

PEDRO HENRIQUE JANDREICE MAGNONI

**ESTIMATIVA DE RECARGA DE ÁGUAS SUBTERRÂNEAS POR
SENSORIAMENTO REMOTO E COMPUTAÇÃO EM NUVEM**

Botucatu

2020

PEDRO HENRIQUE JANDREICE MAGNONI

**ESTIMATIVA DE RECARGA DE ÁGUAS SUBTERRÂNEAS POR
SENSORIAMENTO REMOTO E COMPUTAÇÃO EM NUVEM**

Dissertação apresentada à Faculdade de Ciências Agrônômicas da Unesp Câmpus de Botucatu, para obtenção do título de Mestre em Agronomia (Irrigação e Drenagem).

Orientador: Rodrigo Lilla Manzione

Botucatu

2020

M198e

Magnoni, Pedro Henrique Jandreice
Estimativa de recarga de águas subterrâneas por
sensoriamento remoto e computação em nuvem / Pedro
Henrique Jandreice Magnoni. -- Botucatu, 2020
100 p. : il., tabs., mapas

Dissertação (mestrado) - Universidade Estadual
Paulista (Unesp), Faculdade de Ciências Agrônomicas,
Botucatu

Orientador: Rodrigo Lilla Manzione

1. Águas subterrâneas. 2. Sensoriamento remoto. I.
Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca
da Faculdade de Ciências Agrônomicas, Botucatu. Dados fornecidos pelo
autor(a).

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: ESTIMATIVA DE RECARGA DE ÁGUAS SUBTERRÂNEAS POR SENSORIAMENTO REMOTO E COMPUTAÇÃO EM NUVEM

AUTOR: PEDRO HENRIQUE JANDREICE MAGNONI

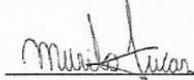
ORIENTADOR: RODRIGO LILLA MANZIONE

Aprovado como parte das exigências para obtenção do Título de Mestre em AGRONOMIA (IRRIGAÇÃO E DRENAGEM), pela Comissão Examinadora:

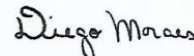
Prof. Dr. RODRIGO LILLA MANZIONE
Engenharia de Biosistemas / Faculdade de Ciências e Engenharia - UNESP - Tupã



Prof. Dr. MURILO CESAR LUCAS
Engenharia Civil / Universidade Tecnológica Federal do Paraná



Prof. Dr. DIEGO AUGUSTO DE CAMPOS MORAES
Análise e Desenvolvimento de Sistemas / Faculdade Eduvale de Avaré



Botucatu, 11 de setembro de 2020

AGRADECIMENTOS

Agradeço aos meus pais, Antônio Francisco Magnoni e Maria José Jandreice, pelo apoio familiar necessário em todas as etapas de minha vida.

A minha companheira, Melissa Neves de Souza, por todo apoio e carinho durante meu período de estudos e dedicação a este trabalho.

Ao Orientador e amigo Professor Doutor Rodrigo Lilla Manzione, pela postura profissional, pelos ensinamentos e o constante estímulo a exceder minhas próprias expectativas.

Ao meu grande amigo César de Oliveira Ferreira Silva, por ajudar-me a desenvolver o interesse contínuo pela pesquisa e pensamento científico, com paciência e sabedoria, além dos preciosos feedbacks que ajudaram a elaboração deste trabalho.

Aos amigos e colegas do programa de pós-graduação que convivi ao longo desses dois anos em ambiente universitário.

Aos Professores Doutores Murilo Cesar Lucas, Diego Augusto de Campos Moraes, Edson Luís Piroli e Sérgio Campos pela disposição em participar da banca examinadora.

Aos Professores do Programa de Pós-Graduação em Agronomia (Irrigação e Drenagem) pelos ensinamentos passados a diante com profissionalismo, dedicação e amizade, e a Seção Técnica de Pós-Graduação por todo exemplar comprometimento profissional em seu suporte.

À coordenação do curso de Pós-Graduação em Agronomia (Irrigação e Drenagem), pela dedicação, assim como ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela bolsa de estudos (Processo 134361/2018-0) concedida e a FEHIDRO (projeto 2012-ALPA-244) que foi fundamental para instrumentação da área de estudo em etapas anteriores, realizadas por outros pesquisadores e funcionários da EECa.

À Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP/FCA), pela oportunidade e suporte para a realização do mestrado.

A todos os citados, os meus mais sinceros agradecimentos!

“A estrada em frente vai seguindo
deixando a porta onde começa.
Agora longe já vai indo,
devo seguir, nada me impeça.
Em seu encalço vão meus pés,
até a junção com a grande estrada,
de muitas sendas através.
Que vem depois? Não sei mais nada”.

RESUMO

A popularização do sensoriamento remoto via computação em nuvem em plataformas como o Google Earth Engine (GEE) trouxe novas perspectivas aos modeladores, facilitando acesso e processamento de dados espacializados em diferentes localidades. No entanto, estas ferramentas ainda são pouco exploradas no processo de planejamento e tomada de decisões sobre recursos hídricos, especialmente tratando-se das águas subterrâneas. O Sistema Aquífero Guaraní (SAG) é o maior reservatório transfronteiriço de água subterrânea da América do Sul, mas a recarga em suas zonas de afloramento é uma das variáveis hidrológicas menos conhecidas. Portanto, o objetivo deste trabalho foi contribuir para a compreensão do processo de recarga das águas subterrâneas em uma área de afloramento do SAG. Avaliou-se a adequação do uso de dados de sensoriamento remoto na equação do balanço hídrico para estimar a recarga (GWR) e o impacto nos níveis freáticos (WTD), por meio da utilização do GEE. Um modelo de estimativa da WTD foi adaptado a partir do método de flutuação do nível freático (WTF). Séries temporais estimadas de precipitação, evapotranspiração e escoamento superficial de três bases de dados hidroclimáticos baseados em sensoriamento remoto (FLDAS, GLDAS e TERRACLIMATE) foram obtidas ao longo de 2014 a 2017, no GEE na localização da Estação Ecológica de Angatuba (EEcA), no Estado de São Paulo. As estimativas da GWR e da WTD foram calculadas na localização de oito poços de monitoramento do nível freático nas imediações da EEcA. Uma análise do viés das estimativas de precipitação foi realizada usando dados meteorológicos observados. Dois cenários de estimativa da GWR foram avaliados, bem como o efeito de diferentes faixas de rendimento específico (S_y) adotados no modelo. A GWR no cenário 1 (C1) variou de 10,8% a 19,69% da precipitação observada para o FLDAS, de 18,65% a 38,09% no GLDAS e de 0,36% a 6,11% no TERRACLIMATE, enquanto que no cenário 2 (C2) as variações foram de 0,9 a 13%, de 3,76% a 27,36% e de 0,13% a 3,25%, respectivamente. Quanto as estimativas da WTD , o FLDAS (base com melhor resultado nas métricas de validação do modelo) obteve a Raiz do Erro Médio Quadrático (RMSE) com variação de 0,36 a 1,12 m, e melhores resultados em poços de profundidade média até 15 m.

Palavras-chave: FLDAS. GLDAS. TERRACLIMATE. Recarga das águas subterrâneas. Balanço hídrico. Google Earth Engine.

ABSTRACT

The advent, improvement and popularization of remote sensing by cloud computing such as Google Earth Engine (GEE) has brought new perspectives to modelers, allowing access to reliable and representative data over vast areas. However, several tools are still under-explored and actually used in the water resources planning and decision-making process. The Guarani Aquifer System (GAS) is the largest transboundary groundwater reservoir in South America, yet recharge in the GAS outcrop zones is one of the least known hydrological variables. This work aimed to contribute to understanding of the groundwater recharge process in an outcrop area of the SAG. Through GEE, the use of remote sensing data in the water-budget equation was evaluated to recharge estimation (*GWR*) and groundwater levels modelling (*WTD*). The *WTD* model was adapted from the water table fluctuation method (WTF). Estimated series of precipitation, evapotranspiration and runoff from three hydroclimatic remote sensing based databases (FLDAS, GLDAS and TERRACLIMATE) were obtained from GEE at the location of the Ecological Station of Angatuba (EEcA), in State of São Paulo, from 2014 to 2017. *GWR* and *WTD* were obtained at the location of eight monitoring wells near to EEcA. Bias analysis of precipitation estimates was performed using observed meteorological data. Two *GWR* scenarios were evaluated, as well as the effect of different ranges of specific yield (S_y) adopted. The *GWR* in scenario 1 (C1) ranged from 10.8% to 19.69% of the observed rainfall for FLDAS, from 18.65% to 38.09% for GLDAS and from 0.36% to 6.11% for TERRACLIMATE, while in scenario 2 (C2), the results ranged from 0.9 to 13%, from 3.76% to 27.36% and 0.13% 3.25%, respectively. For *WTD* modelling, using FLDAS data (database with better validation results) the Root Mean Square Error (RMSE) ranged from 0.36 to 1.12 m, with better agreement in wells of medium water depth up to 15 m.

Keywords: FLDAS. GLDAS. TERRACLIMATE. Groundwater Recharge. Water-budget. Google Earth Engine.

LISTA DE FIGURAS

Figura 1 - O balanço hídrico no solo e seus componentes e sua relação com as águas subterrâneas e sistemas aquíferos.....	29
Figura 2 - Mapa de Localização da EEcA	39
Figura 3 - Uso e ocupação da terra na área de estudo	40
Figura 4 - Mapa Altimétrico da área de estudo.....	41
Figura 5 - Mapeamento de declividade da área de estudo.....	42
Figura 6 - Mapa litológico da área de estudo	42
Figura 7 - Mapa pedológico da área de estudo	44
Figura 8 - Uma estrutura metodológica que descreve as etapas adotadas para gerar uma série temporal espacial e temporal de dados de entrada para o balanço hídrico usando a API GEE e o processo de modelagem do nível da água subterrânea, análise de incerteza e validação no ambiente R. ..	45
Figura 9 - Mapa de localização dos poços de monitoramento utilizados	48
Figura 10 - Exemplos de visualização séries temporais de precipitação no Google Earth Engine do FLDAS, GLDAS e TERRACLIMATE na EEcA. (1) editor de código (2) poços de monitoramento no mapa de referência (pontos pretos) e (3) séries temporais de precipitação no console (ícone de exportação destacado em vermelho).	51
Figura 11 - Precipitação mensal acumulada (mm) de janeiro 2000 até dezembro de 2018 observada pelo DAEE e estimada pelo FLDAS, GLDAS E TERRACLIMATE.....	58
Figura 12 - Gráfico de dispersão e análise de correlação entre as estimativas e observações de precipitação durante o período de janeiro de 2000 até dezembro de 2018.....	59
Figura 13 - Estimativas de P, ET e SR das três bases no período de janeiro de 2014 até dezembro de 2017.....	60
Figura 14 - Dispersão mensal e análise de Correlação de Pearson as estimativas de GWR e GWRavg do FLDAS com a GWRref, considerando três valores de rendimento específico (S_y) e uso das séries de precipitação com correção do viés no período de Junho de 2014 até Setembro de 2017.	66
Figura 15 - Dispersão mensal e análise de Correlação de Pearson as estimativas de GWR e GWRavg do GLDAS com a GWRref, considerando três valores de	

rendimento específico (S_y) e uso das séries de precipitação com correção do viés no período de Junho de 2014 até Setembro de 2017..... 67

Figura 16 - Dispersão mensal e análise de Correlação de Pearson as estimativas de GWR e GWRavg do TERRACLIMATE com a GWRref, considerando três valores de rendimento específico (S_y) e uso das séries de precipitação com correção do viés no período de Junho de 2014 até Setembro de 2017..... 68

Figura 17 - Séries FLDAS GWR e GWRavg com limite superior e inferior de incerteza (área sombreada) de Junho de 2014 até Setembro de 2017 e GWRref. A) sem correção do viés da estimativa de precipitação e B) com correção.. 69

Figura 18 - Séries GLDAS GWR e GWRavg com limite superior e inferior de incerteza (área sombreada) de Junho de 2014 até Setembro de 2017 e GWRref. A) sem correção do viés da estimativa de precipitação e B) com correção.. 70

Figura 19 - Séries TERRACLIMATE GWR e GWRavg com limite superior e inferior de incerteza (área sombreada) de Junho de 2014 até Setembro de 2017 e GWRref para comparação. A) sem correção do viés da estimativa de precipitação e B) com correção. 71

Figura 20 - Séries observadas (linhas contínuas) e estimadas (linhas tracejadas) a partir do FLDAS GWRavg nos oito poços de monitoramento da EECA de junho de 2014 até setembro de 2017. 77

Figura 21 - Séries observadas (linhas contínuas) e estimadas (linhas tracejadas) a partir do GLDAS GWRavg nos oito poços de monitoramento da EECA de junho de 2014 até setembro de 2017. 78

Figura 22 - Séries observadas (linhas contínuas) e estimadas (linhas tracejadas) a partir do TERRACLIMATE GWRavg nos oito poços de monitoramento da EECA de junho de 2014 até setembro de 2017..... 79

LISTA DE TABELAS

Tabela 1 - Uso e ocupação da terra, classe de solo e localização geográfica onde estão instalados os poços de monitoramento da EEcA.....	47
Tabela 2 - Descrição e links para acessar as informações dos códigos elaborados no GEE para obter as séries temporais de precipitação, evapotranspiração, escoamento superficial e o balanço hídrico.....	50
Tabela 3 - Séries anuais estimadas de P, ET e SR das três bases hidroclimáticas e precipitação anual observada (DAEE P) de janeiro de 2014 até dezembro de 2017.	61
Tabela 4 - Recarga anual acumulada do FLDAS, GLDAS e TERRACLIMATE pelo balanço hídrico no Cenário 1 (<i>GWR</i>), Cenário 2 (<i>GWRavg</i>) e baseada no WTF (<i>GWRref</i>) no período de Junho de 2014 a Setembro 2017.....	63
Tabela 5 - Comparação entre as estimativas de recarga (Cenário 1 e 2) e WTF (<i>GWRref</i>), considerando diferentes valores de rendimento específico (<i>Sy</i>) e séries de precipitação com correção do viés no período de Junho de 2014 a Setembro de 2017.	65
Tabela 6 - Média, máximo, mínimo e raiz do erro médio quadrático (RMSE) e coeficiente de determinação (R^2) das séries de oscilação dos níveis freáticos modeladas com FLDAS sob 3 diferentes faixas de rendimento específico em relação a séries observadas nos poços de monitoramento no período de junho de 2014 até setembro de 2017.	73
Tabela 7 - Média, máximo, mínimo e raiz do erro médio quadrático (RMSE) e coeficiente de determinação (R^2) das séries de oscilação dos níveis freáticos modeladas do GLDAS em relação a séries observadas nos poços de monitoramento no período de junho de 2014 até setembro de 2017.	74
Tabela 8 - Média, máximo, mínimo e raiz do erro médio quadrático (RMSE) e coeficiente de determinação (R^2) das séries de oscilação dos níveis freáticos modeladas do TERRACLIMATE em relação a séries observadas nos poços de monitoramento no período de junho de 2014 até setembro de 2017.	75

LISTA DE ABREVIATURAS E SIGLAS

ANA	Agência Nacional de Águas
CETESB	Companhia Ambiental do Estado de São Paulo
CHG	Climate Hazards Group
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
DAEE	Departamento de Águas e Energia Elétrica do Estado de São Paulo
EEcA	Estação Ecológica de Angatuba
ENOS	El Niño-Oscilação Sul
ESA CCI	European Space Agencies Climate Change Initiative
FEWS NET	The Famine Early Warning Systems Network
FLDAS	Famine Early Warning Systems Network Land Data Assimilation System
GDAS	Global Data Assimilation System
GEE	Google Earth Engine
GLDAS	Global Land Data Assimilation System
GPM	Global Precipitation Measurement
GRACE	The Gravity Recovery and Climate Experiment
GRDC	Global Runoff Data Center
GSFC	Goddard Space Flight Center
JAXA	Japan Aerospace Exploration Agency
LDT	Land Data Tool Kit
LIS	Land Information System
METRIC	Mapping Evapotranspiration at High Resolution and With Internalized Calibration
MODIS	Moderate Resolution Imaging Spectroradiometer
NASA	National Aeronautics and Space Administration
NCEP	National Centers for Environmental Prediction
NDVI	Índice de vegetação da diferença normalizada
NOAA	National Oceanic and Atmospheric Administration
RFE2	The African Rainfall Estimation version 2.0

RMSE	Raiz do erro médio quadrático
SAFER	Simple Algorithm For Evapotranspiration Retrieving
SAG	Sistema Aquífero Guarani
SEBAL	Surface Energy Balance Algorithm for Land
SIG	Sistemas de informações geográficas
SNUC	Sistema Nacional de Unidades de Conservação da Natureza
SPI	Standardized Precipitation Index
SRTM	Shuttle Radar Topography Mission
SSEBop	Operational Simplified Surface Energy Balance
TERRACLIMATE	Monthly Climate and Climatic Water Balance for Global Terrestrial Surfaces
TRMM	Tropical Rainfall Measurement Mission
UCSB	University of California at Santa Barbara
UNESP	Universidade Estadual Paulista “Júlio de Mesquita Filho”
VIC	Variable Infiltration Capacity
WTF	Método de Flutuação de Nível da Água

LISTA DE SÍMBOLOS

ΔS^{gw}	Armazenamento de água (mm)
h_t	Profundidade de nível freático no tempo t (m)
GWR_{ref}	Recarga das águas subterrâneas baseada no WTF (mm)
S_y	Rendimento específico do aquífero
U_{GWR}	Incerteza associada a estimativa da GWR (mm)
ΔH	Varição do armazenamento de água (mm)
Δt	Intervalo de tempo
GWR	Recarga das águas subterrâneas (mm)
P	Precipitação (mm)
SR	Escoamento superficial (mm)
WTD	Profundidades do nível freático (m)
ET	Evapotranspiração real (mm)
r	Coefficiente de correlação de Pearson
R^2	Coefficiente de determinação

SUMÁRIO

1	INTRODUÇÃO	23
2	OBJETIVO	25
2.1	Objetivos específicos.....	25
3	JUSTIFICATIVA.....	26
4	REVISÃO DE LITERATURA.....	27
4.1	Águas subterrâneas e o balanço hídrico para estimativa da recarga	27
4.2	Sensoriamento remoto no monitoramento e obtenção de dados auxiliares ao estudo das águas subterrâneas.....	30
4.2.1	Famine Early Warning Systems Network (FEWS NET) Land Data Assimilation System (FLDAS)	34
4.2.2	Global Land Data Assimilation System (GLDAS)	35
4.2.3	Monthly Climate and Climatic Water Balance for Global Terrestrial Surfaces (TERRACLIMATE).....	36
5	MATERIAL E MÉTODOS	38
5.1	Descrição da área de estudo	38
5.1.2	Geomorfologia e geologia	40
5.1.3	Hidrogeologia	43
5.1.4	Solos.....	43
5.2	Descrição geral da metodologia	44
5.3	Origem dos dados	46
5.3.1	Monitoramento dos níveis freáticos e precipitação	46
5.3.2	Dados de monitoramento por sensoriamento remoto	48
5.3.3	Computação em nuvem no Google Earth Engine (GEE)	50
5.4	Modelagem das águas subterrâneas	51
5.4.1	Modelagem da recarga pelo método do balanço hídrico.....	51
5.4.2	Modelagem dos níveis freáticos	52
5.5	Incerteza dos componentes do balanço hídrico e validação dos modelos da GWR e WTD	54
6	RESULTADOS E DISCUSSÃO	57
6.1	Precipitação, evapotranspiração e escoamento com base em dados de sensoriamento remoto e monitoramento das águas subterrâneas	57

6.2	Estimativas de recarga	62
6.2.1	Comparação entre a GWR e GWRref e análise de incerteza	64
6.3	Modelagem dos níveis freáticos (WTD).....	72
6.4	Perspectivas e futuros estudos.....	80
7	CONCLUSÕES.....	82
	REFERÊNCIAS	85

1 INTRODUÇÃO

As águas subterrâneas desempenham um papel vital no ciclo universal da água, na manutenção dos ecossistemas terrestres, bem como no suprimento das necessidades antrópicas (GÜNTNER; SCHMIDT; DÖLL, 2007).

O equilíbrio entre as entradas e saídas mútuas dos corpos hídricos e dos sistemas aquíferos de superfície controlam as mudanças no nível das águas subterrâneas (FREEZE; CHERRY, 1979). Observar e analisar estas variações no espaço e no tempo, é necessário para garantir sustentabilidade em seu uso a longo prazo (SILVA; MANZIONE; ALBUQUERQUE FILHO, 2019a).

No entanto, a observação e quantificação por estimativa das propriedades das águas subterrâneas é um grande problema para o gerenciamento dos poços para irrigação, abastecimento industrial e doméstico. A estimativa da recarga e dos níveis de água subterrânea é crucial para gerenciar os recursos hídricos, a fim de garantir a segurança da água para todos os cidadãos e atividades econômicas (LIMAYE, 2017; MOGK; BRUCKNER, 2020). Como recarga entende-se a porção de água que atinge a superfície e penetra pelo solo até atingir a zona saturada (HEALY, 2010). É uma componente importante do balanço hídrico para o gerenciamento sustentável da água, porém de difícil de estimação, pois não pode ser medida diretamente devido à complexidade dos processos que a envolvem (GEMITZI; AJAMI; RICHNOW, 2017).

Dessa forma, a falta de informação a respeito de processos como a recarga gera um desafio técnico-científico, já que a coleta consistente de dados é um requisito fundamental para o projeto de um sistema de monitoramento destinado a refletir uma avaliação representativa da situação dos recursos hídricos (BAALOUSHA, 2010). E como as redes de monitoramento de águas subterrâneas são escassas, diferentes autores apresentam metodologias de estimativa de componentes como a recarga (HEALY; COOK, 2002; WALTER; NECSOIU; MCGINNIS, 2011; NIMMO; HOROWITZ; MITCHELL, 2014; WALKER et al., 2019; PETERSON; FULTON, 2019; SILVA; MANZIONE; ALBUQUERQUE FILHO, 2019a), abordando diferentes escalas de espaço e tempo, associados a diferentes incertezas.

Atualmente, o sensoriamento remoto e o uso de sistemas de informações geográficas (SIG) são uma importante fonte para levantamento de dados auxiliares aos estudos de monitoramento e gerenciamento das águas subterrâneas em locais

com poucos dados observados. Estas tecnologias permitem a obtenção e manipulação de dados e modelos em escalas espacializadas, importantes para estudos em grandes áreas como os sistemas aquíferos. O advento do Big Data, aliado a melhoria contínua das ferramentas e produtos de sensores remotos induzem os pesquisadores a incorporar o máximo possível de informações em suas análises, além das plataformas de computação em nuvem online, como o GEE, que diminuem drasticamente o tempo para acesso e análise das informações em escala global (GORELICK et al., 2017; MANZIONE; CASTRIGNANÒ, 2019).

Neste sentido, vários autores vêm associando dados de sensoriamento remoto aos estudos da recarga das águas subterrâneas. Coelho et al. (2017) utilizaram dados de precipitação da missão TRMM (Tropical Rainfall Measurement Mission) e evapotranspiração do modelo SEBAL (BASTIAANSEN et al., 1998a; BASTIAANSEN et al., 1998b) em imagens do sensor MODIS, para estudar a distribuição da recarga na bacia hidrográfica do Ipanema, localizada no Estado de Pernambuco. Gemitzi, Ajami e Richnow (2017) desenvolveram equações empíricas mensais para estimar recarga com base em dados de modelagem e sensoriamento remoto na bacia do rio Vosvozis, na Grécia. Brito et al. (2019) utilizaram dados de armazenamento de água na superfície da missão GRACE (Gravity Recovery and Climate Experiment) para estudar o efeito do fenômeno El Niño-Oscilação Sul (ENOS) na relação entre precipitação e recarga em uma área de afloramento dos Sistemas Aquíferos Áter do Chão e Trombeta, localizados na Amazônia Central. O termo afloramento refere-se as áreas onde a formação geológica está exposta e os aquíferos não confinados expostos à recarga direta. Wu et al. (2019) utilizaram dados da missão GRACE e do modelo hidroclimático GLDAS para estimar na China, a recarga de forma análoga ao método WTF, na bacia do Ordos. Outros trabalhos que utilizam sensoriamento remoto e técnicas de geoprocessamento para apoiar o entendimento do processo de recarga em diferentes locais podem ser consultados em Henry, Allen e Huang (2011), Yin, Hu e Jiao (2017), Brewington, Keener e Mair (2019), Fallatah et al. (2019), Wang et al. (2019), Chatterjee et al. (2020).

2 OBJETIVO

O objetivo geral deste trabalho foi desenvolver uma nova abordagem para a estimativa da recarga subterrânea em regiões com ausência/escassez de dados, por meio de produtos de sensoriamento remoto e a utilização da ferramenta Google Earth Engine para operações de computação em nuvem.

2.1 Objetivos específicos

Os objetivos específicos deste trabalho compreenderam:

- O desenvolvimento de uma nova abordagem de aplicação de um modelo de estimativa de recarga de águas subterrâneas baseada no balanço hídrico, que utilizou produtos de sensoriamento remoto em uma área de afloramento do SAG.
- Realizar a estimativa da recarga mensal das águas subterrâneas (*GWR*) por sensoriamento remoto e aplicá-la em um modelo de variação nas profundidades do nível freático (*WTD*).
- Avaliar a acurácia dos modelos da *GWR* e *WTD* em comparação com dados observados entre os anos de 2014 e 2017.
- Comparar os resultados desta abordagem com resultados obtidos por outros autores e discutir vantagens e incertezas.

3 JUSTIFICATIVA

Tal projeto torna-se justificável do ponto de vista legal pois vai ao encontro dos objetivos específicos do Plano Nacional de Recursos Hídricos, Lei nº 9.433/97, que visa “melhoria das disponibilidades hídricas, superficiais e subterrâneas, em qualidade e quantidade; a redução de conflitos reais e potenciais pelo uso da água, bem como dos eventos hidrológicos críticos e a percepção da conservação da água como valor socioambiental relevante”. Do ponto de vista científico, a pesquisa é justificável porque o tema dispõe de vasta literatura para subsidiar os referenciais teóricos e apresenta viabilidade técnica, científica e econômica, pela atual facilidade de obtenção e análise de dados espaciais sobre a superfície terrestre mediante sensores remotos, o uso de sistemas de informação geográfica e ferramentas de computação em nuvem, como aquelas que estão disponíveis pelo Google Earth Engine.

