual quantile-comparison plot, QQnorm. The results are graphically illustrated in Fig. 5 (A) and (B), where the residuals are stationary and have a normal distribution.

Although extreme values can influence both positively and negatively the OLS results (Fig. 5A), Bonferroni's test did not identify outliers with p-value < 0.05, within the OLS residuals. Therefore, the most intense residual, -1.40 m , was not classified as an outlier by Bonferroni's test (p-value = 0.07).

The Global Moran's I statistic results (p-value = 0.97; z-score = 0.04) indicate that there is no spatial clustering within the regression's residuals. The calculated Moran's I was equal to -0.062 , while the expected Moran's I was equal to -0.05 . These results indicate a random pattern of OLS residuals values.

OLS statistics results indicate: stationary model (Koenker test); residuals with normal distribution behavior (Jarque-Bera and Shapiro-Wilks test); and slightly high collinearity between soil's bulk density and the other selected explanatory variables (VIF test). Comparing to other studies, it's possible to notice the difficulty to achieve satisfactory results in all tests. For instance, Erdogan (2010) had unsatisfactory VIF, Koenker's test, and Jarque-Bera's test results. On the other hand, Cardozo et al. (2012) obtained overall satisfactory VIF, but unsatisfactory residual analysis results (Koenker's test and Jarque-Bera test).

OLS validation result's (Fig. 4B) demonstrate how good the selected linear model, with the estimated coefficients, simulates the amplitude of groundwater variation with a different dataset used in the calibration processes (Fig. 1). This time, there is not such a good agreement between estimated and observed values ($R^2 = 0.22$). Then again, the selected OLS model uses only independent variables related to soils physical properties to access groundwater behavior, which is very complex in tropical regions.

3.3. GWR results

Table 3 presents the summary statistics of the distribution of the spatial GWR estimated coefficients. There was a great variability in the GWR estimated coefficients. The selected explanatory environmental variables (Ds0cm, A60 cm, dp60 cm, Ds60 cm, Po60 cm, S60 cm) had both negative and positive correlations with the response variable.

Fig. 6 presents the estimated GWR coefficients spatial distribution. It is possible to notice a greater tendency to occur higher correlations in the south/southwest part of the basin. On the other hand, negative correlations occurred predominantly in the upper central part of the basin. At this region, GWR estimated more negative coefficients to A60 cm, S60 cm and Ds60 cm, followed by dp60 cm Po60 cm, and Ds0cm which presented a slightly different pattern from the other variables. Finally, the model's intercept showed an inverse pattern, with low estimates on the south/southwest part of the basin and high values in the central part.

The GWR statistics results were: $R^2 = 0.99$; $R^2_{\text{Adjusted}} = 0.90$; and AICc = -1220.71 . The F-test (p-value = $9.0 \cdot 10^{-3}$) indicates difference between the explanatory variables, within 1% of significance level. The estimated AICc for OLS analysis was bigger (AICc = 71.52) than the GWR result (AICc = -1220.71). If OLS has AICc smaller than the result obtained in GWR, the spatial component inserted in the model brought no advantage to the model developed with spatial weights (Fotheringham et al., 2002). Other studies also showed the same pattern achieved in this study (Cardozo et al., 2012; Erdogan, 2010; Gao et al., 2012). GWR had lower AICc, which indicates that the spatial weights inserted in the model brought advantage to the results (Fotheringham et al., 2002). The most valuable understanding gained from the GWR analysis is an appreciation of the spatial variance in the model parameters (Wooldridge, Brodie, & Furnas, 2006).

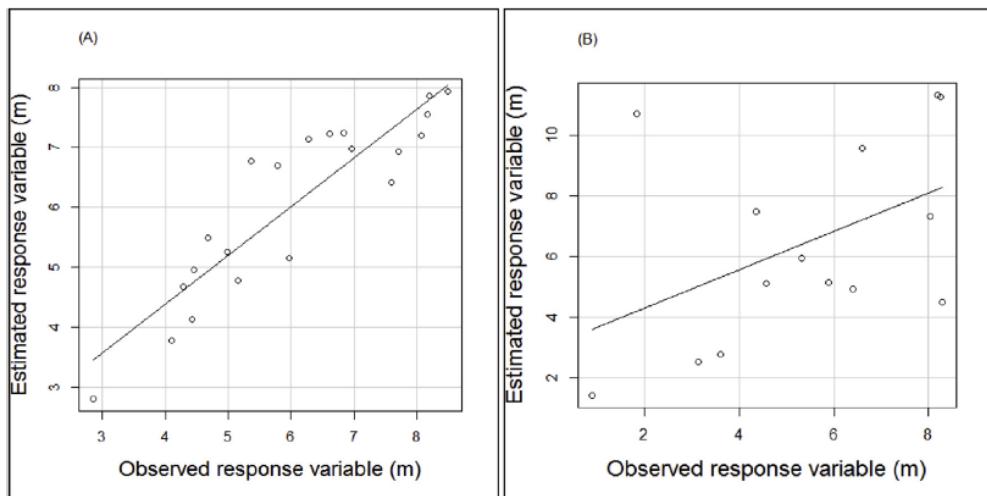


Fig. 4. OLS calibration (A) and validation (B) results.

