



**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE PESQUISAS HIDRÁULICAS E ESCOLA DE ENGENHARIA
CURSO DE ENGENHARIA AMBIENTAL**

Leonardo Laipelt dos Santos

**GEESEBAL: UMA FERRAMENTA GOOGLE EARTH ENGINE
PARA ESTIMATIVA DE SÉRIES TEMPORAIS DE
EVAPOTRANSPIRAÇÃO**

Porto Alegre

Novembro de 2020

Leonardo Laipelt dos Santos

**GEESEBAL: UMA FERRAMENTA GOOGLE EARTH ENGINE PARA
ESTIMATIVA DE SÉRIES TEMPORAIS DE EVAPOTRANSPIRAÇÃO**

TRABALHO DE CONCLUSÃO
APRESENTADO AO CURSO DE
ENGENHARIA AMBIENTAL DA
UNIVERSIDADE FEDERAL DO RIO
GRANDE DO SUL COMO PARTE DOS
REQUISITOS PARA A OBTENÇÃO DO
TÍTULO DE ENGENHEIRO
AMBIENTAL.

Orientador: Anderson Luís Ruhoff

Coorientador: Ayan Santos Fleischmann

Porto Alegre

Novembro de 2020

CIP - Catalogação na Publicação

Laipelt dos Santos, Leonardo
GESEBAL: UMA FERRAMENTA GOOGLE EARTH ENGINE PARA
ESTIMATIVA DE SÉRIES TEMPORAIS DE EVAPOTRANSPIRAÇÃO /
Leonardo Laipelt dos Santos. -- 2020.
67 f.
Orientador: Anderson Luís Ruhoff.

Coorientador: Ayan Santos Fleischmann.

Trabalho de conclusão de curso (Graduação) --
Universidade Federal do Rio Grande do Sul, Instituto
de Pesquisas Hidráulicas, Curso de Engenharia
Ambiental, Porto Alegre, BR-RS, 2020.

1. Evapotranspiração. 2. SEBAL. 3. Google Earth
Engine. 4. Landsat. 5. GLDAS. I. Luis Ruhoff,
Anderson, orient. II. Santos Fleischmann, Ayan,
coorient. III. Título.

Leonardo Laipelt dos Santos

**GESEBAL: UMA FERRAMENTA GOOGLE EARTH ENGINE PARA
ESTIMATIVA DE SÉRIES TEMPORAIS DE EVAPOTRANSPIRAÇÃO**

Trabalho de Conclusão de Curso em Engenharia Ambiental da Universidade Federal do Rio Grande do Sul defendido e aprovado em **20/11/2020** pela Comissão avaliadora constituída pelos professores:

Banca Examinadora:

.....
Prof. Dr. Anderson Luís Ruhoff – Orientador

.....
Msc. Ayan Santos Fleischmann – Coorientador

.....
Prof Dr. Carlos Antônio Costa dos Santos – Universidade Federal de Campina Grande

.....
Prof. Dr. Walter Collischon – Departamento de Hidromecânica e Hidrologia

.....
Msc. Bruno César Comini de Andrade – Instituto de Pesquisas Hidráulicas

Conceito:.....

RESUMO

A estimativa acurada da evapotranspiração (*ET*) é essencial para diversas aplicações na gestão de recursos hídricos. O uso de modelos de *ET* que utilizam produtos de sensoriamento remoto vem crescendo nos últimos anos com o desenvolvimento de novas tecnologias como computação em nuvem, *deep learning* e processamento de alta performance. Esse estudo apresenta o geeSEBAL, uma nova ferramenta para estimativa automática de *ET* baseado no modelo *Surface Energy Balance Algorithm for Land* (SEBAL) e desenvolvido utilizando a plataforma Google Earth Engine (GEE). O uso de imagens Landsat e dados meteorológicos do *Global Land Data Assimilation System* (GLDAS) permite a estimação de longas séries temporais de *ET*. A estrutura da ferramenta é apresentada, bem como estudos de caso em diferentes condições climáticas do Brasil através da validação da estimativa de *ET* diária com dados de torres de fluxo com medições de covariância de vórtices turbulentos (EC) nos biomas da Amazônia, Cerrado, Pantanal e Pampa. As estimativas da *ET* diária apresentaram uma média de RMSD de 0,75 mm dia⁻¹, com um total de 224 imagens Landsat processadas. Por fim, é apresentado uma longa série temporal de *ET* (1984-2019) para uma pequena área localizada no bioma Cerrado, caracterizado por uma intensa expansão de agricultura com sistemas de irrigações. A ferramenta está disponível na plataforma GitHub (<https://github.com/et-brasil/geesebal>) e possui uma versão com interface gráfica do usuário (<https://etbrasil.org/geesebal>), permitindo importantes avanços na gestão de recursos hídricos em relação a mudanças na *ET*.

Palavras-chave: Google Earth Engine, SEBAL, Landsat, GLDAS.

ABSTRACT

An accurate estimation of evapotranspiration (*ET*) is essential for many applications in water resources management. *ET* models using remote sensing products have flourished in recent years with new technologies as cloud computation, deep learning and high performance computing. This study presents geeSEBAL, a new tool for automatic estimation of *ET* based on the Surface Energy Balance Algorithm for Land (SEBAL) model and developed within the Google Earth Engine platform (GEE). The usage of Landsat images and meteorological data from the Global Land Data Assimilation System (GLDAS) allows estimating long term *ET* series. The tool framework is introduced, and case studies across multiple climate conditions in Brazil are presented by validating daily *ET* with eddy covariance (EC) data in the Amazon, Cerrado, Pantanal and Pampa biomes. Daily *ET* estimations yielded an average RMSD of 0.75 mm day^{-1} , with a total of 224 Landsat images being processed. Finally, we present a long term *ET* assessment (from 1984 to 2019) in a small area located in the Cerrado biome, characterized by an intense irrigated cropland expansion over the last decades, demonstrating the potential of the tool to understand the effects of land cover changes and water use in agriculture. The tool is freely available on GitHub (<https://github.com/et-brasil/geesebal>) and has a graphical user interface (<https://etbrasil.org/geesebal>), allowing important advances in water resources management regarding *ET* changes.

Keywords: Google Earth Engine, SEBAL, Landsat, GLDAS.

LISTA DE FIGURAS

- Figura 1 - Esquema do processo de evapotranspiração (*ET*), em que a água no seu estado líquido é convertida em vapor d'água através da evaporação de superfícies líquidas (rios, lagos, oceanos) e transpiração da vegetação. Fonte: ONSET (Adaptado).
.....19
- Figura 2 - Exemplo da instalação de lisímetros para medições de *ET* para uma cultura de vegetação específica. Fonte: Lysimeter.21
- Figura 3 - Equipamentos de medição utilizados por torres EC. O sistema é composto por analisador de gases, anemômetro ultrassônico e um sistema para armazenamento, aquisição e processamento dos dados. Fonte: ELITE SCIENTIFIC INSTRUMENTS SDN BHD.22
- Figura 4 - Ilustração da medição dos vórtices turbulentos por torre de monitoramento com sistema de EC. Fonte: EARTH & ENVIRONMENTAL SCIENCES AREA (Adaptado).....22
- Figura 5 - Espectro eletromagnético. Fonte: Miniphysics (Adaptado).....24
- Figura 6 - Ilustração das principais missões em órbita mapeando a superfície e a atmosfera terrestre. Fonte: NASA.25
- Figura 7 - Esquematização do modelo SEBAL. Fonte: Autoria própria.30
- Figura 8 – Fluxograma com as etapas e possibilidades para estimar *ET* usando o geeSEBAL. Três funções estão disponíveis, para processar apenas uma imagem, uma coleção de imagens, e para extrair uma série temporal dado uma coordenada.39
- Figura 9 – A interface do usuário (www.etbrasil.com/geesebal) permite a visualização da composição RGB, *NDVI*, *Ts* e a *ET* diária, através da seleção de um ponto específico no mapa e determinação da imagem a ser visualizada.39
- Figura 10 - Localização das 10 torres EC (triângulos brancos) usados para validar as estimativas do geeSEBAL, e o ponto onde foi extraído uma longa série temporal de *ET* (*ET-LTP*) (triângulo Vermelho).....42
- Figura 11 – Comparação entre as medições de *ET* e estimativas do geeSEBAL para diferentes torres localizadas em diferentes biomas do Brasil.....45

Figura 12 – Estimativas diárias de ET de acordo com o dia do ano (DOY) baseado nas medições de EC e das estimativas do geeSEBAL.46

Figura 13 – (A) Aplicação da estimação de uma longa série temporal de ET no ponto ET-LTP. As tendências de ET apresentaram mudanças ao longo das décadas devido a alterações no uso e cobertura da terra, como a implementação de sistemas de irrigações. (B) Mapas de NDVI (coluna superior) e *ET* (coluna inferior) para oito datas durante o período analisado. Os triângulos vermelhos se referem as mesmas imagens apresentadas abaixo da série temporal.48

Figura 14 – Valores de RMSD e MBD obtidos no comparativo das estimativas de ET do geeSEBAL com torres que apresentam dados no período em que GLDAS 2.1 e 2.0 coexistem (2000-2010).50

Figura 15 - Variáveis meteorológicas extraídas para ET-LTP. *R_{sdown} 24h*, *ux*, *UR* e *T_{air}* são extraídos para GLDAS 2.0 (1984-1999) e 2.1 (2000-2019). *R_n24h* é estimado usando o método de Bruin (1987).51

LISTA DE TABELAS

Tabela 1. Detalhes das bandas presents nos satélites Landsat 5 TM, Landsat 7 ETM+ e Landsat 8 OLI e TIRS.	26
Tabela 2 – Descrição dos produtos disponíveis na plataforma GEE que são utilizados no geeSEBAL.	38
Tabela 3 - Grupos de percentis utilizados para cada torre.	40
Tabela 4 – Principais referências das torres EC utilizadas no estudo para validar o geeSEBAL, e o total de imagens que combinam com os dados medidos.	43

LISTA DE SÍMBOLOS

u_{200} (m s⁻¹) velocidade do vento desprezando os efeitos de rugosidade da superfície

τ_{sw} (-) transmissividade atmosférica

ET_{24h} (mm dia⁻¹) evapotranspiração diária

G_{hot} (W m⁻²) fluxo de calor do solo no pixel quente

G_{sc} (W m⁻²) constante solar

H_{hot} (W m⁻²) fluxo de calor sensível no pixel quente

K_t (-) constante de turbidez

RL_{down} (W m⁻²) radiação incidente de ondas longas

RL_{up} (W m⁻²) radiação de ondas longas refletidas

$R_{n\ 24h}$ (W m⁻²) saldo de radiação diária

$R_{n\ hot}$ (W m⁻²) saldo de radiação no pixel quente

R_n (W m⁻²) saldo de radiação

RS_{down} (W m⁻²) radiação incidente de ondas curtas

$RS_{down\ 24h}$ (W m⁻²) radiação incidente de ondas curtas média diária

T_{air} (°C) temperatura do ar

T_b (K) temperatura de brilho

$T_{s\ hot}$ (°C) temperatura da superfície no pixel quente

$T_{s\ cold}$ (°C) temperatura da superfície no pixel frio

T_s (K) Temperatura da Superfície

dT_{hot} (°C) gradiente de temperatura no pixel quente

dT_{cold} (°C) gradiente de temperatura no pixel frio

e_a (kPa) pressão de vapor atual

e_{sat} (kPa) pressão de vapor saturada

$r_{ah\ hot}$ resistência atmosférica no pixel quente

r_{ah} (s m⁻¹) resistência aerodinâmica

u_{ws} (m s⁻¹) velocidade de fricção do vento na altura da estação meteorológica

u_x (m⁻¹) velocidade do vento

z_{om} (m) comprimento de rugosidade da vegetação

ε_0 (-) emissividade da superfície

ε_{NB} (-) emissividade da superfície para banda termal

θ_{hor} (rad) ângulo zenital solar

θ_{rel} (rad) ângulo solar de incidência

ρ_{hot} densidade do ar no pixel quente

ρ_{air} (Kg m⁻³) densidade do ar

ψ_h (-) transporte de calor

ψ_m (-) transporte de momentum

α (-) albedo da superfície

h (m) altura da vegetação

P (kPa) pressão atmosférica

W (mm) quantidade de água na atmosfera

λ (kJ kg⁻¹) calor latente de evaporação

C_p (J kg⁻¹ K⁻¹) calor específico do ar à pressão constante

ET (mm) evapotranspiração

ET_p (mm) evapotranspiração potencial

FE (-) fração evaporativa

G (W m⁻²) fluxo de calor do solo

H (W m⁻²) fluxo de calor sensível

L (m) comprimento de Monin-Obukhiv

LAI (m² m⁻²) índice de área foliar

LE (W m⁻²) fluxo de calor latente

$NDVI$ (-) índice de vegetação por diferença normalizada

$NDWI$ (-) índice de diferença normalizada da água

$SAVI$ (-) índice de vegetação ajustado ao solo

UR (%) umidade relativa

d (-) distância relativa Terra-Sol

dT (°C) gradiente de temperatura

g ($m\ s^{-2}$) aceleração gravitacional

k (-) constante de von Karman

u_* ($m\ s^{-1}$) velocidade de fricção do vento

z (m) altura de medição da velocidade do vento

β (-) razão de Bowen

σ ($W\ m^{-2}\ K^{-4}$) constante de Stefan-Boltzman

δ (μm) comprimento de onda

SUMÁRIO

1	INTRODUÇÃO	15
2	OBJETIVOS	18
3	REVISÃO BILIOGRÁFICA	19
3.1	<i>EVAPOTRANSPIRAÇÃO</i>	19
3.2	<i>MÉTODOS PARA MEDIÇÃO DA EVAPOTRANSPIRAÇÃO</i>	20
3.3	<i>SENSORIAMENTO REMOTO</i>	23
3.4	<i>SENSORIAMENTO REMOTO APLICADO À ESTIMATIVA DE ET</i>	27
3.5	<i>Plataforma Google Earth Engine</i>	29
4	METODOLOGIA	30
4.1	<i>Surface Energy Balance Algorithm for Land (SEBAL)</i>	30
4.1.1	Índices de vegetação	31
4.1.2	Temperatura da Superfície (<i>T_s</i>)	31
4.1.3	Albedo da superfície (α)	32
4.1.4	Saldo de Radiação instantâneo (<i>R_n</i>).....	32
4.1.5	Fluxo de calor do solo instantâneo (<i>G</i>)	33
4.1.6	Fluxo de calor sensível instantâneo (<i>H</i>)	33
4.1.7	Fluxo de Calor Latente instantâneo (<i>LE</i>) e <i>ET</i> diária (<i>ET_{24h}</i>).....	36
4.2	<i>Calibração Automática</i>	37
4.3	<i>geeSEBAL</i>	37
4.4	<i>Aplicação do geeSEBAL em diferentes biomas</i>	40
5	RESULTADOS	43
5.1	<i>Comparativo entre as estimativas do geeSEBAL com os dados de EC</i>	43
6	DISCUSSÃO	48

6.1	<i>Análise da performance</i>	48
6.2	<i>Incertezas do modelo</i>	49
6.3	<i>Eficiência do geeSEBAL</i>	51
7	CONCLUSÕES	52
7.1	<i>Perspectivas futuras</i>	53
8	REFERÊNCIAS BIBLIOGRÁFICAS	53

1 INTRODUÇÃO

A evapotranspiração (*ET*) é conceituada como o processo de passagem da água em seu estado líquido e sólido para vapor d'água atmosférico, através da evaporação de superfícies líquidas (rios, lagos e oceano), da água presente no solo e da lâmina interceptada pelo dossel, como também da transpiração proveniente da respiração das plantas. Por estar diretamente relacionada com a disponibilidade hídrica, o conhecimento da *ET* e de seu comportamento é fundamental para o melhor manejo, planejamento e uso da água (Allen et al., 2011; Bastiaanssen et al., 1999; Biggs et al., 2015). De fato, ter pleno conhecimento de todos os processos do ciclo hidrológico vem sendo cada vez mais requisitado com o aumento da insegurança hídrica em escala global (Vörösmarty et al., 2010; Wagener et al., 2010), devido ao crescimento da demanda por água ocorrendo em concomitância com a diminuição de sua disponibilidade (Boretti and Rosa, 2019; Davies and Simonovic, 2011). Na agricultura, por exemplo, o aumento da demanda por água está diretamente relacionado com a necessidade de atender uma maior produção de alimentos (Davis et al., 2017), incluindo aqueles relacionados a produtos de origem animal (Gerbens-Leenes et al., 2013). Junto a isso, mudanças climáticas agravam a situação por alterarem as dinâmicas ecossistêmicas, proporcionando alterações nos regimes de chuvas (Davidson et al., 2012; Spracklen et al., 2012), nas vazões de rios (Bates et al., 2008; Ukkola et al., 2016), além de impactos na produção de alimentos (Iizumi and Ramankutty, 2015). Ainda, mudanças no uso e cobertura do solo ocasionadas pelo desmatamento, com a substituição de vegetação natural por áreas de agricultura e pastagem, impactam diretamente as taxas de *ET* (Aragão, 2012), assim como o uso de sistemas de irrigações (Boucher et al., 2004), podendo afetar o clima em múltiplas escalas.