4 REVISÃO DE LITERATURA

4.1 Águas subterrâneas e o balanço hídrico para estimativa da recarga

Representando apenas uma pequena porção da quantia de água disponível no planeta, a água doce é um elemento essencial para o sistema terrestre. Sua presença regula e fornece suporte a biodiversidade e a produtividade dos ecossistemas, sendo um recurso indispensável para o desenvolvimento das sociedades humanas e de suas atividades (VÖRÖSMARTY et al., 2004). As águas subterrâneas, parcela de água que permanece no subsolo, representa aproximadamente 30% da água doce disponível no planeta e é uma importante fonte para as mais diversas atividades antrópicas. Assim, a evolução das técnicas para sua obtenção e compreensão se deu a partir do avanço da sociedade humana e sua dependência por este recurso (SHIKLOMANOV; RODDA, 2003; NAUMBURG et al., 2005; MANZIONE, 2015).

No caso brasileiro, conforme a Agência Nacional de Águas (ANA) (2010), 39% dos municípios brasileiros já eram abastecidos, de maneira exclusiva, por águas subterrâneas. No Estado de São Paulo, segundo relatório da Companhia Ambiental do Estado de São Paulo (CETESB), em 1997 aproximadamente 72% de seus 645 municípios já utilizavam este recurso de forma mista ou exclusiva para suprir as suas demandas de abastecimento público. Em 2007, estes números já eram aproximadamente 80% e atualmente, seguem aumentando de acordo com o crescimento populacional e a grande demanda por captação privada de água doce (CETESB, 1997; CETESB, 2016).

Baseada nesta demanda crescente, as boas práticas de gestão das águas subterrâneas são necessárias para garantir o uso sustentável deste precioso recurso. Uma boa gestão dos recursos hídricos depende de práticas regulamentadoras do uso controlado, medidas de proteção definidas em função das normas e, em conformidade as legislações pertinentes. Na prática, as águas subterrâneas são mais complexas de serem geridas em relação aos corpos hídricos superficiais, visto que não é encontrada de forma visível no ambiente, fator que dificulta o entendimento de sua dinâmica e a detecção de processos nocivos (MANZIONE, 2015). Neste sentido, o conhecimento técnico científico sobre os processos naturais que envolvem as águas subterrâneas, além de atividades antrópicas que o impactam, é necessário para que uma gestão

correta possa ser entendida e aplicada em um cenário de cada vez maior dependência e pressão sobre os recursos hídricos subterrâneos.

Um dos processos mais importantes no ciclo das águas subterrâneas é a recarga, que pode ser definida como o fluxo descendente de água que chega ao lençol freático e aumenta seu armazenamento. Sua estimativa é necessária para o gerenciamento adequado dos recursos hídricos subterrâneos e, portanto, existem muitas abordagens diferentes para se obtê-la. Embora seja um dos componentes mais importantes nos estudos das águas subterrâneas, a recarga também é uma das menos compreendidas, principalmente porque suas taxas variam amplamente no espaço e no tempo, o que faz da medição direta um processo muito difícil (HEALY; COOK, 2002; HEALY, 2010).

O balanço hídrico pode ser usado para estimar a recarga de forma indireta ou “residual”. Sua definição obedece ao princípio da conservação da massa ou princípio da continuidade, no qual em um sistema qualquer, a diferença entre as entradas e as saídas é igual à variação do armazenamento no sistema. Isso permite adicionar ou remover termos para retratar com precisão as peculiaridades do sistema hidrológico estudado. Nesta abordagem, todas as variáveis do balanço hídrico devem ser conhecidas, medidas ou estimadas, exceto a recarga (GWR) que é definida como resíduo da equação (SCANLON; HEALY; COOK, 2002; MANOEL FILHO, 2008; HEALY, 2010).

Um exemplo da aplicação do balanço hídrico para estimar a recarga em uma região, como por exemplo uma bacia hidrográfica, pode ser descrita como:

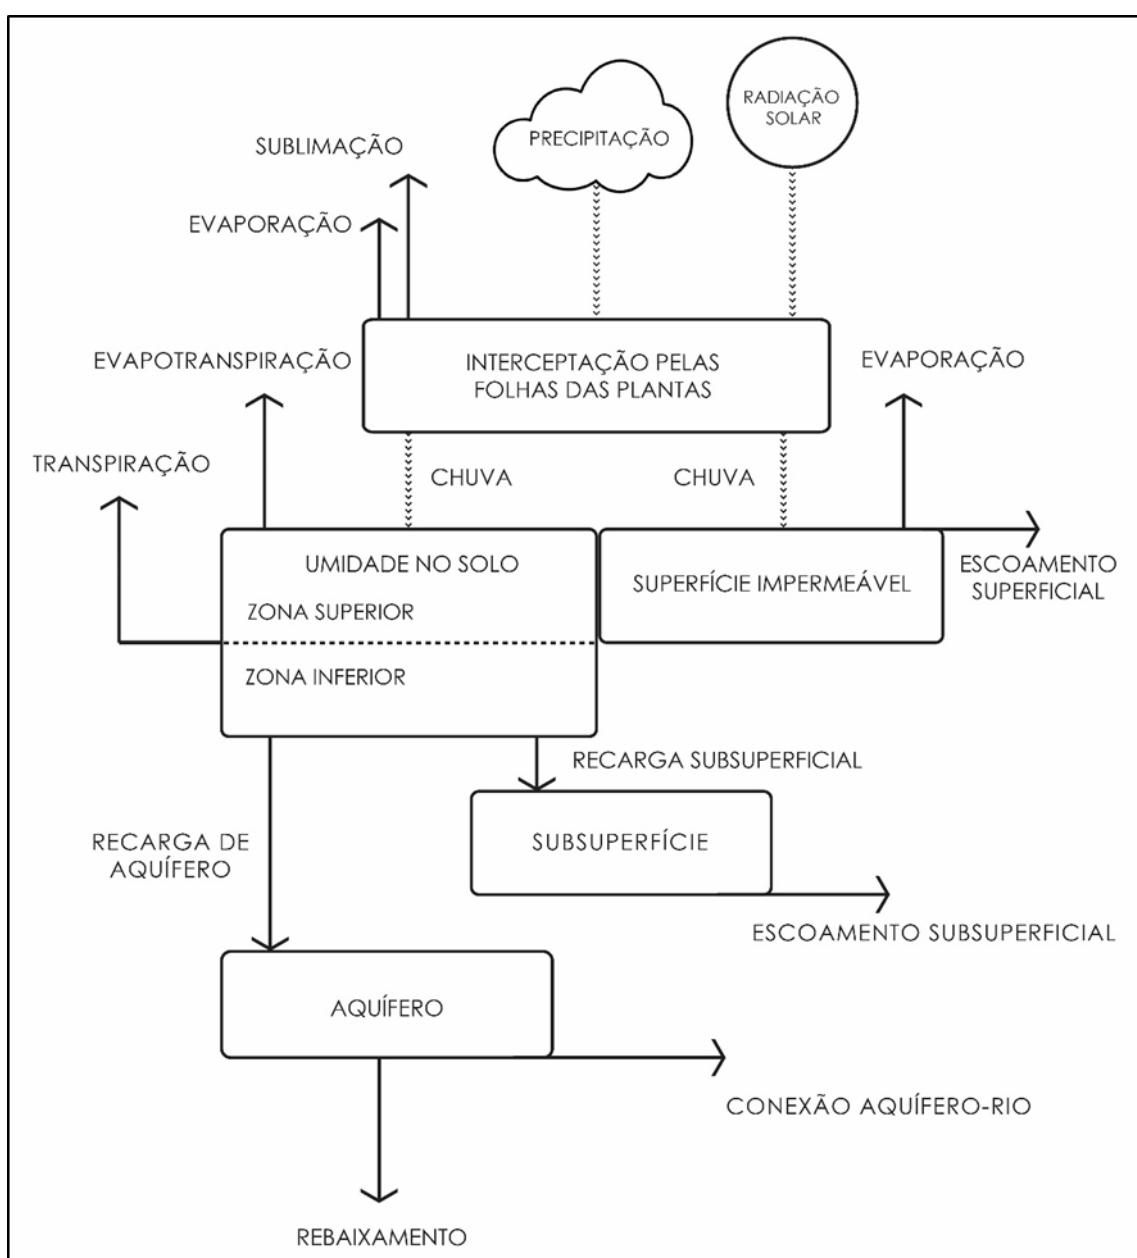
$$\Delta S = P - ETa - SR - GWR \quad (1)$$

onde:

- ΔS é igual à variação do armazenamento de água no solo (mm),
- GWR é a recarga das águas subterrâneas (mm),
- P corresponde a precipitação (mm),
- ETa é a evapotranspiração real (mm), e
- SR é o deflúvio ou escoamento superficial (mm).

O balanço hídrico, como mostrado na Equação 1, é apenas um exemplo simplificado. Na prática vários outros processos podem ser adicionados como fatores que influenciam a variação do armazenamento de água no perfil de solo, como a água de irrigação, efeito da vegetação (volumes interceptados pelas raízes), capilaridade, escoamentos subsuperficiais, entre outros. A Figura 1 apresenta o conceito de Healy (2010), sobre o impacto dos componentes do balanço hídrico no solo na recarga das águas subterrâneas em um ambiente subtropical, adaptado por Silva (2019).

Figura 1 - O balanço hídrico no solo e seus componentes e sua relação com as águas subterrâneas e sistemas aquíferos



Fonte: Silva (2019)

Na prática, apesar de ser de “fácil compreensão”, o balanço hídrico tem suas incertezas associadas a capacidade de se medir ou estimar os termos da equação. Quanto mais termos são inseridos, maior torna-se a incerteza. Outro ponto é que taxas de recarga calculadas por esta abordagem devem ser consideradas como o “potencial de recarga” que pode não atingir completamente o lençol freático, dada a presença da zona de umidade do solo e a perdas por processos como a evapotranspiração, entre outros que impedem que a água percole profundamente e abasteça o sistema aquífero (CHRISTOFOLETTI, 1999; MANOEL FILHO, 2008; SILVA; MANZIONE; ALBUQUERQUE FILHO, 2019a).

4.2 Sensoriamento remoto no monitoramento e obtenção de dados auxiliares ao estudo das águas subterrâneas

Por se tratar de um recurso valioso e limitado, a disponibilidade das águas subterrâneas, em quantidade e qualidade, depende de medidas de proteção. Assim, o monitoramento, caracterizado por procedimentos sistemáticos de coleta, armazenamento, análise e interpretação dos dados, se faz fundamental para avaliar a situação atual dos sistemas aquíferos, bem como o desenvolvimento de ações de gerenciamento. Frente a isso, o monitoramento dos processos que podem influenciar as taxas recarga, assim como oscilações nos níveis freáticos, se fazem importantes para acompanhar a evolução/recuperação de rebaixamentos, determinar vazões seguras para a exploração, auxiliar a elaboração de modelos conceituais e numéricos, avaliar vulnerabilidades a contaminações, interações entre uso e ocupação da terra e o corpo hídrico subterrâneo, entre outras variáveis que auxiliem no entendimento da dinâmica dos sistemas (MESTRINHO, 2008; MANZIONE, 2015).

Na hidrogeologia, área do conhecimento que reúne os conhecimentos e diferentes abordagens científicas para o estudo das águas subterrâneas, pesquisadores tem cada vez mais utilizado dados de monitoramento terrestre por sensores remotos como ferramenta auxiliar na compreensão dos fenômenos ligados ao ciclo da água, como sua distribuição geográfica e disponibilidade global. O sensoriamento remoto consiste na medição ou aquisição de informações sobre determinado objeto ou fenômeno, sem a necessidade do contato físico com o meio estudado (JENSEN; EPIPHANIO, 2011), permitindo a geração de dados auxiliares no monitoramento de áreas em diferentes escalas espaciais e temporais, podendo ser

usado nos estudos hidrológicos e climáticos, gerando informação de grande valor para aprimorar a gestão/monitoramento das águas subterrâneas.

Um exemplo dos avanços propiciados pelo sensoriamento remoto nos estudos hidrogeológicos é missão GRACE, lançada em março de 2002, que mapeou as variações no campo gravitacional terrestre, a partir de análises destas variações devido a correntes superficiais e profundas dos oceanos, escoamento superficial e armazenamento das águas subterrâneas em massas terrestres, trocas entre camadas de gelo, geleiras e o oceano, além de variações de massa dentro da Terra (SWENSON, 2012). Landerer e Swenson (2012), avaliaram a acurácia das estimativas da variação do armazenamento de água terrestre (TWS) do GRACE, além de outros estudos ligados as águas subterrâneas, como a comparação do TWS com oscilações dos níveis freático observados em algumas bacias hidrográficas brasileiras (MATOS et al., 2012) e estimativas de recarga em diferentes países, como nos Estados Unidos da América (MIRO; FAMIGLIETTI, 2018), na China (WU et al., 2019) e na Índia (CHATTERJEE et al., 2020). Mais informações sobre o uso dos dados da missão GRACE em estudos hidrológicos podem ser vistas em Swenson e Wahr (2006), Scanlon et al. (2012) e Vishwakarma, Devaraju e Sneeuw (2018).

Além de avaliar o campo gravitacional, satélites e sensores também tem conseguido monitorar com precisão fenômenos e variáveis do clima, dados de grande valor para o estudo das águas subterrâneas. Um exemplo notável é a missão Tropical Rainfall Measuring Mission (TRMM) desenvolvida pelas agências governamentais National Aeronautics and Space Administration (NASA) e a Japan Aerospace Exploration Agency (JAXA), que foi projetada para monitorar e estudar as chuvas tropicais (HUFFMAN et al., 2009). Outro exemplo mais atual, já que a missão TRMM foi finalizada, é a Global Precipitation Measurement (GPM), missão de cooperação internacional para fornecer estimativas de precipitação e neve em todo o mundo a cada três horas (HUFFMAN et al., 2019). Modelos de estimativa de evapotranspiração partir da associação de imagens multiespectrais com dados climatológicos como o Surface Energy Balance Algorithm for Land (SEBAL) (BASTIAANSEN et al., 1998a; BASTIAANSEN et al., 1998b), também o Mapping Evapotranspiration at High Resolution and With Internalized Calibration (METRIC) (ALLEN et al., 2005) e o Simple Algorithm For Evapotranspiration Retrieving (SAFER) (TEIXEIRA, 2010), também vem sendo aprimorados ao longo das últimas duas décadas.

Recentemente, a Agência Nacional de Águas (ANA) lançou um estudo inédito de estimativa de evapotranspiração real através da automatização do modelo Operational Simplified Surface Energy Balance (SSEBop) (SENAY, 2018) com uso da API do Google Earth Engine (ANA, 2020). O produto é gerado para o todo o território brasileiro, que ainda carece de dados sobre evapotranspiração, que são essenciais na gestão hídrica levando em conta a demanda de uso da água pela agricultura irrigada (ver Silva, Manzione e Albuquerque Filho (2019b) para uma revisão de produtos de sensoriamento remoto para o manejo da irrigação) além de auxiliar outros estudos hidrológicos. Silva, Teixeira e Manzione (2019) criaram o pacote “agriwater” em ambiente de trabalho R para propiciar a aplicação do SAFER em imagens do satélite/sensor SENTINEL2/MSI, LANDSAT8/OLI e TERRA e AQUA/MODIS, usado por Silva, Manzione e Albuquerque Filho (2019a) para estimar a evapotranspiração real a nível de resolução espacial do pixel, em bacias hidrográficas no Estado de São Paulo, e usá-la na estimativa de recarga do Sistema Aquífero Bauru em uma abordagem com uso do balanço hídrico. Em outro estudo sobre o processo de recarga, Lucas et al. (2015) usou dados de precipitação estimados do produto TRMM 3B42 V7, da missão TRMM, e estimativas de evapotranspiração real do produto MOD16 (RUNNING; MU; ZHAO, 2017), a partir de imagens do sensor MODIS, para modelar a recarga e levantar incertezas associadas pelo método do balanço hídrico em uma bacia hidrográfica, localizada em área de afloramento do Sistema Aquífero Guarani (SAG) no Estado de São Paulo, comparando os resultados com os obtidos por outros métodos. Melati, Fan e Athayde (2019) também usaram dados do MOD16 em estudo sobre recarga das águas subterrâneas em duas bacias hidrográficas.

Como vem sendo discutido, grande é o potencial de aplicações dos produtos de sensoriamento remoto em estudos relacionados as águas subterrâneas já que grande quantidade de dados estimados por satélites e sensores estão atualmente amplamente disponíveis para análise. No entanto, realizar operações com esse grande número de dados também se torna um desafio, sendo essencial armazená-los de maneira organizada e eficiente. Além do armazenamento de dados, deve ser possível chamar e aplicar algoritmos a esses conjuntos de dados (processamento e geração de produtos). Por esse motivo, ferramentas de computação em nuvem, como o Google Earth Engine (GEE), estão ganhando mais visibilidade e interesse dentro das comunidades científicas que trabalham com geotecnologias.

O GEE é uma plataforma para o processamento de imagens de satélite em escala global que remonta 40 anos de dados de observação da Terra. Ele permite que os usuários baixem e carreguem imagens de satélite globais, além de realizar cálculos complexos sobre as mesmas. Esta ferramenta é composta por dois componentes principais que funcionam em sincronia, o Google Earth Engine Explorer (EE) (para visualizar conjuntos de dados) e o Google Earth Engine Playground (EEP). Plataformas de computação em nuvem *online*, como o GEE, facilitam o acesso e a análise de bancos de dados de sensoriamento remoto em escala global (GORELICK et al., 2017). A coleção de imagens de dados detectados remotamente por satélites como LANDSAT, TERRA/AQUA, SENTINEL, dados das missões GRACE, TRMM, GPM, produtos de evapotranspiração como o MOD16, e modelos hidroclimáticos como o Famine Early Warning Systems Network (FEWS NET) Land Data Assimilation System (FLDAS) (MCNALLY et al., 2017), Global Land Data Assimilation System (GLDAS) (RODELL et al., 2004) e Monthly Climate and Climatic Water Balance for Global Terrestrial Surfaces (TERRACLIMATE) (ABATZOGLOU, 2018), que reúnem diferentes variáveis físicas e climatológicas estimadas por diferentes métodos e produtos de sensoriamento remoto, são alguns dos exemplos de bancos de dados disponíveis na plataforma e que podem auxiliar estudos hidrológicos e hidrogeológicos.

Os multimodelos hidroclimáticos FLDAS, GLDAS e TERRACLIMATE, citados acima, reúnem produtos de diferentes variáveis de interesse hidrológicos, agrometeorológicos e hidrogeológicos, como estimativas de precipitação, evapotranspiração, escoamento superficial, umidade do solo e outras que podem auxiliar no entendimento do balanço hídrico da água. Atualmente, em comparação a outros produtos de sensoriamento remoto, poucos estudos na literatura avaliam o uso destas bases hidroclimáticas para a estimativa de recarga das águas subterrâneas. Fato que, aliado ao grande potencial do GEE para manuseio destas informações propiciou a iniciativa de realização deste trabalho. Assim, nas próximas seções estas três bases de dados serão melhor discutidas.

4.2.1 Famine Early Warning Systems Network (FEWS NET) Land Data Assimilation System (FLDAS)

The Famine Early Warning Systems Network (FEWS NET) Land Data Assimilation System (FLDAS) foi desenvolvido com recursos do Applied Sciences Program Water Resources da National Aeronautics and Space Administration (NASA) em colaboração com o United States Geological Survey (USGS) Earth Resources Observation and Science (EROS), NASA Goddard Space Flight Center (GSFC), e a University of California at Santa Barbara (UCSB) - Climate Hazards Group (CHG). Inclui estimativas de vários modelos e forçantes hidroclimáticas por diferentes fontes de dados de entrada, como produtos de sensoriamento remoto, projetados para ajudar a garantir a segurança alimentar em países com dados escassos como os do continente africano. Os dados modelados e produtos derivados, como percentis de umidade do solo e disponibilidade de água foram projetados e atualmente complementam as observações operacionais de chuvas, evapotranspiração e vegetação da FEWS NET, detectadas remotamente. Mais de 30 anos de saídas mensais das simulações FLDAS estão disponíveis ao público no Goddard Earth Sciences Data and Information Services Center (GES DISC) da NASA, e atualmente no GEE, e são recomendados para uso em estudos de hidroclimáticos (MCNALLY et al., 2017; MCNALLY et al., 2019).

O Land Data Tool Kit (LDT) (ARSENAULT et al., 2018) é usado para pré-processar os parâmetros da cobertura terrestre do FLDAS da classificação IGBP land cover classification (BELWARD, ESTES E KLINE, 1999) e UMD Global land cover classification (HANSEN, et al., 1998; HANSEN et al., 2000), que são derivados dos instrumentos MODIS e AVHRR, respectivamente. Se necessário para resolver equações de balanço de energia, o LDT transforma as chuvas diárias do The African Rainfall Estimation version 2.0 (RFE2) (NOVELLA e THIAW, 2013) e CHIRPS (FUNK et al., 2015) em entradas sub-diárias para os modelos de superfície terrestre. Entradas meteorológicas adicionais são do National Oceanic and Atmospheric Administration (NOAA) Global Data Assimilation System (GDAS) (DERBER; PARRISH; LORD, 1991) e NASA's Modern Era Reanalysis (MERRA2) (GELARO et al., 2017). O FLDAS inclui os modelos Noah (MCNALLY e NASA/GSFC/HSL, 2018), Variable Infiltration Capacity (VIC) e GeoWRSI, que são executados em três domínios na África, e produz estimativas de estados hidrológicos como umidade do solo, escoamentos superficiais

e subsuperficiais, evapotranspiração e outros. As saídas do modelo são usadas como entradas para o Land Verification Toolkit (LVT) (KUMAR et al., 2012) para avaliação ou geração de índices de seca. A avaliação inclui anomalias de ET detectadas remotamente a partir do modelo SSEBop, umidade do solo do produto CCI-SMv2.2 da European Space Agencies Climate Change Initiative (ESA CCI) (<http://cci.esa.int/>) e o Índice de vegetação da diferença normalizada (NDVI) (ROUSE et al., 1973), bem como observações do Global Runoff Data Center (GRDC) (GRDC, 2014). O FLDAS calcula rotineiramente os percentis de umidade do solo e possui recursos para calcular o Standardized Precipitation Index (SPI) (MCKEE, DOESKEN, E KLEIST, 1993) e outros. Atualmente, os dados do FLDAS Noah L4 estão disponíveis em escala temporal mensal e resolução espacial de 0.1 graus com cobertura global no GEE ([link](#)) (MCNALLY e NASA/GSFC/HSL, 2018).

4.2.2 Global Land Data Assimilation System (GLDAS)

O Global Land Data Assimilation System (GLDAS) (RODELL et al., 2004) foi desenvolvido em conjunto por cientistas da GSFC da NASA, National Oceanic and Atmospheric Administration (NOAA) e National Centers for Environmental Prediction (NCEP). Tem como objetivo processar produtos de dados observacionais baseados em satélite e no solo, usando técnicas de modelagem da superfície terrestre e de assimilação de dados, para gerar campos de estados e fluxos da superfície terrestre. O software, que foi simplificado e paralelizado pelo projeto irmão LIS (Land Information System), dirige vários modelos de superfície terrestre e integra uma enorme quantidade de dados baseados em observação, que são executados globalmente em altas resoluções e capazes de produzir resultados em tempo quase real (RODELL, 2020). O GLDAS tem parâmetros de solo baseados em conjuntos de dados globais de alta resolução de Reynolds, Jackson e Rawls (2000), um conjunto de dados que inclui informação sobre frações de areia, silte e argila e porosidade, entre outros campos, e é baseado no mapa mundial de solo da FAO, vinculado a um banco de dados global de mais de 1300 núcleos de amostra de solo. Dados de elevação são definidos pelo GTOPO30 (VERDIN; GREENLEE, 1996), com os campos de forçantes meteorológicas (temperatura, pressão, umidade e radiação de ondas longas) ajustados para diferenças na elevação do GLDAS e na respectiva altura do terreno do modelo. Parâmetros de cobertura terrestre são obtidos atualmente usando os

conjuntos de dados da superfície terrestre do sensor MODIS, que monitora o uso e ocupação da terra segundo o IGPB land cover classification. Algumas análises da vegetação utilizadas no GLDAS são o Leaf Area Index (LAI) e Canopy greenness fraction (fg).

Produtos de precipitação com base em observação e radiação descendente, como o TRMM 3B42 V7 (TRMM, 2011), NOAA/CPC CMORPH Precipitation (JOYCE et al., 2004) e PERSIANN Precipitation (NGUYEN et al., 2018) entre outras, e análises disponíveis em sistemas de assimilação de dados atmosféricos como NASA's Goddard EOS Data Assimilation System (GEOS) e NCEP's Global Data Assimilation System (GDAS), e outros, são empregadas para forçar os modelos. Atualmente, técnicas de assimilação de dados para incorporar produtos hidrológicos baseados em satélite, incluindo cobertura de neve e água equivalente, umidade do solo, temperatura da superfície e índice de área foliar, estão sendo implementadas. As suas estimativas globais sobre a superfície da terra auxiliam em previsões sobre clima, estudos hidrológicos e investigações do ciclo da água. O GLDAS resultou em um enorme arquivo de dados meteorológicos de superfície modelados e observados, globais, mapas de parâmetros e resultados, com diferentes resoluções e simulações com uso dos modelos Noah (BEAUDOING, RODELL e NASA/GSFC/HSL, 2020a), CLM (RODELL; BEAUDOING; NASA/GSFC/HSL, 2007a), VIC (BEAUDOING; RODELL; NASA/GSFC/HSL, 2020b), Mosaic (RODELL; BEAUDOING; NASA/GSFC/HSL, 2007b) e Catchment (LI et al. 2018) (RODELL et al., 2004). Atualmente, 20 anos de dados do GLDAS Noah L4 estão disponíveis em escala temporal de 3 horas e resolução espacial de 0,25 graus com cobertura global no GEE ([link](#)) (BEAUDOING; RODELL; NASA/GSFC/HSL, 2020a).

4.2.3 Monthly Climate and Climatic Water Balance for Global Terrestrial Surfaces (TERRACLIMATE)

O TERRACLIMATE é um conjunto de dados do balanço mensal climático e da água para a superfícies terrestre global (ABATZOGLOU et al., 2018). Esses dados fornecem informações importantes para estudos ecológicos e hidrológicos em escalas globais que exigem alta resolução espacial e dados variáveis no tempo. Este modelo usa interpolação, combinando normais climatológicas de alta resolução espacial do conjunto de dados WorldClim (<https://worldclim.org>), com resolução espacial mais

grosseira, mas com dados variáveis no tempo do CRU TS 4.0 (HARRIS et al., 2020) e a japonesa JRA-55 (ONOGI et al., 2007; EBITA et al., 2011). Conceitualmente, o procedimento aplica interpolação de anomalias variadas no tempo do CRU TS 4.0 e JRA55 à climatologia de alta resolução espacial do WorldClim, para poder criar um conjunto de dados de alta resolução espacial que cobre um registro temporal mais amplo. As informações temporais do CRU TS 4.0 são herdadas para a maioria das superfícies terrestres globais em variáveis como temperatura, precipitação e pressão de vapor. No entanto, os dados do JRA55 são usados para regiões onde os dados da CRU tiveram zero estações climáticas contribuindo (incluindo toda a Antártica e partes da África, América do Sul e ilhas dispersas). Para variáveis climáticas primárias de temperatura, pressão de vapor e precipitação, fornece informações adicionais sobre o número de estações (entre 0 e 8) que contribuiriam com dados do CRU TS 4.0 usados pelo TERRACLIMATE. Os dados do JRA55 foram usados exclusivamente para estimar radiação solar e velocidade do vento.