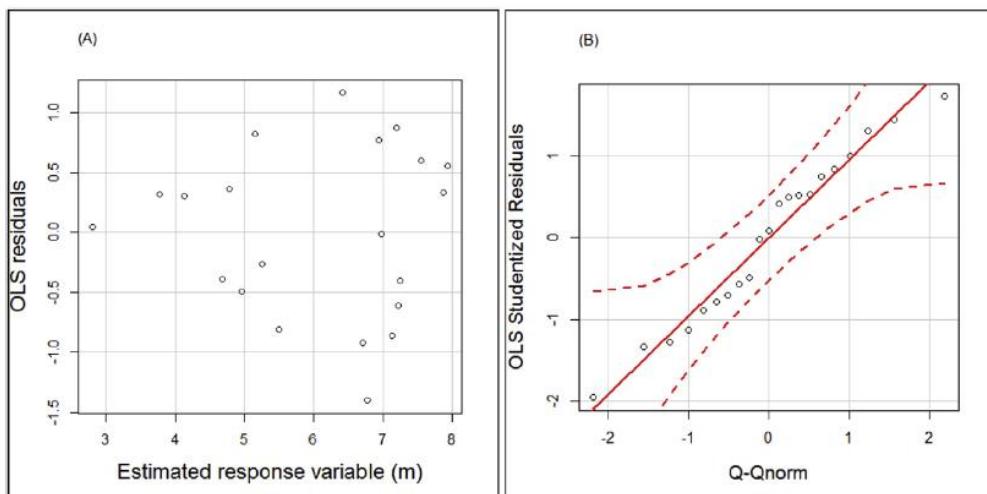


Fig. 5. Relation between the residuals and the estimated values (A) and the theoretical and the residuals quantiles (B).

Table 3
Summary statistics of the distribution of the spatial GWR estimated coefficients.

Explanatory variable	Minimum	1 ^o Quartile	Median	3 ^o Quartile	Maximum
A60 cm	-0.32	-0.16	0.07	0.41	0.87
dp60 cm	-0.94	1.16	7.94	8.67	9.25
Ds0	-12.97	5.58	6.77	17.79	47.06
Ds60 cm	-62.33	-4.32	2.62	31.29	44.50
Po60 cm	-19.41	22.25	44.69	108.69	188.65
S60 cm	-0.39	-0.11	0.04	0.36	0.49
(Intercept)	-277.64	-159.53	-48.68	21.32	100.98

The Global Moran's I statistic results ($p\text{-value} = 0.84$; $z\text{-score} = -0.20$) indicate that there is no spatial clustering within the regressions residuals. The calculated Moran's I was equal to -0.10 , while the expected Moran's I was equal to -0.05 . Like the OLS, these results also indicate a random pattern of the GWR residuals values.

Fig. 7(A) and (B) presents the groundwater's maximum amplitude observed in the Upper Jardim river basin, between 17/02/2004 and

01/10/2012, and the estimated value with GWR, after IDW interpolation. The observed water table amplitude ranged between 2.86 and 8.48 m while the estimated by GWR ranged between 2.92 and 8.39 m. It is possible to notice that the GWR estimates were similar to the observed data. Using GWR, the explanatory variables explained 90% of the response variable ($R^2_{\text{Adjusted}} = 0.90$).

Fig. 8 (A) and (B) shows the spatial distribution of the GWR local R^2 and R^2_{Adjusted} results, after IDW interpolation. The best local estimates were obtained in the southwest and central portion of the basin occurring higher values, while in the southeast and upper region of Upper Jardim river basin occurred the worst estimates.

4. Discussion

Latosols cover around 50% of the Cerrado biome (Reatto, Correia, & Spera, 1998), and 75% of the studied area (Reatto et al., 2000). Most of the assessed piezometric wells (82.86%) are situated on Latosols. These soils play an important role on groundwater recharge due to its intrinsic characteristics which allows the development of important porous