Apesar da importância de obter informações *in situ*, incluindo estimativas de *ET*, o uso dessas informações para representar escalas maiores do que a área de influência da medição apresentam limitações. Além disso, os equipamentos necessários para obter as medições para estimar a *ET in situ*, além de precisarem de constante manutenção, são onerosos para

aplicação em larga escala, dificultando ainda mais a obtenção de dados em locais remotos. Sendo assim, uma alternativa viável para a estimação da ET em diferentes escalas espaciais e temporais é através de modelos que utilizam produtos de sensoriamento remoto (Fisher et al., 2017; Yang et al., 2012). De um modo geral, os modelos existentes se distribuem em dois grupos: modelos de índice de vegetação (VI) e de temperatura da superfície (T_s). Dentre os modelos existentes do segundo caso, há os modelos de balanço energético da superfície (SEB), e que se apresentam diferenciações enquanto a sua estrutura para estimação da ET . Os que estimam transpiração e evaporação como uma única variável são conhecidos como “fonte-única”, fazendo parte desse grupo *Surface Energy Balance Algorithm for Land* (SEBAL) (Bastiaanssen, 1995), *Mapping EvapoTranspiration at high Resolution with Internalized Calibration* (METRIC) (Allen et al., 2007) e *Simplified Surface Energy Balance operation* (SSEBop) (Senay et al., 2013). Já os que estimam transpiração e evaporação separadamente, para no fim somá-los e estimar a ET , são conhecidos como “fonte-dupla”: *Two-Source Evapotranspiration Balance* (T-SEB) (Norman et al., 1995) e *Atmosphere – Land Exchange Inverse* (ALEXI) (Anderson et al., 1997). Em particular, o modelo SEBAL tem sido amplamente aplicado com sucesso em diferentes vegetações e condições climáticas (Bhattarai et al., 2012; Ruhoff et al., 2012; Singh et al., 2008; Sun et al., 2011; Tang et al., 2013; Teixeira et al., 2009; Yang et al., 2012; Zhang et al., 2011), apresentando como característica a estimação do fluxo de calor latente (LE) como o saldo residual da equação do balanço energético ($LE = R_n - H - G$), em que R_n , H e G são o saldo de radiação, fluxo de calor sensível e o fluxo de calor do solo, respectivamente. Para estimar a ET , o SEBAL apresenta um processo de calibração interna para selecionar pixels âncoras que representam extremos em termos de umidade e temperatura na imagem. Para condições de baixa umidade e de altas temperaturas é selecionado o pixel quente, representando uma condição em que o H possui toda a energia disponível para aquele ponto, enquanto o LE é assumido como zero. Para o pixel frio, a operação é inversa, considerando LE como o total de energia disponível e H como zero. Apesar de os primeiros estudos envolvendo SEBAL determinarem a localização dos pixels frio e quente de forma manual, Allen et al. (2013) automatizaram esse procedimento utilizando

um grupo de percentis para definir pixels pré-candidatos utilizando informações de T_s e índice de vegetação por diferença normalizada (*NDVI*), possibilitando novas aplicações com a automatização do modelo, como apresentado posteriormente por Jaafar e Ahmad (2019), Dhungel e Barber (2018) e Bhattarai et al. (2017).

Novas tecnologias como o uso de *deep learning*, inteligência artificial e computadores de alta performance têm proporcionado avanços em aplicações envolvendo o gerenciamento de recursos hídricos (Saraiva et al., 2020; Vos et al., 2019). A plataforma de processamento em nuvem *Google Earth Engine* (GEE) tem se demonstrado uma interessante opção para estudos hidrometeorológicos devido ao fácil acesso a computadores de alta performance e aos principais produtos de sensoriamento remoto existentes atualmente. Diversas aplicações já demonstraram o potencial do GEE para áreas da ciência da terra, inclusive em aplicações na agricultura (Saraiva et al., 2020; Zhang et al., 2020), mapeamento de inundações (Alonso et al., 2020; Hird et al., 2017), detecção de superfícies aquáticas (Nguyen et al., 2019; Pekel et al., 2016; Wang et al., 2019), e mudanças de uso e cobertura da terra (Kennedy et al., 2018; Midekisa et al., 2017; Parente et al., 2019). Já modelos de SEB desenvolvidos no GEE ainda são novidades, com iniciativas da Agência Nacional de Água (ANA) utilizando SSEBop (Brazilian Water Agency, 2020), e a aplicação do METRIC a partir da ferramenta EEFlux (Allen et al., 2015).

2 OBJETIVOS

Os objetivos principais do trabalho consistem em validar e disponibilizar uma ferramenta de código aberto para estimar *ET* utilizando o modelo SEBAL, desenvolvendo-o no ambiente da plataforma GEE.

Como objetivos específicos, pretende-se:

- Apresentar uma aplicação de longa série temporal entre 1984-2019 utilizando a ferramenta desenvolvida no GEE;

- Disponibilizar uma interface gráfica ao usuário (GUI) que poderá ser acessada através de um endereço de web (www.etbrasil.org/geesebal);

- Fornecer acesso ao código desenvolvido a outros usuários para que possam utilizá-lo e aprimorá-lo (www.github.com/etbrasil/geesebal).

3 REVISÃO BILIOGRÁFICA

3.1 EVAPOTRANSPIRAÇÃO

A evapotranspiração (*ET*) é um importante componente do ciclo hidrológico, sendo conhecido como o fenômeno físico no qual a água em estado líquido é convertida em vapor d'água através da evaporação de superfícies líquidas (rios, lagos e oceanos), da água presente no solo e da interceptada pelo dossel, além da transpiração proveniente da vegetação (Figura 1). Para que ocorra esse fenômeno é fundamental a presença de energia, possibilitando a liberação das moléculas de água da superfície líquida, energia essa fornecida pela radiação solar.



Figura 1 - Esquema do processo de evapotranspiração (*ET*), em que a água no seu estado líquido é convertida em vapor d'água através da evaporação de superfícies líquidas (rios, lagos, oceanos) e transpiração da vegetação. Fonte: ONSET (Adaptado)¹.

¹ Disponível em: https://www.onsetcomp.com/onset-content/public_site/top-level-landing-pages/wireless-sensor-networks/et-info-graphic.jpg. Acesso em: set. 2020.

O termo 'Evapotranspiração' foi inicialmente definido por Thornthwaite e Wilm (1944) em seus estudos relacionados a evapotranspiração potencial (ET_p), em que a transição do estado líquido da água ocorreria sem estresses hídricos, em condições ideais de evaporação e transpiração. Assim, Thornthwaite e Wilm (1944) definiram os conceitos de ET_p e de métodos para sua quantificação com uma complexa função empírica considerando informações de dados observados de temperatura e duração do dia (Hillel et al., 2005). Com o aumento do interesse em compreender os complexos processos físicos e de como estimar ET , diversos outros estudos surgiram. Com mais destaque, Penman (1948) e posteriormente Monteith (1965) foram responsáveis em desenvolver conceitos e equações até hoje utilizadas para estimar ET . Penman (1948), por exemplo, foi o primeiro a considerar efeitos do balanço energético para estimar ET , baseando-se nos conceitos apresentados sobre a mudança de estado físico da água de Dalton. Por outro lado, Monteith (1965) foi responsável em apresentar a equação conhecida como Penman-Monteith, uma versão modificada da equação de Penman (1948), baseando-se em processos físicos, e que possibilitou estimar ET em condições naturais de forma simples e representando condições de estresse hídrico.

3.2 MÉTODOS PARA MEDIÇÃO DA EVAPOTRANSPIRAÇÃO

Ao longo dos anos surgiram diversos equipamentos capazes de estimar a ET . Os lisímetros (Figura 2), por exemplo, são tanques enterrados com sistemas de drenagem para captação do volume de água captado pelo solo em que é desejado conhecer a ET . Posteriormente, esse volume é coletado e medido para que seja possível estimar ET através da equação do balanço hídrico ($ET = P - Q_s - Q_b - \frac{\Delta V}{\Delta T}$), em que a precipitação (P) é medido através de um pluviômetro, considerando um intervalo de tempo (ΔT) de variação do volume (ΔV) e da diferença do escoamento superficial medido (Q_s) e do escoamento subterrâneo (Q_b) medido no fundo do tanque (Collischonn e Dornelles, 2015).



Figura 2 - Exemplo da instalação de lisímetros para medições de *ET* para uma cultura de vegetação específica. Fonte: Lysimeter².

Outra opção para a determinar *ET* é através do método de covariância dos vórtices turbulentos, também conhecido como *eddy covariance* (EC) (Figura 3). Esse método é amplamente utilizado para as medições de fluxos de calor entre a superfície e a atmosfera, como também para obter informações relacionadas ao vapor d'água, metano e gás carbônico. O sistema de EC é composto por um analisador de gases, anemômetro ultrassônico e sistema para armazenamento, aquisição e processamento dos dados.

De acordo com Shuttleworth (2012), as medições do vapor d'água na atmosfera para sua quantificação ocorrem em uma altura vertical mínima em que não haja influência nos fluxos energéticos por parte da altura. Ainda, o método relaciona as movimentações verticais do vapor d'água na atmosfera, em região de turbulência do ar, com flutuações acima da média da umidade do ar e a velocidade do vento (Figura 4), proporcionando uma correlação positiva entre esses dois fatores. Por outro lado, flutuações abaixo da média da umidade do ar apresenta uma correlação negativa com a variável vertical da velocidade do vento. Com essas informações medidas em alta frequência, é possível obter as

² Disponível em: <https://lysimeter.info/>. Acesso em: jul. 2020.

medições do calor latente (H) e do calor sensível (LE) em curtos intervalos de tempo, sendo considerado um dos métodos mais precisos disponíveis.



Figura 3 - Equipamentos de medição utilizados por torres EC. O sistema é composto por analisador de gases, anemômetro ultrassônico e um sistema para armazenamento, aquisição e processamento dos dados. Fonte: ELITE SCIENTIFIC INSTRUMENTS SDN BHD³.



Figura 4 - Ilustração da medição dos vórtices turbulentos por torre de monitoramento com sistema de EC. Fonte: EARTH & ENVIRONMENTAL SCIENCES AREA (Adaptado)⁴.

³ Disponível em: <https://esi.com.my/inst-home/eddy-covariance/>. Acesso em: jul. 2020.

⁴ Disponível em: <https://eesa.lbl.gov/projects/ameriflux-management-project/>. Acesso em: set. 2020.

3.3 SENSORIAMENTO REMOTO

De acordo com Baghdadi e Zribi (2016) (tradução nossa), “O *sensoriamento remoto* refere-se à aquisição de informação de um objeto sem que haja contato com o mesmo. Para isso, é utilizado todo o espectro eletromagnético, variando de comprimento de ondas curtas (por exemplo, ultravioleta) a comprimentos de ondas longas (microondas)”. Historicamente, o primeiro registro que se tem conhecimento da captação de uma imagem da superfície terrestre é de 1859, através de uma fotografia aérea obtida utilizando um balão. Por muitos anos, contudo, o uso de sensoriamento remoto para observações foi destinado a fins militares, e utilizado em diversas guerras da primeira metade do século XX, sendo inclusive o período do desenvolvimento de tecnologias que permitiram a invenção de sensores capazes de captar informações na faixa do infravermelho, termal, e de imageamento por radar. Na segunda metade do século XX, o uso de sensoriamento remoto para fins não militares ganhou força, iniciando o seu uso para fins de estudos ambientais (Curran, 1985).

O uso de técnicas de sensoriamento remoto busca relacionar as informações obtidas do espectro magnético (Figura 5) através da detecção da energia refletida, emitida e dispersada em diferentes bandas e frequências para correlacionar com fenômenos físicos, biológicos e químicos (Jensen, 2013). Para cada intervalo de comprimento de onda do espectro magnético pode ser atribuído uma banda em que o sensor é sensível, permitindo diferentes análises em porções diferentes do espectro magnético. O satélite Landsat 8, por exemplo, apresenta três bandas no intervalo do visível em que cada uma está em diferente intervalo do espectro: Azul (0.45 – 0.51 μm), Verde (0.53 – 0.69 μm) e Vermelho (0.64 – 0.67 μm).

Uma característica importante dos produtos de sensoriamento remoto é a resolução espacial, conceituada como uma célula unitária (*pixel*), de proporções (x,y), que representará através de um valor médio a variável existente dentro dos limites espaciais. Quanto maior a resolução espacial, menor será o tamanho do pixel, enquanto para tamanhos de pixel maiores, a resolução diminui. A resolução espacial é fundamental para a caracterização do estudo, e podem influenciar nos resultados obtidos.

Outra informação relevante é a resolução temporal, conceituada como o período necessário para que o sensor retorne a mesma área para obter o seu imageamento. A obtenção da imagem normalmente ocorre em um mesmo intervalo de tempo para manter um padrão das informações obtidas. Os satélites Landsat, por exemplo, apresentam resolução temporal de 16 dias, ou seja, em um período de 16 dias os satélites Landsat retornam os dados mapeados, gerando informações de uma mesma localidade, e em um mesmo intervalo de tempo.

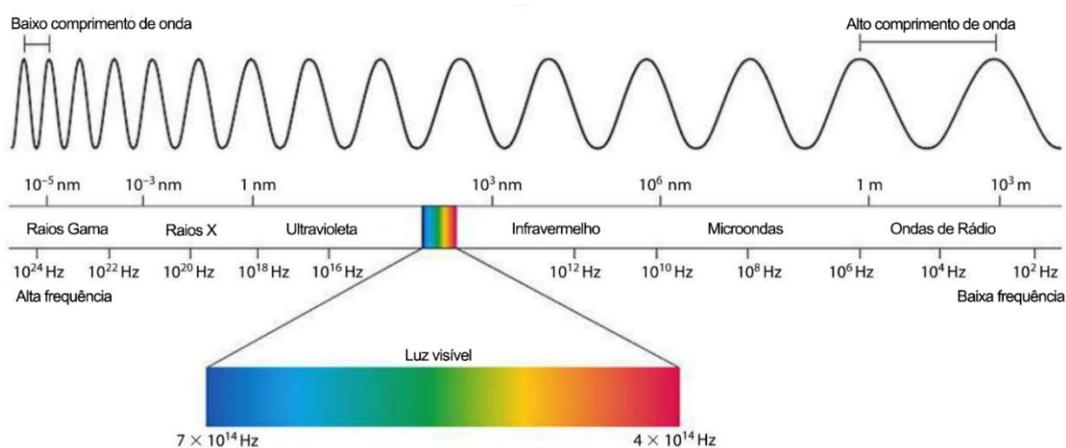


Figura 5 - Espectro eletromagnético. Fonte: Miniphysics (Adaptado)⁵.

A resolução espacial e temporal variam de acordo com o objetivo do satélite. Para análises meteorológicas, por exemplo, espera-se obter informações em um curto intervalo de tempo para identificar mudanças na atmosfera que auxiliem na previsão meteorológica, não necessariamente precisando de uma grande resolução espacial. Esse é o caso dos satélites GOES (*Geostationary Operational Environmental Satellite*) que apresentam resoluções espacial de 1 – 4 km, mas alta resolução temporal de aproximadamente 15 min. Já satélites que possuem como objetivo estudos envolvendo a superfície terrestre precisam de maiores resoluções, como para a delimitação de áreas de agricultura, floresta, análises de cheias e secas em corpos hídricos, sendo esta a proposta dos satélites Landsat.

⁵ Disponível em: https://www.miniphysics.com/electromagnetic-spectrum_25.html
Acesso em: out. 2020.

Nas últimas décadas, o uso de sensoriamento remoto para a obtenção de observações da superfície terrestre vem sendo cada vez mais recorrente, com um aumento considerável no número de satélites em órbita obtendo informações, tais como: reflectância da superfície, temperatura da superfície, emissões atmosféricas, precipitação, entre outros (Figura 6).



Figura 6 - Ilustração das principais missões em órbita mapeando a superfície e a atmosfera terrestre. Fonte: NASA⁶.

Em relação a missão Landsat, utilizada nesse estudo, o programa é conhecido como o primeiro a utilizar tecnologia de satélites ópticos para fins não militares no início dos anos 70 (Baghdadi and Zribi, 2016). Após a primeira missão que colocou em órbita o Landsat 1 em julho de 1972, foi dado prosseguimento a outros satélites do programa, avançando em termos de tecnológicos, como durabilidade e resolução espacial. Uma das missões mais longevas foi realizada pelo satélite Landsat 5, tendo iniciado a captura de imagens no ano de 1984, sendo encerrado a sua missão após apresentar falha

⁶ Disponível em: <https://www.jpl.nasa.gov/news/news.php?feature=4487>. Acesso em: jul. 2020.

em seus sensores no ano de 2011. O Landsat 5 utilizava o sensor *Thematic Mapper* (TM) para imageamento.

Atualmente, os sensores *Enhanced Thematic Mapper Plus* (ETM+), no satélite Landsat 7, e *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS) no Landsat 8 (em órbita desde 2013), continuam obtendo imagens com resolução de 30 m e frequência de passagem de 16 dias. No caso particular do Landsat 7, em órbita desde 1999, uma falha no escaneamento linear de correção (SLC), ocorrida em 31 de maio de 2003, acarretou falhas nas novas imagens obtidas a partir dessa data, sendo ainda disponibilizadas para uso. Além disso, está programado para 2021 uma nova missão que colocará em órbita novos sensores acoplados ao Landsat 9. A Tabela 1 apresenta as informações das bandas nos satélites Landsat 5 TM, Landsat 7 ETM+ e Landsat 8 OLI e TIRS.

Tabela 1. Detalhes das bandas presentes nos satélites Landsat 5 TM, Landsat 7 ETM+ e Landsat 8 OLI e TIRS.