Finalmente, o TERRACLIMATE produz adicionalmente conjuntos mensais de dados do balanço hídrico superficial, usando um modelo que incorpora evapotranspiração de referência, precipitação, temperatura e capacidade de água extraível do solo pela vegetação interpolada. O modelo de balanço hídrico climático Thornthwaite-Mather modificado e dados de capacidade de armazenamento de água no solo extraíveis são usados em uma grade de 0,5 graus de Wang-Erlandsson et al. (2016). Atualmente, os dados do TERRACLIMATE estão disponíveis em escala temporal mensal e resolução espacial de aproximadamente 4 km com cobertura global no GEE ([link](#)) de 1958 até o presente (ABATZOGLOU et al., 2018).

5 MATERIAL E MÉTODOS

5.1 Descrição da área de estudo

Criada pelo Decreto Estadual nº 23.790 de 13/08/1985 a Estação Ecológica de Angatuba (EEcA) está localizada entre as cidades de Angatuba e Guareí no Estado de São Paulo, Região Sudeste do Brasil, nas coordenadas 23° 24 '22 "sul e 48° 20' 53" oeste (Figura 2). Possui extensão de 1.394,4 ha e atualmente é considerada como Unidade de Conservação de Proteção Integral pelo Sistema Nacional de Unidades de Conservação da Natureza - SNUC (Lei Federal 9.985/00).

O uso predominante da terra na EEcA é a vegetação natural (Cerrado). Nas proximidades da EEcA, há silvicultura (eucaliptos e pinheiros) e outras atividades agrícolas, como pastagens para gado (Figura 3) (MAPBIOMAS, 2019). Segundo a classificação de Köppen-Geiger, o clima na região é clima subtropical úmido com invernos secos (Cwa). A temperatura média mensal varia de aproximadamente 22 °C no verão a 18° C no inverno. As distribuições de chuva mais intensas ocorrem na primavera e no verão. A precipitação anual e evapotranspiração na EEcA são em média de 1.325,7 mm.ano⁻¹ e 1.019,9 mm.ano⁻¹, respectivamente (MONTEIRO; PRADO; DIAS, 2009).

A EEcA foi escolhida como área experimental para elaboração deste trabalho pois tem: “finalidade de assegurar a integridade dos ecossistemas ali existentes e de proteger sua flora e fauna, bem como sua utilização para objetivos educacionais e científicos” (OLIVEIRA; XAVIER; SANTOS, 2006).

Figura 2 - Mapa de Localização da EEcA

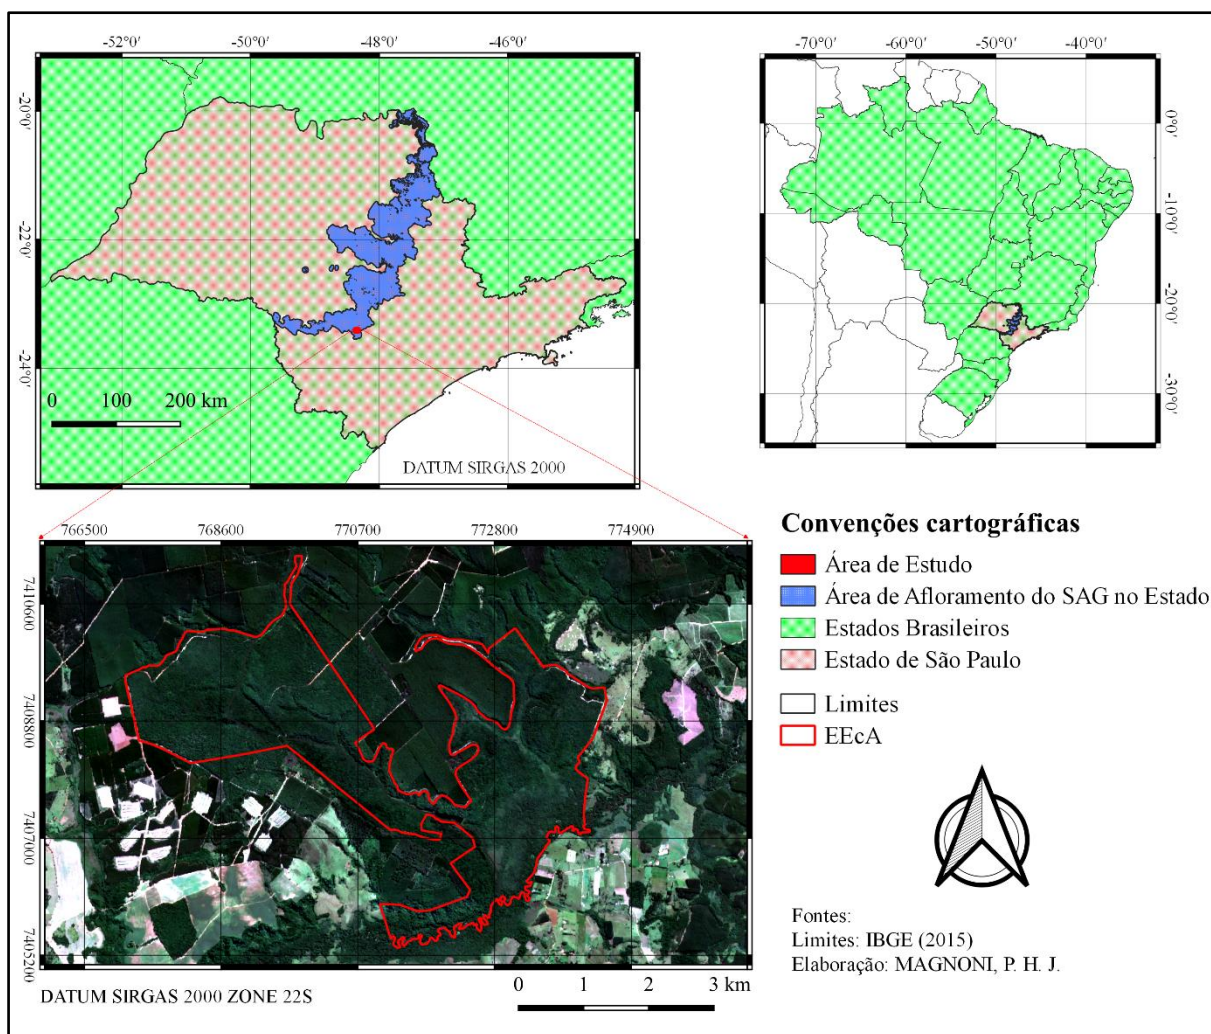
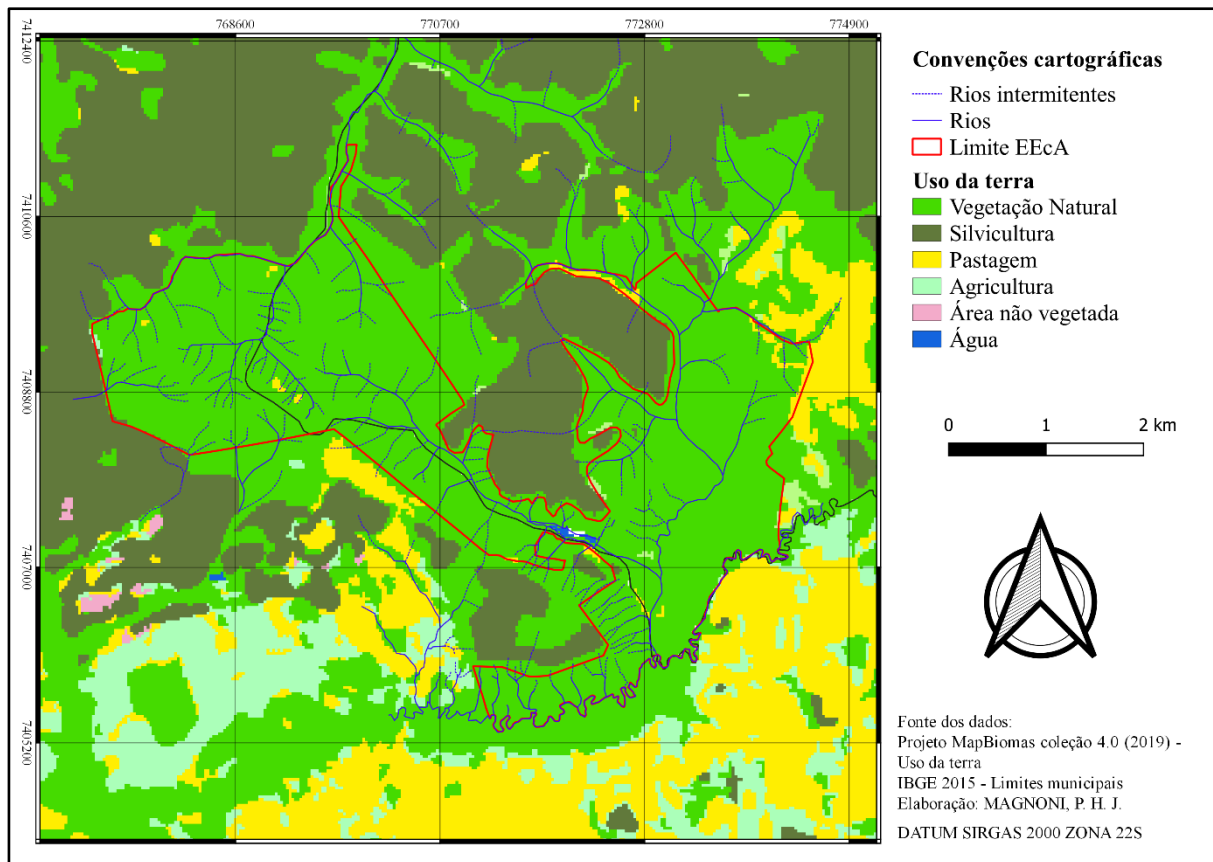


Figura 3 - Uso e ocupação da terra na área de estudo



5.1.2 Geomorfologia e geologia

A Estação Ecológica de Angatuba tem altitudes que variam de aproximadamente 580 metros próximas ao Rio Guareí e a 820 metros no Morro da Conquista (Figura 4). No relevo local predominam os declives ondulados e forte ondulados (Figura 5). As declividades planas e suave onduladas são encontradas na planície fluvial do Rio Guareí e nos topos aplanados das colinas sustentados por arenitos Pirambóia. Por sua vez, as declividades maiores são observadas nas bacias do córrego da Conquista e ribeirão do Sargento, em área de ocorrência de rochas intrusivas básicas (MONTEIRO; PRADO; DIAS, 2009).

Quanto a caracterização geológica, a EEcA está localizada na parte nordeste da Bacia Sedimentar do Paraná, com presença de sedimentos da Formação Piramboia, Grupo São Bento, e de forma secundária, rochas Intrusivas Tabulares Básicas. Depósitos de sedimentos aluviais também estão presentes na estação ao longo do Rio Guareí (Figura 6). A Formação Pirambóia caracteriza-se por uma sucessão de camadas arenosas mais comumente vermelhas, depositadas em

ambiente fluvial no Mesozoico, seus arenitos são predominantes na estação com cerca de 1.019,82 ha (MONTEIRO; PRADO; DIAS, 2009; INSTITUTO DE PESQUISAS TECNOLÓGICAS, 1981).

Figura 4 - Mapa Altimétrico da área de estudo

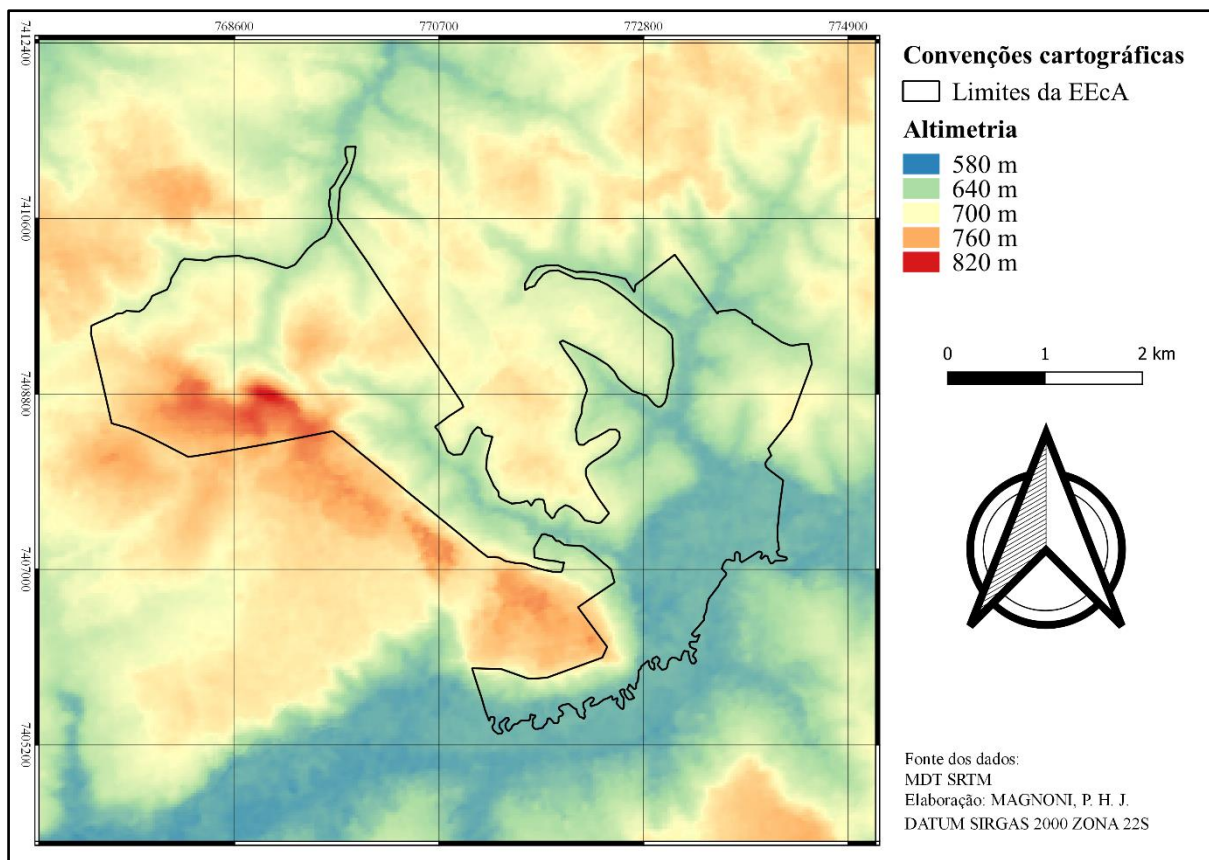


Figura 5 - Mapeamento de declividade da área de estudo

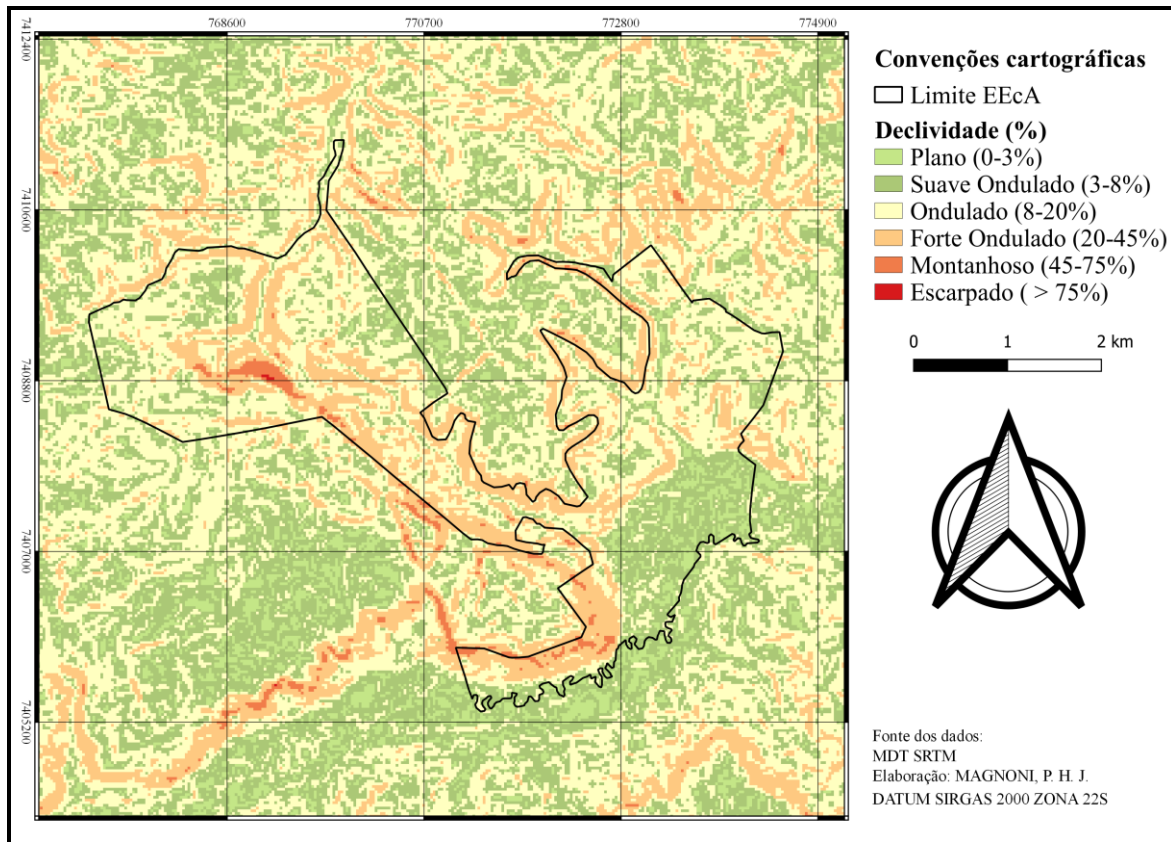
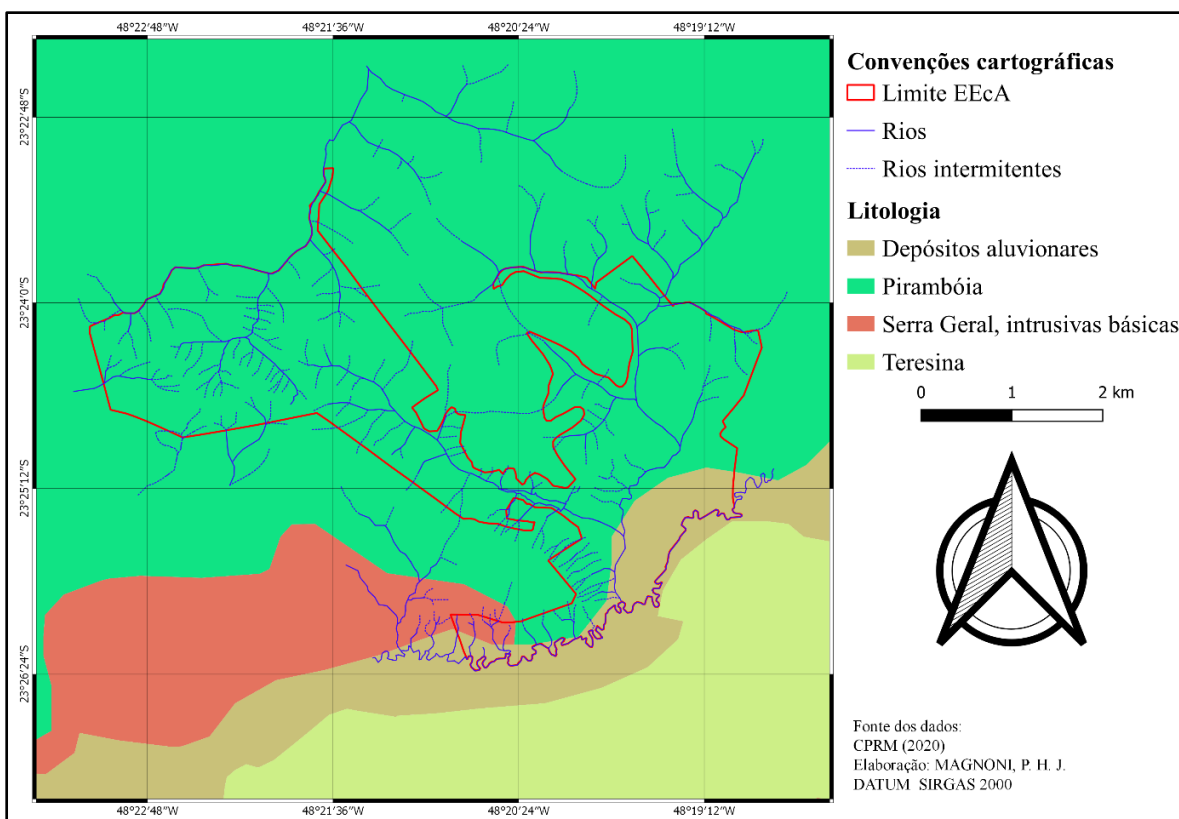


Figura 6 - Mapa litológico da área de estudo



5.1.3 Hidrogeologia

A EECA está localizada sob área de zona de afloramento do Sistema Aquífero Guarani (SAG) no Estado de São Paulo, o maior reservatório transfronteiriço de água subterrânea da América do Sul (Figura 2). O SAG é granular, homogêneo e regionalmente livre na sua porção aflorante, a dominantemente confinado, constituindo um pacote contínuo desde sua área de afloramento, a leste, até o extremo oeste de São Paulo, onde extrapola os limites do Estado. O aquífero abrange cerca de 76% de seu território e é composto na base por arenitos da Formação Pirambóia, e no topo, pela Formação Botucatu (DAEE; IG; IPT; CPRM, 2005).

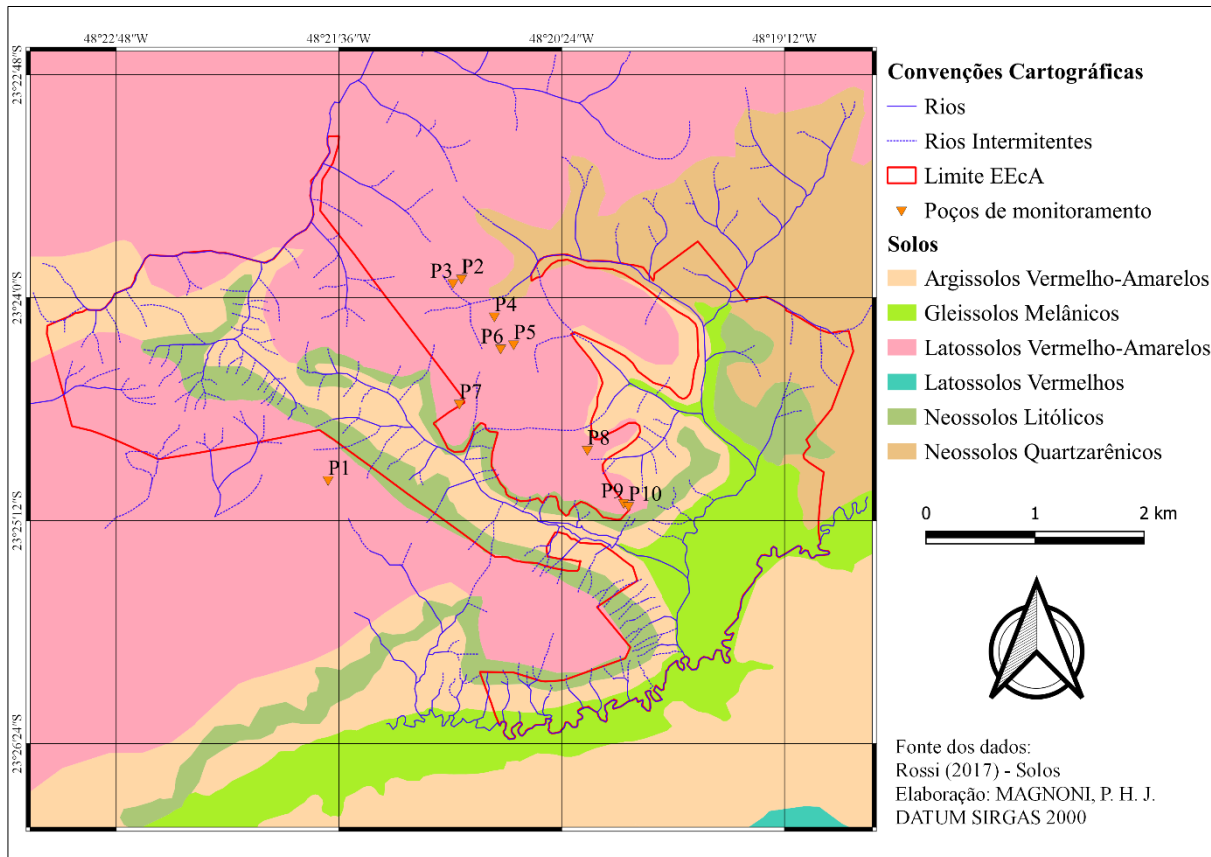
As condutividades hidráulicas médias do SAG no Estado como um todo são de $2,5 \text{ m.dia}^{-1}$ para a Formação Pirambóia e $3,5 \text{ m.dia}^{-1}$ para a Botucatu. Na área confinada, os valores médios obtidos são de $2,6 \text{ m.dia}^{-1}$ e $3,0 \text{ m.dia}^{-1}$ para a porção livre. O rendimento específico médio da porção livre do aquífero é de 0,15 para a Formação Pirambóia e 0,25 para a Formação Botucatu. Na porção confinada, a média não foi calculada pela inexistência de valores definidos para cada uma das formações. A transmissividade é de de aproximadamente $260 \text{ m}^2.\text{dia}^{-1}$ na área aflorante, aumentando progressivamente para oeste até atingir valores superiores a $1200 \text{ m}^2.\text{dia}^{-1}$ na parte confinada e as faixas de vazão explorável são de: 40 a $80 \text{ m}^3.\text{h}^{-1}$, no sistema livre e de 80 a $120 \text{ m}^3.\text{h}^{-1}$, 120 a $250 \text{ m}^3.\text{h}^{-1}$ e 250 a $360 \text{ m}^3.\text{h}^{-1}$, no sistema confinado (DAEE; IG; IPT; CPRM, 2005).