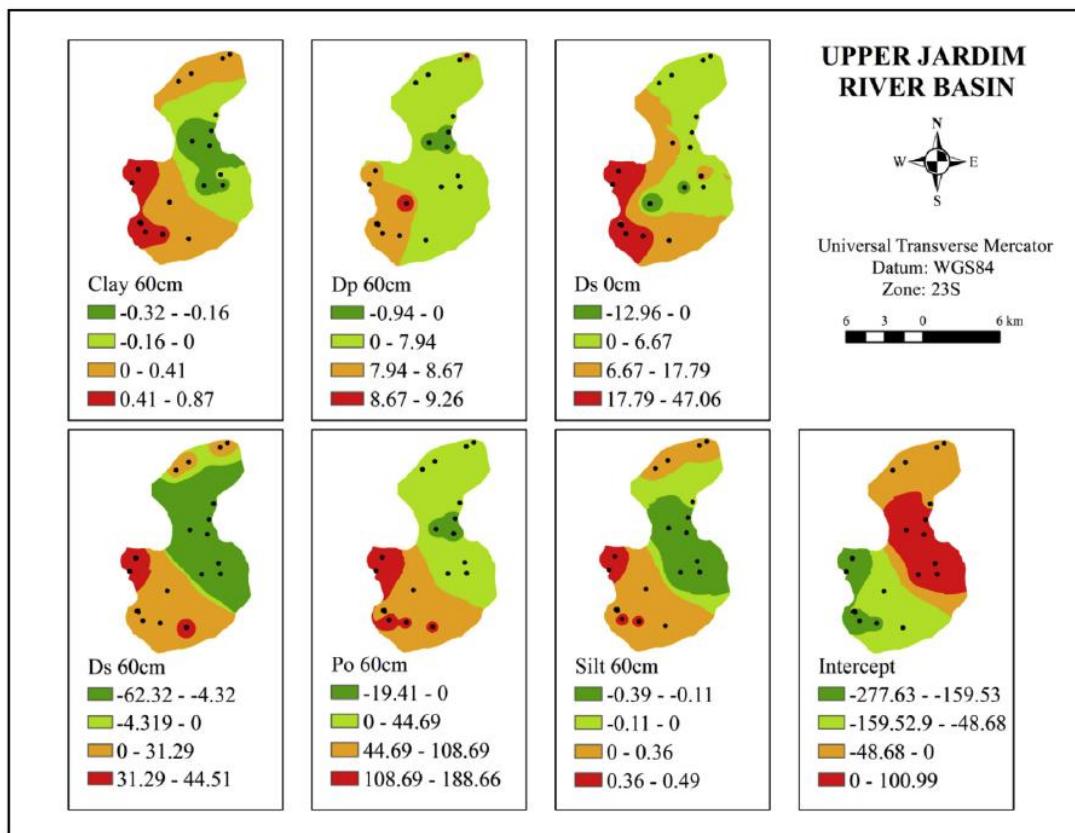


Fig. 6. Spatial distribution of the estimated geographically weighted regression's coefficients.

aquifers and recharge areas for fractured aquifers (Campos et al., 2006). Water flux observed in Latosols illustrates the complexity of groundwater behavior in tropical regions, since it does not relate high amount of clay to impermeable soils. Latosols are deep (> 2 m) and highly weathered soils, presenting from 15% to 80% of clay and, despite this high amount, they are classified as well drained soils (Reatto et al., 1998). Although Latosols can present clay texture with high amounts of clay in their composition (Campos, Lacerda, Silva, Sá, & Sousa, 2010; Lima, 2010) they present high hydraulic conductivity at soil's surface layers (Campos et al., 2006; Lima, 2010; Gonçalves et al., 2015). Soil's structure with a good distribution of pores (Danalatos, Kosmas, Driessen, & Yassoglou, 1994) can help explain this behavior. Hydraulic conductivity of Red, Red-Yellow and Yellow Latosols' surface layers, assessed in the Upper Jardim river Basin, has reached magnitudes of $3.64 \cdot 10^{-4}$, $6.51 \cdot 10^{-4}$, and $7.23 \cdot 10^{-4} \text{ m s}^{-1}$, respectively, against $2.12 \cdot 10^{-4} \text{ m s}^{-1}$ registered on Quartzarenic Neosols (Lima, 2010), which is a class of soil that presents high amount of sand in its composition (Mingot, Spadotto, & Moraes, 2016). Usually Latosols' hydraulic conductivity decreases from shallow to deeper soil layers, since these soils are less structured at higher depths, with magnitudes varying from 10^{-4} to 10^{-7} m s^{-1} at the surface, to 10^{-5} and 10^{-8} m s^{-1} between 50 cm and 200 cm soil depth (Campos et al., 2006).

The heterogeneity of porous aquifers hydraulic conductivity within the Federal District region is conditioned by soil's texture, structure and macroporosity (Gonçalves et al., 2015). The stepwise regression methodology ended up selecting inputs variables (A60cm; S60cm; dp60cm; Ds60cm; Ds0cm; Po60cm) directly related to them. The OLS

(Fig. 4A) and GWR (Figs. 7 and 8) analysis managed to express groundwater's maximum amplitude observed in piezometric wells according with the river basin's local geomorphology and soil's physical properties, indicating where the porous aquifer's can present higher variation.

Although OLS and GWR yielded acceptable statistics, the model's validation using an independent dataset (Fig. 4B) shows that the relationships between the porous aquifer and environmental variables in tropical regions, such as the Cerrado biome, are very complex and need to be carefully evaluated before making any generalizations with the estimated OLS coefficients. Some hypotheses can explain limitations within the modeling process: spatial variability of the environmental factors and groundwater behavior; land use; inadequate representation of the environment, including accuracy and representativeness of measured data; inadequate representation of water circulation in the basin, such as the existence of preferential paths or fractures in the soil area assumed as impermeable; and failure to consider soil's vertical variability of physical and hydraulic characteristics.