Landsat 5 TM e Landsat 7 ETM+		Landsat 8 OLI e TIRS	
Bandas espectrais (resolução)	Comprimento de onda (µm)	Bandas espectrais (resolução)	Comprimento de onda (µm)
B1 – Azul (30 m)	0,45 – 0,52	B1 – Aerossol (30 m)	0,43 – 0,45
B2 – Verde (30 m)	0,52 – 0,60	B2 – Azul (30 m)	0,45 – 0,51
B3 – Vermelho (30 m)	0,63 – 0,69	B3 – Verde (30 m)	0,53 – 0,59
B4 – Infravermelho (30m)	0,77 – 0,90	B4 – Vermelho (30 m)	0,64 – 0,67
B5 – Infravermelho de ondas curtas 1 (30 m)	1,55 – 1,75	B5 – Infravermelho (30m)	0,85 -0,88
B6 – Termal (Landsat 5 – 120 m e Landsat 7 – 60 m)	10,40 – 12,50	B6 – Infravermelho de ondas curtas 1 (30 m)	1,57 – 1,65
B7 - Infravermelho de ondas curtas 2 (30 m)	2,08 – 2,35	B7 – Infravermelho de ondas curtas 2 (30 m)	2,11 – 2,29
		B10 – Termal 1 (100 m)	10,60 – 11,19
		B11 – Termal 2 (100 m)	11,50, 12,51

3.4 SENSORIAMENTO REMOTO APLICADO À ESTIMATIVA DE ET

Apesar de não existirem sensores que medem diretamente ET , há diversas alternativas utilizando modelos de sensoriamento remoto, possibilitando análises em diferentes escalas espaciais (locais, regionais e globais) e temporais visto a vasta disponibilidade de produtos e satélites disponíveis atualmente, com informações desde a década de 80. Os modelos apresentam diferentes metodologias, e são divididos entre dois grupos. Os modelos de índice de vegetação (IV) utilizam parametrizações para estimar a evaporação e transpiração através de produtos de índices de vegetação: *Global Land-surface Evaporation Amsterdam Methodology* (GLEAM) (Martens et al., 2016), *Moderate Resolution Imaging Spectroradiometer Land Surface Evapotranspiration* (MOD16) (Mu et al., 2011), *Priestley-Taylor Jet Propulsion Laboratory* (PT-JPL) (Fisher et al., 2008) e *Water Cycle Multi-mission Observation Strategy – Evapotranspiration* (WACMOS-ET) (Miralles et al., 2016). Já os modelos de T_s utilizam essa informação para estimar a ET : *Surface Energy Balance Algorithm for Land* (SEBAL) (Bastiaanssen et al., 1998a, 1998b), *The Mapping Evapotranspiration at high Resolution with Internalized Calibration* (METRIC) (Allen et al., 2007), *The Atmosphere-Land Exchange Inverse* (ALEXI) (Anderson et al., 2007), *the operational Simplified Surface Energy Balance* (SSEBop) (Senay et al., 2013) e o *Two-Source Evapotranspiration Balance* (T-SEB) (Norman et al., 1995).

Especificamente em relação ao segundo grupo, os modelos podem ser subdivididos entre “fonte-única”, em que a transpiração e a evaporação são estimadas como uma única variável: SEBAL, METRIC, SSEBop. No caso de a transpiração e a evaporação serem estimadas separadas, são considerados modelos de “fonte-dupla”: ALEXI, T-SEB. Ainda, alguns desses modelos se baseiam no método do balanço de energia (SEBAL, METRIC, ALEXI, TSEB) em que as informações instantâneas do saldo de radiação da superfície (R_n), o fluxo de calor do solo (G) e H são estimados para determinar LE como valor residual do balanço energético (Equação 1) em $W m^{-2}$.

$$LE = R_n - G - H \quad (1)$$

Em relação ao modelo SEBAL, desenvolvido e validado inicialmente por Bastiaanssen (Bastiaanssen, 1995; Bastiaanssen et al., 1998b, 1998a), foi um dos pioneiros em estimar ET através de imagens de satélite com o balanço energético. Além disso, o modelo SEBAL se destaca pela abordagem da correlação linear entre o gradiente de temperatura (dT) e a T_s , demonstrado empiricamente por Bastiaanssen (1995). Segundo Allen et al. (2007), nessa abordagem, assume-se que a uma altura entre 100-200 m a temperatura pode ser considerada independente de H , permitindo que os efeitos de instabilidades sejam incorporados a condições de resistência aerodinâmica (r_{ah}). Assim, a determinação de H para uma dada imagem pode ser obtida visto a sua proporcionalidade direta com dT e T_s .

Para que seja obtida a relação linear entre dT e T_s , SEBAL requer a seleção de dois pixels âncoras na imagem que representam condições extremas de umidade e temperatura, conhecidos como pixels quente e frio. Para a seleção do pixel frio, é escolhido o pixel que representa condições de grande cobertura vegetal e de umidade, assumindo-se que LE será máximo nesse ponto, enquanto que H será zero. Já o pixel quente representa uma condição contrária, em que há baixa umidade e pouca vegetação, e o H é assumido como máximo e LE zero.

Apesar da possibilidade de selecionar os pixels âncoras de maneira manual para cada imagem, a não automatização do processo dificulta a sua aplicação em larga escala. Assim, Allen et al. (2013) desenvolveram um método de seleção dos pixels âncoras através da seleção de pixels pré-candidatos considerando as informações de índice de vegetação por diferença normalizada ($NDVI$) e T_s . Para isso, foi proposto a seleção dos 5% de pixels com maiores valores de $NDVI$, dos quais são selecionados os 20% menores valores de T_s desses valores para a definição do pixel frio. Já para identificar o pixel quente é realizado a seleção dos 10% menores valores de $NDVI$, dos quais são selecionados 20% do maiores valores de T_s .

Diversos trabalhos utilizaram o modelo SEBAL em diferentes condições climáticas e de vegetações. Bhattarai et al. (2012), por exemplo, validaram o modelo SEBAL no sudeste dos Estados Unidos utilizando imagens Landsat 5

TM e comparando os resultados com dados de torres EC, obtendo um erro médio de aproximadamente 8%. Já Tang et al. (2013) validaram o modelo em condições de clima úmido em planície ao norte da China, utilizando produtos MODIS em áreas de cultivos agrícolas. Em relação a validações no Brasil, Ruhoff et al. (2012) utilizaram produtos MODIS para validar o modelo SEBAL comparando as estimativas obtidas com informações de duas torres EC existentes em uma região de Cerrado e plantação de cana-de-açúcar. Ainda no Cerrado, em região de transição com a floresta Amazônia, Laipelt et al. (2020) utilizaram o modelo SEBAL com imagens Landsat e dados meteorológicos de produtos de reanálise para validar as estimativas com torre EC presente na Ilha do Bananal, Tocantins. Além disso, nessa pesquisa os autores avaliaram diferentes grupos de percentis para obterem os melhores resultados de *ET*, visto que a seleção dos pixels âncora demonstram grande influência nos resultados (Bastiaanssen et al., 1998a).

3.5 Plataforma *Google Earth Engine*

Google Earth Engine (GEE) é uma plataforma baseada em processamento em nuvem lançada pela Google em 2010 como uma importante ferramenta para a realização de pesquisas na área de ciência da terra (Amani et al., 2020). Entre os grandes diferenciais do GEE está o fácil acesso a dados dos principais produtos de sensoriamento remoto disponíveis atualmente (Landsat, Sentinel, MODIS), com a possibilidade de o usuário desenvolver seu próprio banco de dados, o acesso a diversos algoritmos já desenvolvidos para realização de estudos, e avançada capacidade computacional para trabalhar com grande quantidade de dados (Gorelick et al., 2017). Além disso, os usuários do GEE não precisam realizar qualquer download para operá-lo, visto que o mesmo foi desenvolvido para ser manuseado via internet através de Interfaces de programação de aplicações (API), contendo um ambiente de desenvolvimento integrado (<https://code.earthengine.google.com/>) em linguagem JavaScript, além de uma versão API em Python .

A plataforma vem ganhando destaque no meio científico, com diversas aplicações nas áreas de agricultura (Saraiva et al., 2020; Zhang et al., 2020),

mudanças de uso e cobertura da terra (Kennedy et al., 2018) e hidrologia (Nguyen et al., 2019; Traganos et al., 2018; Zhou et al., 2019). Ainda, iniciativas envolvendo o uso de modelos de SEB estão presentes em iniciativas da Agência Nacional de Água (ANA) através do modelo SSEBop (Brazilian Water Agency, 2020) (<https://ssebop.users.earthengine.app/>) e da EEFlux (<https://eeflux-level1.appspot.com/>) na aplicação do modelo METRIC (Allen et al., 2015).

4 METODOLOGIA

4.1 Surface Energy Balance Algorithm for Land (SEBAL)

A esquematização do modelo SEBAL é apresentado na Figura 7, sendo descritas a seguir as equações utilizadas no modelo desenvolvido na plataforma GEE para obtenção das variáveis necessárias para estimar *ET*.

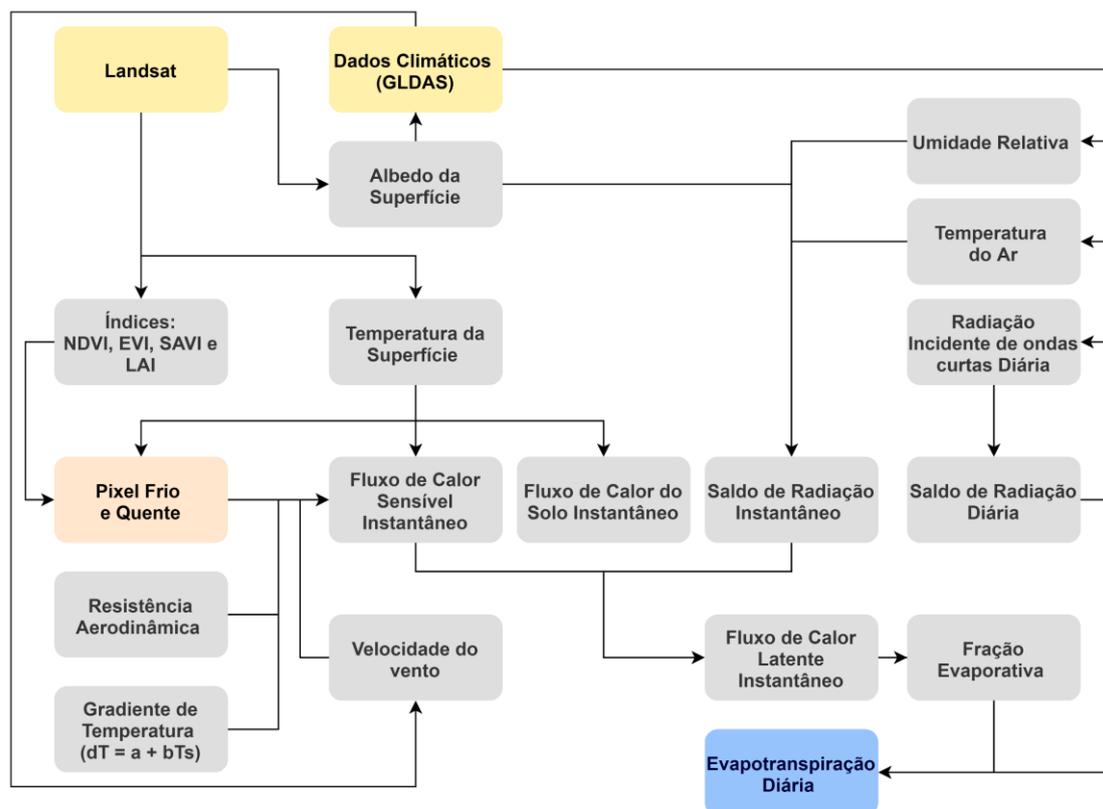


Figura 7 - Esquematização do modelo SEBAL. Fonte: Autoria própria.

4.1.1 Índices de vegetação

O SEBAL utiliza diferentes índices ao longo do seu processamento para caracterizar a vegetação presente ou uma área em que não ocorra vegetação. Os índices utilizados são: *NDVI*, índice de vegetação ajustado ao solo (*SAVI*), índice de diferença normalizada da água (*NDWI*) e índice de área foliar (*LAI*), calculados de acordo com as Equações 2-5, respectivamente.

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (2)$$

onde NIR e RED são as bandas do infravermelho próximo e vermelha, respectivamente.

$$SAVI = \frac{(1+0,5)(NIR-RED)}{(0,5+(NIR-RED))} \quad (3)$$

em que valores de *SAVI* > 0,689 são substituídos para 0,689 para evitar instabilidade no modelo no processo iterativo para estimação do *H* (seção 4.1.6).

$$NDWI = \frac{GREEN-NIR}{GREEN+NIR} \quad (4)$$

onde GREEN é a banda verde.

$$LAI = - \left(\frac{\log \left(\frac{0,69-SA VI}{0,59} \right)}{0,91} \right) \quad (5)$$

4.1.2 Temperatura da Superfície (T_s)

A temperatura da superfície T_s (K) foi estimada convertendo a informação da banda de temperatura de brilho (banda 6 para Landsat 5 e 7 e banda 10 para Landsat 8) através da Equação 6:

$$T_s = \frac{Tb}{(1+((\delta Tb)/1,438e^{-2}) \log(\epsilon_{NB}))} \quad (6)$$

onde Tb é a banda de temperatura de brilho (K), δ é o comprimento de onda (μm) e ϵ_{NB} é a emissividade da superfície para banda termal calculada através da Equação 7:

$$\epsilon_{NB} = 0,97 + (0,0033 LAI) \quad (7)$$

onde valores de $\epsilon_{NB} > 3$ são alterados para 0.98.

T_s foi ajustada para uma elevação padrão usando o produto digital de elevação do *Shuttle Radar Topography Mission* (SRTM) (adicionando uma taxa de variação de $0,0065 \text{ } ^\circ\text{C}^{-1}$). Efeitos de declividade também foram corrigidas de acordo com Jaafar e Ahmad (2019).

4.1.3 Albedo da superfície (α)

Para estimar o albedo (α) da superfície foi utilizado a metodologia proposta por Tasumi et al. (2008) (Equação 8):

$$\alpha = \sum(\omega_\lambda * \rho_\lambda) \quad (8)$$

onde ω_λ são coeficientes tabelados e ρ_λ é a reflectância da superfície das bandas do sensor multiespectral. Para Landsat 5 e 7, os coeficientes utilizados são os propostos por Tasumi et al. (2008), enquanto que para Landsat 8 foram utilizados os coeficientes estimados por Ke et al. (2016).

4.1.4 Saldo de Radiação instantâneo (Rn)

A estimativa do saldo de radiação instantâneo (Rn) é realizada através da Equação 9:

$$Rn = (1 - \alpha)Rs_{down} + Rl_{down} - Rl_{up} - (1 - \varepsilon_0) Rs_{down} \quad (9)$$

onde Rs_{down} é a radiação incidente de ondas curtas, Rl_{down} a radiação incidente de ondas longas e Rl_{up} a radiação de ondas longas refletidas (W m^{-2}). A emissividade da superfície (ε_0) na equação do saldo de radiação é estimado através da Equação 10:

$$\varepsilon_0 = 0,95 + (0,01LAI) \quad (10)$$

Para estimar Rs_{down} , Rl_{down} e Rl_{up} foram utilizadas as Equações 11-13, propostas por Allen et al. (2007):

$$Rs_{down} = G_{sc} \cos(\theta_{rel}) \tau_{sw} d^2 \quad (11)$$

$$Rl_{down} = 0,85(-\log(\tau_{sw}))^{0,09} \sigma T_s^4 \quad (12)$$

$$Rl_{up} = \varepsilon_0 \sigma T_s^4 \quad (13)$$

onde G_{sc} é a constante solar (1367 W m^{-2}), θ_{rel} é o ângulo solar de incidência (rad), τ_{sw} é a transmissividade atmosférica, d^2 a distância relativa Terra-Sol e σ a constante de Stefan-Boltzmann ($5,67 \cdot 10^{-8} \text{ W m}^{-2} \text{ K}^{-4}$).

Para calcular τ_{sw} é utilizado a equação sugerida por ASCE-EWRI (2005) (Equação 14):

$$\tau_{sw} = 0,35 + 0,627 \exp \left[\frac{-0,00146P}{K_t \cos \theta_{hor}} - 0,075 \left(\frac{W}{\cos \theta_{hor}} \right)^{0,4} \right] \quad (14)$$

onde P é a pressão atmosfera (kPa), W a quantidade de água na atmosfera (mm), θ_{hor} o ângulo solar zenital em relação a superfície (rad) e K_t a constante de turbidez, em que seu valor é igual a $K_t=1$ para condições de ar limpo.

O cálculo de W é realizado através da Equação 15, sugerido por Garrison and Adler (1990):

$$W = 0,14 e_a P + 2,1 \quad (15)$$

onde e_a é a pressão de vapor atual (kPa) e pode ser estimada utilizando a Equação 16 (Shuttleworth, 2012):

$$e_a = (1/0.622) * Q * P \quad (16)$$

onde Q é a umidade específica (kg/kg) (Equação 17):

$$e_{sat} = 0,6108 \exp \left(\frac{17,27 T_{air}}{T_{air} + 237,3} \right) \quad (17)$$

4.1.5 Fluxo de calor do solo instantâneo (G)

O Fluxo de calor do solo (G) é estimado utilizando a Equação 18, sugerida por Bastiaanssen (2000):

$$G = R_n (T_s - 273,15) (0,0038 + (0,0074 \alpha)) (1 - 0,98 (NDVI)^4) \quad (18)$$

onde G é estimado em W m^{-2} .

4.1.6 Fluxo de calor sensível instantâneo (H)

O processo de estimação do H no SEBAL é realizado utilizando a Equação 19 (Allen et al., 2011):

$$H = \rho_{air} C_p \frac{dT}{r_{ah,1,2}} \quad (19)$$

onde ρ_{air} é a densidade do ar (Kg m^{-3}), C_p o calor específico em condição de pressão constante ($\text{J Kg}^{-1} \text{K}^{-1}$) e $r_{ah,1,2}$ a resistência aerodinâmica (s m^{-1}) entre duas altitudes próximas à superfície, e dT é o gradiente de temperatura entre a superfície e temperatura do ar (K), representado por uma função linear como proposto por Bastiaanssen et al. (1998) (Equação 20):

$$dT = a + bT_s \quad (20)$$

onde a e b são empiricamente determinados para cada imagem.

Como na Equação 19 tanto H e r_{ah} são informações desconhecidas, SEBAL utiliza um processo iterativo para determiná-las. Para isso, uma primeira estimação de r_{ah} realizada, assumindo uma condição aerodinâmica estável:(Allen et al., 2007) (Equação 21):

$$r_{ah} = \frac{\ln(z_2/z_1)}{u_* k} \quad (21)$$

onde z_1 e z_2 são diferentes alturas acima da vegetação (m), u_* é a velocidade de fricção (m s^{-1}) e k é a constante de von Karman (0.41).

A primeira estimação de u_* é realizado utilizando a Equação 22:

$$u_* = \frac{k u_{200}}{\ln(200/z_{om})} \quad (22)$$

em que u_{200} é a velocidade do vento (m s^{-1}) a 200 metros e z_{om} é o comprimento da rugosidade (m).