5.1.4 Solos

O Mapa (Figura 7) com os tipos de solos presentes na área de estudo foi elaborado segundo estudos de Rossi (2017). Estes são os Argissolos Vermelhos-Amarelos, Gleissolos Melânicos, Latossolos Vermelhos-Amarelos, Neossolos litólicos e Neossolos Quartzarênicos. Os poços de monitoramento usados no estudo encontram-se sob áreas da ocorrência dos Latossolos Vermelho-Amarelos. Estes são solos minerais, profundos, porosos e bem drenados, com características físicas favoráveis ao desenvolvimento radicular. Tem baixa fertilidade natural, baixa capacidade de troca de cátions e baixa saturação por bases. Apresentam textura média, e normalmente encontram-se sob relevo plano a suave ondulado e ocorrem associados aos Neossolos Quartzarênicos órticos típicos nos relevos de Topos,

Colinas e Rampas, sob os arenitos da Formação Pirambóia (MONTEIRO; PRADO; DIAS, 2009).

Figura 7 - Mapa pedológico da área de estudo



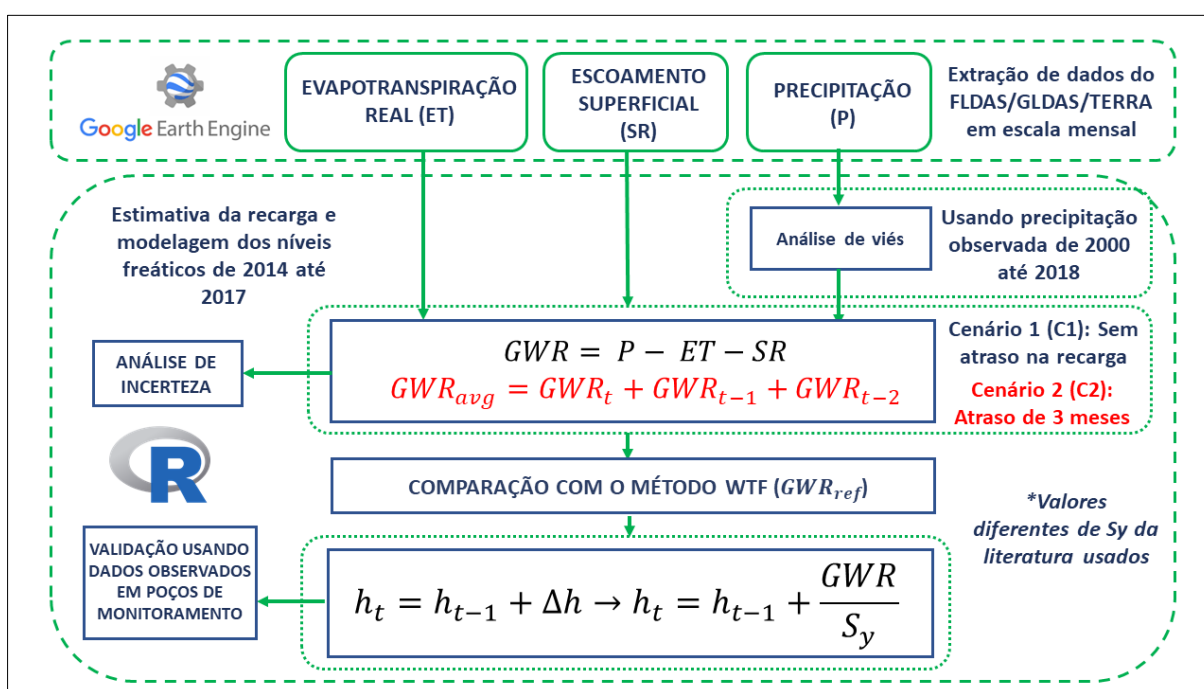
5.2 Descrição geral da metodologia

Neste tópico, um resumo geral da metodologia é apresentado para melhor situar o leitor sobre os procedimentos e etapas adotados. Todas as etapas serão descritas de forma mais detalhada nos tópicos posteriores.

No presente estudo a estimativa de recarga das águas subterrâneas (*GWR*) foi calculada como resíduo da equação do balanço hídrico, usando estimativas de variáveis do ciclo hidrológico por sensoriamento remoto de diferentes bases hidroclimáticas: FLDAS, GLDAS e TERRACLIMATE, usando a ferramenta de computação em nuvem Google Earth Engine (GEE). O GEE agrega grande valor aos usuários de dados de sensoriamento remoto, especialmente aos especialistas que podem não estar cientes de todos os detalhes envolvidos na organização dos dados, pré-processamento de imagens, pós-processamento e computação em larga escala.

Além disso, o GEE traz a possibilidade de análise rápida e precisa em um horizonte de popularização de abordagens baseadas em sensoriamento remoto para modelagem hidrológica. A Figura 8 apresenta o fluxo metodológico proposto para a estimativa da recarga de águas subterrâneas (GWR) e profundidades do nível freático (WTD) usando estimativas de precipitação (P), evapotranspiração (ET) e escoamento superficial (SR) do FLDAS, GLDAS, TERRACLIMATE no GEE. No esquema, h_t tem o mesmo significado de WTD .

Figura 8 - Uma estrutura metodológica que descreve as etapas adotadas para gerar uma série temporal espacial e temporal de dados de entrada para o balanço hídrico usando a API GEE e o processo de modelagem do nível da água subterrânea, análise de incerteza e validação no ambiente R.



Uma análise do viés de precipitação deste conjunto de dados foi realizada usando dados pluviométricos de 2000-2018, que foram coletados nas proximidades da área de estudo, em uma estação meteorológica. As estimativas de GWR e WTD foram realizadas durante um período de junho de 2014 a setembro de 2018. Os resultados foram comparados aos estimados pelo Método de Flutuação de Nível da Água (WTF) (HEALY, 2010). Foi realizada uma análise de incerteza dos componentes P , ET e SR das bases hidroclimáticas a partir da propagação dos desvios das variáveis. Métricas estatísticas de erro e de concordância como a Raiz do Erro Quadrático Médio (RMSE), Coeficiente de Correlação de Pearson (r) e o Coeficiente

de Determinação (R^2) foram utilizadas como critérios de avaliação de desempenho para validação. A validação do modelo envolve a comparação do *WTD* com os dados dos poços de observação para verificar sua adequação. Destaca-se a capacidade de processamento computacional do GEE para obtenção dos dados necessários para a estimativa de *GWR* pela abordagem do balanço hídrico e posteriormente, pela modelagem do *WTD*.

A principal vantagem da metodologia proposta é que a estimativa da *GWR* não requer uso de dados medidos, sendo necessário o uso de dados observados apenas para validação. Por outro lado, a modelagem da *WTD* precisa apenas de um primeiro valor medido para iniciar a modelagem, necessitando de séries medidas em poços apenas para validação e acurácia das estimativas. Os valores de S_y podem ser encontrados na literatura científica (FETTER, 1994; HEALY; COOK, 2002; DAEE; IG; IPT; CPRM, 2005; IPT, 2011). Os códigos desenvolvidos no GEE podem ser adaptados para extração de dados em regiões com dados escassos ou inexistentes, simplesmente alterando a localização geográfica dos pontos na interface do editor de código. Entre as vantagens de usar a computação em nuvem para gerenciar dados gerados por sensoriamento remoto, destacamos o baixo tempo computacional necessário. A modelagem da *GWR* e *WTD* é simples e pode ser feita no R (R CORE TEAM, 2019), bem como, com a utilização de outras linguagens de programação ou software de planilha de cálculo. A análise de incerteza fornece parâmetros para avaliar o uso da modelagem para tomada de decisão em regiões onde não há possibilidade de validação por falta de dados observados.

5.3 Origem dos dados

5.3.1 Monitoramento dos níveis freáticos e precipitação

As profundidades do nível freático foram observadas em oito poços de monitoramento localizados na EEcA, com frequência quinzenal de maio de 2014 a setembro de 2017 (Tabela 1 e Figura 9), sendo as séries usadas para obter a média mensal da profundidade dos níveis. Para medição dos níveis fora usado um medidor de nível tipo carretel da marca Solinst.

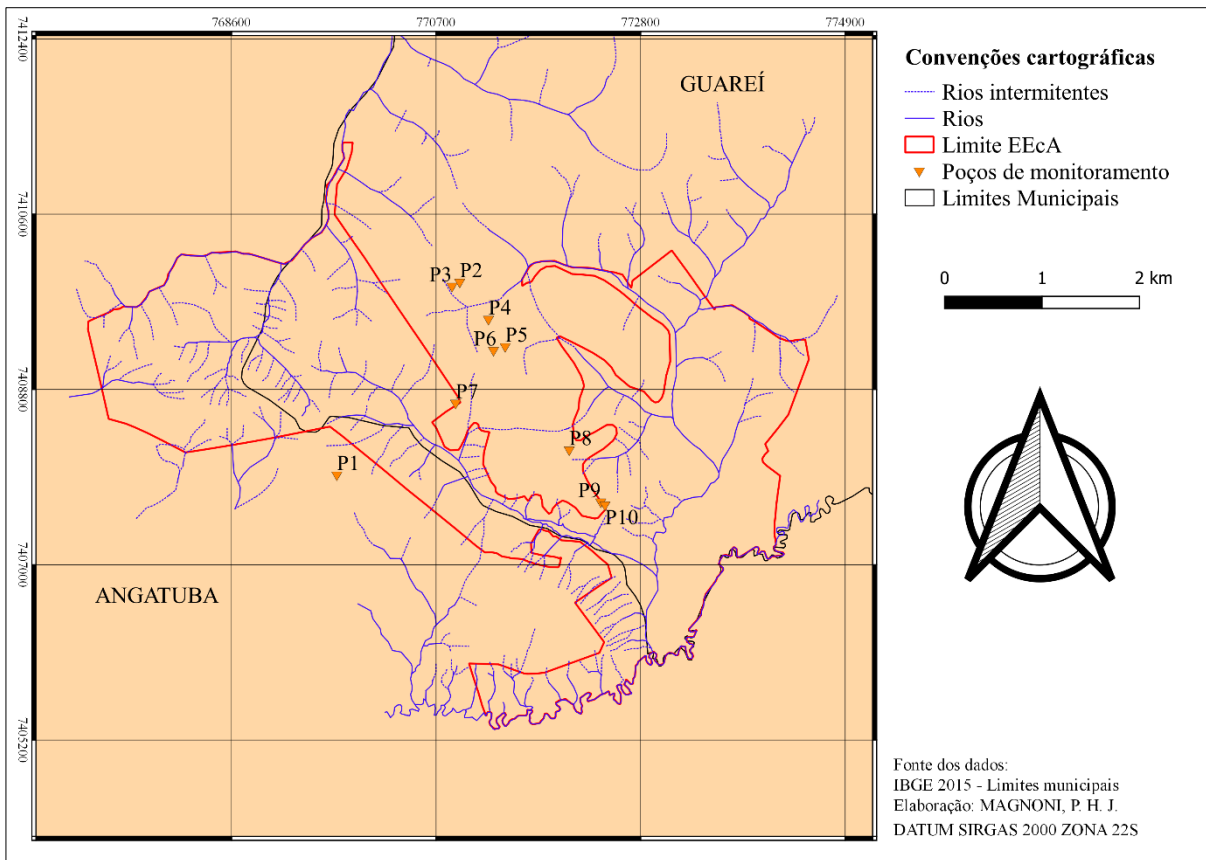
As observações climáticas de precipitação foram coletadas por uma estação climatológica convencional localizada a aproximadamente 11 km fora da área de

estudo (coordenadas 23°29'18" Sul e 48° 25'02" Oeste) regularmente monitorada pelo Departamento de Água e Eletricidade do Estado de São Paulo (DAEE) em uma frequência diária de janeiro de 2000 a dezembro de 2018.

Tabela 1 - Uso e ocupação da terra, classe de solo e localização geográfica onde estão instalados os poços de monitoramento da EECA.

ID poço	Uso da Terra	Coordenadas		Classe de Solo
		Latitude	Longitude	
P1	Pinus	-23.416313°	-48.360970°	Latosolos Vermelhos Amarelos
P2	Pinus	-23.398238°	-48.348997°	
P3	Cerrado	-23.398639°	-48.349762°	
P4	Pinus	-23.401636°	-48.346044°	
P7	Cerrado	-23.409461°	-48.349184°	
P8	Eucalipto	-23.413598°	-48.337697°	
P9	Pinus	-23.418371°	-48.334433°	
P10	Cerrado	-23.418635°	-48.334007°	

Figura 9 - Mapa de localização dos poços de monitoramento utilizados



5.3.2 Dados de monitoramento por sensoriamento remoto

Para o cálculo do balanço hídrico na localização dos poços foram utilizados dados de precipitação (P), evapotranspiração real (ET) e escoamento superficial (SR) estimados das três bases hidroclimáticas FLDAS, GLDAS e TERRACLIMATE.

As séries temporais do FLDAS foram retiradas do produto FLDAS_NOAH01_C_GL_M: FLDAS Noah Land Surface Model L4 Global Monthly 0.1 x 0.1 degree (MERRA-2 e CHIRPS). Este conjunto de dados contém uma série de parâmetros da superfície terrestre simulados a partir do modelo Noah 3.6.1 no Famine Early Warning Systems Network (FEWS NET) Land Data Assimilation System (FLDAS). Os dados possuem resolução espacial de 0,10 graus e estão disponíveis no GEE, desde de janeiro de 1982, até o presente, com a disponibilidade de 26 bandas de diferentes variáveis hidroclimáticas. A resolução temporal é mensal e a cobertura espacial é global (MACNALLY, 2017; MCNALLY NASA/GSFC/HS, 2018). As séries do GLDAS foram retiradas do produto GLDAS-2.1 Noah 3-hourly 0.25 degree, com

resolução temporal de 3h e espacial de 0,25 graus o produto é simulado com o Modelo Noah 3.6 no Sistema de Informação da Terra (LIS) Versão 7, tendo 36 bandas de saída de diferentes parâmetros da superfície terrestre. Atualmente os dados estão disponíveis no GEE de janeiro de 2000 até o presente com cobertura espacial global (RODELL, 2004; BEAUDOING; RODELL; NASA/GSFC/HSL, 2020a). Finalmente, as séries temporais do TERRACLIMATE foram obtidas do produto mensal TerraClimate de resolução espacial de aproximadamente 4 km, dados disponíveis no GEE de 1958 até o presente e com cobertura espacial global e 14 bandas de saída com parâmetros da superfície terrestre (ABATZOGLOU et al., 2018).

Todos os produtos usados estão disponíveis para serem manipulados e baixados no “playground do GEE”. A próxima seção descreve a obtenção de todos e apresenta os códigos usados para qualquer usuário que se cadastrar na plataforma (acesso livre) possa ter acesso a metodologia de estimativa da *GWR*.

5.3.3 Computação em nuvem no Google Earth Engine (GEE)

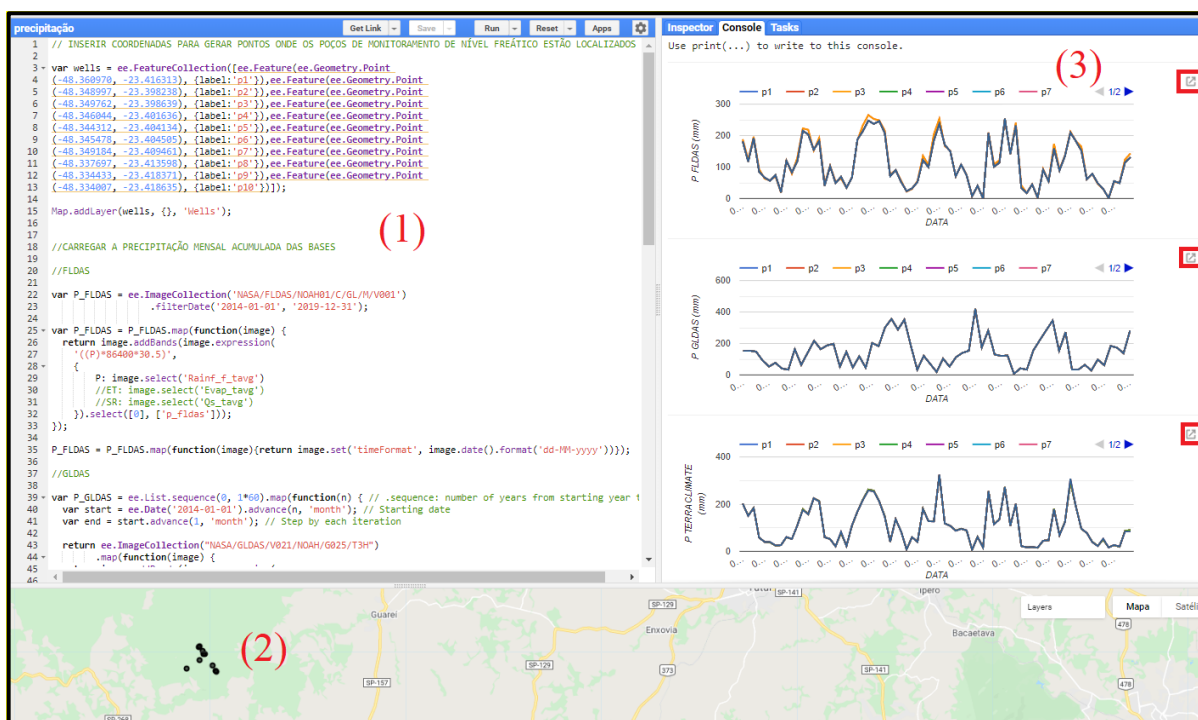
O GEE foi usado para estimar a *GWR* pelo balanço hídrico usando a P, ET e SR das três bases hidroclimáticas. Este cálculo será melhor explicado na seção 5.4.1, aqui serão mostrados e compartilhados os códigos usados.

A Tabela 2 apresenta os *links* para os códigos desenvolvidos no GEE onde qualquer usuário com uma conta do serviço (que pode ser criada gratuitamente no [link](#)) poderá acessar os dados. Ao acessar um dos links, o usuário é redirecionado para o editor de código GEE (Figura 10). Estes códigos ao serem abertos podem ser associados a conta GEE de qualquer usuário, podendo ser modificados e aplicados para qualquer lugar dentro da cobertura geográfica espacial e temporal das bases de dados.

Tabela 2 - Descrição e links para acessar as informações dos códigos elaborados no GEE para obter as séries temporais de precipitação, evapotranspiração, escoamento superficial e o balanço hídrico.

Estimativa	Descrição do código	Acesso	Informação do produto
Precipitação (P)	Séries temporais de P do FLDAS, GLDAS E TERRACLIMATE na localização dos poços	link	FLDAS, GLDAS e TERRACLIMATE
Evapotranspiração (ET)	Séries temporais de ET do FLDAS, GLDAS E TERRACLIMATE na localização dos poços	link	
Escoamento superficial (SR)	Séries temporais de SR do FLDAS, GLDAS E TERRACLIMATE na localização dos poços	link	
Balanço = P - ET - SR	Séries temporais do balanço hídrico do FLDAS, GLDAS E TERRACLIMATE na localização dos poços	link	

Figura 10 - Exemplos de visualização séries temporais de precipitação no Google Earth Engine do FLDAS, GLDAS e TERRACLIMATE na EECA. (1) editor de código (2) poços de monitoramento no mapa de referência (pontos pretos) e (3) séries temporais de precipitação no console (ícone de exportação destacado em vermelho).



5.4 Modelagem das águas subterrâneas

5.4.1 Modelagem da recarga pelo método do balanço hídrico

Como a recarga não pode ser medida diretamente, a maneira mais comum de estimá-la é de forma indireta, usando o método do balanço hídrico ou a abordagem residual. Nesta abordagem, todas as variáveis da equação do balanço hídrico, exceto a recarga, são estimadas e o valor residual é considerado como a recarga (SCANLON et al. 2002; SZILAGYI et al. 2011; KHALAF; DONOGHUE, 2012, LUCAS et al., 2015; SILVA; MANZIONE; ALBUQUERQUE FILHO, 2019a). Aqui, as séries hidroclimáticas do FLDAS, GLDAS e TERRACLIMATE foram usadas para modelagem mensal da recarga pelo simples cálculo do balanço hídrico:

$$GWR = P - ET - SR \quad (2)$$

onde:

- GWR é recarga das águas subterrâneas (mm.mês^{-1}),
- P é a precipitação (mm.mês^{-1}),
- ET é a evapotranspiração real (mm.mês^{-1}), e
- SR é o escoamento superficial (mm.mês^{-1}).

A GWR representa a estimativa do potencial recarga ou o saldo de recarga (HEALY, 2010). Na Equação 2, os seus valores negativos indicam déficit hídrico no solo e foram contabilizados em condições de estado estacionário, como o consumo de água proveniente da ET (SILVA; MANZIONE; ALBUQUERQUE FILHO, 2019a). Não há bombeamento de água subterrânea na área de estudo e as mudanças na umidade do solo foram consideradas insignificantes em escala anual. A ET subterrânea foi ignorada já que os níveis freáticos na EECA apresentaram máxima profundidade observada média de 8,70 m abaixo da superfície.

5.4.2 Modelagem dos níveis freáticos

O método WTF foi utilizado para calcular a recarga conforme descrito e aplicado em várias publicações (HEALY; COOK, 2002; SIMON et al., 2017; TERAMOTO; CHANG, 2018; GONÇALVES; MANZIONE, 2019; CAMBRAIA NETO; RODRIGUES, 2020). Esse modelo considera que a mudança no nível freático (aumento) corresponde à mudança no armazenamento de água durante o evento de recarga, conforme a Equação 3:

$$GWR = \Delta S^{gw} = S_y \cdot \frac{\Delta H}{\Delta t} \quad (3)$$

onde:

- ΔS^{gw} é o armazenamento de água,
- S_y é o rendimento específico,
- ΔH é a variação do armazenamento de água, e
- Δt é o intervalo de tempo.

Como proposto por Silva, Manzione e Albuquerque Filho (2019a), a Equação 4 apresenta uma adaptação do método WTF para modelar a WTD , assumindo que a

GWR está relacionada às flutuações do nível freático em função do rendimento específico (S_y) do aquífero:

$$WTD = h_t = h_{t-1} + \Delta h \rightarrow WTD = h_t = h_{t-1} + \frac{GWR}{S_y} \quad (4)$$

onde:

- h é a profundidade do nível freático, e
- t é o intervalo de tempo (em escala mensal).

O primeiro valor h (h_0) deve ser um valor medido para iniciar a série temporal mensal. O S_y é o volume de água liberado por uma unidade volumétrica de material aquífero saturado drenado por um lençol freático decrescente, valor muito variável espacialmente (SCANLON; HEALY; COOK, 2002), fator que agrega incerteza ao modelo, pois influencia diretamente o valor final da estimativa. Para este estudo, foram adotados os valores médios de 0,15 e 0,25 para a parcela livre do SAG (DAEE; IG; IPT; CPRM, 2005) e o valor de 0,19 determinado empiricamente ao longo do trabalho. A GWR estimada pelo balanço hídrico pode não atingir completamente o lençol freático, dada a presença da zona de umidade do solo (SILVA; MANZIONE; ALBUQUERQUE FILHO, 2019a). Há um atraso entre o volume excedente do balanço hídrico e a recarga efetiva. Os processos de fluxo de água no solo, da zona não saturada para a zona saturada, são complexos e altamente variáveis sob diferentes propriedades pedológicas e geológicas. Shilpakar, Bastiaanssen e Molden (2011) propuseram usar a média aritmética da precipitação de um mês com a do mês anterior para incluir o efeito do atraso, em uma estimativa de excedente hídrico em uma bacia hidrográfica, da chuva anterior (evento de chuva ocorrido antes de um período avaliado no presente) nas observações atuais. De forma a abordar o tempo dos processos que influenciam a recarga, devido as profundidades do nível freático no SAG (MANZIONE; WENDLAND; TANIKAWA, 2012), foi proposto o uso do mesmo conceito para calcular o GWR de um mês em relação aos estimados em dois meses anteriores (GWR_{avg}), com o objetivo de incorporar o efeito do atraso, como mostrado na Equação 5.

$$GWR_{avg} = \frac{(GWR_t + GWR_{t-1} + GWR_{t-2})}{3} \quad (5)$$

Combinando a Eq. 4 com a 5, temos:

$$WTD = h_t = h_{t-1} + \Delta h \rightarrow h_t = h_{t-1} + \frac{GWR_{avg}}{S_y} \quad (6)$$

Dois cenários foram realizados. Primeiro, a modelagem sem considerar o atraso, chamado Cenário 1 (C1), onde a GWR se dá mediante a Equação 1 e depois considerando o atraso na recarga no Cenário 2 (C2), pelo cálculo da GWR_{avg} na Equação 5. Esses cenários foram modelados entre os meses de junho de 2014 e setembro de 2017, período com dados observados dos níveis freáticos para posterior aplicação de métricas de precisão e validação do modelo da WTD .

5.5 Incerteza dos componentes do balanço hídrico e validação dos modelos da GWR e WTD

Para validar as séries de estimativa de precipitação (P) por sensoriamento remoto, foram utilizados dados observados de uma estação meteorológica. Evapotranspiração (ET) e o escoamento superficial (SR) não puderam ser validados com dados observados. O viés estatístico anual dos dados de P do FLDAS, GLDAS e TERRACLIMATE foi determinada pela subtração da chuva observada no período 2000-2018, conforme descrito por Moazami et al. (2013), Lucas et al. (2015) e Sharifi, Bahram e Steinacker (2019):

$$viés = \frac{1}{n} \sum_{i=1}^n (p_i - p_i^*) \quad (7)$$

onde:

- p_i^* é o valor estimado,
- p_i é o valor observado, e
- n é o número de observações.

O viés mensal médio de cada ano foi utilizado para a correção das séries estimadas de P do FLDAS, GLDAS e TERRACLIMATE pelo modelo do erro aditivo:

$$\text{Erro aditivo} = p_i^* + \text{viés}_i \quad (8)$$

O desvio padrão anual de das variáveis P, ET e SR foi considerado como uma medida de incerteza para calcular a incerteza associada às estimativas da *GWR*. A incerteza da *GWR* (U_{GWR}) foi calculada para cada ano, aplicando a equação de propagação de erro conforme descrito por Taylor (2012) e Lucas et al. (2015):

$$U_{GWR} = \sqrt{(U_P)^2 + (U_{ET})^2 + (U_{SR})^2} \quad (9)$$

onde:

- U_P corresponde ao desvio padrão anual da série estimada de precipitação mensal,
- U_{ET} é o desvio padrão anual da série estimada de evapotranspiração real mensal, e
- U_{SR} o desvio padrão anual da série estimada de escoamento superficial mensal.