For instance, spatial variability of the environmental factors and of the groundwater behavior can be identified as a source of error, which has contributed with the reduction of the model's accuracy when the independent dataset was used in the OLS validation analysis. The independent variables presented a positive performance with regard to the models objectives, where their magnitudes increases' in regions where the groundwater response variable also presents higher magnitudes. However, GWR showed that the independent variables can also present a negative performance, especially in the upper central part of the basin, where high magnitudes of the groundwater's maximum

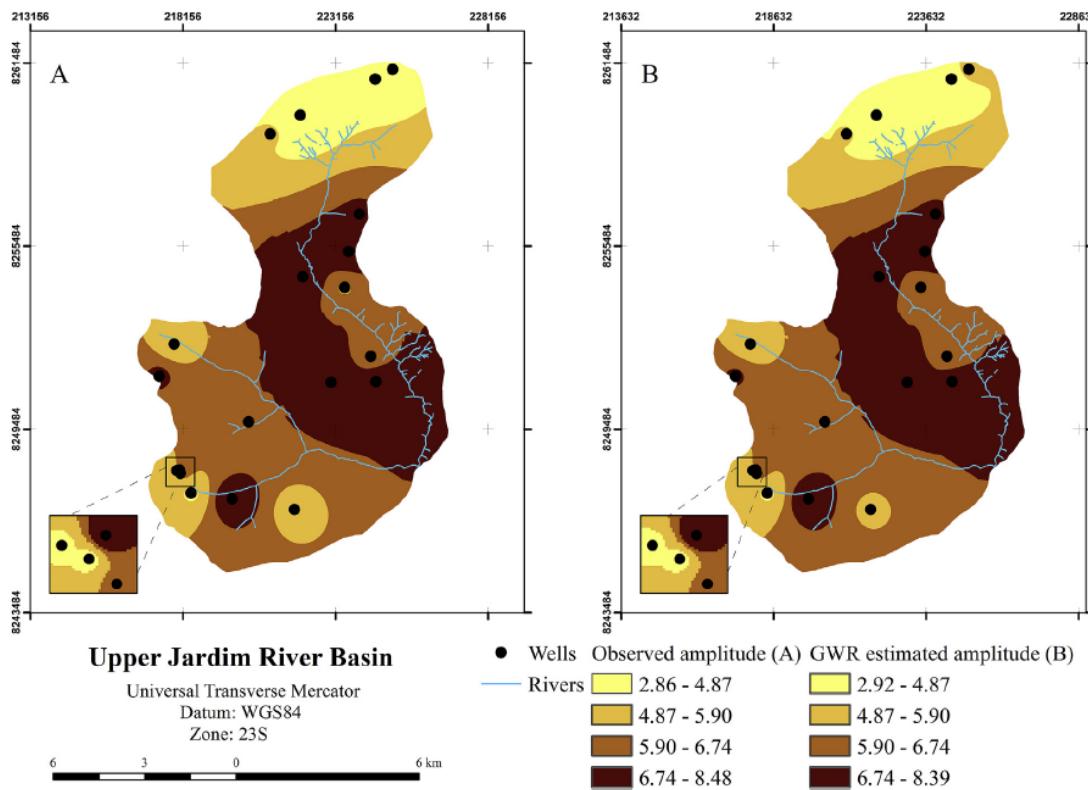


Fig. 7. Maximum groundwater amplitude observed in piezometric wells (A) and estimated with GWR (B), after IDW interpolation.

amplitude registered at the piezometric wells were correlated to smaller magnitudes of A60 cm, S60 cm and Ds60 cm. Comparing the OLS (Table 2) and the GWR (Table 3) estimated coefficients, it is possible to notice that all the OLS coefficients are within the interquartile range of the GWR estimated coefficients and that they are all positive, while GWR has coefficients with both negative and positive values (Fig. 6). OLS summarizes data for the whole region and emphasizes similarities across space, while the GWR locally disaggregates the global statistics and emphasizes the spatial differences (Fotheringham et al., 2002). In this way, the estimated OLS coefficients represent a global relation between the selected environmental variables and groundwater behavior, which ends up losing local relations between the assessed variables and incorporating error into the model's output. GWR managed to reduce this source of error, since it improved statistics used to assess the model's output.

Besides spatial variability of the environmental factors, others sources of error have contributed negatively to the models performance when the independent dataset was used to validate the estimated OLS coefficients, yielding lower statistics results. A recent assessment of groundwater behavior in the Federal District presented evidence that hydraulic conductivity of porous aquifers can present anisotropic behavior (Gonçalves et al., 2015). Anisotropy can influence negatively and is a relevant source of error for modeling.

Land use and soil's management changes some of the soils' physical and hydrological proprieties, when compared with areas covered by native vegetation (Figueiredo et al., 2009). Therefore, they are elements that can also affect the models performance and can be identified as a source of error. Agriculture can make soils more compacted, thick, and shallow, forming clods when plowed (Fontana et al., 2016). Soil revolving decreases the amount of organic matter and the soil water storage capacity (Figueiredo et al., 2008). Irrigation can reduce

macropores enhancing soil-water retention capacity (Rocha et al., 2016) affecting soil's physical proprieties too. Agricultural use can also reduce the saturated hydraulic conductivity of Latosols in surface layers (Fontana et al., 2016).

Structural elements such as faults and fractures, geomorphological characteristics also influence groundwater behavior (Gonçalves et al., 2015) and can also be identified as a source of error which can affect the model's performance when the independent dataset was used to validate the estimated OLS coefficients, yielding lower statistics results.

The results indicate that using linear models to estimate groundwater's behavior with environmental variables easily collected at the surface soil layers (geomorphology or/and soils physical properties) can help comprehend these complex systems. Yet, the proposed model use's inputs that changes only across space, they do not vary through time except as a consequence of land use and soil's management, as discussed previously. Therefore, future investigations are suggested to evaluate relationships between hydrological variables, such as Precipitation and Actual Evapotranspiration, with geomorphology and soil's physical properties, in order to assess porous aquifers water balance.