Para u_{200} , é utilizado a Equação 23:

$$u_{200} = u_{ws} * \frac{\ln(\frac{height}{z_{om}})}{k} \quad (23)$$

onde $u_{ws} *$ (Equação 24) é a velocidade de fricção na altura da estação meteorológica (m s^{-1}) e $height$ a altura da medição (m).

$$u_{ws} * = \frac{k u_x}{\ln(\frac{z_{ws}}{z_{om}})} \quad (24)$$

onde z_{ws} é a altura da estação (m) e u_x a velocidade do vento (m s^{-1})

z_{om} é assumido como (Equação 25):

$$z_{om} = 0.12(h) \quad (25)$$

onde h é a altura da vegetação (m).

No processo iterativo, o dT para condições secas dT_{hot} é estimado pela Equação 26:

$$dT_{hot} = \frac{H_{hot} r_{ah\ hot}}{\rho_{hot} Cp} \quad (26)$$

onde H_{hot} , $r_{ah\ hot}$ e ρ_{hot} é o calor sensível ($W\ m^{-2}$), a resistência aerodinâmica ($s\ m^{-1}$) e a densidade do ar ($Kg\ m^{-3}$) para o pixel quente selecionado, respectivamente. H_{hot} é estimado através da Equação 27:

$$H_{hot} = R_{n\ hot} - G_{hot} \quad (27)$$

onde $R_{n\ hot}$ e G_{hot} são os valores extraídos de Rn e G ($W\ m^{-2}$) para o pixel quente.

Para calcular os coeficientes a e b da relação linear entre T_s e dT , é considerado que $dT_{cold} = 0$ e é utilizado as Equações 28 e 29:

$$a = \frac{dT_{cold} - dT_{hot}}{T_{s\ cold} - T_{s\ hot}} \quad (28)$$

$$b = dT_{hot} - a T_{s\ hot} \quad (29)$$

O próximo passo é a parte final da primeira etapa do processo iterativo. Para avaliar as condições de estabilidade atmosférica no processo, é calculado o comprimento de Monin-Obukhiv (L) (m) (Allen et al., 2007). A Equação 30 representa o comprimento das forças de fluatibilidade e de mistura mecânica.

$$L = - \frac{\rho_{air} Cp u_*^3 T_s}{kgH} \quad (30)$$

onde g é a aceleração gravitacional ($9,807\ m\ s^{-1}$).

Quando o valor $L < 0$, a borda da camada atmosférica é considerada instável, sendo o contrário para $L > 0$. Com essa informação, é estimado o transporte de momentum e calor (ψ_m e ψ_h) através das seguintes equações para diferentes condições de L . No caso de $L < 0$, ψ_m e ψ_h são calculados com as Equações 31-33, para uma altura de 200, 2 e 0,1 metros:

$$\psi_m(200\ m) = 2 \ln\left(\frac{1+x(200\ m)}{2}\right) + \ln\left(\frac{1+x^2(200\ m)}{2}\right) - 2 \arctan(x(200\ m)) + 0.5\pi \quad (31)$$

$$\psi_h(2\ m) = 2 \ln\left(\frac{1+x(2\ m)}{2}\right) \quad (32)$$

$$\psi_{h(0,1m)} = 2 \ln \left(\frac{1+x_{(0,1m)}^2}{2} \right) \quad (33)$$

em que $x_{(200m)}$, $x_{(2m)}$ e $x_{(0,1m)}$ são estimados pelas Equações 34-36, respectivamente:

$$x_{(200m)} = \left(1 - 16 \frac{200}{L} \right)^{0,25} \quad (34)$$

$$x_{(2m)} = \left(1 - 16 \frac{2}{L} \right)^{0,25} \quad (35)$$

$$x_{(0,1m)} = \left(1 - 16 \frac{0,1}{L} \right)^{0,25} \quad (36)$$

Enquanto para $L > 0$ é utilizado as Equações 37-39:

$$\psi_{m(200m)} = -5 \left(\frac{2}{L} \right) \quad (37)$$

$$\psi_{h(2m)} = -5 \left(\frac{2}{L} \right) \quad (38)$$

$$\psi_{h(0,1m)} = -5 \left(\frac{0,1}{L} \right) \quad (39)$$

Por fim, no caso de condições neutras ($L = 0$), $H = 0$, $\psi_m = 0$ e $\psi_h = 0$.

Na parte final do processo iterativo, r_{ah} e u^* são estimados novamente utilizando os resultados obtidos de ψ_m e ψ_h :

$$r_{ah} = - \frac{\ln(z_1/z_2) - \psi_{h(z_2)} + \psi_{h(z_1)}}{u^* k} \quad (40)$$

$$u^* = \frac{u_{200} k}{\ln(200/z_{0m}) - \psi_{m(200m)}} \quad (41)$$

O processo iterativo continua até atingir um número máximo de 15 iterações, resultando em valores finais de r_{ah} e H .

4.1.7 Fluxo de Calor Latente instantâneo (LE) e ET diária (ET_{24h})

Com as estimativas de R_n , G e H instantâneo, LE pode ser estimado utilizando a Equação 1. Para obter o valor final de ET diária, SEBAL estima a fração evaporativa (FE) com a Equação 42 (Crago, 1996):

$$FE = \frac{LE}{R_n - G} \quad (42)$$

Finalmente, a ET diária é calculada considerando o valor obtido de FE é constante ao longo do dia (Equação 43):

$$ET_{24h} = 0.0864 FE \frac{R_{n\ 24h}}{\lambda} \quad (43)$$

onde $R_{n\ 24h}$ é a radiação diária estimada através do método de Bruin (1987) e λ é o calor latente de evaporação (kJ kg^{-1}).

4.2 Calibração Automática

A metodologia de calibração automática para selecionar os pixels frio e quente é baseado em uma versão simplificada do algoritmo *Calibration using Inverse Modeling at Extreme Conditions* (CIMEC) desenvolvido para o modelo METRIC (Allen et al., 2013) e válido também para o SEBAL, utilizando percentis de T_s e $NDVI$. O pixel frio é identificado como aquele selecionado aleatoriamente dentro do universo amostral dos pixels candidatos que contém os maiores valores de $NDVI$ (5%) e que dentro dos selecionados haja os menores valores de T_s (20%). O pixel quente é identificado através da seleção dos 10% menores valores de $NDVI$ e os 20% maiores valores de T_s . Para o modelo desenvolvido no GEE, esses são os grupos de percentis ajustados como padrão, contudo o usuário tem a liberdade de alterar esses valores para obter resultados mais acurados de ET diária.

4.3 geeSEBAL

O modelo SEBAL desenvolvido no GEE (versão 0.1.209), nomeado de geeSEBAL, foi programado nas duas versões seguintes: JavaScript e Python API (versão do Python 3.6 ou maior). O modelo utiliza dados de entrada dos produtos Landsat 5, 7 e 8 em suas versões de melhor qualidade (*Tier 1*) para correções atmosféricas de reflectância da superfície e temperatura de brilho, incluindo filtro de cobertura de nuvens do algoritmo CFMask (Foga et al., 2017). Para os dados meteorológicos de entrada, foram utilizadas 4 variáveis meteorológicas disponíveis no produto de reanálise *Global Land Assimilation System* (GLDAS) (Rodell et al., 2004), tanto com a versão 2.0 (antes de Janeiro de 2020) e 2.1 (para informações após Janeiro de 2000): T_{air} , UR , u_x e a

radiação incidente diária de ondas curtas ($Rs_{down\ 24h}$). Ainda, o produto de elevação do SRTM foi utilizado para a estimativa de P (Shuttleworth, 2012). A Tabela 2 resume as informações dos dados de entrada utilizados pelo geeSEBAL.

O geeSEBAL apresenta três funções: (i) *Image*: para estimar ET diária de uma imagem específica (disponível para JavaScript e Python); (ii) *ImageCollection*: estima a ET diária de todas as imagens disponíveis em um intervalo de data selecionado pelo usuário (exclusivo para Python); (iii) *TimeSeries*: estima uma série temporal de ET para um janela 3x3 de pixels com o ponto especificado centralizado, retornando a média, para o período a ser considerado (exclusivo para Python). A Figura 8 resume todas as possibilidades e os processos utilizados pelo geeSEBAL.

Tabela 2 – Descrição dos produtos disponíveis na plataforma GEE que são utilizados no geeSEBAL.

Produto	Informações	Período de disponibilidade	Resolução
LANDSAT 8 OLI/TIRS	Radiância espectral, reflectância da superfície, temperatura de brilho na banda 10.	Abr/2013- Presente	30 m
LANDSAT 7 ETM+	Radiância espectral, reflectância da superfície, temperatura de brilho na banda 6.	Jan/1999- Presente	30 m
LANDSAT 5 ETM	Radiância espectral, reflectância da superfície, temperatura de brilho na banda 6.	Mar/1984– Mai/2012	30 m
GLDAS 2.0	Dados meteorológicos de reanálise ($T_{air}, UR, u_x, Rs_{down\ 24h}$)	Jan/1948– Dez/2010	0,25 graus de arco
GLDAS 2.1	Dados meteorológicos de reanálise ($T_{air}, UR, u_x, Rs_{down\ 24h}$)	Jan/2000- Presente	0,25 graus de arco
SRTM	Elevação	Levantamento (missão espacial) (Fev/2000)	30 m

Uma versão GUI do geeSEBAL está disponível através da ferramenta *Earth Engine application* (Figura 9) (<https://etbrasil.org/geesebal>). Isso permite ao usuário acesso fácil às estimativas de *ET*, possibilitando a seleção de um período específico para obter uma lista de imagens Landsat ao selecionar um dado ponto no mapa. Para a imagem selecionada, o usuário pode visualizar os produtos de composição RGB, *NDVI*, T_s e *ET* diária. O geeSEBAL app também permite que o usuário mude os valores de percentis de T_s e *NDVI*.

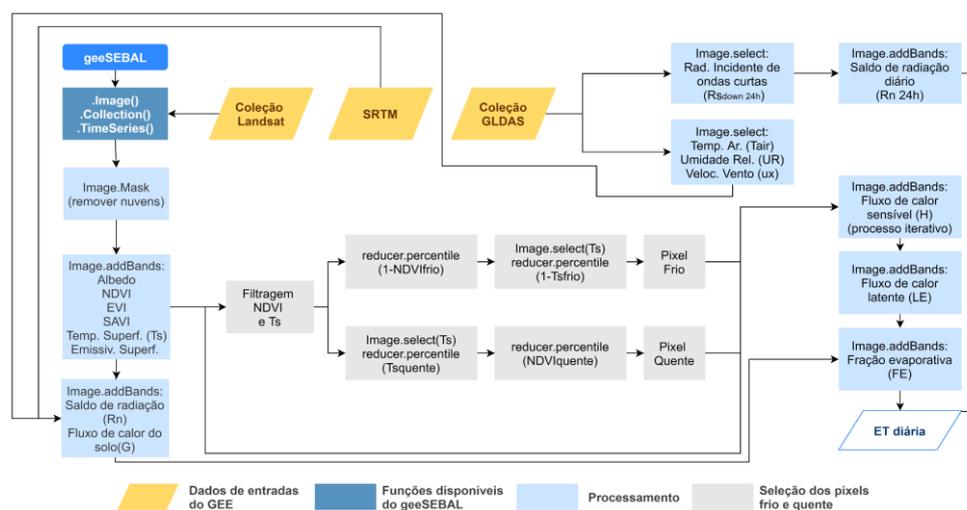


Figura 8 – Fluxograma com as etapas e possibilidades para estimar *ET* usando o geeSEBAL. Três funções estão disponíveis, para processar apenas uma imagem, uma coleção de imagens, e para extrair uma série temporal dado uma coordenada.

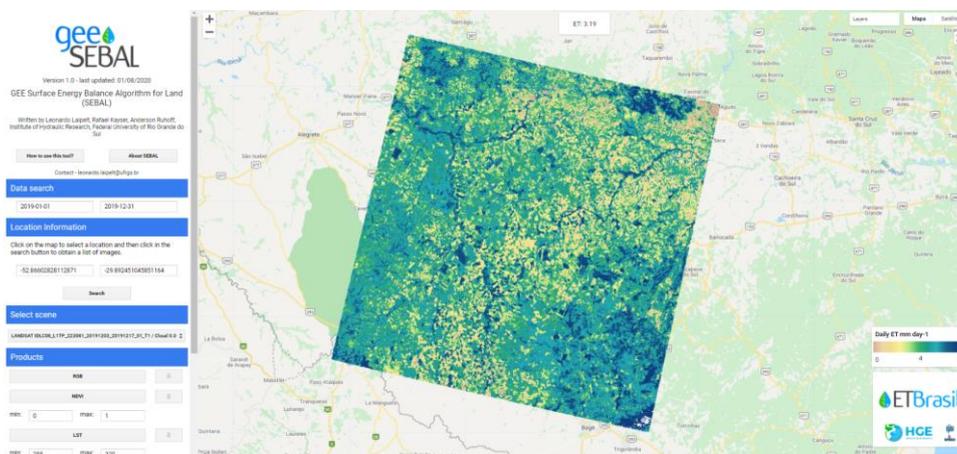


Figura 9 – A interface do usuário (www.etbrasil.com/geesebal) permite a visualização da composição RGB, *NDVI*, T_s e a *ET* diária, através da seleção de um ponto específico no mapa e determinação da imagem a ser visualizada.

4.4 Aplicação do geeSEBAL em diferentes biomas

Para demonstrar a aplicabilidade da ferramenta geeSEBAL, foram comparados os resultados de ET diária medidos em 10 torres de fluxo no Brasil através do método de EC (Figura 10), localizados em diferentes biomas e cobertura do solo. Para cada torre, foi selecionado de modo manualmente um grupo de percentil otimizado baseado na variação dos percentis originais do CIMEC (Tabela 3). As estimativas das longas séries temporais de ET foram obtidas utilizando a função *TimeSeries* do geeSEBAL. Considerando os períodos das medições das torres e dos dados Landsat, os resultados obtidos foram comparados com as torres com três métricas: o coeficiente de determinação (R^2) (Equação 45), a raiz do desvio quadrático médio (RMSD) (Equação 46) e a tendência do desvio médio (MBD) (Equação 47). A ferramenta aplica o SEBAL para todas as cenas Landsat disponíveis e retornam a ET média diária sobre uma janela de pixels 3x3 centrada na coordenada da torre. Para o total das 10 torres, foram obtidas 224 imagens que combinaram com os dados disponíveis.

Tabela 3 - Grupos de percentis utilizados para cada torre.

Torres	Grupos de percentis			
	$NDVI_{frio}$	T_{sfrio}	$NDVI_{quente}$	$T_{squeunte}$
K34	5%	0.01%	10%	0.01%
RJA	5%	0.01%	10%	0.01%
FNS	5%	1%	1%	10%
SIN	5%	1%	1%	10%
BAN	5%	0.01%	10%	0.01%
NPW	5%	0.1%	10%	0.1%
PAN	5%	1%	10%	1%
BRA	5%	10%	1%	20%
PDG	5%	1%	10%	1%
SMA	5%	1%	1%	10%

$$R^2 = \frac{\sum(E_i - \bar{E})^2}{\sum(M_i - \bar{E})^2} \quad (45)$$

$$RMSD = \sqrt{\frac{\sum(M_i - E_i)^2}{n}} \quad (46)$$

$$MBD = \frac{\sum(M_i - E_i)}{n} \quad (47)$$

em que M_i são os dados medidos e E_i são os dados estimados para um número (n) de amostras.

A torre mais ao norte (K34) está localizada em uma área de floresta tropical no centro da Amazônia. As torres da Reserva Biológica do Jarú (RJA), Fazenda Nossa Senhora (FNS) e Sinop (SIN) estão localizadas na parte sudoeste da Amazônia, representando diferentes coberturas de terra: floresta tropical, pastagem e cerradão, respectivamente. Uma área de floresta inundável na região de transição entre os biomas Amazônia-Cerrado é monitorado pela torre localizada na Ilha do Bananal (BAN). Duas torres representam o bioma Cerrado: uma localizado em formação intermediária entre floresta e pastagem, conhecido como campo sujo, no centro do Brasil (BRA) e outra torre é localizada em uma formação florestal de savana no sudeste do Brasil (PDG). As medições EC também estão disponíveis para o bioma Pantanal (PAN e NPW), associados a grandes áreas úmidas de inundação sazonal. A torre do bioma pampa (SMA) está localizada ao sul do Brasil, e sua vegetação circundante é predominantemente de pastagem. Todas as torres já foram analisadas e documentadas em estudos anteriores (Tabela 4). Esses dados já foram utilizados para a compreensão dos componentes energéticos da superfície sobre os biomas (da Rocha et al., 2009), (Restrepo-Coupe et al., 2013), e impactos da agricultura irrigada e na mudança de cobertura e uso da terra na bacia amazônica (Chagas et al., 2019; Lathuillière et al., 2018; Oliveira et al., 2019). Essas torres também foram utilizadas para avaliar modelos globais de produtos de sensoriamento remoto (Moreira et al., 2019; Souza et al., 2019; Paca et al., 2019; Wu et al., 2020), e para validar diferentes modelos SEB, como o SEBAL nas torres do BAN e PDG (Laipelt et al., 2020; Ruhoff et al., 2012), METRIC para RJA, FNS e SIN (Khand et al., 2017; Numata et al., 2017), e SSEBop para K34, FNS, BAN e JRU (Paca et al., 2019).