Um valor único de U_{GWR} (mm) foi aplicado como limite inferior (subtração) e superior (soma) da incerteza da *GWR* e GWR_{avg} mensal de cada ano durante o período do estudo.

A partir das medições realizadas em campo dos níveis freáticos nos poços de monitoramento foram feitas estimativas de recarga baseadas no WTF (GWR_{ref}) para valores distintos de S_y de 0,15, 0,19 e 0,25, como mostrado na Equação 10. Os valores negativos resultantes do cálculo representam o déficit hídrico responsável pelo rebaixamento do nível nos poços.

$$GWR_{ref} = S_y \cdot \frac{\Delta H}{\Delta t} = S_y \cdot \Delta h^* \quad (10)$$

onde:

- Δh^* representa a variação mensal do nível freático nos poços de monitoramento.

A Raiz do Erro Quadrático Médio (RMSE) e o Coeficiente de Correlação de Pearson (r) foram utilizados para avaliar o ajuste e erro das séries estimadas de precipitação do FLDAS com/sem a correção do viés pelo erro aditivo, em comparação aos dados de chuva observados na estação do DAEE. O mesmo procedimento foi realizado para as séries de precipitação do GLDAS e TERRACLIMATE. As mesmas métricas (RMSE e r) também foram usadas para comparar a GWR e a GWR_{avg} das três bases hidroclimáticas com a GWR_{ref} , baseada no WTF. O valor do RMSE deve estar próximo de zero, enquanto o coeficiente r varia de -1 a 1, indicando a direção e a força do relacionamento entre duas variáveis. O RMSE é calculado pela Equação 11, enquanto que o Coeficiente de Correlação de Pearson (r) é calculado pela Equação 12.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (p_i - p_i^*)^2}{n}} \quad (11)$$

$$r = \frac{\sum_{i=1}^n (p_i^* - \bar{p}^*) (p_i - \bar{p})}{(\sqrt{\sum_{i=1}^n (p_i^* - \bar{p}^*)^2})(\sqrt{\sum_{i=1}^n (p_i - \bar{p})^2})} \quad (12)$$

onde:

- \bar{p} é o valor médio observado, e
- \bar{p}^* é o valor médio estimado.

A acurácia do modelo da WTD foi avaliada pelo uso do RMSE e do Coeficiente de Determinação (R^2). R^2 é uma medida de ajuste de um modelo ao valor observado, seu resultado deve ser o mais próximo possível de 1, e seu cálculo é realizado conforme exposto na seguinte equação:


$$R^2 = 1 - \sum_{i=1}^n \frac{p_i - p_i^*}{p_i - \bar{p}} \quad (13)$$

6 RESULTADOS E DISCUSSÃO

6.1 Precipitação, evapotranspiração e escoamento com base em dados de sensoriamento remoto e monitoramento das águas subterrâneas

Para processar 18 anos do produto de precipitação das três bases hidroclimáticas e gerar os gráficos das séries temporais, foi necessário menos de um minuto no GEE usando o código desenvolvido (Tabela 2). A Figura 11 apresenta as séries mensais de precipitação observadas na estação meteorológica (DAEE P) e as estimadas pelo FLDAS (FLDAS P), GLDAS (GLDAS P) e TERRACLIMATE (TERRAC P), no período de janeiro de 2000 a dezembro de 2018. Há uma forte variação anual no volume precipitado, bem como o efeito da sazonalidade causada pelas variações climáticas ao longo dos anos, com verões chuvosos e invernos secos. Também digno de nota, o período de 2013-14 em que o Estado de São Paulo sofreu uma seca severa e teve os seus regimes de chuvas seriamente afetados (COELHO; CARDOSO; FIRPO, 2016), seguido pela ocorrência do El Niño Oscilação Sul (ENOS) em 2015-16. O ENOS aumentou a precipitação nos meses de inverno no Estado de São Paulo (CPRM, 2015) e causou um ano atípico (GONÇALVES; MANZIONE, 2019). A DAEE P durante o inverno (estação seca) no período 2014-17 variou do mínimo acumulado de 149,50 mm em 2014 ao máximo de 384,90 mm em 2015.

Figura 11 - Precipitação mensal acumulada (mm) de janeiro 2000 até dezembro de 2018 observada pelo DAEE e estimada pelo FLDAS, GLDAS E TERRACLIMATE.

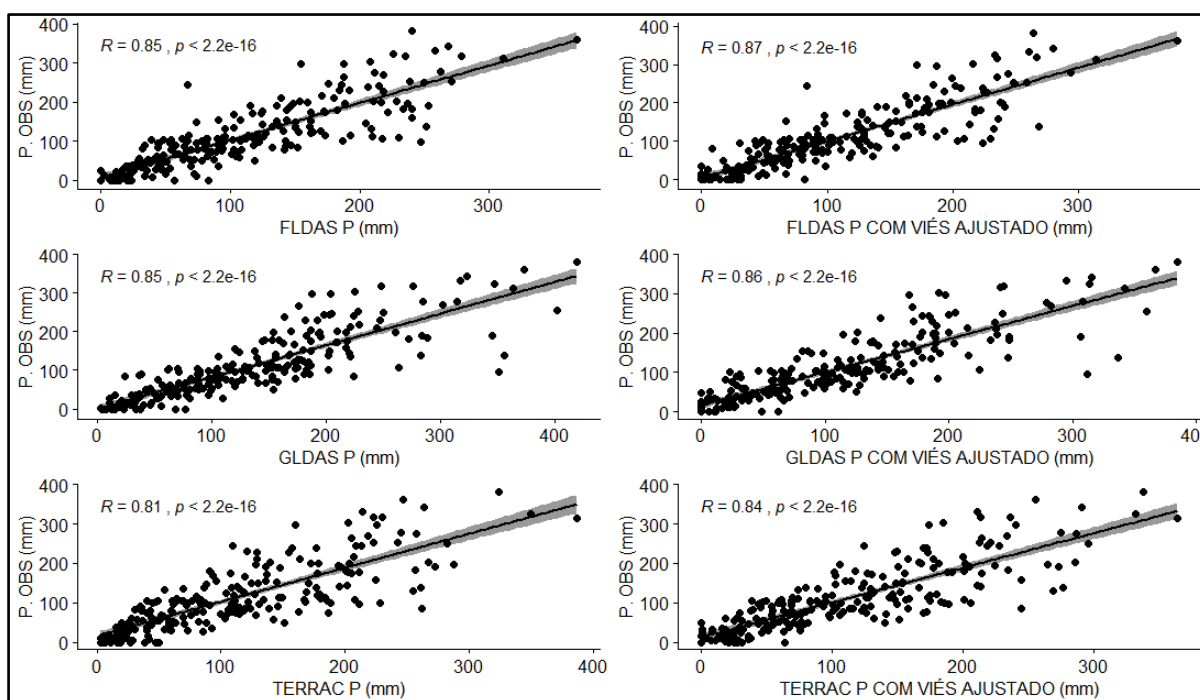


A Figura 12 apresenta os gráficos de dispersão e análise de correlação das séries estimadas de precipitação sem/com correção do viés em comparação a chuva observada do DAEE (P. OBS), com boa concordância para FLDAS com $r = 0,85$ e $RMSE = 43,95 \text{ mm.mês}^{-1}$, para o GLDAS com $r = 0,85$ e $RMSE = 52,05 \text{ mm.mês}^{-1}$ e para o TERRACLIMATE com $r = 0,81$ e $RMSE = 49,97 \text{ mm.mês}^{-1}$. Após a correção anual do viés os resultados foram $r = 0,87$ e $RMSE = 41,24 \text{ mm.mês}^{-1}$, $r = 0,86$ e $RMSE = 44,29 \text{ mm.mês}^{-1}$ e $r = 0,84$ e $RMSE = 46,95 \text{ mm.mês}^{-1}$, respectivamente para o FLDAS, GLDAS e TERRACLIMATE. Lucas et al. (2015) encontraram $RMSE$ de 42 mm.mês^{-1} usando estimativa de precipitação do produto TRMM 3B42 V7 em outra área no município de Brotas/SP, enquanto na Bacia do Rio Sapucaí em Itajubá/MG, Reis, Rennó e Lopes (2017) tiveram $RMSE$ de $54,89 \text{ mm.mês}^{-1}$ para o mesmo produto, o que aponta para erros similares do TRMM (amplamente abordado em diversos trabalhos científicos) aos das estimativas de precipitação das três bases hidroclimáticas usadas neste trabalho, porém mais comparações necessitam ser realizadas em mais localidades, para aumentar a confiabilidade dos dados apurados.

A média (\pm desvio padrão) da DAEE P foi de $1.305,76 \text{ mm.ano}^{-1}$ ($245,15 \text{ mm.ano}^{-1}$) no período 2000-18, enquanto que o FLDAS P foi de $1.284,18 \text{ mm.ano}^{-1}$ ($151,81 \text{ mm.ano}^{-1}$), o GLDAS P de $1.584,37 \text{ mm.ano}^{-1}$ ($191,69 \text{ mm.ano}^{-1}$) e o TERRA

P de $1.290,23 \text{ mm.ano}^{-1}$ ($163,23 \text{ mm.ano}^{-1}$). No período de 18 anos, o FLDAS P e o TERRAC P apresentaram tendência a subestimar a chuva observada com viés médio mensal de 1,81 mm e 1,30 mm, respectivamente. O GLDAS P apresentou superestimativa em relação a DAEE com viés médio mensal de 23,32 mm.

Figura 12 - Gráfico de dispersão e análise de correlação entre as estimativas e observações de precipitação durante o período de janeiro de 2000 até dezembro de 2018.




A Figura 13 apresenta as estimativas de P, ET e SR das três bases hidroclimáticas no período 2014-17. O valor de FLDAS P durante a estação chuvosa (dezembro a março) variou do mínimo de 644,53 mm (2013-14) ao máximo de 948,52 mm (2015-16), enquanto que o GLDAS P variou de 561,03 mm (2013-14) a 1182,25 mm (2015-16) e o TERRAC P variou de 606,20 mm (2013-14) a 877,0 mm (2015-16). Há discrepância interanual esperada entre os dados de precipitação observada e os dados das bases hidroclimáticas. A DAEE P acumulada durante a estação chuvosa foi de 478 mm em 2013-14 e 979,20 mm em 2015-16.

Em comparação as séries de precipitação, no período 2014-17, as estimativas de ET apresentaram menor variação interanual durante a estação chuvosa. O valor da estimativa de evapotranspiração do FLDAS (FLDAS ET) variou do mínimo de 549,68 mm (2014-15) a um valor máximo de 606,58 mm (2013-14), enquanto que a

evapotranspiração do GLDAS (GLDAS ET) variou de 506,68 mm (2013-14) a 539,71 (2016-17) e a do TERRACLIMATE (TERRA ET) variou de 406,58 mm (2013-14) a 444,10 mm (2016-17). Os valores de escoamento superficial do FLDAS (FLDAS SR) e os do GLDAS (GLDAS SR) durante a estação chuvosa também apresentaram baixa variação interanual, variando de 31,41 mm (2013-14) a 129,19 mm (2015-16) e de 58,58 mm (2013-14) a 185,41 mm (2015-16), respectivamente. O escoamento superficial do TERRACLIMATE (TERRA SR) apresentou forte variação interanual variando do mínimo de 178,20 mm (2013-14) ao máximo de 448,80 mm (2015-16); os valores são bem discrepantes em comparação ao mesmo período com o estimado pelas outras bases.

Figura 13 - Estimativas de P, ET e SR das três bases no período de janeiro de 2014 até dezembro de 2017.



Estes resultados sugerem que a variabilidade interanual das estimativas da *GWR* das bases está mais relacionada com variações das estimativas de precipitação do que as de ET e SR para o FLDAS e GLDAS. Anderson et al. (2012) e Lucas et al. (2015) também verificaram o mesmo comportamento na estimativa de recarga pelo método do balanço hídrico usando estimativas de precipitação e evapotranspiração de produtos de sensoriamento remoto. Já o TERRACLIMATE, com altos valores estimados de SR no período chuvoso, aparenta ter sua estimativa da *GWR* fortemente influenciada pelo SR do que as demais bases, que apresentaram menor variação

interanual deste parâmetro. No entanto, como as estimativas de ET e SR das bases hidroclimáticas não puderam ser validadas com dados observados, não é possível confirmar se ET e SR podem estar sub ou superestimados. Na Tabela 3, são apresentados os valores anuais de precipitação observada e as séries estimadas de P, ET e SR de cada uma das bases são apresentados. Observa-se que o desvio padrão das séries estimadas de P tende a ser maior que ET e SR, corroborando a hipótese de maior influência da chuva estimada na variação da *GWR*.

Tabela 3 - Séries anuais estimadas de P, ET e SR das três bases hidroclimáticas e precipitação anual observada (DAEE P) de janeiro de 2014 até dezembro de 2017.

Base	Anos (mm)				Média±Desvio
	2014	2015	2016	2017	
DAEE P	998,20	1.769,70	1.156,90	1.480,00	1.351,20±343,56
FLDAS P	1.336,50	1.566,82	1.436,39	1.217,17	1.389,22±148,49
GLDAS P	1.336,21	2.002,70	1.632,45	1.863,13	1.708,62±291,46
TERRAC P	1.123,60	1.586,40	1.421,00	1.323,00	1.363,50±193,38
FLDAS ET	1.299,67	1.276,38	1.394,17	1.251,12	1.305,33±62,45
GLDAS ET	1.123,52	1.172,25	1.169,49	1.157,78	1.155,76±22,39
TERRAC ET	881,54	983,58	978,82	976,94	955,22±49,20
FLDAS SR	60,49	85,95	159,60	81,60	96,91±43,25
GLDAS SR	117,52	243,17	177,83	204,20	185,68±52,77
TERRAC SR	209,60	603,00	442,80	431,00	421,60±161,65

Apesar de não haver possibilidade de validação de todas as variáveis utilizadas neste trabalho, pesquisas recentes de outros autores vêm mostrando aplicações destas bases no Brasil em estudos climatológicos. Rampazo, Picoli e Kazue (2018) demonstraram boa correlação entre estimativas de temperatura do ar e velocidade do vento do GLDAS com dados observados de 31 estações meteorológicas do INMET de São Paulo, verificando sua adequabilidade em estudos climáticos no Estado. Araujo et al. (2019) verificou a viabilidade da utilização de estimativas de componentes do balanço de radiação e calor na superfície do GLDAS para realização de estudos em locais com escassez de dados, como o Estado do Maranhão. Duarte et al., (2019) usou a razão de Bowen com dados micrometeorológicos para calibrar estimativas de calor latente do FLDAS em área do Pantanal no Estado do Mato Grosso. Sobreiro (2019) usou estimativas de evapotranspiração do TERRACLIMATE para estudar como a distribuição da vegetação está ligada à disponibilidade de água na Serra do Espinhaço, uma cadeia

montanhosa localizada no planalto Atlântico, estendendo-se pelos estados de Minas Gerais e Bahia. Dentre as três bases, o GLDAS por ter dados disponíveis a mais tempo possui mais exemplos na literatura que o FLDAS e TERRACLIMATE, que ainda carecem de mais aplicações de uso e validação de suas informações em território brasileiro.

6.2 Estimativas de recarga

O rendimento específico (S_y) apresentou forte influência sobre as estimativas de recarga baseadas no WTF (GWR_{ref}). Para $S_y = 0,15$, as estimativas mínimas e máximas de GWR_{ref} de junho de 2014 a setembro de 2017 variaram de 0 em 2014 a 225,12 mm.ano⁻¹ em 2017 (15,21% da precipitação observada neste ano). Para o mesmo período, a GWR_{ref} variou de 0 a 249,22 mm.ano⁻¹ (16,83% da precipitação observada no ano) para $S_y = 0,19$ e de 0 a 327,92 mm.ano⁻¹ (22,17% da precipitação observada no ano) para $S_y = 0,25$ nos anos de 2014 e 2017, respectivamente. Este resultado mostra o grande impacto do S_y na modelagem, em que as estimativas apresentaram resultados diferentes para os mesmo anos. Varni et al. (2013) destacaram a importância do S_y no cálculo de recarga usando o método WTF. Cambraia Neto e Rodrigues (2020), utilizando o WTF na bacia hidrográfica do Rio Buriti Vermelho (em área de Cerrado no Distrito Federal), observaram diferenças de 15,9% entre estimativas de recarga a partir de dois valores diferentes do S_y no modelo utilizado. As estimativas de recarga pelo método do balanço hídrico apresentaram diferenças nos dois cenários avaliados (C1 e C2). Entre junho de 2014 e setembro de 2017, a GWR acumulada anual do FLDAS variou de um mínimo de 107,80 mm (10,8% da precipitação observada) a um máximo de 348,49 mm (19,69% da precipitação observada) no C1 e 9 mm (0,9% da precipitação observada) a 229,89 mm (13% do pluviômetro) no C2 (GWR_{avg}). No mesmo período a GWR acumulada anual do GLDAS variou de 186,18 mm (18,65% da precipitação observada) a 674,16 mm (38,09% da precipitação observada) no C1 e 37,55 mm (3,76% da precipitação observada) a 484,32 mm (27,36% da precipitação observada) no C2, enquanto que as estimativas anuais do TERRACLIMATE variaram de 5,38 mm (0,36% da precipitação observada) a 70,72 mm (6,11% da precipitação observada) no C1 e de 1,88 mm (0,13% da

precipitação observada) a 57,50 mm (3,25% da precipitação observada) no C2. A Tabela 4 apresenta as estimativas anuais de GWR , GWR_{avg} e GWR_{ref} .

Tabela 4 - Recarga anual acumulada do FLDAS, GLDAS e TERRACLIMATE pelo balanço hídrico no Cenário 1 (GWR), Cenário 2 (GWR_{avg}) e baseada no WTF (GWR_{ref}) no período de Junho de 2014 a Setembro 2017.

Base	¹ Anos (mm)				Média±Desvio
	2014	2015	2016	2017	
FLDAS GWR	107,8	348,49	157,62	114,6	182,13±113,08
GLDAS GWR	186,18	674,16	430,32	487,21	444,47±201,24
TERRAC GWR	43,78	48,34	70,72	5,38	42,06±27,14
FLDAS GWR_{avg}	9,0	229,89	179,16	107,19	131,31±95,83
GLDAS GWR_{avg}	37,55	484,32	464,38	461,35	361,90±216,47
TERRAC GWR_{avg}	13,90	57,50	35,61	1,88	27,22±24,54
GWR_{ref} ($S_y=0,15$)	0	155,43	196,75	225,12	144,33±100,38
GWR_{ref} ($S_y=0,19$)	0	196,87	249,22	285,16	182,81±127,15
GWR_{ref} ($S_y=0,25$)	0	259,04	327,92	375,21	240,54±167,31

¹Junho de 2014 até setembro de 2017

Em um estudo realizado pelo IPT (2011), foi verificada para o SAG uma média de recarga de sua área de afloramento em torno de 200 mm.ano⁻¹. Lucas, Guanabara e Wendland (2012) encontraram taxas de recarga de 80 mm (7% do volume precipitado) no período de 2005-2006 e 359 mm (20% do volume precipitado) em 2010-2011, utilizando o método WTF na Bacia do Ribeirão da Onça no município de Brotas/SP, área de afloramento do SAG. Santos (2018) verificou valor médio de recarga anual de 452 mm em área de afloramento do SAG em Bofete - SP também utilizando o método WTF. No entanto, a estimativa de recarga pelo WTF demanda de dados de níveis freáticos observados, o que inviabiliza sua aplicação em locais com dados escassos. A vantagem de estimativas de recarga por sensoriamento remoto é a não necessidade de dados observados; usa-se observações apenas para avaliar a acurácia do modelo. Lucas et al. (2015), também ao estudarem a recarga na Bacia do Ribeirão da Onça com dados dos produtos de precipitação TRMM 3B42 V7 e evapotranspiração MOD16, em uma abordagem de modelagem de recarga pelo balanço hídrico encontraram no período de 2004-2012 recarga média anual de 537 mm. Silva, Manzione e Alburquerque Filho (2019), sob área de afloramento do Sistema Aquífero Bauru (SAB) no município Águas de Santa Barbara/SP, encontraram intervalos de porcentagens de recarga em relação ao precipitado anual

para diferentes usos da terra, pelo método do balanço hídrico com uso de evapotranspiração modelada em imagens do satélite/sensor SENTINEL2/MSI pelo algoritmo SAFER, entre 15,3 e 23,6% em áreas de plantio cana-de-açúcar, entre 12,5 e 16,9% para pastagens, entre 29,0 e 38,9% para a silvicultura e entre 47,0 e 50,6% em áreas florestais.

Apesar dos campos de estudos aqui citados para via de comparação também estarem situados em áreas do SAG, pela dimensão do sistema estudado as formações geológicas das áreas que as compõem, muitas vezes, podem apresentar diferenças que repercutiriam diretamente nos resultados obtidos pelos demais autores, além das diferentes metodologias utilizadas.

6.2.1 Comparação entre a GWR e GWR_{ref} e análise de incerteza

Verificou-se fraca correlação (foi considerado nível de significância de 5%) entre a GWR e GWR_{ref} no C1, enquanto no C2 (GWR_{avg}) essa relação foi significativamente melhorada nas séries do FLDAS e GLDAS, enquanto que o TERRACLIMATE não apresentou resultados significativos em nenhum cenário (Figura 14, Figura 15 e Figura 16). Em comparação ao GWR_{ref} o C2 apresentou melhores resultados que o C1 sob as três diferentes faixas de S_y consideradas. No C2, o uso das séries de precipitação com correção do viés melhorou a correlação da GWR_{avg} do FLDAS mas não causou grande impacto no RMSE, enquanto que para a GWR_{avg} do GLDAS não houve impacto na correlação das séries, mas o RMSE diminuiu significativamente. Na Tabela 5 é apresentado o Coeficiente de Correlação de Pearson (r) e Raiz do Erro Médio Quadrático (RMSE) entre estimativas de recarga baseadas no balanço hídrico (Cenário 1 e 2) e WTF (GWR_{ref}), considerando diferentes valores de rendimento específico (S_y) e uso das séries de precipitação com correção do viés no período de Junho de 2014 a Setembro de 2017.

Sem considerar o uso das séries de precipitação com correção do viés, a incerteza anual das bases (U_{GWR}) no período de 2014-2017 variou de um mínimo de 69,83 mm.ano⁻¹ (2014) a um máximo de 90,17 mm.ano⁻¹ (2016) com média de 81,75 mm.ano⁻¹ no FLDAS, de um mínimo de 68,56 mm.ano⁻¹ (2014) a um máximo de 125,74 mm.ano⁻¹ (2017) com média de 101,05 mm.ano⁻¹ no GLDAS, e de um mínimo de 80,74 mm.ano⁻¹ (2014) a um máximo de 115,23 mm.ano⁻¹ (2017) com média de 99,79 mm.ano⁻¹ no TERRACLIMATE. Já utilizando a correção do viés, a incerteza das bases

variou de um mínimo de 68,84 mm.ano⁻¹ (2014) a um máximo de 90,16 mm.ano⁻¹ (2016) com média de 81,81 mm.ano⁻¹ no FLDAS, de um mínimo de 68,56 mm.ano⁻¹ (2014) a um máximo de 122,06 mm.ano⁻¹ (2017) com média de 99,49 mm.ano⁻¹ no GLDAS, e de um mínimo de 80,74 mm.ano⁻¹ (2014) a um máximo de 115,64 mm.ano⁻¹ (2017) com média de 99,53 mm.ano⁻¹ no TERRACLIMATE. Estes resultados sugerem o pequeno impacto do uso da correção do viés da precipitação na estimativa anual da incerteza, o que faz sentido, já que incerteza também é dependente das estimativas de ET e SR que não puderam ser validadas e não tiveram seu viés avaliado para tornar possível as correções. Outras incertezas também não possíveis de serem avaliadas estão associadas ao cálculo da GWR_{ref} , realizado usando valores de S_y da literatura, já que não haviam dados de campo desta variável.

Tabela 5 - Comparação entre as estimativas de recarga (Cenário 1 e 2) e WTF (GWR_{ref}), considerando diferentes valores de rendimento específico (S_y) e séries de precipitação com correção do viés no período de Junho de 2014 a Setembro de 2017.