5. Conclusions

This study showed relationships between groundwater, geomorphology and soil's physical properties, using spatial multivariate statistics and geoprocessing, in the Upper Jardim experimental river basin. The OLS analysis established positive correlations, while GWR found positive and negative local correlations between groundwater behavior and the environmental variables during the studied period. This demonstrates the complexity of groundwater behavior in tropical soils.

The results identified the possibility to estimate, from geomorphology and soil's physical characteristics, how much water is stored in

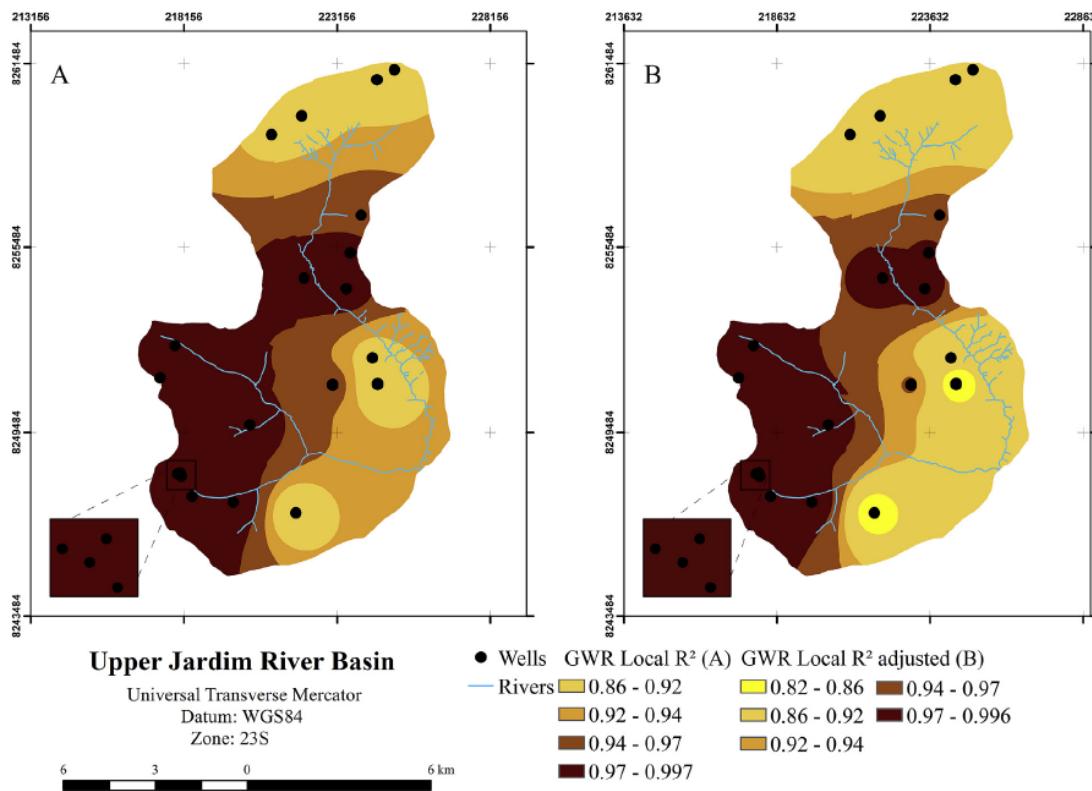


Fig. 8. GWR local R^2 (A) and R^2_{adjusted} (B) results, after IDW interpolation.

porous aquifers and groundwater behavior in soils of the Brazilian central plateau. The study indicates that data collected near the surface can be used to explain the spatial and temporal variation of groundwater, which enables to have important information about recharge areas, being of great use to unmonitored river basins. Further studies are recommended to better comprehend these complex process.

Conflicts of interest

None.

Acknowledgments

We thank FINEP/CTHIDRO for supporting the REHIDRO Project (National Network of Experimental River Basins) and also thank the Climate Fund/MMA for supporting the Chuva-vazão Project.