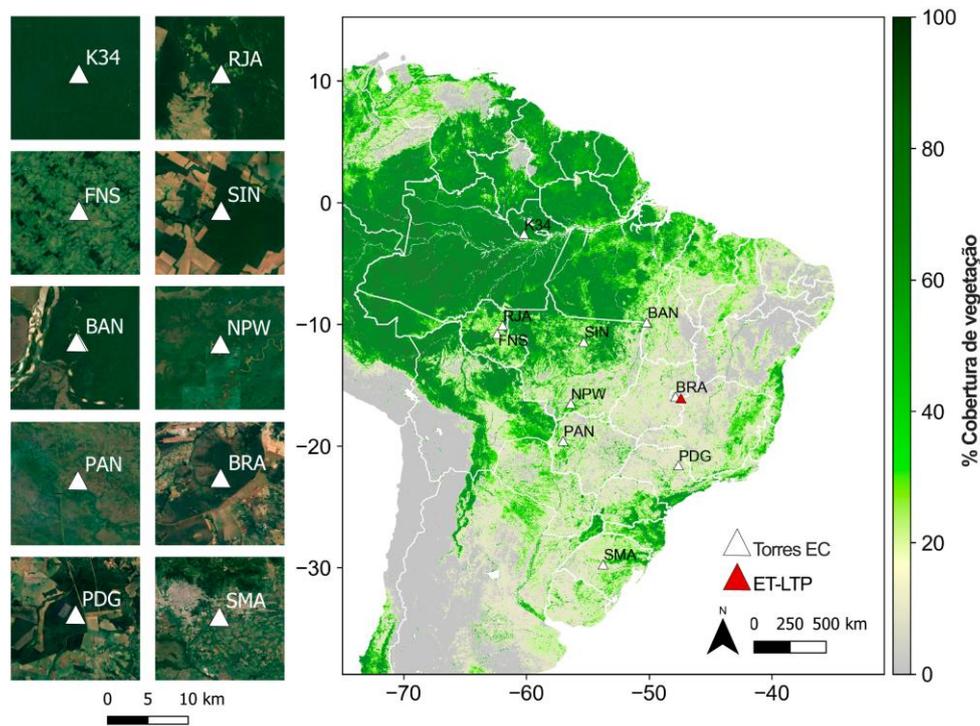


Figura 10 - Localização das 10 torres EC (triângulos brancos) usados para validar as estimativas do geeSEBAL, e o ponto onde foi extraído uma longa série temporal de ET (ET-LTP) (triângulo Vermelho).

As medições de EC normalmente apresentam inconsistência no fechamento energético devido a uma desigualdade entre a soma dos fluxos de H e LE e da energia disponível (diferença entre Rn e G) (Kanda et al., 2004; Souza et al., 2019; Wilson et al., 2002; Zhang et al., 2017). Por isso, o fechamento do balanço energético foi forçado utilizando a metodologia proposta por Twine et al. (2000), usando a razão de Bowen (β) (Equação 48) para particionar a energia disponível entre H e LE (Equação 49 e 50).

$$\beta = \frac{H}{LE} \quad (48)$$

$$H = \frac{\beta(Rn - G)}{1 + \beta} \quad (49)$$

$$LE = \frac{Rn - G}{1 + \beta} \quad (50)$$

Por fim, a função *TimeSeries* foi utilizada para a obtenção de uma longa série temporal de ET diária em uma localização (nomeada de ET-LTP) no bioma

Cerrado, usando todas as imagens Landsat disponíveis entre 1984-2019 com cobertura de nuvem menor do que 15%. Essa localização foi selecionada por apresentar mudanças de uso e cobertura da terra nas últimas décadas, com a conversão da vegetação natural em áreas agrícolas, seguidos pela implementação de sistemas de irrigação.

Tabela 4 – Principais referências das torres EC utilizadas no estudo para validar o geeSEBAL, e o total de imagens que combinam com os dados medidos.

Torres	Principais Referências	Data de disponibilidade	Número de imagens utilizadas
K34	(Araújo et al., 2002)	Jan/2000 - Set/2006	16
RJA	(von Randow et al., 2004)	Jan/2000 - Nov/2002	15
FNS	(von Randow et al., 2004)	Jun/2000 - Mar/2004	18
SIN	(Biudes et al., 2015)	Mai/2005 - Out/2008	23
BAN	(Borma et al., 2009)	Out/2003 - Dez/2006	17
NPW	(Dalmagro et al., 2019)	Jan/2013 - Set/2016	52
PAN	(Oliveira et al., 2006)	Set/2000 - Dez/2002	15
BRA	(Santos et al., 2003)	Jan/2011 - Dez/2011	16
PDG	(Rocha et al., 2002)	Jan/2001 - Dez/2006	13
SMA	(Rubert et al., 2018)	Jan/2013 - Dez/2016	39

5 RESULTADOS

5.1 Comparativo entre as estimativas do geeSEBAL com os dados de EC

A comparação entre os dados observados de *ET* e as estimativas do geeSEBAL são apresentados na Figura 11 para as 10 torres EC. De um modo geral, as estimativas diárias de *ET* do geeSEBAL apresentaram resultados satisfatórios, com uma média de RMSD de 0,78 mm dia⁻¹. Por outro lado, os

valores de correlação (R^2) obtidos para algumas torres foram baixos devido a disponibilidade de imagens Landsat apenas em certos períodos do ano, coincidentes a períodos de baixa ocorrência de nuvens, ou devido à baixa sazonalidade da *ET* (como em regiões de florestas tropicais). Figura 12 apresenta a sazonalidade da *ET* para as diferentes torres, baseado nos valores observados e estimados de acordo com o dia do ano (DOY), e demonstram uma representação razoável da sazonalidade das maiorias das localidades. A torre K34 na Amazônia, por exemplo, apresentou imagens Landsat apenas durante o período seco (Jul-Set), e apesar da grande variabilidade das taxas de *ET* ao longo do ano, os valores de RMSD e R^2 foram de $0,91 \text{ mm dia}^{-1}$ e $0,31$, respectivamente. No sul da Amazônia, as torres RJA e SIN apresentam diferentes condições hidroclimáticas. Enquanto valores baixos de R^2 para SIN são ocasionados pela disponibilidade de imagens Landsat apenas para o período seco (Abr-Set), em que as taxas de *ET* se mantêm baixas, o R^2 para RJA apresentou resultado semelhante devido à falta de sazonalidade nas taxas de *ET*. Mesmo assim, os valores de RMSD foram razoáveis ($0,68$ e $0,93 \text{ mm dia}^{-1}$, respectivamente). Apesar da proximidade com RJA, a torre FNS apresentou menores taxas de *ET* ao longo do ano devido à vegetação de pastagem, o que implica também uma maior sazonalidade. Nesse caso, R^2 foi de $0,68$ e RMSD de $0,58 \text{ mm dia}^{-1}$. Na região de transição entre os biomas Amazônia-Cerrado, as estimações do geeSEBAL também foram consistentes comparados aos dados medidos, e apesar do valores baixos de R^2 , influenciados pela disponibilidade de imagens apenas nos períodos secos, o RMSD apresentou resultados satisfatórios de $0,58 \text{ mm dia}^{-1}$.

A comparação com a torre PAN localizada no bioma Pantanal demonstra o potencial do geeSEBAL em representar mudanças na disponibilidade hídrica. Apesar de ser uma área caracterizada por períodos sazonais de inundações (período úmido durante Dez-Abr), os dados medidos de 2000/2001 representaram um período de anomalia com a diminuição da ocorrência de chuvas, ocasionando apenas pequenos pontos de inundação na região da torre (Oliveira et al., 2006), estabilizando os valores de *LE* ao longo do ano de 2001. A diminuição das taxas *ET* ocasionadas por um ano anômalo foi bem representada pelo geeSEBAL, com RMSD de $0,76 \text{ mm dia}^{-1}$ e razoável R^2 de

0,72. Por outro lado, a torre localizada no pantanal (NPW) não apresentou nenhuma condição extrema de seca ao longo do seu período de medição, e mesmo com uma sazonalidade bem definida e disponibilidade das imagens ao longo do ano, RMSD foi de 0,93 mm dia⁻¹ e R² de 0,30.

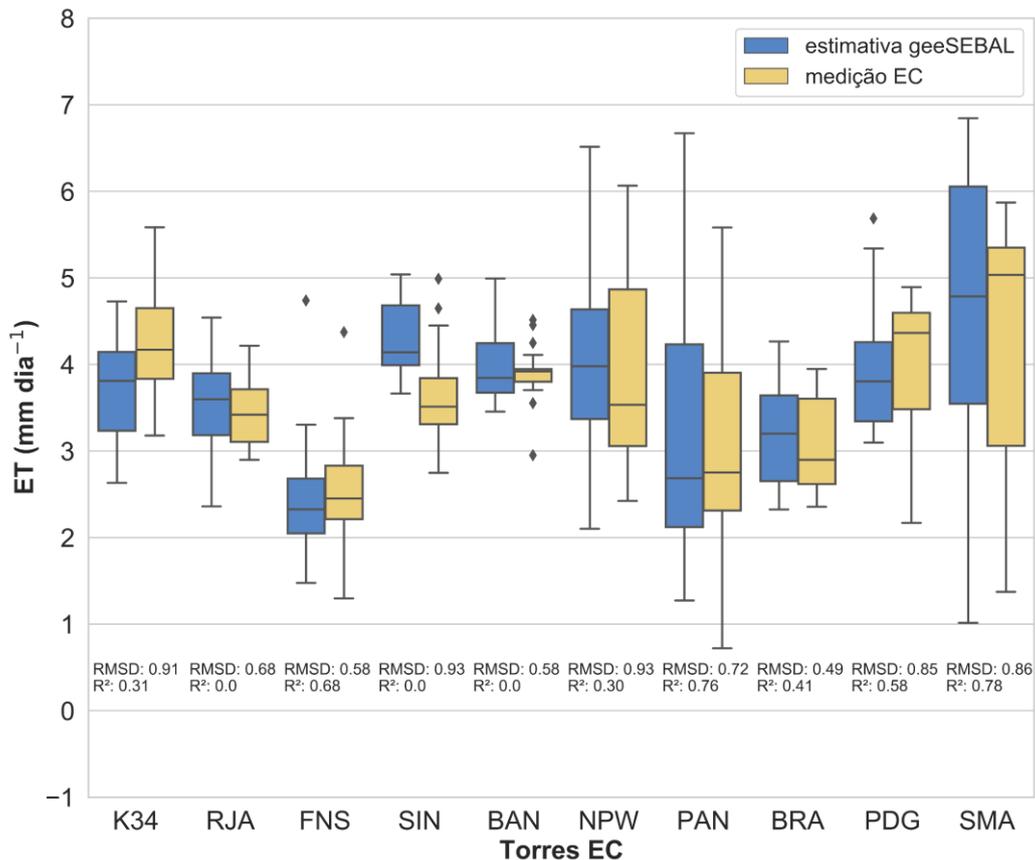


Figura 11 – Comparação entre as medições de *ET* e estimativas do geeSEBAL para diferentes torres localizadas em diferentes biomas do Brasil.

As duas torres localizadas no Cerrado (PDG e BRA) apresentaram diferentes comportamentos. Para PDG, embora os dados de EC demonstraram grande sazonalidade nas estimativas de *ET*, geeSEBAL apresentou uma superestimação durante o início do período seco. Apesar do RMSD de 0,85 mm dia⁻¹ e R² de 0,58. Para BRA, localizado em uma área de formação de savana com árvores e gramíneas (Santos et al., 2003), os resultados foram mais próximos dos obtidos pelas torres EC, com RMSD de 0,49 e R² de 0,41. Por fim, a torre mais ao sul do estudo (SMA), caracterizada pela predominância de gramíneas e localizada em clima subtropical com sazonalidade bem definida.

Com bons resultados de $R^2= 0,77$ e $RMSD$ de $0,86 \text{ mm dia}^{-1}$, as estimativas do geeSEBAL sugerem que o SEBAL responde apropriadamente com as mudanças na radiação incidente ao longo do ano, como esperado por ser uma variável de entrada do modelo.

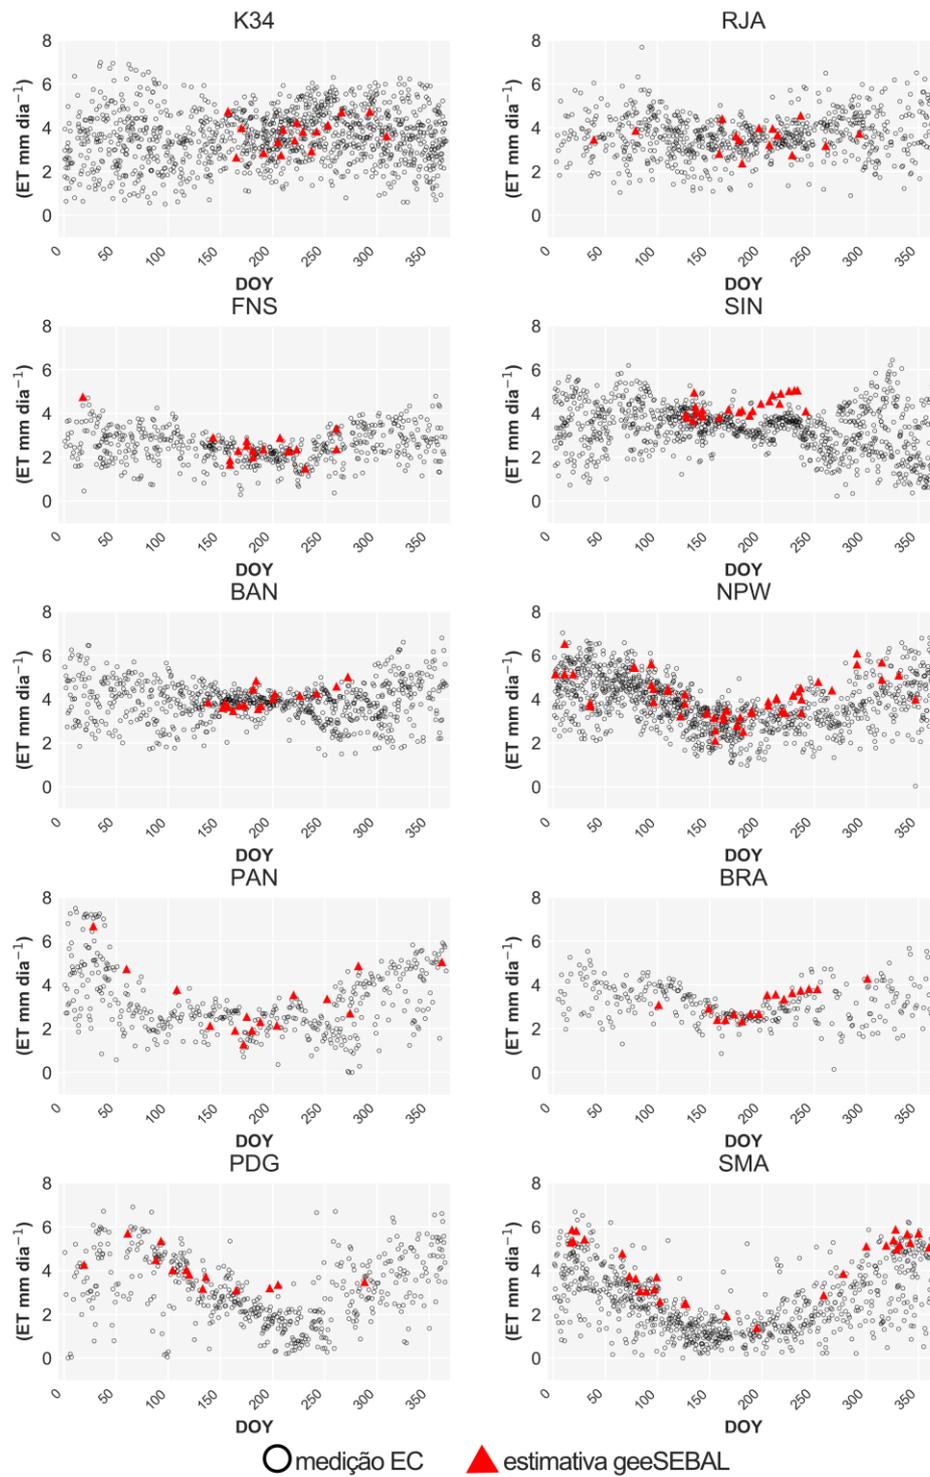


Figura 12 – Estimativas diárias de ET de acordo com o dia do ano (DOY) baseado nas medições de EC e das estimativas do geeSEBAL.

A longa série temporal de *ET* extraída para o ponto ET-LTP (Figura 13) e localizada no município de Cristalina, no estado de Goiás (16°6'3.84"S 47°23'42.31" W; ver localização na Figura 10) demonstra a variação da *ET* ao longo das últimas décadas. A seleção da localização coincide com a intensificação da expansão agrícola ocorrida no Cerrado desde 1990 (Noojipady et al., 2017), alterando a vegetação natural por áreas de plantios e sistemas de irrigação. Essas mudanças são bem documentadas como principais fatores que impactam diretamente as taxas de *ET* (da Silva et al., 2019; Dias et al., 2015), devido, principalmente, pelas mudanças no particionamento energético entre *H* e *LE* (Biudes et al., 2015; Cabral et al., 2015; Pongratz et al., 2006). A maioria dos estudos sugerem que no Cerrado a conversão da vegetação natural em pastagens e áreas agrícolas pode ocasionar diminuições significativas nas taxas de *ET* (Nóbrega et al., 2017; Oliveira et al., 2014; Spera et al., 2016). Apesar disso, a implementação por sistemas de irrigação pode ocasionar o aumento nas taxas de *ET* (Gordon et al., 2005), enquanto que impacta no balanço da água devido a retirada de água (Tang et al., 2007). Tais efeitos são demonstrados na Figura 13, em que a implementação do sistema de irrigação é visível nas médias de *ET* para 2000-2004 (3,5 mm dia⁻¹), enquanto os valores entre 1985-1990 são menores (2,1 mm dia⁻¹). Os menores valores ocorreram entre 1990-1994 e coincidem com a diminuição do *NDVI* (0,32 em 1985-1989 e 0,21 em 1990-1994), indicando a possibilidade de a vegetação ter sido retirada nesse período. Essas estimativas são passíveis de incertezas relacionadas a disponibilidade de imagens do Landsat e os dados meteorológicos utilizados como entrada no modelo, e serão discutidas na próxima seção.