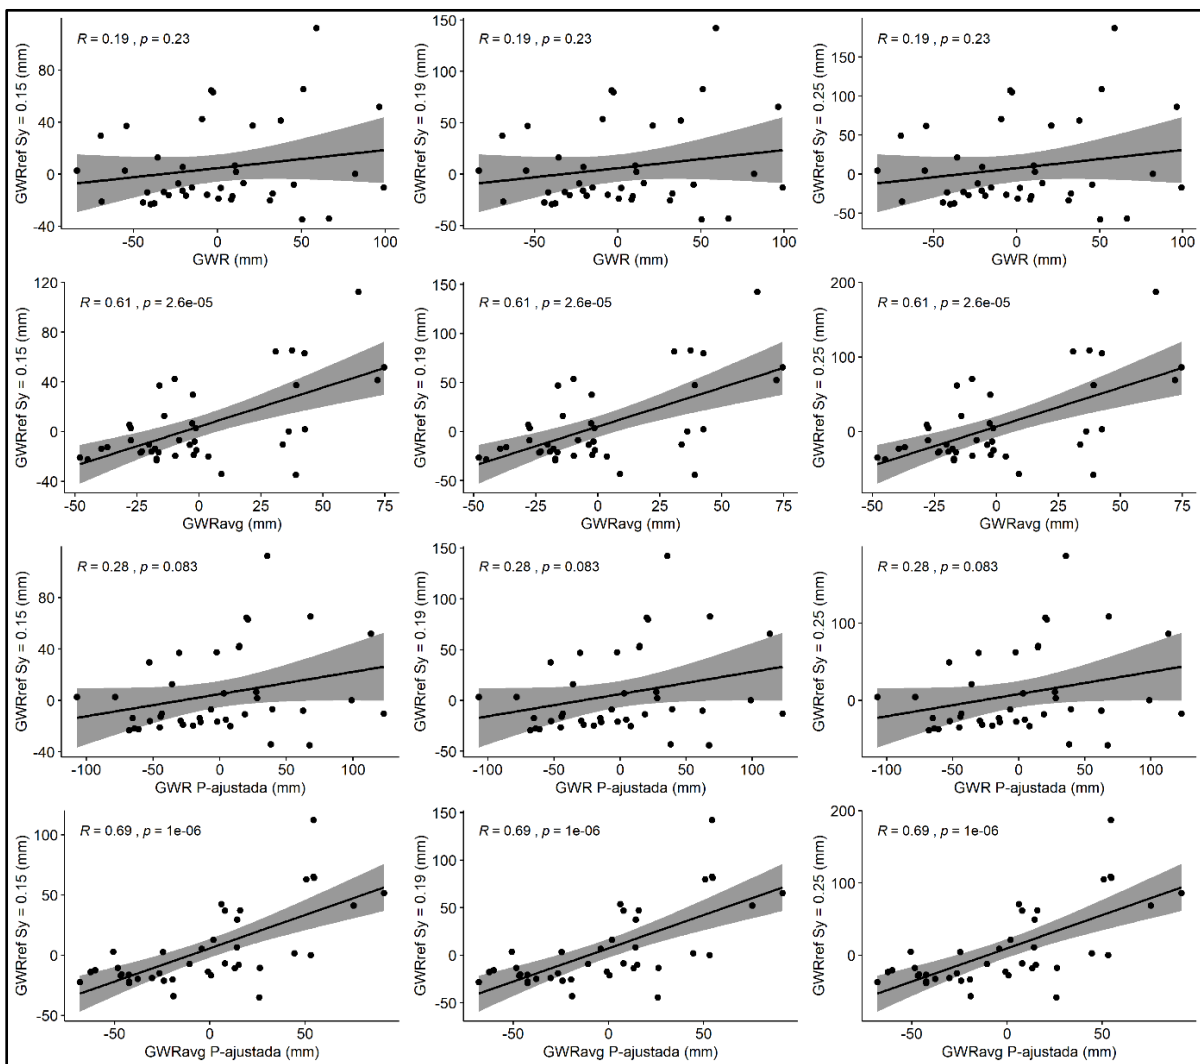
	GWR_{ref}					
	$S_y = 0.15$		$S_y = 0.19$		$S_y = 0.25$	
	RMSE (mm)	r	RMSE (mm)	r	RMSE (mm)	r
F GWR	50,13	0,19	54,87	0,19	63,59	0,19
G GWR	69,41	0,38	70,28	0,38	73,53	0,38
T GWR	38,93	-0,23	47,15	-0,23	59,75	-0,23
F GWR P-aj	53,54	0,28	57,17	0,28	64,47	0,28
G GWR P-aj	62,83	0,38	64,35	0,38	68,68	0,38
T GWR P-aj	39,42	-0,04	47,09	-0,04	59,16	-0,04
F GWR_{avg}	28,37	0,61	33,41	0,61	43,22	0,61
G GWR_{avg}	42,46	0,73	42,35	0,73	45,44	0,73
T GWR_{avg}	34,21	-0,06	42,75	-0,06	55,67	-0,06
F GWR_{avg} P-aj	30,44	0,69	33,21	0,69	40,65	0,69
G GWR_{avg} P-aj	31,00	0,73	31,92	0,73	37,29	0,73
T GWR_{avg} P-aj	33,06	0,25	40,95	0,25	53,27	0,25

F = FLDAS; G = GLDAS; T = TERRACLIMATE; P-aj = Série estimada de precipitação com correção do viés usando dados observados.

A Figura 17, Figura 18 e Figura 19 apresentam as séries mensais de GWR e GWR_{avg} , com os limites superiores e inferiores de incerteza estimada pela Equação 9, do FLDAS, GLDAS e TERRACLIMATE, juntamente com as séries da GWR_{ref} calculadas com três valores de S_y . No âmbito do uso de dados de sensoriamento para geração de informação útil para a tomada de decisão em locais

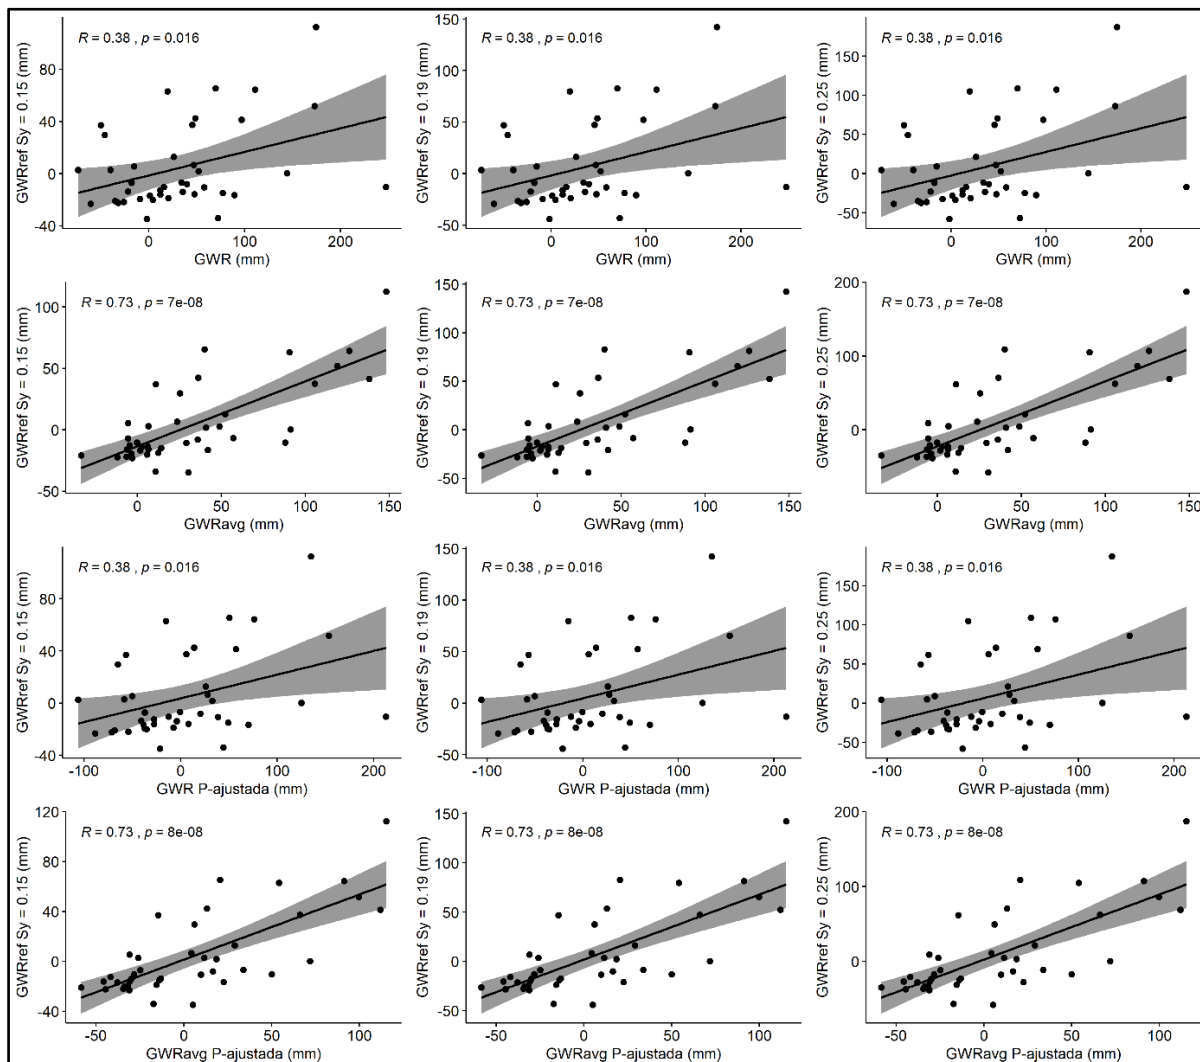
com dados escasso e/ou inexistentes, o FLDAS apresentou resultados mais representativos que as demais bases para estimativa de recarga no período e na área de estudo deste trabalho, com dados baseado nos resultados do cenário 2 na Tabela 5 e, da análise de incerteza (menor que nas demais bases). A correção do viés da estimativa de precipitação melhorou significativamente o RMSE na estimativa da recarga do GLDAS no cenário 2, mas para tanto foi necessário usar dados de chuva observados. Finalmente, o TERRACLIMATE não apresentou resultados significativos em comparação as séries de recarga do WTF usadas como referência.

Figura 14 - Dispersão mensal e análise de Correlação de Pearson as estimativas de GWR e GWR_{avg} do FLDAS com a GWR_{ref} , considerando três valores de rendimento específico (S_y) e uso das séries de precipitação com correção do viés no período de Junho de 2014 até Setembro de 2017.



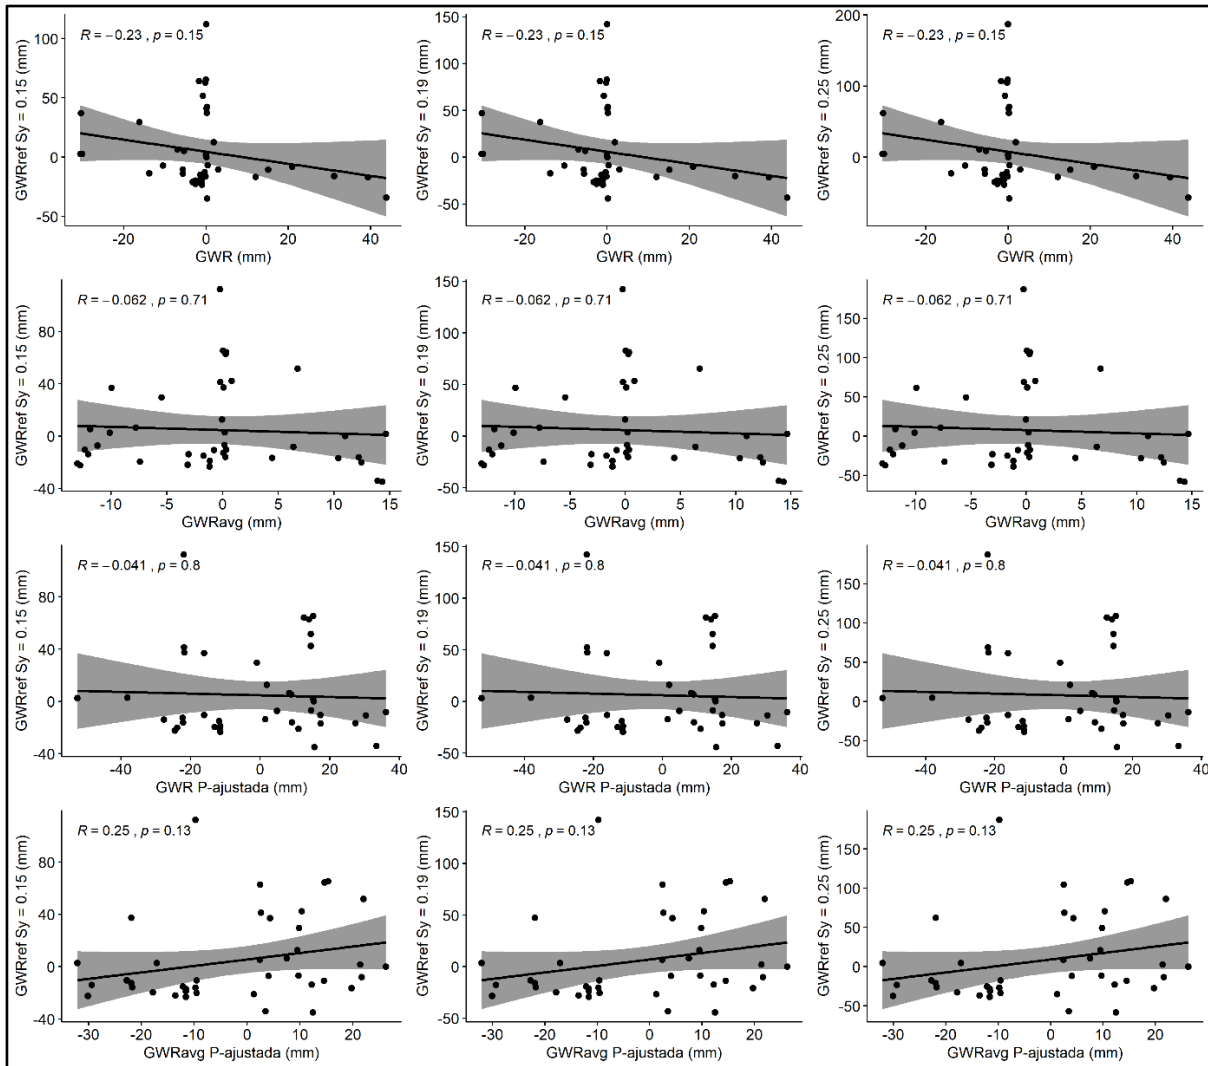
R é o coeficiente de correlação de Pearson (normalmente representado por r); P-ajustada = série de precipitação estimada pelo FLDAS com correção do viés

Figura 15 - Dispersão mensal e análise de Correlação de Pearson as estimativas de GWR e GWR_{avg} do GLDAS com a GWR_{ref} , considerando três valores de rendimento específico (S_y) e uso das séries de precipitação com correção do viés no período de Junho de 2014 até Setembro de 2017.



R é o coeficiente de correlação de Pearson (normalmente representado por r); P-ajustada = série de precipitação estimada pelo GLDAS com correção do viés

Figura 16 - Dispersão mensal e análise de Correlação de Pearson as estimativas de GWR e GWR_{avg} do TERRACLIMATE com a GWR_{ref} , considerando três valores de rendimento específico (S_y) e uso das séries de precipitação com correção do viés no período de Junho de 2014 até Setembro de 2017.



R é o coeficiente de correlação de Pearson (normalmente representado por r); P-ajustada = série de precipitação estimada pelo TERRACLIMATE com correção do viés

Figura 17 - Séries FLDAS GWR e GWR_{avg} com limite superior e inferior de incerteza (área sombreada) de Junho de 2014 até Setembro de 2017 e GWR_{ref} . A) sem correção do viés da estimativa de precipitação e B) com correção.




Figura 18 - Séries GLDAS GWR e GWR_{avg} com limite superior e inferior de incerteza (área sombreada) de Junho de 2014 até Setembro de 2017 e GWR_{ref} . A) sem correção do viés da estimativa de precipitação e B) com correção.

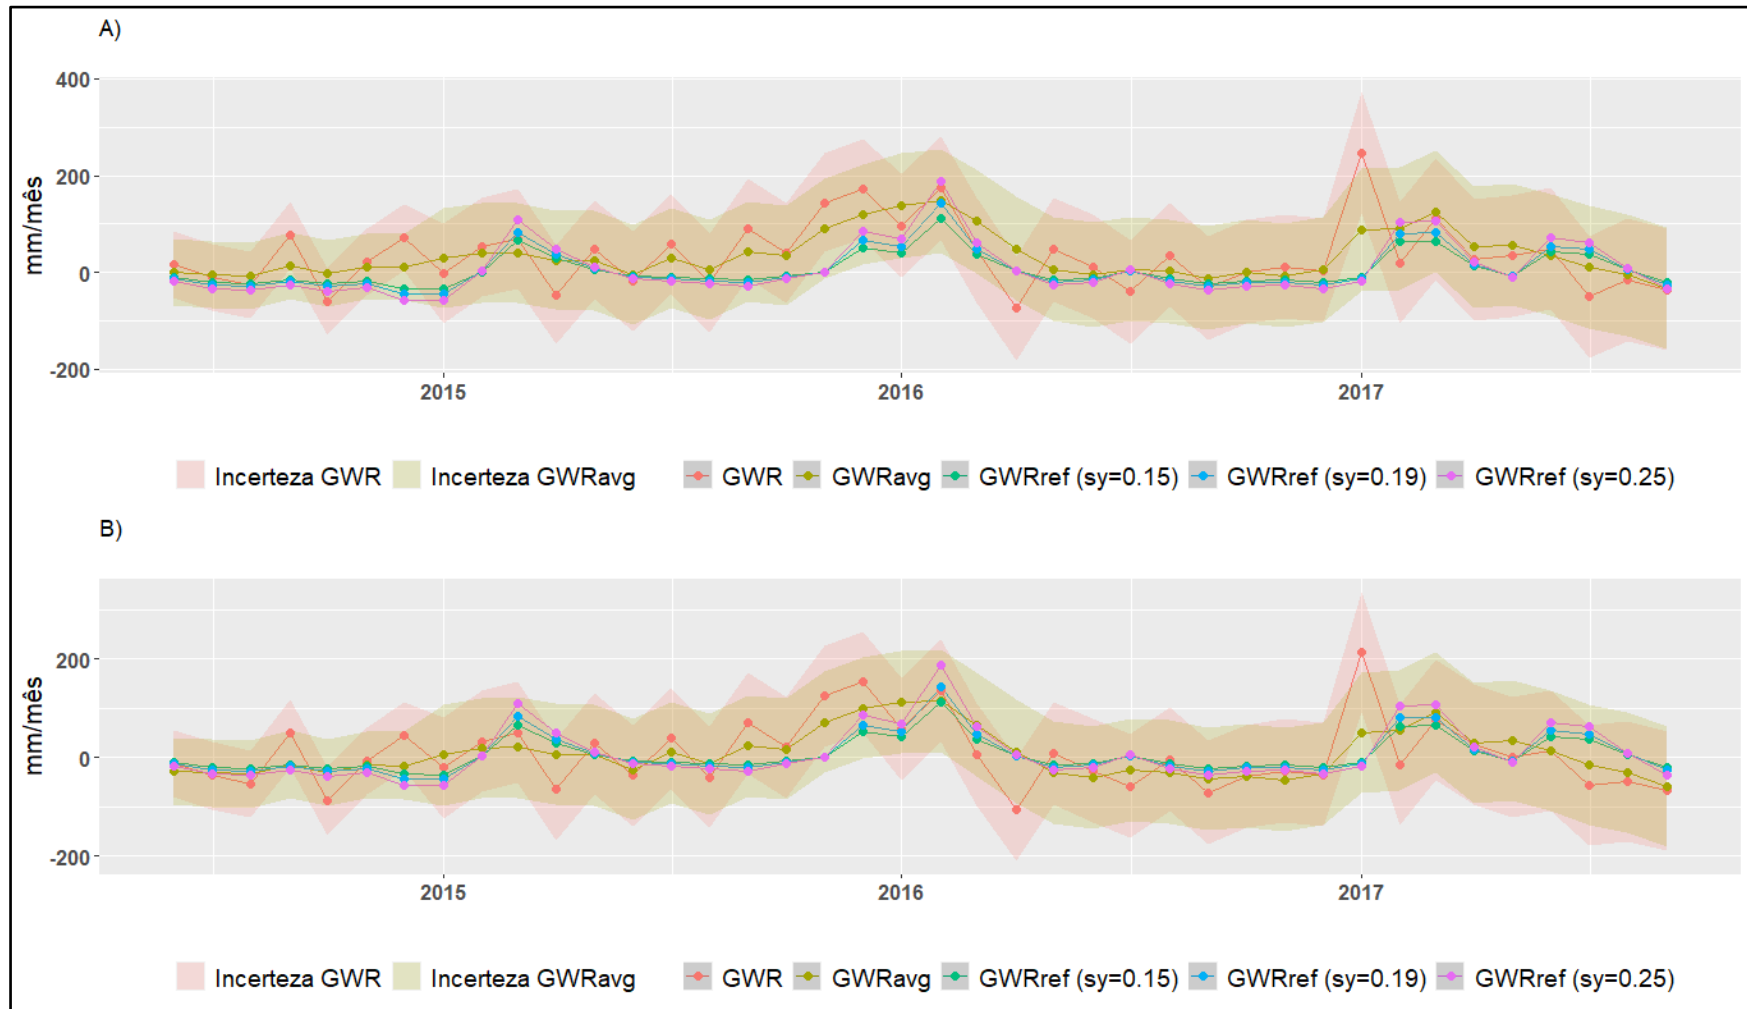



Figura 19 - Séries TERRACLIMATE GWR e GWR_{avg} com limite superior e inferior de incerteza (área sombreada) de Junho de 2014 até Setembro de 2017 e GWR_{ref} para comparação. A) sem correção do viés da estimativa de precipitação e B) com correção.



6.3 Modelagem dos níveis freáticos (*WTD*)

As estimativas de recarga no C2 (GWR_{avg}) apresentaram melhor ajuste e menor erro em comparação a GWR_{ref} , portanto, foram usadas para modelar a *WTD*, como mostrado na Equação 6, com os resultados apresentados e discutidos nesta seção. Para modelar a *WTD* não foram usadas as estimativas da GWR_{avg} que tiveram correção do viés da estimativa precipitação, pois o foco foi avaliar a modelagem a partir de dados brutos do FLDAS, GLDAS e TERRACLIMATE em locais com dados escassos e/ou inexistentes, que não permitem avaliação e correção do viés. A Tabela 6, Tabela 7 e Tabela 8 apresentam os valores médios, máximos, mínimos, o Coeficiente de Determinação (R^2) e RMSE entre as séries estimadas da *WTD* do FLDAS, GLDAS e TERRACLIMATE e as observadas nos poços de monitoramento no período de junho de 2014 até setembro de 2017, respectivamente.

A variação do rendimento específico (S_y) não afetou a tendência das séries da *WTD* estimada, porque o valor de R^2 permaneceu constante em cada uma das bases para as três diferentes faixas consideradas (0,15, 0,19 e 0,25). No entanto, a variação do S_y afetou significativamente o valor do RMSE (Tabela 6, Tabela 7 e Tabela 8). Nos poços com nível freático médio máximo (PMM) de até 15 m (P3, P8, P9 e P10) o RMSE do modelo de *WTD* do FLDAS variou de 0,36 a 0,81 m e R^2 de 65 a 72%, enquanto que os poços mais profundos (P1, P2, P4 e P7) apresentaram RMSE variando de 0,86 a 1,12 m e R^2 de 7 a 63%, considerando $S_y = 0,19$. Para o mesmo valor de S_y , no GLDAS os PMM apresentaram valores de RMSE que variaram de 3,42 a 3,59 m e R^2 de 63 a 85%, enquanto que os poços mais profundos apresentaram RMSE variando de 3,36 a 4,39 m e R^2 de 28 a 79%. Entretanto, no TERRACLIMATE os valores de RMSE variaram de 0,60 a 1,13 m e R^2 de 36 a 59% nos PMM, enquanto que os poços mais profundos apresentaram o RMSE com variação de 0,63 a 1,23 m e R^2 de 0 a 16% em comparação aos dados observados nos poços de monitoramento.

Tabela 6 - Média, máximo, mínimo e raiz do erro médio quadrático (RMSE) e coeficiente de determinação (R²) das séries de oscilação dos níveis freáticos modeladas com FLDAS sob 3 diferentes faixas de rendimento específico em relação a séries observadas nos poços de monitoramento no período de junho de 2014 até setembro de 2017.

Poço	MODELAGEM DOS NÍVEIS FREÁTICOS FLDAS							
	p1	p2	p3	p4	p7	p8	p9	p10
OBSERVADO / ESTIMADO								
S_y = 0,25								
Média	-23,93/-23,49	-19,85/-19,74	-14,50/-14,46	-16,37/-15,66	-25,15/-24,29	-9,87/-9,81	-9,79/-9,76	-8,70/-8,61
Máximo	-22,02/-22,71	-17,37/-18,94	-13,45/-13,66	-15,22/-14,88	-24,10/-23,51	-8,65/-9,02	-8,14/-8,97	-6,85/-7,82
Mínimo	-25,41/-24,06	-21,64/-20,36	-15,26/-15,08	-17,24/-16,23	-25,94/-24,86	-10,92/-10,38	-11,10/-10,33	-11,82/-9,18
RMSE	0,85	1,02	0,34	0,83	1,00	0,38	0,56	0,87
R²	0,63	0,46	0,66	0,36	0,07	0,68	0,72	0,65
S_y = 0,19								
Média	-23,93/-23,40	-19,85/-19,65	-14,50/-14,37	-16,37/-15,57	-25,15/-24,19	-9,87/-9,71	-9,79/-9,66	-8,70/-8,51
Máximo	-22,02/-22,37	-17,37/-18,59	-13,45/-13,31	-15,22/-14,54	-24,10/-23,16	-8,65/-8,68	-8,14/-8,63	-6,85/-7,48
Mínimo	-25,41/-24,15	-21,64/-20,46	-15,26/-15,18	-17,24/-16,32	-25,94/-24,94	-10,92/-10,46	-11,10/-10,41	-11,82/-9,26
RMSE	0,86	0,98	0,36	0,93	1,12	0,39	0,51	0,81
R²	0,63	0,46	0,66	0,36	0,07	0,68	0,72	0,65
S_y = 0,15								
Média	-23,93/-23,29	-19,85/-19,54	-14,50/-14,26	-16,37/-15,46	-25,15/-24,08	-9,87/-9,60	-9,79/-9,55	-8,70/-8,40
Máximo	-22,02/-21,98	-17,37/-18,21	-13,45/-12,93	-15,22/-14,15	-24,10/-22,78	-8,65/-8,30	-8,14/-8,25	-6,85/-7,10
Mínimo	-25,41/-24,24	-21,64/-20,58	-15,26/-15,30	-17,24/-16,41	-25,94/-25,04	-10,92/-10,55	-11,10/-10,50	-11,82/-9,35
RMSE	0,90	0,98	0,45	1,06	1,26	0,46	0,51	0,79
R²	0,63	0,46	0,66	0,36	0,07	0,68	0,72	0,65

Tabela 7 - Média, máximo, mínimo e raiz do erro médio quadrático (RMSE) e coeficiente de determinação (R^2) das séries de oscilação dos níveis freáticos modeladas do GLDAS em relação a séries observadas nos poços de monitoramento no período de junho de 2014 até setembro de 2017.