References

- Almeida, L., Resende, L., Rodrigues, A. P., & Campos, J. E. G. (2006). Hidrogeologia do Estado de Goiás (Hydrogeology of the State of Goiás). Superintendência de Geologia e Mineração, Governo do Estado de Goiás.
- Bayramov, E., Buchroithner, M. F., & McGurtty, E. (2012). Determination of main climate and ground factors controlling vegetation cover regrowth along oil and gas pipelines using multiple, spatial and geographically weighted regression procedures. *Environmental Earth Science*, 66, 2047–2062. <http://dx.doi.org/10.1007/s12665-011-1429-6>.
- Bierman, P., Lewis, M., Ostendorf, B., & Tanner, J. (2011). A review of methods for analyzing spatial and temporal patterns in coastal water quality. *Ecological Indicators*, 11, 103–114. <http://dx.doi.org/10.1016/j.ecolind.2009.11.001>.
- Blainey, S. (2010). Trip end models of local rail demand in England and Wales. *Journal of Transport Geography*, 18, 153–165. <http://dx.doi.org/10.1016/j.jtrangeo.2008.11.002>.
- Brasil (1992). Companhia de Planejamento do Distrito Federal. *Mapas Topográficos* Planilítmétricos Digitais do Distrito Federal na escala de 1:10.000, Brasília (Planilítmetric Topographic Digital Maps of the Federal District in 1:10,000, Brasília). Governo do Distrito Federal. See http://www.sedhab.df.gov.br/mapas_sicad/index2.htm.
- Brasil, & Companhia de Planejamento do Distrito Federal (1984). *Atlas do Distrito Federal na escala de 1: 10.000 (Atlas of the Federal District in the scale of 1: 10,000)*. Governo do Distrito Federal.
- Breetzke, G. D. (2012). The effect of altitude and slope on the spatial patterning of burglary. *Applied Geography*, 34, 66–75. <http://dx.doi.org/10.1016/j.apgeog.2011.10.017>.
- Campos, J. E. G. (2004). Hidrogeologia do Distrito Federal: Bases para a gestão dos recursos hídricos subterrâneos (Hydrogeology of the Federal District: Bases for groundwater resources management). *Brazilian Journal of Geology*, 34(1), 41–48.
- Campos, J. E. G., & Freitas-Silva, F. H. (1998). Hidrogeologia do Distrito Federal (Hydrogeology of the Federal District). IEMA/SEMAP/UnB. Inventário Hidrogeológico e dos Recursos Hídricos Superficiais do Distrito Federal. Brasília.
- Campos, P. M., Lacerda, M. P. C., Silva, C. L., Sá, M. A. C., & Sousa, D. M. G. (2010). Drenagem interna como fator de diferenciação de Latossolos do Distrito Federal (The internal drainage as a differentiation factor in Oxisols of Distrito Federal, Brazil). *Pesquisa Agropecuária Brasileira*, 45(3) 306–3140900044.
- Campos, J. E. G., Monteiro, C. P., & Rodrigues, L. N. (2006). *Geologia e Zoneamento Hidrogeológico da Bacia do Rio Preto, DF/GO/MG (Geology and Hydrogeological Zoning of the Rio Preto Basin, DF/GO/MG)*. Planaltina, DF: Embrapa Cerrados54 ISSN: 1517-5111:172.
- Cardozo, O. D., García-Palomares, J. C., & Gutiérrez, J. (2012). Application of geographically weighted regression to the direct forecasting of transit ridership at station-level. *Applied Geography*, 34, 548–558. <http://dx.doi.org/10.1016/j.apgeog.2012.01.005>.
- Danalatos, N. G., Kosmas, C. S., Driessens, P. M., & Yassoglou, N. (1994). Estimation of the draining soil moisture characteristic from standard data as recorded in routine soil surveys. *Geoderma*, 64, 155–165. [http://dx.doi.org/10.1016/0016-7061\(94\)90095-7](http://dx.doi.org/10.1016/0016-7061(94)90095-7).
- Deller, S. (2011). Spatial heterogeneity in the wage curve. *Economics Letters*, 113, 231–233. <http://dx.doi.org/10.1016/j.econlet.2011.04.015>.
- Erdogan, S. (2010). Modelling the spatial distribution of DEM error with geographically weighted regression: An experimental study. *Computer Geoscience*, 36, 34–43. <http://dx.doi.org/10.1016/j.cageo.2009.06.005>.
- Figueiredo, C. C., Ramos, M. L. G., & Tostes, R. (2008). Propriedades físicas e matéria orgânica de um latossolo vermelho sob sistemas de manejo e cerrado nativo (Physical properties and organic matter in a red latosol under management systems and native cerrado). *Bioscience Journal*, 24(3), 24–30.