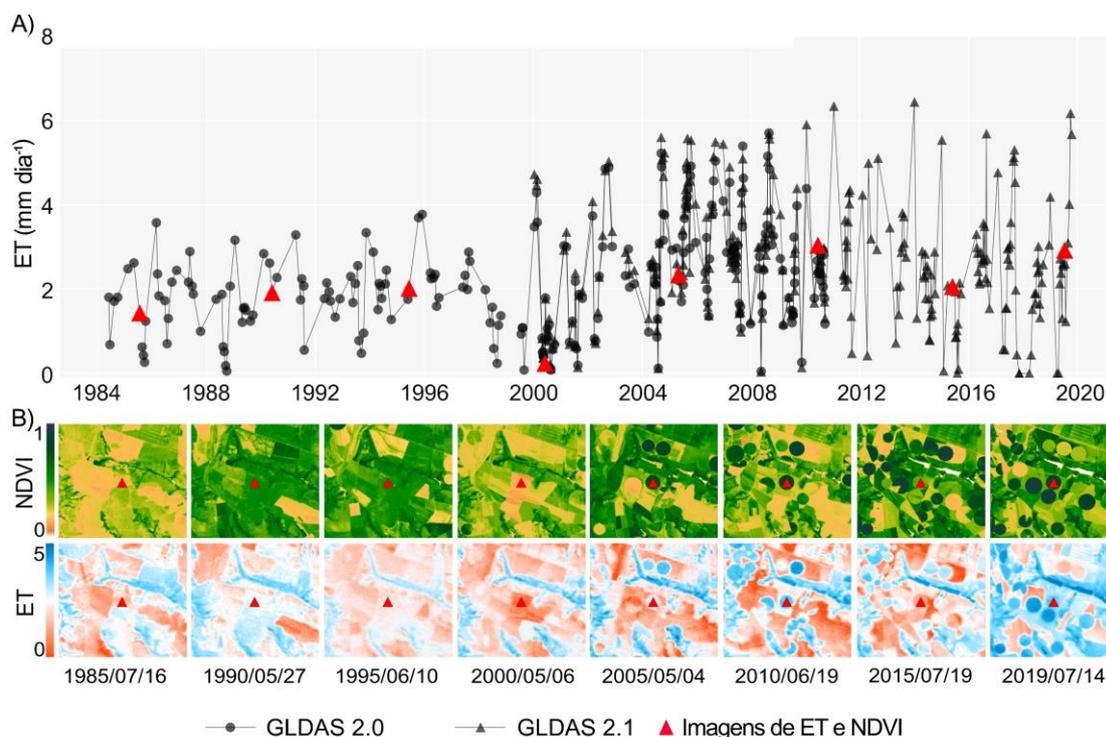


Figura 13 – (A) Aplicação da estimação de uma longa série temporal de ET no ponto ET-LTP. As tendências de ET apresentaram mudanças ao longo das décadas devido a alterações no uso e cobertura da terra, como a implementação de sistemas de irrigações. (B) Mapas de NDVI (coluna superior) e *ET* (coluna inferior) para oito datas durante o período analisado. Os triângulos vermelhos se referem as mesmas imagens apresentadas abaixo da série temporal.

6 DISCUSSÃO

6.1 Análise da performance

Os resultados obtidos na comparação das estimativas do geeSEBAL com dados observados de EC são similares com outros estudos realizados no Brasil. Laipelt et al. (2020) obtiveram para a torre BAN usando SEBAL e dados meteorológicos de reanálise do MERRA-2 um RMSD de 0,37 mm dia⁻¹ com o mesmo grupo de percentis utilizado nesse estudo, mas com o resultado de 0,58 mm dia⁻¹. As diferenças podem ser atribuídas aos diferentes produtos meteorológicos utilizados (MERRA-2 não está disponível no GEE), como também no uso de imagens Landsat 5 e 7 nesse estudo, enquanto em Laipelt et al. (2020) apenas utilizou Landsat 5. Numata et al. (2017) avaliaram a performance do modelo METRIC usando imagens Landsat para a torre RJA. Para os períodos secos entre 2000 e 2002, eles obtiveram um RMSD de 0,81

mm dia⁻¹, enquanto nesse estudo foi obtido 0,50 mm dia⁻¹. A superestimação em comparação ao geeSEBAL pode ser resultado da escolha de um grupo diferente de percentis utilizados para selecionar os pixels frio e quente. Como exemplo, caso fosse utilizado os percentis sugeridos por Allen et al. (2013), o resultado do RMSD aumentaria para 0,90 mm dia⁻¹. Além disso, para o geeSEBAL foi utilizado uma versão simplificada do CIMEC, sem a adição do filtro de vegetação como proposto por Allen et al. (2013). Essa adaptação foi realizada para que o geeSEBAL pudesse estimar *ET* em qualquer área, sem depender da classificação de uso da terra. Entretanto, visto que a ferramenta é totalmente adaptável, a aplicação desse filtro e outras metodologias para melhorar a acurácia do modelo (Biggs et al., 2016; Dhungel and Barber, 2018; Jaafar and Ahmad, 2019; Long and Singh, 2012; Silva et al., 2019) é totalmente viável.

6.2 Incertezas do modelo

Nesse estudo, os valores dos percentis foram alterados para obtenção de melhores estimativas de *ET* para cada torre. É de conhecimento que o modelo SEBAL apresenta uma alta sensibilidade na escolha dos pixels frio e quente (Bastiaanssen, 1995; Long et al., 2011), impactando diretamente nas estimativas de *ET* (Paul et al., 2013). Ainda, áreas de vegetações heterogêneas podem impactar diretamente na seleção dos percentis (Tang et al., 2013). Uma maior acurácia pode ser obtida alterando-os, o que é possível de ser feito em todas as funções disponíveis do geeSEBAL. Em relação às mudanças dos pixels pré-candidatos de T_s e *NDVI*, alterações nos percentis de T_s tendem a influenciar mais nos resultados dos fluxos energéticos quando comparados as mudanças nos percentis de *NDVI* (Choragudi, 2011).

Outra incerteza a ser considerada é em relação aos dados meteorológicos de entrada, que podem ser uma importante fonte de erro (Bhattarai et al., 2019; Biggs et al., 2016). Para o geeSEBAL foram utilizadas informações meteorológicas de reanálise do GLDAS devido as informações horárias disponíveis para um longo período e por estar disponibilizado no GEE. É importante notar que existe algumas diferenças entre os produtos GLDAS 2.0 e 2.1 (Rui and Beaudoin, 2015). Apesar disso, as estimativas de *ET* usando o

SEBAL apresentaram uma baixa sensibilidade aos dados do GLDAS 2.0 e 2.1, como observado na Figura 13 para o período de 2000-2010, intervalo em que ambos apresentam informações. Na comparação das estimativas de ET do geeSEBAL utilizando dados do GLDAS 2.1 e 2.0 com as estimativas de EC com dados disponíveis entre 2000-2010 (K34, RJA, FNS, SIN, BAN, PAN, PDG) é obtido RMSD médio de $0,75 \text{ mm dia}^{-1}$ e MBD médio de $0.015 \text{ mm dia}^{-1}$, utilizando GLDAS 2.1, e $0,81 \text{ mm dia}^{-1}$ e $-0.005 \text{ mm dia}^{-1}$ de RMSD e MBD, respectivamente, para dados GLDAS 2.0 (Figura 14). Contudo, como mostra na Figura 15, há maiores variações no comportamento dos dados de reanálise anteriores a 2000 para o GLDAS 2.0. Por fim, o uso de dados de reanálise com modelos de ET vem demonstrando bons resultados (Bhattarai et al., 2019; Mu et al., 2011), embora ainda existam incertezas relacionados à sua acurácia. Para o geeSEBAL, outros produtos de reanálise podem ser facilmente implementados caso haja sua disponibilização no GEE.

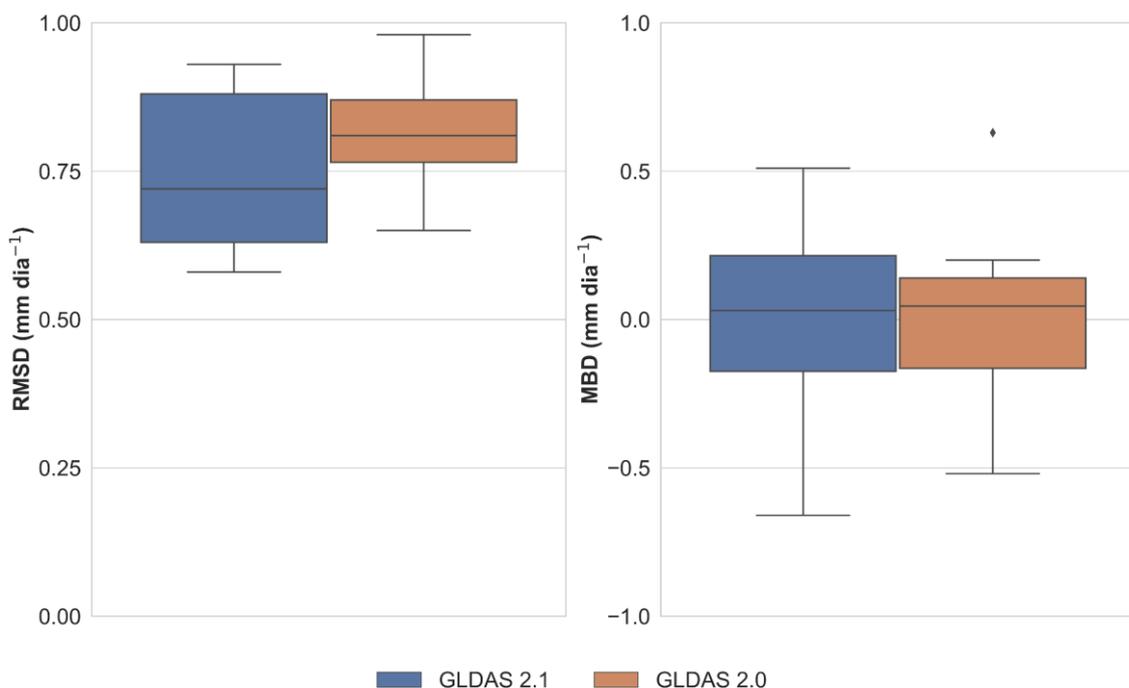


Figura 14 – Valores de RMSD e MBD obtidos no comparativo das estimativas de ET do geeSEBAL com torres que apresentam dados no período em que GLDAS 2.1 e 2.0 coexistem (2000-2010).

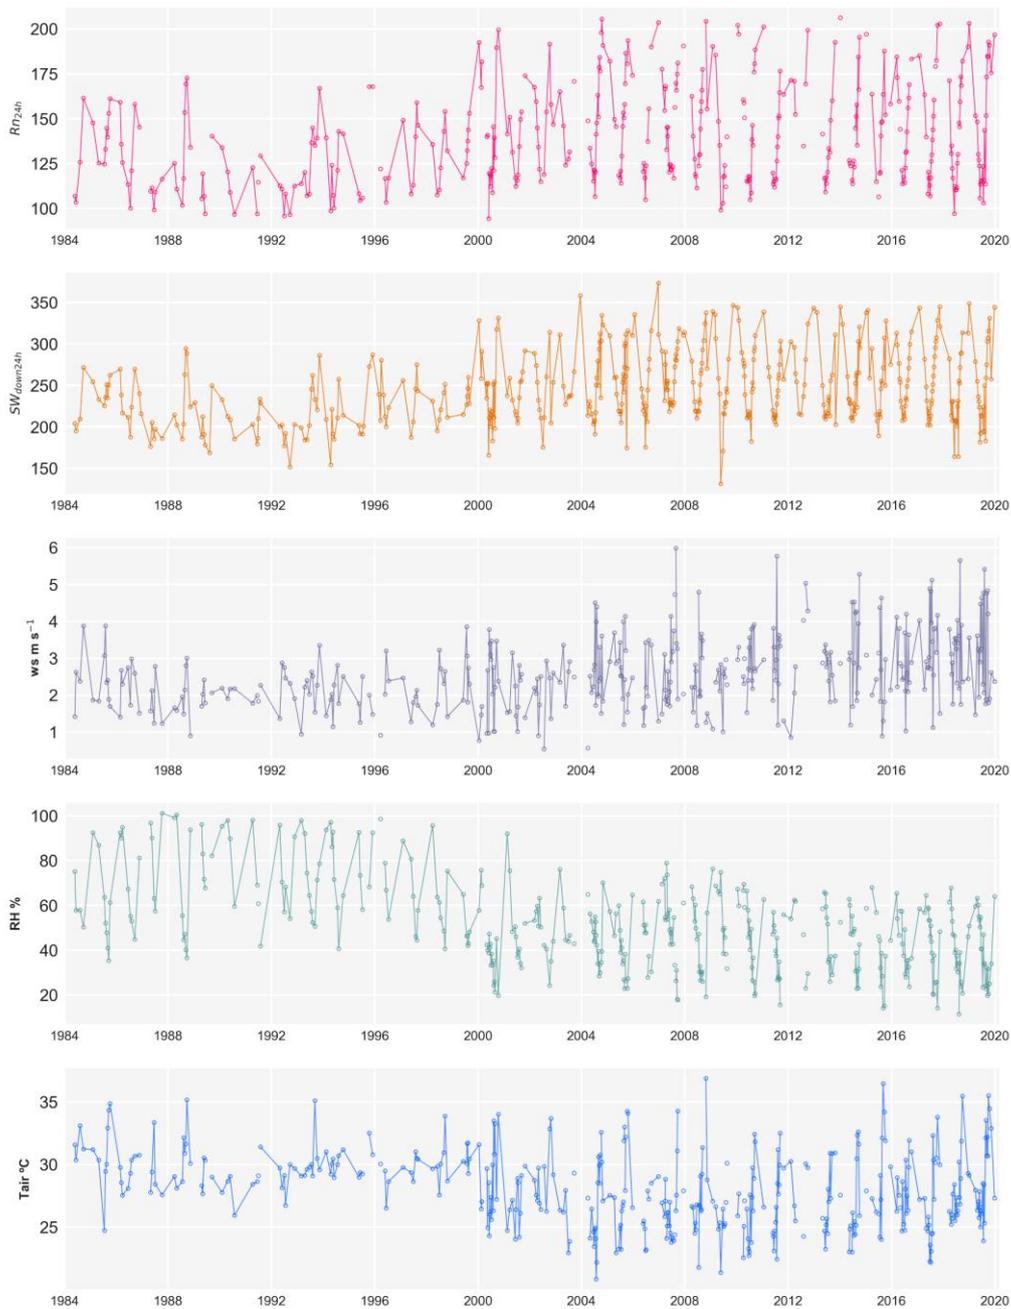


Figura 15 - Variáveis meteorológicas extraídas para ET-LTP. $R_{s_{down\ 24h}}$, u_x , UR e T_{air} são extraídos para GLDAS 2.0 (1984-1999) e 2.1 (2000-2019). Rn_{24h} é estimado usando o método de Bruin (1987).

6.3 Eficiência do geeSEBAL

A estimação diária de ET com o geeSEBAL depende de alguns fatores. A área da imagem, por exemplo, aumentará o processamento à medida que for maior. É importante destacar que, como padrão, o geeSEBAL estima a ET para a área de domínio da imagem Landsat. A diminuição da área estimada, caso o

usuário desejar ganho de performance, deve ser feita com precaução visto que a alteração da área de domínio apresenta um impacto direto no modelo SEBAL (dos Santos et al., 2020; Long et al., 2011) devido a alteração dos pixels candidatos.

O tempo de processamento do geeSEBAL está entre 3-5 min para cada imagem Landsat (185 km x 185 km). Além disso, como o processamento é realizado através dos supercomputadores onde estão localizados os servidores do GEE, a capacidade de processamento do computador não é algo relevante para a aplicação do geeSEBAL, entretanto, a velocidade de conexão com os servidores pode impactar no processamento.

Apesar de utilizar imagens Landsat, outros produtos podem ser utilizados com o geeSEBAL, como no caso de imagens MODIS para melhorar a resolução temporal das estimativas de *ET* e que já demonstraram resultados satisfatórios com o modelo SEBAL em estudos anteriores (Kiptala et al., 2013; Lee and Kim, 2016; Ruhoff et al., 2012). Novos dados meteorológicos (e.g., dados de reanálise do ERA) também serão incluídos no geeSEBAL assim que se tornarem disponíveis no GEE.

7 CONCLUSÕES

O uso de modelos de balanço energético da superfície é uma opção viável para aplicações envolvendo o uso da água. Nesse estudo, é introduzido o geeSEBAL, uma ferramenta de código aberto com opção de GUI desenvolvido para estimar *ET* em diferentes escalas ao longo do globo. Essa ferramenta permite diversas aplicações na área de ciência da terra juntando SEBAL com o processamento do GEE, permitindo uma maneira rápida e acurada para estimar *ET*. A comparação entre dados EC e estimados do geeSEBAL demonstraram a capacidade do modelo em diferentes tipos de vegetação e biomas, apresentando resultados razoáveis de RMSD $<0,8 \text{ mm dia}^{-1}$ para a maioria das torres. Ainda, a longa série temporal de *ET* para uma localização específica do Cerrado brasileiro demonstrou o potencial do geeSEBAL para estudos de impactos de mudanças do uso e cobertura da terra ao longo das décadas. A compreensão das dinâmicas envolvendo *ET* é crucial para mitigação dos impactos da depleção

da água nos ecossistemas devido, por exemplo, ao aumento da demanda de água para produção de alimentos e abastecimento urbano. O autor espera que a ferramenta seja útil para o desenvolvimento de estudos em largas escalas envolvendo o uso da água e o balanço energético, assim como o gerenciamento da água como um todo.

7.1 Perspectivas futuras

Pesquisas futuras de aplicação do geeSEBAL focarão na estimação de ET em largas escalas. Além disso, o geeSEBAL pode ser utilizado para estimar longas séries temporais em diferentes escalas, como em áreas de irrigação, ou para analisar mudanças nos fluxos energéticos em áreas desmatadas em escala regional. Atualmente, produtos de *ET* disponíveis em escalas globais apresentam limitações em suas concepções por serem baseados em produtos de índices de vegetações como parâmetros principais, e o uso de um algoritmo automatizado de balanço energético da superfície em escalas continentais pode melhorar os resultados de modelos hidrológicos e climáticos.