Poço	MODELAGEM DOS NÍVEIS FREÁTICOS GLDAS							
	p1	p2	p3	p4	p7	p8	p9	p10
OBSERVADO / ESTIMADO								
$S_y = 0,25$								
Média	-23,93/-21,42	-19,85/-17,66	-14,50/-12,38	-16,37/-13,59	-25,15/-22,22	-9,87/-7,74	-9,79/-7,69	-8,70/-6,54
Máximo	-22,02/-18,18	-17,37/-14,42	-13,45/-9,14	-15,22/-10,35	-24,10/-18,98	-8,65/-4,50	-8,14/-4,45	-6,85/-3,30
Mínimo	-25,41/-23,85	-21,64/-20,09	-15,26/-14,81	-17,24/-16,02	-25,94/-24,64	-10,92/-10,16	-11,10/-10,11	-11,82/-8,96
RMSE	2,77	2,44	2,58	3,20	3,43	2,62	2,47	2,49
R²	0,79	0,77	0,85	0,60	0,28	0,63	0,77	0,67
$S_y = 0,19$								
Média	-23,93/-20,67	-19,85/-16,91	-14,50/-11,63	-16,37/-12,84	-25,15/-21,47	-9,87/-6,99	-9,79/-6,94	-8,70/-5,79
Máximo	-22,02/-16,41	-17,37/-12,65	-13,45/-7,37	-15,22/-8,58	-24,10/-17,20	-8,65/-2,72	-8,14/-2,67	-6,85/-1,52
Mínimo	-25,41/-23,86	-21,64/-20,10	-15,26/-14,82	-17,24/-16,03	-25,94/-24,66	-10,92/-10,18	-11,10/-10,13	-11,82/-8,98
RMSE	3,71	3,36	3,55	4,16	4,39	3,59	3,42	3,42
R²	0,79	0,77	0,85	0,60	0,28	0,63	0,77	0,67
$S_y = 0,15$								
Média	-23,93/-19,84	-19,85/-16,08	-14,50/-10,80	-16,37/-12,01	-25,15/-20,64	-9,87/-6,16	-9,79/-6,11	-8,70/-4,96
Máximo	-22,02/-14,44	-17,37/-10,68	-13,45/-5,40	-15,22/-6,61	-24,10/-15,23	-8,65/-0,75	-8,14/-0,70	-6,85/0,45
Mínimo	-25,41/-23,88	-21,64/-20,12	-15,26/-14,84	-17,24/-16,05	-25,94/-24,68	-10,92/-10,19	-11,10/-10,14	-11,82/-8,99
RMSE	4,77	4,42	4,63	5,23	5,47	4,67	4,50	4,48
R²	0,79	0,77	0,85	0,60	0,28	0,63	0,77	0,67

Tabela 8 - Média, máximo, mínimo e raiz do erro médio quadrático (RMSE) e coeficiente de determinação (R^2) das séries de oscilação dos níveis freáticos modeladas do TERRACLIMATE em relação a séries observadas nos poços de monitoramento no período de junho de 2014 até setembro de 2017.

Poço	MODELAGEM DOS NÍVEIS FREÁTICOS TERRACLIMATE								
	p1	p2	p3	p4	p7	p8	p9	p10	
OBSERVADO / ESTIMADO									
$S_y = 0,25$									
Média	-23,93/-23,84	-19,85/-20,08	-14,50/-14,80	-16,37/-16,01	-25,15/-24,63	-9,87/-10,15	-9,79/-10,10	-8,70/-8,95	
Máximo	-22,02/-23,77	-17,37/-20,01	-13,45/-14,73	-15,22/-15,94	-24,10/-24,56	-8,65/-10,08	-8,14/-10,04	-6,85/-8,89	
Mínimo	-25,41/-23,95	-21,64/-20,19	-15,26/-14,91	-17,24/-16,12	-25,94/-24,75	-10,92/-10,27	-11,10/-10,21	-11,82/-9,06	
RMSE	0,98	1,23	0,61	0,64	0,68	0,65	0,88	1,14	
R^2	0,16	0,16	0,44	0,10	0,00	0,59	0,40	0,36	
$S_y = 0,19$									
Média	-23,93/-23,85	-19,85/-20,09	-14,50/-14,81	-16,37/-16,02	-25,15/-24,64	-9,87/-10,16	-9,79/-10,12	-8,70/-8,97	
Máximo	-22,02/-23,76	-17,37/-20,00	-13,45/-14,72	-15,22/-15,93	-24,10/-24,55	-8,65/-10,07	-8,14/-10,04	-6,85/-8,89	
Mínimo	-25,41/-24,00	-21,64/-20,24	-15,26/-14,96	-17,24/-16,17	-25,94/-24,79	-10,92/-10,31	-11,10/-10,26	-11,82/-9,11	
RMSE	0,97	1,23	0,60	0,63	0,67	0,64	0,87	1,13	
R^2	0,16	0,16	0,44	0,10	0,00	0,59	0,40	0,36	
$S_y = 0,15$									
Média	-23,93/-23,86	-19,85/-20,10	-14,50/-14,82	-16,37/-16,03	-25,15/-24,66	-9,87/-10,18	-9,79/-10,13	-8,70/-8,98	
Máximo	-22,02/-23,74	-17,37/-19,98	-13,45/-14,70	-15,22/-15,91	-24,10/-24,54	-8,65/-10,06	-8,14/-10,03	-6,85/-8,88	
Mínimo	-25,41/-24,05	-21,64/-20,29	-15,26/-15,01	-17,24/-16,22	-25,94/-24,85	-10,92/-10,37	-11,10/-10,31	-11,82/-9,16	
RMSE	0,97	1,23	0,60	0,62	0,67	0,63	0,87	1,12	
R^2	0,16	0,16	0,44	0,10	0,00	0,59	0,40	0,36	

Considerando o erro e ajuste, em comparação com os níveis freáticos observados nos poços de monitoramento, o modelo da *WTD* usando a GWR_{avg} do FLDAS foi superior aos demais. A GWR_{avg} do GLDAS, em comparação a GWR_{ref} , superestimou a recarga anual (Tabela 4), e conseqüentemente, maior foi o RMSE observado no modelo da *WTD*. Já o TERRACLIMATE não apresentou correlação significativa em suas estimativas de recarga (Tabela 5 e Figura 16) e, conseqüentemente, a modelagem da *WTD* apresentou baixo R^2 , o que implicou em valores baixos de RMSE, que devem ser entendidos como baixa variação da série observada no poço, e não como uma boa acurácia do modelo. A Figura 20, Figura 21 e Figura 22 mostram os níveis freáticos observados e estimados pelo uso do modelo da Equação 6 com $S_y = 0,19$ e GWR_{avg} do FLDAS, GLDAS e TERRACLIMATE, respectivamente.

Com base nos resultados da GWR_{avg} do FLDAS, que apresentou melhor desempenho na modelagem da *WTD*, verificou-se melhor ajuste em poços rasos onde o modelo foi capaz de capturar no período estudado, as oscilações temporais da subida e diminuição do nível freático. Nava e Manzione (2015), Manzione, Soldara e Wendland (2016) e Silva, Manzione e Albuquerque Filho (2019a) também identificaram alta sensibilidade à recarga em poços rasos em áreas aflorantes de aquíferos. Uma característica comum em todos os poços de monitoramento da EECA foi o aumento dos níveis no período de 2015-16. O excesso de precipitação nesse período causado pelo fenômeno ENOS contribuiu para esses aumentos. O mesmo aumento foi registrado em 32 poços de monitoramento localizados no município de Águas de Santa Bárbara, Estado de São Paulo (MANZIONE, 2018). Manzione, Wendland e Tanikawa (2012) obtiveram RMSE médio de 0,53 m em 21 poços usando o modelo PIRFICT (VON ASMUTH; BIERKENS; MAAS, 2002) para modelagem da *WTD* na bacia hidrográfica do Ribeirão da Onça em outra área de afloramento do SAG em São Paulo. Neste trabalho, o RMSE médio do modelo da *WTD* com a GWR_{avg} do FLDAS (melhor modelo) foi de 0,74 m. No entanto, o modelo PIRFICT é mais complexo de se aplicar e os autores utilizaram em seu trabalho dados climatológicos observados como entrada, além de que a área de afloramento do SAG em seu trabalho está sob uma área da Formação de Botucatu, enquanto a EECA está sob uma área da Formação Pirambóia. Tais diferenças nas formações geológicas podem influenciar o processo de recarga do aquífero.

Figura 20 - Séries observadas (linhas contínuas) e estimadas (linhas tracejadas) a partir do FLDAS GWR_{avg} nos oito poços de monitoramento da EECA de junho de 2014 até setembro de 2017.




Figura 21 - Séries observadas (linhas contínuas) e estimadas (linhas tracejadas) a partir do GLDAS GWR_{avg} nos oito poços de monitoramento da EECa de junho de 2014 até setembro de 2017.





Figura 22 - Séries observadas (linhas contínuas) e estimadas (linhas tracejadas) a partir do TERRACLIMATE GWR_{avg} nos oito poços de monitoramento da EECA de junho de 2014 até setembro de 2017.



6.4 Perspectivas e futuros estudos

O Brasil é um país que ainda carece de fontes de dados de monitoramento com frequência e qualidade necessária para a boa gestão das águas subterrâneas. Bases como o FLDAS, GLDAS e TERRACLIMATE fornecem diferentes estimativas hidroclimáticas, que como as que foram aqui abordadas, podem ser usadas para auxiliar no entendimento de processos de recarga das águas subterrâneas e monitoramento dos níveis freáticos. Atualmente, em diferentes contextos hidrológicos, estas bases de dados, além de outras citadas como a missão GRACE, vêm sendo aplicadas com sucesso. Khaki et al. (2018) avaliou flutuações do nível da água do Rio Nilo e o armazenamento total de água (água superficial, umidade do solo e armazenagem subterrânea) usando produtos do GRACE, FLDAS e outros, e suas associações as variabilidades climáticas na região. Em escala regional alguns exemplos interessantes podem ser vistos como em Wu et al. (2019) que pela subtração da anomalia de armazenamento de água no solo da zona não saturada (SWSA), do GLDAS, pela anomalia de armazenamento de água total (TWSA), da missão GRACE, estimam a anomalia de armazenamento das águas subterrâneas (GWSA), usada posteriormente para estimar a recarga de forma análoga ao método WTF. Nesse trabalho, realizado na China, na bacia do Ordos, os autores compararam a estimativa de recarga com dados do GLDAS e GRACE com métodos pontuais, encontrando superestimativas anuais na faixa de 20 mm.ano^{-1} , um erro muito pequeno comparado a vantagem de realizar a modelagem de forma espacializada e a partir de dados de sensoriamento remoto que não demandam dados observados. Abordagens semelhantes podem ser observadas em Henry, Allen e Huang (2011) e Yin, Hu e Jiao (2017).

De todos esses resultados, é evidente a possibilidade de aplicar dados de sensoriamento remoto à modelagem das águas subterrâneas, diante das facilidades que as plataformas de computação em nuvem estão propiciando para os usuários da hidrogeologia. Há uma quebra de paradigma em andamento, onde os modelos hidrológicos tradicionalmente pontuais tendem a ser estimados de forma espacializada, com incertezas compatíveis aos modelos de escala pontual e a um custo significativamente reduzido. A validação de campo nunca pode ser negligenciada, no entanto, as missões de campo para coleta de dados podem ser

roteadas para locais onde existem maiores incertezas nos modelos estimados remotamente, economizando tempo, dinheiro e esforço das equipes de monitoramento. Especificamente para as águas subterrâneas, há um horizonte próspero com as missões GRACE-FO (Follow-On) ([link](#)), SMAP (Soil Moisture Active Passive) ([link](#)) além de outras bases de informação com as usadas neste trabalho, por exemplo, fornecendo dados de alta qualidade, mas ainda em resoluções mais adequadas para grandes áreas e Sistemas Aquíferos. Mesmo assim, esses dados podem servir de base para dados auxiliares para estimativas de recarga na escala das bacias hidrográficas, incorporando o armazenamento das águas subterrâneas e a umidade do solo nos estudos sobre o balanço hídrico da água, abrindo caminho para futuros trabalhos sobre um vasto e diversificado campo de pesquisa.

7 CONCLUSÕES

Neste trabalho foi desenvolvida uma nova abordagem para a estimativa da recarga subterrânea em regiões com ausência/escassez de dados, por meio da utilização de produtos de sensoriamento remoto disponíveis na ferramenta de computação em nuvem do Google Earth Engine.

Atualmente diferentes produtos/modelos baseados em estimativas por sensoriamento remoto encontram-se disponíveis e mais facilmente acessáveis por usuários finais. Nesse sentido, extrair dados das três bases hidroclimáticas por meio do GEE forneceu fácil e rápido acesso aos dados de evapotranspiração, escoamento superficial e precipitação (Tabela 2), para aplicar o balanço hídrico da água na estimativa da GWR em dois cenários (C1 e C2) e, utilizando um modelo baseado no WTF, modelar a WTD nos arredores da EEcA.

As estimativas anuais da GWR do FLDAS e GLDAS mostram-se mais correlacionadas com a P do que com ET e SR . Já no TERRACLIMATE, o SR causou forte influência no balanço hídrico, prejudicando a estimativa de recarga nos dois cenários. E, conseqüentemente, o modelo da WTD com dados desta base apresentou pior desempenho. A estimativa de precipitação das três bases mostrou boa concordância com os dados de chuva observada na estação do DAEE com $r = 0,85$ e $RMSE = 43,95 \text{ mm.mês}^{-1}$, $r = 0,85$ e $RMSE = 52,05 \text{ mm.mês}^{-1}$ e $r = 0,81$ e $RMSE = 49,97 \text{ mm.mês}^{-1}$ para o FLDAS, GLDAS e TERRACLIMATE, respectivamente. Já as estimativas de evapotranspiração e o escoamento superficial não foram validadas pela falta de dados observados.

A hipótese de considerar um atraso entre o volume excedente do balanço hídrico e a recarga efetiva no cenário 2 (GWR_{avg}), melhorou significativamente a correlação da série de recarga estimada com a GWR_{ref} (com três diferentes faixas de S_y) para o FLDAS ($r = 0,19$ no C1 para $r = 0,61$ no C2) e GLDAS ($r = 0,38$ para $r = 0,73$) e diminuiu o RMSE, enquanto que o TERRACLIMATE não demonstrou resultados significativos (Tabela 5). Este resultado aponta a importância de considerar a avaliação do efeito do atraso na recarga em áreas de afloramento do SAG em modelos baseados no balanço hídrico. No entanto, mais pesquisas em demais áreas do SAG devem ser elaboradas para corroborar ou não esta hipótese.

Na modelagem da WTD , considerando os resultados do FLDAS (base com melhores desempenho na modelagem dos níveis freáticos), os melhores resultados

foram observados em poços menos profundos, com RMSE variando de 0,36 a 0,81 e R^2 de 65 a 72% em comparação aos poços observados. O GLDAS, apesar de captar a tendência da oscilação dos níveis, superestimou a recarga gerando níveis freáticos mais elevados que os verificados na realidade. No entanto, este produto possui menor resolução espacial que as demais bases, o que pode ter influenciado suas estimativas e aumentado a incerteza de sua P, ET e SR. Por último, o TERRACLIMATE, provavelmente por estimativas de SR muito discrepantes em comparação as demais bases (apesar de nenhuma estimativa de ET e SR terem sido validadas), não apresentou resultados significativos na estimativa da recarga e modelagem da *WTD*.

Entre as três bases hidroclimáticas, os dados do FLDAS tiveram melhor desempenho para estimar a recarga das águas subterrâneas e modelar os níveis freáticos na EECA, usando o balanço hídrico e uma adaptação do método WTF, respectivamente. No entanto, o uso das demais bases não deve ser descartado em demais pesquisas relacionadas as águas subterrâneas. Os dados das três bases possuem estimativas de resolução espacial grosseira, porém com grande valor temporal com longos períodos de dados disponíveis e facilidade de acessá-los mediante ferramentas como o GEE. Este estudo foi elaborado de forma exploratória e fornece ferramentas úteis para regiões onde os dados são escassos ou inexistentes. Este trabalho pode ser de interesse para pesquisadores, profissionais e formuladores de políticas envolvidos em estudos e projetos de gerenciamento da água. Particularmente, este estudo pode ajudar a entender o benefício de incorporar dados detectados remotamente no gerenciamento das águas subterrâneas. Esta abordagem usou apenas estimativas dos componentes do ciclo hidrológico que são de fácil acesso por meio da computação em nuvem, evitando a necessidade de dados observados em missões de campo como variáveis de entrada.

Aqui destaca-se o esforço crescente dos profissionais ligados aos recursos hídricos, especificamente das águas subterrâneas, na geração contínua de conhecimento que ajude a gerir de forma inteligente este valioso recurso. Além do desafio fundamental da comunidade de sensoriamento remoto de manipular dados de observação da terra, especialmente com o aumento de plataformas concorrentes para lidar com vários tipos de arquivos com diferentes arquiteturas e recursos computacionais

REFERÊNCIAS

- ABATZOGLOU, J.T.; S.Z. DOBROWSKI, S.A.; PARKS, K.C. HEGEWISCH. TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015. **Scientific data**, v. 5, p. 170191, 2018. <https://doi.org/10.1038/sdata.2017.191>.
- AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Atlas Brasil: abastecimento urbano de água, panorama nacional**. 2010. Disponível em: <<http://atlas.ana.gov.br/Atlas/forms/Home.aspx>>. Acesso em: 10 janeiro de 2018.
- AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Estimativas de evapotranspiração real por sensoriamento remoto no Brasil**. 2020. Disponível em: <<http://www.snirh.gov.br/portal/snirh/centrais-de-conteudos/central-de-publicacoes/23-estimativas-de-evapotranspiracao-real-por-sensoriamento-remoto>>. Acesso em: 12 julho de 2020.
- ARSENAULT, K.R.; KUMAR, S.V.; GEIGER, J.V.; WANG, S.; KEMP, E.; MOCKO, D.M.; BEAUDOING, H. K.; GETIRANA, A.; NAVARI, M.; LI, B.; JACOB, J.; WEGIEL, J.; PETERS-LIDARD, C.D. The Land surface Data Toolkit (LDT v7. 2) – a data fusion environment for land data assimilation systems. **Geoscientific Model Development**, v. 11, n. 9, p. 3605-3621, 2018. <https://doi.org/10.5194/gmd-11-3605-2018>.
- BAALOUSHA, H. Assessment of a groundwater quality monitoring network using vulnerability mapping and geostatistics: A case study from Heretaunga Plains, New Zealand. **Agricultural water management**, v. 97, n. 2, p. 240-246, 2010. <https://doi.org/10.1016/j.agwat.2009.09.013>.
- BASTIAANSSEN, W. G. M.; MENENTI, M.; FEDDES, R. A.; HOLTSLAG, A. M. A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. **Journal of Hydrology**, v. 212–213, n. 1-4, p. 198-212. 1998a.
- BASTIAANSSEN, W. G. M.; PELGRUM, H.; WANG, J.; MORENO, J. F.; ROERINK, G. J.; WAL, T. V. A remote sensing surface energy balance algorithm for land (SEBAL). 2. Validation. **Journal of Hydrology**, v. 212–213, n. 1-4, p. 213-229. 1998b.

BEAUDOING, H.; RODELL, M.; NASA/GSFC/HSL. **GLDAS Noah Land Surface Model L4 3 hourly 0.25 x 0.25 degree V2.1**, Greenbelt, Maryland, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC). 2020a.

Disponível em:<

https://disc.gsfc.nasa.gov/datasets/GLDAS_NOAH025_3H_2.1/summary>. Acesso em: 12 julho de 2020.

BEAUDOING, H.; RODELL, M.; NASA/GSFC/HSL. **GLDAS VIC Land Surface Model L4 3 hourly 1.0 x 1.0 degree V2.1**, Greenbelt, Maryland, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC). 2020b.

Disponível

em:<https://disc.gsfc.nasa.gov/datasets/GLDAS_VIC10_3H_2.1/summary>. Acesso em: 12 julho de 2020.

BELWARD, A. S.; ESTES, J. E.; AND KLINE, K. D. The IGBP-DIS global 1-km land-cover data set DISCover: A project overview. **Photogrammetric Engineering and Remote Sensing**, v. 65, n. 9, p. 1013-1020, 1999.

BREWINGTON L.; KEENER V.; MAIR A. Simulating Land Cover Change Impacts on Groundwater Recharge under Selected Climate Projections, Maui, Hawai'i. **Remote Sensing**, v. 11, n. 24, p. 3048, 2019. <https://doi.org/10.3390/rs11243048>.

BRITO A. P.; TOMASSELA J.; WAHNFRIED I. D.; CANDIDO L. A.; MONTEIRO M. T.; FILGUEIRAS S. J. F. Relação entre precipitação e recarga de águas subterrâneas na Amazônia Central. **Águas Subterrâneas**, v. 34, n. 1, p. 39-49, 2020. <https://doi.org/10.14295/ras.v34i1.29616>.

CAMBRAIA NETO, A. J.; RODRIGUES, L. N. Evaluation of groundwater recharge estimation methods in a watershed in the Brazilian Savannah. **Environmental Earth Sciences**, v. 79, n. 6, p. 1-14, 2020. <https://doi.org/10.1007/s12665-020-8884-x>.

CHATTERJEE, R. S.; PRANJAL, P.; JALLY, S.; KUMAR, B.; DADHWAL, V. K.; SRIVASTAV, S. K.; KUMAR, D. Potential groundwater recharge in north-western India vs spaceborne GRACE gravity anomaly based monsoonal groundwater storage change for evaluation of groundwater potential and sustainability. **Groundwater for**

Sustainable Development, v. 10, p. 100307, 2020.

<https://doi.org/10.1016/j.gsd.2019.100307>.

CHRISTOFOLETTI, A. **Modelagem de Sistemas Ambientais**. São Paulo, SP: Edgard Blücher, 1999. 236 p.

COELHO, C. A.; CARDOSO, D. H.; FIRPO, M. A. Precipitation diagnostics of an exceptionally dry event in São Paulo, Brazil. **Theoretical and applied climatology**, v. 125, n. 3-4, p. 769-784, 2016. <https://doi.org/10.1007/s00704-015-1540-9>.

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. Alluvial groundwater recharge estimation in semi-arid environment using remotely sensed data. **Journal of Hydrology**, v. 548, p. 1-15, 2017.

<https://doi.org/10.1016/j.jhydrol.2017.02.054>.

COMPANHIA AMBIENTAL DO ESTADO DE SÃO PAULO (CETESB). **Relatório da qualidade de águas subterrâneas no Estado de São Paulo**. São Paulo, 2016.

COMPANHIA AMBIENTAL DO ESTADO DE SÃO PAULO (CETESB). **Uso das águas subterrâneas para abastecimento público no Estado de São Paulo**. São Paulo, 1997.

DAEE (Departamento de Águas e Energia Elétrica); IG (Instituto Geológico); IPT (Instituto de Pesquisas Tecnológicas); CPRM (Serviço Geológico do Brasil). **Mapa de águas subterrâneas do Estado de São Paulo escala: 1:1.000.000**: nota explicativa. São Paulo: Conselho Estadual de Recursos Hídricos, 2005.

DE ARAÚJO, M. L. S.; SANTOS, J. R. N.; FEITOSA, F. E. C. S.; DOS SANTOS, J. S.; SILVA, V. A. R.; ALMEIDA, J. L.; RIBEIRO, C. V.; SILVA, F. B. Caracterização Espaço-Temporal Dos Componentes Do Balanço De Radiação E Calor Na Região De Transição Amazônia-Cerrado. **Revista Brasileira de Climatologia**, v. 24, 2019. <http://dx.doi.org/10.5380/abclima.v24i0.51586>

DERBER, J. C.; PARRISH, D. F.; LORD, S. J. The new global operational analysis system at the National Meteorological Center. **Weather and Forecasting**, v. 6, n. 4, p. 538-547, 1991.

DOS REIS, J. B. C.; RENNÓ, C. D.; LOPES, E. S. S. Validation of satellite rainfall products over a mountainous watershed in a humid subtropical climate region of Brazil. **Remote Sensing**, v. 9, n. 12, p. 1240, 2017.

<https://doi.org/10.3390/rs9121240>.

DUARTE, L. G.; ROMERA, K. S.; SABINO, M.; CURADO, L. F. A.; DA SILVA PALÁCIOS, R.; DE SOUZA NOGUEIRA, J. DYNAMICS OF HEAT FLUXES BY BOWEN AND MATMNXFLX AND NOAH FLDAS PRODUCTS IN THE PANTANAL OF MATO GROSSO. **Raega-O Espaço Geográfico em Análise**, v. 46, n. 3, p. 07-19, 2019.

EBITA, A.; KOBAYASHI, S.; OTA, Y.; MORIYA, M.; KUMABE, R.; ONOGI, K.; HARADA, Y.; YASUI, S.; MIYAOKA, K.; TAKAHASHI, K.; KAMAHORI, H.; KOBAYASHI, C.; ENDO, H.; SOMA, M.; OIKAWA, Y.; ISHIMIZU, T. Japanese 55-year reanalysis “JRA-55”: an interim report. **Sola**, v. 7, p. 149-152, 2011. 10.2151/sola.2011-038.

FALLATAH, O. A.; AHMED, M.; CARDACE, D.; BOVING, T.; AKANDA, A. S. Assessment of modern recharge to arid region aquifers using an integrated geophysical, geochemical, and remote sensing approach. **Journal of Hydrology**, v. 569, p. 600-611, 2019. <https://doi.org/10.1016/j.jhydrol.2018.09.061>.

FETTER, C. W. Applied Hydrogeology: Macmillan College Publishing Company. **New York New York**, 1994.

FREEZE, R. A.; CHERRY, J. A. **Groundwater**. 1979.

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAND, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Scientific data**, v. 2, n. 1, p. 1-21, 2015. 10.1038/sdata.2015.66 2015.

GELARO, R.; MCCARTY, W.; SUÁREZ, M. J.; TODLING, R.; MOLOD, A.; TAKACS, L.; RANGLES, C. A.; DARMENOV, A.; BOSILOVICH, M. G.; WARGAN, R. R. K.; COY, L.; CULLATHER, R.; DRAPER, C.; AKELLA, S.; BUCHARD, V.; CONATY, A.; SILVA, A. M.; GU, W.; KIM, G-K.; KOSTER, R.; LUCCHESI, R.; MERKOVA, D.;

NIELSEN, J. E.; PARTYKA, G.; PAWSON, S.; PUTMAN, W.; RIENECKER, M.; SCHUBERT, S. D.; SIENKIEWICZ, M.; ZHAO, B. The modern-era retrospective analysis for research and applications, version 2 (MERRA-2). **Journal of Climate**, v. 30, n. 14, p. 5419-5454, 2017. <https://doi.org/10.1175/JCLI-D-16-0758.1>.

GEMITZI, A.; AJAMI, H.; RICHNOW, H. H. Developing empirical monthly groundwater recharge equations based on modeling and remote sensing data—Modeling future groundwater recharge to predict potential climate change impacts. **Journal of Hydrology**, v. 546, p. 1-13, 2017. <https://doi.org/10.1016/j.jhydrol.2017.01.005>.

GONÇALVES, V. F. M.; MANZIONE, R. L. ESTIMATIVA DA RECARGA DAS ÁGUAS SUBTERRÂNEAS NO SISTEMA AQUÍFERO BAURU (SAB). **Geo UERJ**, n. 35, p. 37063, 2019. <https://doi.org/10.12957/geouerj.2019.37063>.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote sensing of Environment**, v. 202, p. 18-27, 2017. <https://doi.org/10.1016/j.rse.2017.06.031>.

GRDC. **Global Freshwater Fluxes into the World Oceans**. Tech. Report prepared for the GRDC, Koblenz, Federal Institute of Hydrology (BfG), GRDC Report, 2014. Disponível em: <
https://www.bafg.de/GRDC/EN/03_dtprdcts/31_FWFLX/freshflux_node.html >. Acesso em: 12 julho de 2020.