- Figueiredo, C. C., Santos, G. G., Pereira, S., Nascimento, J. L., & Alves, J., Jr. (2009). Propriedades físico-hídricas em Latossolo do Cerrado sob diferentes sistemas de manejo (Physico-hydric properties of Cerrado Latosol under different management systems). *Revista Brasileira Engenharia Agrícola Ambiente*, 13(2), 146–151.
- Fiori, J. P. O., Campos, J. E. G., & Almeida, L. (2010). Variabilidade da condutividade hidráulica das principais classes de solos do Estado de Goiás (Hydraulic conductivity variability of the main soil classes in Goias). *Geociencias*, 29(2), 229–235.
- Fontana, A., Teixeira, W. G., Balieiro, F. C., Moura, T. P. A., Menezes, A. R., & Santana, C. I. (2016). Características e atributos de Latossolos sob diferentes usos na região Oeste do Estado da Bahia (Characteristics and attributes of Oxisols under different land uses in the western region of the state of Bahia, Brazil). *Pesquisa Agropecuária Brasileira*, 51(9), 1457–1465. <http://dx.doi.org/10.1590/S0100-204X2016000900044>.
- Food and Agriculture Organisation (2015). *World reference base for soil resources 2014, update 2015 international soil classification system for naming soils and creating legends for soil maps*. World Soil Resources Reports No. 106. FAO (Rome).
- Fotheringham, A. S., Brunsdon, C., & Charlton, M. (2002). *Geographically weighted regression: The analysis of spatially varying relationships*. Chichester: John Wiley & Sons Ltd.
- Fox, J. (2005). The R Commander: A basic statistics graphical user interface to R. *Journal of Statistical Software*, 14(9), 1–42. <http://dx.doi.org/10.1863/jss.v014.i09>.
- Gao, Y., Huang, J., Li, S., & Li, S. (2012). Spatial pattern of non-stationarity and scale-dependent relationships between NDVI and climatic factors – a case study in Qinghai-Tibet Plateau, China. *Ecological Indicators*, 20, 170–176. <http://dx.doi.org/10.1016/j.ecolind.2012.02.007>.
- Gilbert, A., & Chakraborty, J. (2011). Using geographically weighted regression for environmental justice analysis: Cumulative cancer risks from air toxics in Florida. *Social Science Research*, 40, 273–286. <http://dx.doi.org/10.1016/j.ssresearch.2010.08.006>.
- Gonçalves, T. D., Lohé, C., & Campos, J. E. G. (2015). Hydraulic characterization from porous aquifers of the Brazilian Federal District. *Brazilian Journal of Geology*, 45(2), 259–271. <http://dx.doi.org/10.1590/23174889201500020006>.
- Grubacic, T. H., Mack, E. A., & Kaylen, M. T. (2012). Comparative Modeling approaches for understanding urban violence. *Social Science Research*, 41, 92–109. <http://dx.doi.org/10.1016/j.ssresearch.2011.07.004>.
- Harris, P., & Brundson, C. (2010). Exploring spatial variation and spatial relationships in a freshwater acidification critical load data set for Great Britain using geographically weighted summary statistics. *Computer Geoscience*, 36, 54–70. <http://dx.doi.org/10.1016/j.cageo.2009.04.012>.
- Himmelberger, Y. O., Pearsall, H., & Rakshit, R. (2009). Concrete evidence & geographically weighted regression: A regional analysis of wealth and the land cover in Massachusetts. *Applied Geography*, 29, 478–487. <http://dx.doi.org/10.1016/j.apgeog.2009.03.001>.
- Ibeas, A., Cordera, R., Dell'Olio, L., & Moura, J. L. (2011). Modelling demand in restricted parking zones. *Transportation Research Part A: Policy and Practice*, 45, 485–498. <http://dx.doi.org/10.1016/j.tra.2011.03.004>.
- Kupfer, J. A., & Farris, C. A. (2007). Incorporating spatial non-stationarity of regression coefficients into predictive vegetation models. *Landscape Ecology*, 22, 837–852. <http://dx.doi.org/10.1007/s10980-006-9058-2>.
- Leyk, S., Norlund, P. U., & Nuckols, J. R. (2012). Robust assessment of spatial non-stationarity in model associations related to pediatric mortality due to diarrheal disease in Brazil. *Spatiotemporal Epidemiology*, 3, 95–105. <http://dx.doi.org/10.1016/j.sste.2012.04.003>.
- Lima, J. E. F. W. (2010). *Modelagem numérica do fluxo da água no solo e do escoamento de base em uma bacia experimental em área agrícola no Cerrado (Numerical modeling of water flux and baseflow in an experimental agricultural area in the Cerrado)*. [Doctorate] Brasília: Departamento de Engenharia Civil e Ambiental, Universidade de Brasília.
- Lima, J. E. F. W., Eid, N. J., Silva, E. M., Martins, E. S., Lopes, W. T. A., & Koide, S. (2007). Estimativa da taxa média anual de erosão na bacia experimental do Alto Rio Jardim – DF (Estimation of the average annual erosion rate in the Upper Rio Jardim experimental basin – DF). *Anais do XVII Simpósio Brasileiro de Recursos Hídricos (CD-ROM)*. São Paulo: ABRH.
- Lima, J. E. F. W., Silva, E. M., Strauch, M., & Lorz, C. (2013). Development of a soil database for applying SWAT model in a catchment of the Brazilian Savanna. *Proceedings of the SWAT-2013 conference, Toulouse-FR* (pp. 1–10).
- Lisboa, F. M., Donegemma, G. K., Burak, D. L., Passos, R. R., & Mendonça, E. S. (2016). Indicadores de qualidade de Latossolo relacionados à degradação de pastagens (Oxisol quality indicators related to degradation of pastures). *Pesquisa Agropecuária Brasileira*, 51(9), 1184–1193. <http://dx.doi.org/10.1590/S0100-204X2016000900018>.
- Lousada, E. O., & Campos, J. E. G. (2005). Proposta de modelos hidrogeológicos conceituais aplicados aos aquíferos da região do Distrito Federal (Proposal of hydrogeological models applied to aquifers in the Federal District). *Brazilian Journal of Geology*, 35(3), 407–414.