8 REFERÊNCIAS BIBLIOGRÁFICAS

- Allen, R., Kilic, A., Trezza, R., Hendrickx, J., Bastiaanssen, W.G.M., Kjaersgaard, J., 2011. Satellite-based ET estimation in agriculture using SEBAL and METRIC. *Hydrol. Process.* 25, 4011–4027. <https://doi.org/10.1002/hyp.8408>
- Allen, R., Morton, C., Kamble, B., Kilic, A., Huntington, J., Thau, D., Gorelick, N., Erickson, T., Moore, R., Trezza, R., Ratcliffe, I., Robison, C., 2015. EEFlux: A Landsat-based Evapotranspiration mapping tool on the Google Earth Engine, in: 2015 ASABE / IA Irrigation Symposium: Emerging Technologies for Sustainable Irrigation - A Tribute to the Career of Terry Howell, Sr. Conference Proceedings. American Society of Agricultural and Biological Engineers, pp. 1–11. <https://doi.org/10.13031/irrig.20152143511>
- Allen, R., Tasumi, M., Trezza, R., 2007. Satellite-Based Energy Balance for Mapping Evapotranspiration With Internalized Calibration (METRIC) – Model. *J. Irrig. Drain. Eng.* 133. [https://doi.org/10.1061/\(ASCE\)0733-9437\(2007\)133:4\(380\)](https://doi.org/10.1061/(ASCE)0733-9437(2007)133:4(380))

- Allen, R.G., Burnett, B., Kramber, W., Huntington, J., Kjaersgaard, J., Kilic, A., Kelly, C., Trezza, R., 2013. Automated Calibration of the METRIC-Landsat Evapotranspiration Process. *JAWRA J. Am. Water Resour. Assoc.* 49, 563–576. <https://doi.org/10.1111/jawr.12056>
- Alonso, A., Muñoz-Carpena, R., Kaplan, D., 2020. Coupling high-resolution field monitoring and MODIS for reconstructing wetland historical hydroperiod at a high temporal frequency. *Remote Sens. Environ.* 247, 111807. <https://doi.org/https://doi.org/10.1016/j.rse.2020.111807>
- Amani, M., Ghorbanian, A., Ahmadi, S.A., Kakooei, M., Moghimi, A., Mirmazloumi, S.M., Moghaddam, S.H.A., Mahdavi, S., Ghahremanloo, M., Parsian, S., Wu, Q., Brisco, B., 2020. Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 13, 5326–5350. <https://doi.org/10.1109/JSTARS.2020.3021052>
- Anderson, M.C., Norman, J.M., Diak, G.R., Kustas, W.P., Mecikalski, J.R., 1997. A two-source time-integrated model for estimating surface fluxes using thermal infrared remote sensing. *Remote Sens. Environ.* 60, 195–216. [https://doi.org/https://doi.org/10.1016/S0034-4257\(96\)00215-5](https://doi.org/https://doi.org/10.1016/S0034-4257(96)00215-5)
- Anderson, M.C., Norman, J.M., Mecikalski, J.R., Otkin, J.A., Kustas, W.P., 2007. A climatological study of evapotranspiration and moisture stress across the continental United States based on thermal remote sensing: 1. Model formulation. *J. Geophys. Res. Atmos.* 112. <https://doi.org/10.1029/2006JD007506>
- Aragão, L., 2012. Environmental science: The rainforest's water pump. *Nature* 489, 217–218. <https://doi.org/10.1038/nature11485>
- Araújo, A.C., Nobre, A.D., Kruijt, B., Elbers, J.A., Dallarosa, R., Stefani, P., von Randow, C., Manzi, A.O., Culf, A.D., Gash, J.H.C., Valentini, R., Kabat, P., 2002. Comparative measurements of carbon dioxide fluxes from two nearby towers in a central Amazonian rainforest: The Manaus LBA site. *J. Geophys. Res. Atmos.* 107, LBA 58-1-LBA 58-20. <https://doi.org/10.1029/2001JD000676>
- Baghdadi, N., Zribi, M., 2016. Introduction, in: Baghdadi, N., Zribi, M.B.T.-O.R.S. of L.S. (Eds.), *Optical Remote Sensing of Land Surface*. Elsevier, pp. xxxix–xlii. <https://doi.org/10.1016/B978-1-78548-102-4.50012-0>

- Bastiaanssen, W.G.M., 2000. SEBAL-based sensible and latent heat fluxes in the irrigated Gediz Basin, Turkey. *J. Hydrol.* 229, 87–100. [https://doi.org/https://doi.org/10.1016/S0022-1694\(99\)00202-4](https://doi.org/https://doi.org/10.1016/S0022-1694(99)00202-4)
- Bastiaanssen, W.G.M., 1995. Regionalization of surface flux densities and moisture indicators in composite terrain: a remote sensing approach under clear skies in Mediterranean climates. Dr. thesis, Wageningen Agric. Univ. Wageningen Netherlands. SC-DLO, Wageningen. <https://doi.org/90-5485-465-0>
- Bastiaanssen, W.G.M., Menenti, M., Feddes, R.A., Holtslag, A.A.M., 1998a. A remote sensing surface energy balance algorithm for land (SEBAL): 1. Formulation. *J. Hydrol.* 212–213, 198–212. [https://doi.org/10.1016/S0022-1694\(98\)00253-4](https://doi.org/10.1016/S0022-1694(98)00253-4)
- Bastiaanssen, W.G.M., Pelgrum, H., Wang, J., Ma, Y., Moreno, J.F., Roerink, G.J., van der Wal, T., 1998b. A remote sensing surface energy balance algorithm for land (SEBAL): 2. Validation. *J. Hydrol.* 212–213, 213–229. [https://doi.org/10.1016/S0022-1694\(98\)00254-6](https://doi.org/10.1016/S0022-1694(98)00254-6)
- Bastiaanssen, W.G.M., Thiruvengadachari, S., Sakthivadivel, R., Molden, D.J., 1999. Satellite Remote Sensing for Estimating Productivities of Land and Water. *Int. J. Water Resour. Dev.* 15, 181–194. <https://doi.org/10.1080/07900629949005>
- Bates, B.C., Kundzewicz, Z.W., Wu, S., Palutikof, J.P., 2008. Climate Change and Water. Technical Paper of the Intergovernmental Panel on Climate Change (IPCC), Climate change and water.
- Bhattarai, N., Dougherty, M., Marzen, L.J., Kalin, L., 2012. Validation of evaporation estimates from a modified surface energy balance algorithm for land (SEBAL) model in the south-eastern United States. *Remote Sens. Lett.* 3, 511–519. <https://doi.org/10.1080/01431161.2011.632655>
- Bhattarai, N., Mallick, K., Stuart, J., Vishwakarma, B.D., Niraula, R., Sen, S., Jain, M., 2019. An automated multi-model evapotranspiration mapping framework using remotely sensed and reanalysis data. *Remote Sens. Environ.* 229, 69–92. <https://doi.org/https://doi.org/10.1016/j.rse.2019.04.026>
- Bhattarai, N., Quackenbush, L.J., Im, J., Shaw, S.B., 2017. A new optimized algorithm for automating endmember pixel selection in the SEBAL and METRIC models. *Remote Sens. Environ.* 196, 178–192.

<https://doi.org/https://doi.org/10.1016/j.rse.2017.05.009>

- Biggs, T., Petropoulos, G.P., Velpuri, N.M., Marshall, M., Glenn, E.P., Nagler, P.L., Messina, A., 2015. Remote Sensing of Actual Evapotranspiration from Cropland: Chapter 3, in: Thenkabail, P.S. (Ed.), *Remote Sensing Handbook, Vol. III: Remote Sensing of Water Resources, Disasters, and Urban Studies*. CRC Press.
- Biggs, T.W., Marshall, M., Messina, A., 2016. Mapping daily and seasonal evapotranspiration from irrigated crops using global climate grids and satellite imagery: Automation and methods comparison. *Water Resour. Res.* 52, 7311–7326. <https://doi.org/10.1002/2016WR019107>
- Biudes, M.S., Vourlitis, G.L., Machado, N.G., de Arruda, P.H.Z., Neves, G.A.R., de Almeida Lobo, F., Neale, C.M.U., de Souza Nogueira, J., 2015. Patterns of energy exchange for tropical ecosystems across a climate gradient in Mato Grosso, Brazil. *Agric. For. Meteorol.* 202, 112–124. <https://doi.org/10.1016/j.agrformet.2014.12.008>
- Boretti, A., Rosa, L., 2019. Reassessing the projections of the World Water Development Report. *npj Clean Water* 2, 15. <https://doi.org/10.1038/s41545-019-0039-9>
- Borma, L.S., da Rocha, H.R., Cabral, O.M., von Randow, C., Collicchio, E., Kurzatkowski, D., Brugger, P.J., Freitas, H., Tannus, R., Oliveira, L., Rennó, C.D., Artaxo, P., 2009. Atmosphere and hydrological controls of the evapotranspiration over a floodplain forest in the Bananal Island region, Amazonia. *J. Geophys. Res.* 114, G01003. <https://doi.org/10.1029/2007JG000641>
- Boucher, O., Myhre, G., Myhre, A., 2004. Direct human influence of irrigation on atmospheric water vapour and climate. *Clim. Dyn.* 22, 597–603. <https://doi.org/10.1007/s00382-004-0402-4>
- Brazilian Water Agency, 2020. Estimativas de evapotranspiração real por sensoriamento remoto no Brasil. Brasília.
- Cabral, O.M.R., da Rocha, H.R., Gash, J.H., Freitas, H.C., Ligo, M.A.V., 2015. Water and energy fluxes from a woodland savanna (cerrado) in southeast Brazil. *J. Hydrol. Reg. Stud.* 4, 22–40. <https://doi.org/10.1016/j.ejrh.2015.04.010>
- Chagas, M.C., Delgado, R.C., de Souza, L.P., de Carvalho, D.C., Pereira, M.G., Teodoro, P.E., Silva Junior, C.A., 2019. Gross primary productivity in areas of different land

- cover in the western Brazilian Amazon. *Remote Sens. Appl. Soc. Environ.* 16, 100259. <https://doi.org/10.1016/j.rsase.2019.100259>
- Choragudi, V.N.R.K., 2011. Sensitivity analysis on mapping evapotranspiration at high resolution using internal calibration (METRIC). *Civ. Eng. Theses, Diss. Student Res.* 78.
- Collischonn, W., Dornelles, F., 2015. *Hidrologia para Engenharia e Ciências Ambientais.*
- Crago, R.D., 1996. Conservation and variability of the evaporative fraction during the daytime. *J. Hydrol.* 180, 173–194. [https://doi.org/10.1016/0022-1694\(95\)02903-6](https://doi.org/10.1016/0022-1694(95)02903-6)
- Curran, P.J., 1985. *Principles of remote sensing.*
- da Rocha, H.R., Manzi, A.O., Cabral, O.M., Miller, S.D., Goulden, M.L., Saleska, S.R., R.-Coupe, N., Wofsy, S.C., Borma, L.S., Artaxo, P., Vourlitis, G., Nogueira, J.S., Cardoso, F.L., Nobre, A.D., Kruijt, B., Freitas, H.C., von Randow, C., Aguiar, R.G., Maia, J.F., 2009. Patterns of water and heat flux across a biome gradient from tropical forest to savanna in Brazil. *J. Geophys. Res. Biogeosciences* 114. <https://doi.org/10.1029/2007JG000640>
- da Silva, H.J.F., Gonçalves, W.A., Bezerra, B.G., 2019. Comparative analyzes and use of evapotranspiration obtained through remote sensing to identify deforested areas in the Amazon. *Int. J. Appl. Earth Obs. Geoinf.* 78, 163–174. <https://doi.org/10.1016/j.jag.2019.01.015>
- Dalmagro, H.J., Zanella de Arruda, P.H., Vourlitis, G.L., Lathuillière, M.J., de S. Nogueira, J., Couto, E.G., Johnson, M.S., 2019. Radiative forcing of methane fluxes offsets net carbon dioxide uptake for a tropical flooded forest. *Glob. Chang. Biol.* 25, 1967–1981. <https://doi.org/10.1111/gcb.14615>
- Davidson, E.A., de Araújo, A.C., Artaxo, P., Balch, J.K., Brown, I.F., Bustamante, M.M.C., Coe, M.T., DeFries, R.S., Keller, M., Longo, M., Munger, J.W., Schroeder, W., Soares-Filho, B.S., Souza, C.M., Wofsy, S.C., 2012. Erratum: Corrigendum: The Amazon basin in transition. *Nature* 483, 232–232. <https://doi.org/10.1038/nature10943>
- Davies, E.G.R., Simonovic, S.P., 2011. Global water resources modeling with an integrated model of the social–economic–environmental system. *Adv. Water Resour.* 34, 684–700. <https://doi.org/10.1016/j.advwatres.2011.02.010>

- Davis, K.F., Rulli, M.C., Seveso, A., D'Odorico, P., 2017. Increased food production and reduced water use through optimized crop distribution. *Nat. Geosci.* 10, 919–924. <https://doi.org/10.1038/s41561-017-0004-5>
- Dhungel, S., Barber, M., 2018. remote sensing Estimating Calibration Variability in Evapotranspiration Derived from a Satellite-Based Energy Balance Model. *Remote Sens.* 10. <https://doi.org/10.3390/rs10111695>
- Dias, L.C.P., Macedo, M.N., Costa, M.H., Coe, M.T., Neill, C., 2015. Effects of land cover change on evapotranspiration and streamflow of small catchments in the Upper Xingu River Basin, Central Brazil. *J. Hydrol. Reg. Stud.* 4, 108–122. <https://doi.org/10.1016/J.EJRH.2015.05.010>
- dos Santos, C.A.C., Mariano, D.A., das Chagas A. do Nascimento, F., da C. Dantas, F.R., de Oliveira, G., Silva, M.T., da Silva, L.L., da Silva, B.B., Bezerra, B.G., Safa, B., de S. Medeiros, S., Neale, C.M.U., 2020. Spatio-temporal patterns of energy exchange and evapotranspiration during an intense drought for drylands in Brazil. *Int. J. Appl. Earth Obs. Geoinf.* 85, 101982. <https://doi.org/10.1016/j.jag.2019.101982>
- Fisher, J.B., Melton, F., Middleton, E., Hain, C., Anderson, M., Allen, R., McCabe, M.F., Hook, S., Baldocchi, D., Townsend, P.A., Kilic, A., Tu, K., Miralles, D.D., Perret, J., Lagouarde, J.-P., Waliser, D., Purdy, A.J., French, A., Schimel, D., Famiglietti, J.S., Stephens, G., Wood, E.F., 2017. The future of evapotranspiration: Global requirements for ecosystem functioning, carbon and climate feedbacks, agricultural management, and water resources. *Water Resour. Res.* 53, 2618–2626. <https://doi.org/10.1002/2016WR020175>
- Fisher, J.B., Tu, K.P., Baldocchi, D.D., 2008. Global estimates of the land–atmosphere water flux based on monthly AVHRR and ISLSCP-II data, validated at 16 FLUXNET sites. *Remote Sens. Environ.* 112, 901–919. <https://doi.org/https://doi.org/10.1016/j.rse.2007.06.025>
- Foga, S., Scaramuzza, P.L., Guo, S., Zhu, Z., Dilley, R.D., Beckmann, T., Schmidt, G.L., Dwyer, J.L., Joseph Hughes, M., Laue, B., 2017. Cloud detection algorithm comparison and validation for operational Landsat data products. *Remote Sens. Environ.* 194, 379–390. <https://doi.org/https://doi.org/10.1016/j.rse.2017.03.026>
- Garrison, J.D., Adler, G.P., 1990. Estimation of precipitable water over the United States

- for application to the division of solar radiation into its direct and diffuse components. *Sol. Energy* 44, 225–241. [https://doi.org/10.1016/0038-092X\(90\)90151-2](https://doi.org/10.1016/0038-092X(90)90151-2)
- Gerbens-Leenes, P.W., Mekonnen, M.M., Hoekstra, A.Y., 2013. The water footprint of poultry, pork and beef: A comparative study in different countries and production systems. *Water Resour. Ind.* 1–2, 25–36. <https://doi.org/10.1016/j.wri.2013.03.001>
- Gordon, L.J., Steffen, W., Jönsson, B.F., Folke, C., Falkenmark, M., Johannessen, Å., 2005. Human modification of global water vapor flows from the land surface. *Proc. Natl. Acad. Sci. U. S. A.* 102, 7612 LP – 7617. <https://doi.org/10.1073/pnas.0500208102>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R., 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sens. Environ.* 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Hillel, D., Hatfield, J.H., Powlson, D.S., Rosenzweig, C., Scow, K.M., Singer, M.J., Sparks, D.L. (Eds.), 2005. *Encyclopedia of Soils in the Environment*. Elsevier/Academic Press, Amsterdam et al.
- Hird, J.N., DeLancey, E.R., McDermid, G.J., Kariyeva, J., 2017. Google Earth Engine, Open-Access Satellite Data, and Machine Learning in Support of Large-Area Probabilistic Wetland Mapping. *Remote Sens.* . <https://doi.org/10.3390/rs9121315>
- Iizumi, T., Ramankutty, N., 2015. How do weather and climate influence cropping area and intensity? *Glob. Food Sec.* 4, 46–50. <https://doi.org/10.1016/j.gfs.2014.11.003>
- Jaafar, H.H., Ahmad, F.A., 2019. Time series trends of Landsat-based ET using automated calibration in METRIC and SEBAL: The Bekaa Valley, Lebanon. *Remote Sens. Environ.* <https://doi.org/https://doi.org/10.1016/j.rse.2018.12.033>
- Jensen, J.R., 2013. *Remote Sensing of the Environment: Pearson New International Edition: An Earth Resource Perspective*. Pearson Education Limited.
- Kanda, M., Inagaki, A., Letzel, M.O., Raasch, S., Watanabe, T., 2004. LES Study of the Energy Imbalance Problem with Eddy Covariance Fluxes. *Boundary-Layer Meteorol.* 110, 381–404. <https://doi.org/10.1023/B:BOUN.0000007225.45548.7a>
- Ke, Y., Im, J., Park, S., Gong, H., 2016. Downscaling of MODIS One Kilometer Evapotranspiration Using Landsat-8 Data and Machine Learning Approaches.