GÜNTNER A.; SCHMIDT, R.; DÖLL, P. Supporting large-scale hydrogeological monitoring and modelling by time-variable gravity data. **Hydrogeology Journal**, v. 15, n. 1, p. 167-170, 2007.

HANSEN, M. C.; DEFRIES, R. S.; TOWNSHEND, J. R. G.; SOHLBERG, R. Global land cover classification at 1km resolution using a decision tree classifier. **International Journal of Remote Sensing**, v. 21, n. 6-7, p. 1331-1365, 2000.

HARRIS, I.; OSBORN, T. J.; JONES, P.; LISTER, D. Version 4 of the CRU TS monthly high-resolution gridded multivariate climate dataset. **Scientific data**, v. 7, n. 1, p. 1-18, 2020.

HEALY, R. W. **Estimating groundwater recharge**. Cambridge University Press, 2010.

HEALY, R. W.; COOK, P. G. (2002) Using groundwater levels to estimate recharge. **Hydrogeology journal**, v. 10, n. 1, p. 91-109, 2002.
<https://doi.org/10.1007/s10040-001-0178-0>.

HENRY, C. M.; ALLEN, D. M.; HUANG, J. Groundwater storage variability and annual recharge using well-hydrograph and GRACE satellite data. **Hydrogeology Journal**, v. 19, n. 4, p. 741-755, 2011. <https://doi.org/10.1007/s10040-011-0724-3>.

HUFFMAN, G. J.; ADLER, R. F.; BOLVIN, D. T.; NELKIN, E. J. The TRMM multi-satellite precipitation analysis (TMPA). In: **Satellite rainfall applications for surface hydrology**. Springer, Dordrecht, 2009. p. 3-22. https://doi.org/10.1007/978-90-481-2915-7_1.

HUFFMAN, G.J.; STOCKER, E.F.; BOLVIN, D.T.; NELKIN, E.J.; JACKSON TAN. **GPM IMERG Final Precipitation L3 Half Hourly 0.1 degree x 0.1 degree V06**. Greenbelt, MD, Goddard Earth Sciences Data and Information Services Center (GES DISC). 2019. Disponível em:<
https://disc.gsfc.nasa.gov/datasets/GPM_3IMERGDF_06/summary> Acesso em: 20 julho de 2020.

INSTITUTO DE PESQUISAS TECNOLÓGICAS (IPT). Mapa geológico do estado de São Paulo. São Paulo: IPT, 1981. (Série Monografias n. 6, v. 1)

INSTITUTO DE PESQUISAS TECNOLÓGICAS (IPT). Sistema Aquífero Guarani: subsídios ao plano de desenvolvimento e proteção ambiental da área de afloramento do Sistema Aquífero Guarani no Estado de São Paulo. São Paulo: IPT, 2011. Disponível em:<<http://www.terrabrasilis.org.br/ecotecadigital/pdf/subsidios-ao-plano-de-desenvolvimento-e-protecao-ambiental-da-area-de-afloramento-do-sistema-aquifero-guarani-do-estado-de-sao-paulo-.pdf>>. Acesso em: 16 janeiro de 2020.

JENSEN, J. R., & EPIPHANIO, J. C. N. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Parêntese, 2011.

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**, v. 5, n. 3, p. 487-503, 2004. [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)

KHALAF, A.; DONOGHUE, D. Estimating recharge distribution using remote sensing: a case study from the West Bank. **Journal of Hydrology**, v. 414, p. 354-363, 2012. <https://doi.org/10.1016/j.jhydrol.2011.11.006>.

KUMAR, S. V.; PETERS-LIDARD, C. D.; SANTANELLO, J.; HARRISON, K.; LIU, Y.; SHAW, M. Land surface Verification Toolkit (LVT)—a generalized framework for land surface model evaluation. **Geoscientific Model Development**, v. 5, n. 3, p. 869-886, 2012. [10.1029/2011WR011453](https://doi.org/10.1029/2011WR011453), 2012.

Li, B.; Beaudoin, H.; Rodell, M.; NASA/GSFC/HSL. **GLDAS Catchment Land Surface Model L4 daily 0.25 x 0.25 degree V2.0**. Greenbelt, Maryland, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC). 2018. Disponível em: <
https://disc.gsfc.nasa.gov/datasets/GLDAS_CLSM025_D_2.0/summary > Acesso em: 20 de julho de 2020.

LIMAYE, S. D. Socio-hydrogeology and low-income countries: Taking science to rural society. **Hydrogeology Journal**, v. 25, n. 7, p. 1927-1930, 2017. <https://doi.org/10.1007/s10040-017-1656-3>.

LONG, D.; CHEN, X.; SCANLON, B. R.; WADA, Y.; HONG, Y.; SINGH, V. P.; CHEN, Y.; WANG, C.; HAN, Z.; YANG, W. Have GRACE satellites overestimated groundwater depletion in the Northwest India Aquifer? **Scientific Reports**, 6, 24398. 2016. <https://doi.org/10.1038/srep24398>.

LUCAS, M. C.; GUANABARA, R. C.; WENLAND, E. Estimativa de recarga subterrânea em área de afloramento do Sistema Aquífero Guarani. **Boletín Geológico y Minero**, v. 123, n. 3, p. 311-323, 2012.

LUCAS, M. C.; OLIVEIRA, P. T. S.; MELO, D. C. D.; WENDLAND, E. Evaluation of remotely sensed data for estimating recharge to an outcrop zone of the Guarani Aquifer System (South America). **Hydrogeology Journal**, v. 23, n. 5, p. 961-969, 2015. [10.1007/s10040-015-1246-1](https://doi.org/10.1007/s10040-015-1246-1).

MANOEL FILHO, J. Ocorrência das águas subterrâneas. In: FEITOSA, F. A. C.; MANOEL FILHO, J.; FEITOSA, E. C.; DEMETRIO, J. G. A. **Hidrogeologia: conceitos e aplicações**. Rio de Janeiro: CPRM: LABHID, 2008. 812 p. 53-75.

MANZIONE R. L.; WENDLAND, E.; TANIKAWA, D. H. Stochastic simulation of time-series models combined with geostatistics to predict water-table scenarios in a Guarani Aquifer System outcrop area, Brazil. **Hydrogeology Journal**, v. 20, n. 7, p. 1239-1249, 2012. <https://doi.org/10.1007/s10040-012-0885-8>

MANZIONE, R. L. **Águas subterrâneas: Conceitos e Aplicações sob uma visão Multidisciplinar**. 1 ed., 386 p. Jundiaí. Paco Editorial, 2015.

MANZIONE, R. L. Water table depths trends identification from climatological anomalies occurred between 2014 and 2016 in a cerrado conservation area in the Médio Paranapanema Hydrographic Region/SP-Brazil. **Boletim Goiano De Geografia**, v. 38, n. 1, p. 68, 2018. <https://doi.org/10.5216/bgg.v38i1.52815>.

MANZIONE, R. L.; CASTRIGNANÒ, A. A geostatistical approach for multi-source data fusion to predict water table depth. **Science of The Total Environment**, v. 696, p. 133763, 2019. <https://doi.org/10.1016/j.scitotenv.2019.133763>

MANZIONE, R. L.; SOLDERA, B. C.; WENDLAND, E. C. Groundwater system response at sites with different agricultural land uses: case of the Guarani Aquifer outcrop area, Brotas/SP-Brazil. **Hydrological Sciences Journal**, v. 62, n. 1, p. 28-35, 2017. <https://doi.org/10.1080/02626667.2016.1154148>.

MAPBIOMAS. **Coleção [4.0] da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil**. 2019. Disponível em: <<https://mapbiomas.org/colecoes-mapbiomas-2-1>>. Acesso em: 29 de dezembro de 2019.

MATOS, A. C. O. C.; BLITZKOW, D.; ALMEIDA, F.; COSTA, S.; CAMPOS, I.; BARBOSA, A. Analysis of water level variations in Brazilian basins using GRACE. **Journal of Geodetic Science**, v. 2, n. 2, p. 76-87, 2012.

MCKEE, T. B.; DOESKEN, N. J.; KLEIST, J. The relationship of drought frequency and duration to time scales. In: **Proceedings of the 8th Conference on Applied Climatology**. 1993. p. 179-183.

MCNALLY A.; NASA/GSFC/HSL. **FLDAS Noah Land Surface Model L4 Global Monthly 0.1 x 0.1 degree (MERRA-2 and CHIRPS)**. Greenbelt, MD, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC). 2018. Disponível em: <https://disc.gsfc.nasa.gov/datasets/FLDAS_NOAH01_C_GL_M_001/summary>. Acesso em: 12 de julho de 2020.

MCNALLY, A.; ARSENAULT, K.; KUMAR, S.; SHUKLA, S.; PETERSON, P.; WANG, S.; FUNK, C.; PETERS-LIDARD, C. D.; VERDIN, J. P. A land data assimilation system for sub-Saharan Africa food and water security applications. **Scientific data**, v. 4, n. 1, p. 1-19, 2017. <https://doi.org/10.1038/sdata.2017.12>.

MCNALLY, A.; NASA/GSFC/HSL/FLDAS. **Noah Land Surface Model L4 Global Monthly 0.1 x 0.1 degree (MERRA-2 and CHIRPS)**. Greenbelt, MD, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC), 2018. Disponível em: <https://disc.gsfc.nasa.gov/datasets/FLDAS_NOAH01_C_GL_M_001/summary> Acesso em: 25 de julho de 2020.

MCNALLY, A.; VERDIN, K.; HARRISON, L.; GETIRANA, A.; JACOB, J.; SHUKLA, S.; ARSENAULT, K.; PETERS-LIDARD, C.; VERDIN, J. P. Acute Water-Scarcity Monitoring for Africa. **Water**, v. 11, n. 10, p. 1968, 2019.

MELATI, M. D.; FAN, F. M.; ATHAYDE, G. B. Groundwater recharge study based on hydrological data and hydrological modelling in a South American volcanic aquifer. **Comptes Rendus Geoscience**, v. 351, n. 6, p. 441-450, 2019.

MESTRINHO, S.S.P. Monitoramento em água subterrânea. In: FEITOSA, FAC; MANOEL FILHO, J.; FEITOSA, E. C; et al. **Hidrogeologia: Conceitos e aplicações**. Rio de Janeiro: CPRM/LABHID, p. 673-686, 2008.

MIRO, M. E.; FAMIGLIETTI, J. S. Downscaling GRACE remote sensing datasets to high-resolution groundwater storage change maps of California's Central Valley. **Remote Sensing**, v. 10, n. 1, p. 143, 2018.

<https://doi.org/10.3390/rs10010143>.

MOAZAMI, S.; GOLIAN, S.; KAVIANPOUR, M. R.; HONG, Y. Uncertainty analysis of bias from satellite rainfall estimates using copula method. **Atmospheric Research**, v. 137, p. 145-166, 2014. (2013) Uncertainty analysis of bias from satellite rainfall estimates using copula method. *Atmos Res* 137:145–166.

<https://doi.org/10.1016/j.atmosres.2013.08.016>.

MOGK, D. W.; BRUCKNER, M. Z. Geoethics training in the Earth and environmental sciences. **Nature Reviews Earth & Environment**, v.1, n. 2, p. 81-83, 2020.

MONTEIRO, C. H. B.; PRADO, B. H. S.; DIAS, A. C. Plano de manejo da Estação Ecológica de Angatuba. **Instituto Florestal. São Paulo, Secretaria do Meio Ambiente**, 2009. Disponível em:<

http://arquivo.ambiente.sp.gov.br/consema/2011/11/oficio_consema_2009_056/Plano_de_Manejo_Estacao_Ecologica_Angatuba.pdf >. Acesso em: 22 de julho de 2020.

NAVA, A.; MANZIONE, R. L. Resposta de níveis freáticos do sistema Aquífero Bauru (formação adamantina) em função da precipitação e evapotranspiração sob diferentes usos da terra. **Águas Subterrâneas**, v. 29, n. 2, p. 191-201, 2015.

<https://doi.org/10.14295/ras.v29i2.28402>.

NGUYEN, P.; SHEARER, E.J.; TRAN, H.; OMBADI, M.; HAYATBINI, N.; PALACIOS, T.; HUYNH, P.; UPDEGRAFF, G.; HSU, K.; KULIGOWSKI, B.; LOGAN, W. S.; SOROOSHIAN, S. The CHRS Data Portal, an easily accessible public repository for PERSIANN global satellite precipitation data. **Scientific data**, v. 6, n. 1, p. 1-10, 2019. <https://doi.org/10.1038/sdata.2018.296>

NIMMO, J. R.; HOROWITZ, C.; MITCHELL, L. Discrete-storm water-table fluctuation method to estimate episodic recharge. **Groundwater**, v. 53, n. 2, p. 282-292, 2015.

<https://doi.org/10.1111/gwat.12177>.

NOVELLA, N. S.; THIAW, W. M. African rainfall climatology version 2 for famine early warning systems. **Journal of Applied meteorology and Climatology**, v. 52, n. 3, p. 588-606, 2013.

OLIVEIRA, J. F. de; XAVIER, A. F.; SANTOS, H. L. **Áreas especialmente protegidas**. Secretaria do Estado do Meio Ambiente. Coordenadoria de Planejamento Ambiental Estratégico e Educação Ambiental. São Paulo: SMA/CPLEA, 2006. (Coletânea de Leis).

ONOGI, K.; TSUTSUI, J.; KOIDE, H.; SAKAMOTO, M.; KOBAYASHI, S.; HATSUSHIKA, H.; MATSUMOTO, T.; YAMAZAKI, N.; KAMAHORI, H.; TAKAHASHI, K.; KADOKURA, S.; WADA, K.; KATO, K.; OYAMA, R.; OSE, T.; MANNOJI, N.; TAIRA, R. The JRA-25 reanalysis. **Journal of the Meteorological Society of Japan. Ser. II**, v. 85, n. 3, p. 369-432, 2007.10.2151/jmsj.85.369.

PETERSON T. J.; FULTON, S. Joint estimation of gross recharge, groundwater usage, and hydraulic properties within HydroSight. **Groundwater**, v. 57, n. 6, p. 860-876, 2019. <https://doi.org/10.1111/gwat.12946>.

R CORE TEAM. **R: A language and environment for statistical computing**. Disponível em <https://www.r-project.org/>. Acesso em: 16 de junho de 2019.

RAMPAZO, N A. M.; PICOLI, M. C. A.; CAVALIERO, C. K. N. Comparação entre dados meteorológicos provenientes de sensoriamento remoto (modelados e de satélites) e de estações de superfície (Comparison of meteorological data obtained by remote sensing (from models and satellites) and weather stations data). **Revista Brasileira de Geografia Física**, v. 12, n. 2, p. 412-426, 2018.

REYNOLDS, C. A.; JACKSON, T. J.; RAWLS, W. J. Estimating soil water-holding capacities by linking the Food and Agriculture Organization soil map of the world with global pedon databases and continuous pedotransfer functions. **Water Resources Research**, v. 36, n. 12, p. 3653-3662, 2000.

RODELL, M. GLDAS: Project Goals. NASA, 2020. Disponível em: <https://ldas.gsfc.nasa.gov/gldas>. Acesso em: 11 de outubro de 2020.

RODELL, M.; BEAUDOING, H. K.; NASA/GSFC/HSL. **GLDAS CLM Land Surface Model L4 3 hourly 1.0 x 1.0 degree Subsetted V001**. Greenbelt, Maryland, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC). 2007a.

Disponível em:<

https://disc.gsfc.nasa.gov/datasets/GLDAS_CLM10SUBP_3H_001/summary>

Acesso em: 20 de julho de 2020.

RODELL, M.; BEAUDOING, H. K.; NASA/GSFC/HSL. **GLDAS Mosaic Land Surface Model L4 3 Hourly 1.0 x 1.0 degree Subsetted V001**. Greenbelt, Maryland, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC). 2007b. Disponível em:<

https://disc.gsfc.nasa.gov/datasets/GLDAS_MOS10SUBP_3H_001/summary>

Acesso em: 20 de julho de 2020.

RODELL, M.; HOUSER, P. R.; JAMBOR, U.; GOTTSCHALCK, J.; MITCHELL, K.; MENG, C. -J.; ARSENAULT, K.; COSGROVE, B.; RADA KOVICH, J.; BOSILOVICH, M.; ENTIN, J. K.; WALKER, J. P.; LOHMANN, D.; TOLL, D. The global land data assimilation system. **Bulletin of the American Meteorological Society**, v. 85, n. 3, p. 381-394, 2004. <https://doi.org/10.1175/BAMS-85-3-381>.

ROSSI, M. **Mapa Pedológico do Estado de São Paulo**. 2017. Disponível em: http://iflorestal.sp.gov.br/files/2017/11/Livro_Solos1.pdf. Acesso em: 16 de junho de 2019.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In: **Earth Resources Technology Satellite-1 Symposium**, Washington. Proceedings... v. 1, sec. A, p. 309-317, 1973.

RUNNING, S.; MU, Q.; ZHAO, M. **MOD16A2 MODIS/Terra Net Evapotranspiration 8-Day L4 Global 500m SIN Grid V006**. NASA EOSDIS Land Processes DAAC, 2017. Disponível em:<<https://doi.org/10.5067/MODIS/MOD16A2.006>>: Acesso em: 20 de julho de 2020.

SANTOS, J. R. **Recarga do sistema aquífero guarani em área de afloramento em bofete-sp entre 2012 e 2016**. 2018. 101 f. Dissertação (Mestrado em Gestão e

Regulação de Recursos Hídricos), Universidade Estadual Paulista (Unesp), Faculdade de Engenharia de Ilha Solteira, Ilha Solteira.

SCANLON, B.; HEALY, R.; COOK, P. Choosing appropriate techniques for quantifying groundwater recharge. **Hydrogeology journal**, v. 10, n. 1, p. 18-39, 2002. <https://doi.org/10.1007/s10040-001-0176-2>.

SCANLON, B.R.; FAUNT, C.C.; LONGUEVERGNE, L.; REEDY, R.C.; ALLEY, W.M.; McGuire, V.L.; McMahon, P.B. Groundwater depletion and sustainability of irrigation in the US High Plains and Central Valley. *Proceedings of the national academy of sciences*, v. 109, n. 24, p. 9320-9325, 2012. <https://doi.org/10.1073/pnas.1200311109>

SENAY, G. B. Satellite Psychrometric Formulation of the Operational Simplified Surface Energy Balance (SSEBop) Model for Quantifying and Mapping Evapotranspiration. **Applied Engineering in Agriculture**, v. 34, n. 3, p. 555-566, 2018. 10.13031/aea.12614.

SERVIÇO GEOLÓGICO DO BRASIL (CPRM). **Acompanhamento da estiagem na região Sudeste do Brasil 2015, relatório 3**. São Paulo, 2015. Disponível em: <http://www.cprm.gov.br/sace/boletins/secas_estiagens/Relatorios/Sao_Paulo/2015_003-20150810%20-%20134643.pdf>. Acesso em: 12 de julho 2020.

SHARIFI, E.; BAHRAM, S.; STEINACKER, R. Copula-based stochastic uncertainty analysis of satellite precipitation products. **Journal of Hydrology**, v. 570, p. 739-754, 2019. <https://doi.org/10.1016/j.jhydrol.2019.01.035>.

SHIKLOMANOV, I. A.; RODDA, J. **World Water Resources at the Beginning of the 21st Century**, Cambridge University Press, 2003.

SHILPAKAR, R. L.; BASTIAANSEN, W. G. M.; MOLDEN, D. J. A remote sensing-based approach for water accounting in the East Rapti River Basin, Nepal. **Himalayan Journal of Sciences**, v. 7, n. 9, p. 15-30, 2011. <https://doi.org/10.3126/hjs.v7i9.5785>.

SILVA, C. O. F. **Modelagem espacial da recarga das águas subterrâneas sob diferentes usos e coberturas da terra**. 2019. 199 f. Dissertação (Mestrado em

Agronomia: Irrigação e Drenagem), Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agronômicas, Botucatu.

SILVA, C. O. F.; MANZIONE, R. L.; ALBUQUERQUE FILHO, J. L. Combining remotely sensed actual evapotranspiration and GIS analysis for groundwater level modeling. **Environmental Earth Sciences**, v. 78, n. 15, p. 462, 2019a. <https://doi.org/10.1007/s12665-019-8467-x>.

SILVA, C. O. F.; MANZIONE, R. L.; ALBUQUERQUE FILHO, J. L. Sensoriamento remoto orbital para manejo da irrigação: uma revisão sistêmica. **Anais do V In INOVAGRI Internation Meeting**, 2019b. Disponível em: <<http://icolibri.com.br/2019/public/biblioteca/v-inovagri-meeting/RES2010022> >. Acesso em: 20 de julho de 2020.

SILVA, C. O. F.; TEIXEIRA, A. H. de C.; MANZIONE, R. L. Agriwater: An R package for spatial modelling of energy balance and actual evapotranspiration using satellite images and agrometeorological data. **Environmental Modelling & Software**, v. 120, p. 104497, 2019. <https://doi.org/10.1016/j.envsoft.2019.104497>.

SIMON, F. W.; REGINATO, P. A. R.; KIRCHHEIM R. E.; TROIAN G. C. Estimativa de recarga do sistema aquífero guarani por meio da aplicação do método da variação da superfície livre na bacia do Rio Ibicuí-RS. **Águas Subterrâneas**, v. 31, n. 2, p. 12-29, 2017. <https://doi.org/10.14295/ras.v31i2.28631>.

SOBREIRO, J. F. F. **Vegetation multitemporal responses to hydroclimate variations in the Espinhaço Range (Brazil)**. 2019. 73 f. Dissertação (Mestrado em Geografia) Universidade Estadual Paulista (Unesp), Instituto de Geociências e Ciências Exatas, Rio Claro.

SWENSON, S. C. **GRACE monthly land water mass grids NETCDF RELEASE 5.0. Ver. 5.0**. PO.DAAC, CA, USA, 2012. Disponível em: <<https://doi.org/10.5067/TELND-NC005>>. Acesso em: 20 de julho 2020.

SWENSON, S. C.; WAHR, J. Post-processing removal of correlated errors in GRACE data. **Geophysical Research Letters**, v. 33, n. 8, 2006. 10.1029/2005GL025285.

SZILAGYI, J.; ZLOTNIK, V. A.; GATES, J. B.; JOZSA, J. Mapping mean annual groundwater recharge in the Nebraska Sand Hills, USA. **Hydrogeology Journal**, v. 19, n. 8, p. 1503-1513, 2011. 10.1007/s10040-011-0769-3.

TAYLOR, J. R. **Introdução à análise de erros: o estudo de incertezas em medições físicas**. Bookman Editora, 2012.

TERAMOTO, E. H.; CHANG, H. K. Métodos WTF e simulação numérica de fluxo para estimativa de recarga—exemplo Aquífero Rio Claro em Paulínia/SP. **Águas Subterrâneas**, v. 32, n. 2, p. 173-180, 2018.
<https://doi.org/10.14295/ras.v32i2.28943>.

TROPICAL RAINFALL MEASURING MISSION (TRMM). **TRMM (TMPA) Rainfall Estimate L3 3 hour 0.25 degree x 0.25 degree V7**. Greenbelt, MD, Goddard Earth Sciences Data and Information Services Center (GES DISC), 2011. Disponível em:<
https://disc.gsfc.nasa.gov/datasets/TRMM_3B42_7/summary> Acesso em: 20 de julho de 2020.

VARNI, M.; COMAS, R.; WEINZETTEL, P.; DIETRICH, S. Application of the water table fluctuation method to characterize groundwater recharge in the Pampa plain, Argentina. **Hydrological Sciences Journal**, v. 58, n. 7, p. 1445-1455, 2013.
<https://doi.org/10.1080/02626667.2013.833663>

VISHWAKARMA, B. D.; DEVARAJU, B.; SNEEUW, N. What is the spatial resolution of GRACE satellite products for hydrology? **Remote Sensing**, v. 10, n. 6, p. 852, 2018. <https://doi.org/10.3390/rs10060852>.

VON ASMUTH, J. R.; BIERKENS, M. F. P.; MAAS, C. Transfer function-noise modeling in continuous time using predefined impulse response functions. **Water Resources Research**, v. 38, n. 12, p. 23-1-23-12, 2002.
<https://doi.org/10.1029/2001WR001136>.

VÖRÖSMARTY, C.; LETTENMAIER, D.; LEVEQUE, C.; MEYBECK, M.; PAHL-WOSTL, C.; ALCAMO, J.; COSGROVE, W.; GRASSL, H.; HOFF, H.; KABAT, P.; LANSIGAN, F.; LAWFORD, R.; NAIMAN, R. Humans transforming the global water system. **Eos, Transactions American Geophysical Union**, v. 85, n. 48, p. 509-514, 2004.

WALKER, D.; PARKIN, G.; SCHMITTER, P.; GOWING, J.; TILAHUN, S. A.; HAILE, A. T.; YIMAM, A. Y. Insights from a multi-method recharge estimation comparison study. **Groundwater**, v. 57, n. 2, p. 245-258, 2019.

<https://doi.org/10.1111/gwat.12801>.

WALTER, G. R.; NECSOIU, M.; MCGINNIS, R. Estimating aquifer channel recharge using optical data interpretation. **Groundwater**, v. 50, n. 1, p. 68-76, 2011.

<https://doi.org/10.1111/j.1745-6584.2011.00815.x>.

WANG, S.; LIU, H.; YU, Y.; ZHAO, W.; YANG, Q.; LIU, J. Evaluation of groundwater sustainability in the arid Hexi Corridor of Northwestern China, using GRACE, GLDAS and measured groundwater data products. **Science of The Total Environment**, v. 705, p. 135829, 2020.

<https://doi.org/10.1016/j.scitotenv.2019.135829>.

WANG-ERLANDSSON, L.; BASTIAANSEN, W. G. M.; GAO, H.; JÄGERMEYR, J.; SENAY, G. B.; VAN DIJK, A. I. J. M.; GUERSCHMAN, J. P.; KEYS, P. W.;

GORDON, L. J.; SAVENIJE, H. H. G. Global root zone storage capacity from satellite-based evaporation. **Hydrology and Earth System Sciences**, v. 20, p.

1459–1481, 2016. <https://doi.org/10.5194/hess-20-1459-2016>.

Wu, Q.; Si, B.; He, H.; Wu, P. Determining regional-scale groundwater recharge with GRACE and GLDAS. **Remote Sensing**, v. 11, n. 2, p. 154, 2019.

<https://doi.org/10.3390/rs11020154>.

YIN, W.; HU, L.; JIAO, J. J. Evaluation of groundwater storage variations in northern China using GRACE data. **Geofluids**, v. 2017, 2017.

<https://doi.org/10.1155/2017/8254824>.