- Mills, R. B., Paterson, A. M., Lean, D. R. S., Smol, J. P., Mierle, G., & Blais, J. M. (2009). Dissecting the spatial scales of mercury accumulation in Ontario lake sediment. *Environmental Pollution*, 157, 2949–2956. <http://dx.doi.org/10.1016/j.envpol.2009.06.009>.
- Mingoti, R. S., Spadotto, C. A., & Moraes, D. A. C. (2016). Suscetibilidade à contaminação da água subterrânea em função de propriedades dos solos no Cerrado brasileiro (Groundwater contamination susceptibility as a function of soil properties in the Brazilian Cerrado). *Pesquisa Agropecuária Brasileira*, 51(9), 1252–1260. <http://dx.doi.org/10.1590/S0100-204X2016000900025>.
- Minoti, R. T., Silva, F. G. B., Lombardi Neto, F., Koide, S., & Crestana, S. (2011). Application of models to estimate erosion, sediment production and future scenarios in two Brazilian tropical watersheds. *IAHS-AISH Publication*, 345, 99–105.
- R Development core team (2012). *R: A language and environment for statistical computing. R foundation for statistical computing*. Vienna, Austria. See <http://www.R-project.org>.
- Rangel, T. F. L. V. B., Diniz-Filho, J. A. F., & Bini, L. M. (2010). Sam: A comprehensive application for spatial analysis in Macroecology. *Ecography*, 33, 46–50. <http://dx.doi.org/10.1111/j.1600-0587.2009.06299.x>. Accessed date: 23 November 2012.
- Reatto, A., Correia, J. R., & Spera, S. T. (1998). Solos do bioma cerrado: Aspectos pedológicos (soils of the cerrado biome: Pedological aspects). In S. M. Sano, & S. P. Almeida (Eds.), *Cerrado: Ambiente e flora* (pp. 556). Planaltina: EMBRAPA-CPAC.
- Reatto, A., Correia, J. R., Spera, S. T., Chagas, C. S., Martins, E. S., Andahur, J. P., Godoy, M. J. S., & Assad, M. L. C. L. (2000). *Levantamento semi-detalhado dos solos da bacia do rio Jardim-DF, escala 1:50.000*. Boletim de Pesquisa e Desenvolvimento 18. Planaltina: Embrapa Cerrados.
- Rocha, O. M., Ramos, M. L. G., Veiga, A. D., Guerra, A. F., Bartholo, G. F., Rodrigues, G. C., & Silva, J. E. (2016). Chemical and hydrophysical attributes of an Oxisol under coffee intercropped with brachiaria in the Cerrado. *Pesquisa Agropecuária Brasileira*, 51(9), 1476–1483. <http://dx.doi.org/10.1590/S0100-204X2016000900046>.
- Salles, L. A. (2012). *Calibração e validação do modelo SWAT para a predição de vazões na bacia do ribeirão Pipiripau (Calibration and validation of SWAT model for the prediction of flow in the Pipiripau river basin)*. [Master degree] Brasília: Departamento de Engenharia Florestal, Universidade de Brasília.
- Santos, R. M. (2012). *Recarga de águas subterrâneas em ambiente de cerrado: Estudo com base em modelagem numérica e simulação hidrológica em uma bacia experimental (Groundwater recharge in cerrado environment: Study based on numerical modeling and hydrological simulation in an experimental basin)*. [Doctorate] Brasília: Departamento de Engenharia Civil e Ambiental, Universidade de Brasília.
- Souza, G. S. (1998). *Introdução aos modelos de regressão linear e não-linear (Introduction to linear and non-linear regression models)*. Brasília: Embrapa-SPI/Embrapa-SEA.
- Souza, E. D., Carneiro, M. A. C., & Paulino, H. B. (2005). Atributos físicos de um Neossolo Quartzarênico e um Latossolo Vermelho sob diferentes sistemas de manejo (Physical attributes of a Typic Quartzipamment and a Rhodic Hapludox under different management systems). *Pesquisa Agropecuária Brasileira*, 40(11), 1135–1139.
- Stefanoski, D. C., Figueiredo, C. C., Santos, G. G., & Marchão, R. L. (2016). Selecting soil quality indicators for different soil management systems in the Brazilian Cerrado. *Pesquisa Agropecuária Brasileira*, 51(9), 1643–1651. <http://dx.doi.org/10.1590/S0100-204X2016000900064>.
- Strauch, M., Bernhofer, C., Koide, S., Volk, M., Lorz, C., & Makeschin, F. (2012). Using precipitation data ensemble for uncertainty analysis in SWAT streamflow simulation. *Journal of Hydrology*, 414(415), 413–424. <http://dx.doi.org/10.1016/j.jhydrol.2011.11.014>.
- Strauch, M., Lima, J. E. F. W., Volk, M., Lorz, C., & Makeschin, F. (2013). The impact of Best Management Practices on simulated streamflow and sediment load in a Central Brazilian catchment. *Journal of Environmental Management*, 127, 24–36. <http://dx.doi.org/10.1016/j.jenvman.2013.01.014>.
- Woodbridge, S., Brodie, J., & Furnas, M. (2006). Exposure of inner-shelf reefs to nutrient enriched runoff entering the Great Barrier Reef Lagoon: Post-European changes and the design of water quality targets. *Marine Pollution Bulletin*, 52(11), 1467–1479. <http://dx.doi.org/10.1016/j.marpolbul.2006.05.009>.
- Wu, W., & Driscoll, C. T. (2009). Application of the PnET-BGC – an integrated biogeochemical model – to assess the surface water ANC recovery in the Adirondack region of New York under three multi-pollutant proposals. *Journal of Hydrology*, 378, 299–312. <http://dx.doi.org/10.1016/j.jhydrol.2009.09.035>.
- Zaninetti, R. A., Moreira, A., & Moraes, L. A. C. (2016). Atributos físicos, químicos e biológicos de Latossolo Amarelo na conversão de floresta primária para seringais na Amazônia (Physical, chemical, and biological attributes of a Xanthic Oxisol after forest conversion to rubber tree plantation in the Amazon). *Pesquisa Agropecuária Brasileira*, 51(9), 1061–1068. <http://dx.doi.org/10.1590/S0100-204X2016000900005>.