- Remote Sens. 8, 215. <https://doi.org/10.3390/rs8030215>
- Kennedy, R., Yang, Z., Gorelick, N., Braaten, J., Cavalcante, L., Cohen, W., Healey, S., 2018. Implementation of the LandTrendr Algorithm on Google Earth Engine. Remote Sens. 10, 691. <https://doi.org/10.3390/rs10050691>
- Khand, K., Numata, I., Kjaersgaard, J., Vourlitis, G., 2017. Dry Season Evapotranspiration Dynamics over Human-Impacted Landscapes in the Southern Amazon Using the Landsat-Based METRIC Model. Remote Sens. 9, 706. <https://doi.org/10.3390/rs9070706>
- Kiptala, J.K., Mohamed, Y., Mul, M.L., der Zaag, P., 2013. Mapping evapotranspiration trends using MODIS and SEBAL model in a data scarce and heterogeneous landscape in Eastern Africa. Water Resour. Res. 49, 8495–8510. <https://doi.org/10.1002/2013WR014240>
- Laipelt, L., Ruhoff, L.A., Fleischmann, S.A., Kayser, H.R., Kich, D.E., da Rocha, R.H., Neale, M.C., 2020. Assessment of an Automated Calibration of the SEBAL Algorithm to Estimate Dry-Season Surface-Energy Partitioning in a Forest–Savanna Transition in Brazil. Remote Sens. . <https://doi.org/10.3390/rs12071108>
- Lathuillière, M.J., Dalmagro, H.J., Black, T.A., Arruda, P.H.Z. de, Hawthorne, I., Couto, E.G., Johnson, M.S., 2018. Rain-fed and irrigated cropland-atmosphere water fluxes and their implications for agricultural production in Southern Amazonia. Agric. For. Meteorol. 256–257, 407–419. <https://doi.org/10.1016/j.agrformet.2018.03.023>
- Lee, Y., Kim, S., 2016. The Modified SEBAL for Mapping Daily Spatial Evapotranspiration of South Korea Using Three Flux Towers and Terra MODIS Data. Remote Sens. 8, 983. <https://doi.org/10.3390/rs8120983>
- Long, D., Singh, V.P., 2012. A modified surface energy balance algorithm for land (M-SEBAL) based on a trapezoidal framework. Water Resour. Res. 48. <https://doi.org/10.1029/2011WR010607>
- Long, D., Singh, V.P., Li, Z.-L., 2011. How sensitive is SEBAL to changes in input variables, domain size and satellite sensor? J. Geophys. Res. Atmos. 116. <https://doi.org/10.1029/2011JD016542>
- Martens, B., Miralles, D., Hans, L., van der Schalie, R., A. M. de Jeu, R., Fernández-Prieto, D., Beck, H., A. Dorigo, W., Verhoest, N., 2016. GLEAM v3: satellite-based

- land evaporation and root-zone soil moisture. *Geosci. Model Dev. Discuss.* 1–36.
<https://doi.org/10.5194/gmd-2016-162>
- Michel, D., Jiménez, C., Miralles, D.G., Jung, M., Hirschi, M., Ershadi, A., Martens, B., McCabe, M.F., Fisher, J.B., Mu, Q., Seneviratne, S.I., Wood, E.F., Fernández-Prieto, D., 2016. The WACMOS-ET project - Part 1: Tower-scale evaluation of four remote-sensing-based evapotranspiration algorithms. *Hydrol. Earth Syst. Sci.* 20, 803–822. <https://doi.org/10.5194/hess-20-803-2016>
- Midekisa, A., Holl, F., Savory, D.J., Andrade-Pacheco, R., Gething, P.W., Bennett, A., Sturrock, H.J.W., 2017. Mapping land cover change over continental Africa using Landsat and Google Earth Engine cloud computing. *PLoS One* 12, e0184926. <https://doi.org/10.1371/journal.pone.0184926>
- Miralles, D.G., Jiménez, C., Jung, M., Michel, D., Ershadi, A., McCabe, M.F., Hirschi, M., Martens, B., Dolman, A.J., Fisher, J.B., Mu, Q., Seneviratne, S.I., Wood, E.F., Fernández-Prieto, D., 2016. The WACMOS-ET project - Part 2: Evaluation of global terrestrial evaporation data sets. *Hydrol. Earth Syst. Sci.* 20, 823–842. <https://doi.org/10.5194/hess-20-823-2016>
- Monteith, J.L., 1965. Evaporation and environment. *Symp. Soc. Exp. Biol.* 205–234.
- Moreira, A.A., Ruhoff, A.L., Roberti, D.R., Souza, V. de A., da Rocha, H.R., Paiva, R.C.D. de, 2019. Assessment of terrestrial water balance using remote sensing data in South America. *J. Hydrol.* 575, 131–147. <https://doi.org/https://doi.org/10.1016/j.jhydrol.2019.05.021>
- Mu, Q., Zhao, M., Running, S.W., 2011. Improvements to a MODIS global terrestrial evapotranspiration algorithm. *Remote Sens. Environ.* 115, 1781–1800. <https://doi.org/https://doi.org/10.1016/j.rse.2011.02.019>
- Nguyen, U.N.T., Pham, L.T.H., Dang, T.D., 2019. An automatic water detection approach using Landsat 8 OLI and Google Earth Engine cloud computing to map lakes and reservoirs in New Zealand. *Environ. Monit. Assess.* 191, 235. <https://doi.org/10.1007/s10661-019-7355-x>
- Nóbrega, R.L.B., Guzha, A.C., Torres, G.N., Kovacs, K., Lamparter, G., Amorim, R.S.S., Couto, E., Gerold, G., 2017. Effects of conversion of native cerrado vegetation to pasture on soil hydro-physical properties, evapotranspiration and streamflow on the

- Amazonian agricultural frontier. *PLoS One* 12, 1–22. <https://doi.org/10.1371/journal.pone.0179414>
- Noojipady, P., Morton, C.D., Macedo, N.M., Victoria, C.D., Huang, C., Gibbs, K.H., Bolfe, L.E., 2017. Forest carbon emissions from cropland expansion in the Brazilian Cerrado biome. *Environ. Res. Lett.* 12, 25004. <https://doi.org/10.1088/1748-9326/aa5986>
- Norman, J.M., Kustas, W.P., Humes, K.S., 1995. Source approach for estimating soil and vegetation energy fluxes in observations of directional radiometric surface temperature. *Agric. For. Meteorol.* 77, 263–293. [https://doi.org/10.1016/0168-1923\(95\)02265-Y](https://doi.org/10.1016/0168-1923(95)02265-Y)
- Numata, I., Khand, K., Kjaersgaard, J., Cochrane, M.A., Silva, S.S., 2017. Evaluation of Landsat-Based METRIC Modeling to Provide High-Spatial Resolution Evapotranspiration Estimates for Amazonian Forests. *Remote Sens.* 9. <https://doi.org/10.3390/rs9010046>
- Oliveira, G., Brunzell, N.A., Moraes, E.C., Shimabukuro, Y.E., Santos, T. V., Randow, C., Aguiar, R.G., Aragao, L.E.O.C., 2019. Effects of land-cover changes on the partitioning of surface energy and water fluxes in Amazonia using high-resolution satellite imagery. *Ecohydrology* 12, e2126. <https://doi.org/10.1002/eco.2126>
- Oliveira, M., Von Randow, C., Manzi, A., Alvalá, R., Sá, L., Leitão, M., Souza, A., 2006. Fluxos Turbulentos de Energia sobre o Pantanal Sul Mato-Grossense. *Rev. Bras. Meteorol.* 21, 159–165.
- Oliveira, P.T.S., Nearing, M.A., Moran, M.S., Goodrich, D.C., Wendland, E., Gupta, H. V., 2014. Trends in water balance components across the Brazilian Cerrado. *Water Resour. Res.* 50, 7100–7114. <https://doi.org/10.1002/2013WR015202>
- Paca, V.H. da M., Espinoza-Dávalos, G.E., Hessels, T.M., Moreira, D.M., Comair, G.F., Bastiaanssen, W.G.M., 2019. The spatial variability of actual evapotranspiration across the Amazon River Basin based on remote sensing products validated with flux towers. *Ecol. Process.* 8, 6. <https://doi.org/10.1186/s13717-019-0158-8>
- Parente, L., Taquary, E., Silva, A.P., Souza, C., Ferreira, L., 2019. Next Generation Mapping: Combining Deep Learning, Cloud Computing, and Big Remote Sensing

- Data. *Remote Sens.* 11, 2881. <https://doi.org/10.3390/rs11232881>
- Paul, G., Gowda, P.H., Vara Prasad, P. V, Howell, T.A., Staggenborg, S.A., Neale, C.M.U., 2013. Lysimetric evaluation of SEBAL using high resolution airborne imagery from BEAREX08. *Adv. Water Resour.* 59, 157–168. <https://doi.org/https://doi.org/10.1016/j.advwatres.2013.06.003>
- Pekel, J.-F., Cottam, A., Gorelick, N., Belward, A.S., 2016. High-resolution mapping of global surface water and its long-term changes. *Nature* 540, 418–422. <https://doi.org/10.1038/nature20584>
- Penman, H.L., 1948. Natural evaporation from open water, bare soil and grass. *Proc. R. Soc. London. Ser. A. Math. Phys. Sci.* 193, 120–145. <https://doi.org/10.1098/rspa.1948.0037>
- Pongratz, J., Bounoua, L., Defries, R.S., Morton, D.C., Anderson, L.O., Mauser, W., Klink, C.A., 2006. The impact of land cover change on surface energy and water balance in Mato Grosso, Brazil. *Earth Interact.* 10, 1–17. <https://doi.org/10.1175/EI176.1>
- Restrepo-Coupe, N., Rocha, H., Hutyra, L., de Araújo, A., Borma, L., Christoffersen, B., Cabral, O., Camargo, P., L. Cardoso, F., da Costa, A., Fitzjarrald, D., L. Goulden, M., Kruijt, B., Maia, J., Malhi, Y., Manzi, A., D. Miller, S., Nobre, A., Von Randow, C., Saleska, S., 2013. What drives the seasonality of photosynthesis across the Amazon basin? A cross-site analysis of eddy flux tower measurements from the Brasil flux network. *Agric. For. Meteorol.* 182–183, 128–144. <https://doi.org/10.1016/j.agrformet.2013.04.031>
- Rocha, H.R. da, Freitas, H.C., Rosolem, R., Juárez, R.I.N., Tannus, R.N., Ligo, M.A., Cabral, O.M.R., Dias, M.A.F.S., 2002. Measurements of CO₂ exchange over a woodland savanna (Cerrado Sensu stricto) in southeast Brasil. *Biota Neotrop.* 2, 1–11. <https://doi.org/10.1590/S1676-06032002000100009>
- Rodell, M., Houser, P.R., Jambor, U., Gottschalck, J., Mitchell, K., Meng, C.-J., Arsenault, K., Cosgrove, B., Radakovich, J., Bosilovich, M., Entin, J.K., Walker, J.P., Lohmann, D., Toll, D., 2004. The Global Land Data Assimilation System. *Bull. Am. Meteorol. Soc.* 85, 381–394. <https://doi.org/10.1175/BAMS-85-3-381>
- Rubert, G., Roberti, D., Pereira, L., Quadros, F., Campos Velho, H., Leal de Moraes, O.,

2018. Evapotranspiration of the Brazilian Pampa Biome: Seasonality and Influential Factors. *Water* 10, 1864. <https://doi.org/10.3390/w10121864>
- Ruhoff, A., Paz, A., Collischonn, W., Aragão, L., Rocha, H., S. Malhi, Y., 2012. A MODIS-Based Energy Balance to Estimate Evapotranspiration for Clear-Sky Days in Brazilian Tropical Savannas, *Remote Sensing*, vol. 4, issue 3, pp. 703-725. <https://doi.org/10.3390/rs4030703>
- Rui, H.L., Beaudoin, H., 2015. README Document for NASA GLDAS Version 2 Data Products [WWW Document]. Goddard Earth Sci. Data Inf. Serv. Cent. (GES DISC). URL https://hydro1.gesdisc.eosdis.nasa.gov/data/GLDAS/README_GLDAS2.pdf (accessed 8.19.20).
- Santos, A.J.B., Silva, G.T.D.A., Miranda, H.S., Miranda, A.C., Lloyd, J., 2003. Effects of fire on surface carbon, energy and water vapour fluxes over campo sujo savanna in central Brazil. *Funct. Ecol.* 17, 711–719. <https://doi.org/10.1111/j.1365-2435.2003.00790.x>
- Saraiva, M., Protas, É., Salgado, M., Souza, C., 2020. Automatic Mapping of Center Pivot Irrigation Systems from Satellite Images Using Deep Learning. *Remote Sens.* 12, 558. <https://doi.org/10.3390/rs12030558>
- Senay, G.B., Bohms, S., Singh, R.K., Gowda, P.H., Velpuri, N.M., Alemu, H., Verdin, J.P., 2013. Operational Evapotranspiration Mapping Using Remote Sensing and Weather Datasets: A New Parameterization for the SSEB Approach. *JAWRA J. Am. Water Resour. Assoc.* 49, 577–591. <https://doi.org/10.1111/jawr.12057>
- Shuttleworth, W.J., 2012. *Terrestrial Hydrometeorology*, 1^o. ed. John Wiley & Sons, Ltd, Chichester, UK. <https://doi.org/10.1002/9781119951933>
- Silva, A.M., da Silva, R.M., Santos, C.A.G., 2019. Automated surface energy balance algorithm for land (ASEBAL) based on automating endmember pixel selection for evapotranspiration calculation in MODIS orbital images. *Int. J. Appl. Earth Obs. Geoinf.* 79, 1–11. <https://doi.org/10.1016/j.jag.2019.02.012>
- Singh, R.K., Irmak, A., Irmak, S., Martin, D.L., 2008. Application of SEBAL Model for Mapping Evapotranspiration and Estimating Surface Energy Fluxes in South-Central Nebraska. *J. Irrig. Drain. Eng.* 134, 273–285.

[https://doi.org/10.1061/\(ASCE\)0733-9437\(2008\)134:3\(273\)](https://doi.org/10.1061/(ASCE)0733-9437(2008)134:3(273))

- Souza, V. de A., Roberti, D.R., Ruhoff, A.L., Zimmer, T., Adamatti, D.S., Gonçalves, L.G.G. de, Diaz, M.B., Alves, R. de C.M., Moraes, O.L.L. de, 2019. Evaluation of MOD16 Algorithm over Irrigated Rice Paddy Using Flux Tower Measurements in Southern Brazil. *Water* 11, 1911. <https://doi.org/10.3390/w11091911>
- Spera, S.A., Galford, G.L., Coe, M.T., Macedo, M.N., Mustard, J.F., 2016. Land-use change affects water recycling in Brazil's last agricultural frontier. *Glob. Chang. Biol.* 22, 3405–3413. <https://doi.org/10.1111/gcb.13298>
- Spracklen, D. V, Arnold, S.R., Taylor, C.M., 2012. Observations of increased tropical rainfall preceded by air passage over forests. *Nature* 489, 282–285. <https://doi.org/10.1038/nature11390>
- Sun, Z., Wei, B., Su, W., Shen, W., Wang, C., You, D., Liu, Z., 2011. Evapotranspiration estimation based on the SEBAL model in the Nansi Lake Wetland of China. *Math. Comput. Model.* 54, 1086–1092. <https://doi.org/10.1016/J.MCM.2010.11.039>
- Tang, Q., Oki, T., Kanae, S., Hu, H., 2007. The Influence of Precipitation Variability and Partial Irrigation within Grid Cells on a Hydrological Simulation. *J. Hydrometeorol.* 8, 499–512. <https://doi.org/10.1175/JHM589.1>
- Tang, R., Li, Z.-L., Chen, K.-S., Jia, Y., Li, C., Sun, X., 2013. Spatial-scale effect on the SEBAL model for evapotranspiration estimation using remote sensing data. *Agric. For. Meteorol.* 174–175, 28–42. <https://doi.org/https://doi.org/10.1016/j.agrformet.2013.01.008>
- Tasumi, M., Allen, R.G., Trezza, R., 2008. At-Surface Reflectance and Albedo from Satellite for Operational Calculation of Land Surface Energy Balance. *J. Hydrol. Eng.* 13, 51–63. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2008\)13:2\(51\)](https://doi.org/10.1061/(ASCE)1084-0699(2008)13:2(51))
- Teixeira, A.H. de C., Bastiaanssen, W.G.M., Ahmad, M.D., Bos, M.G., 2009. Reviewing SEBAL input parameters for assessing evapotranspiration and water productivity for the Low-Middle São Francisco River basin, Brazil: Part A: Calibration and validation. *Agric. For. Meteorol.* 149, 462–476. <https://doi.org/https://doi.org/10.1016/j.agrformet.2008.09.016>
- Thornthwaite, C.W., Wilm, H.G., 1944. An approach towards a rational classification of climate. Washington, DC.

- Traganos, D., Poursanidis, D., Aggarwal, B., Chrysoulakis, N., Reinartz, P., 2018. Estimating Satellite-Derived Bathymetry (SDB) with the Google Earth Engine and Sentinel-2. *Remote Sens.* . <https://doi.org/10.3390/rs10060859>
- Twine, T.E., Kustas, W.P., Norman, J.M., Cook, D.R., Houser, P.R., Meyers, T.P., Prueger, J.H., Starks, P.J., Wesely, M.L., 2000. Correcting eddy-covariance flux underestimates over a grassland. *Agric. For. Meteorol.* 103, 279–300. [https://doi.org/10.1016/S0168-1923\(00\)00123-4](https://doi.org/10.1016/S0168-1923(00)00123-4)
- Ukkola, A.M., Prentice, I.C., Keenan, T.F., van Dijk, A.I.J.M., Viney, N.R., Myneni, R.B., Bi, J., 2016. Reduced streamflow in water-stressed climates consistent with CO₂ effects on vegetation. *Nat. Clim. Chang.* 6, 75–78. <https://doi.org/10.1038/nclimate2831>
- von Randow, C., Manzi, A.O., Kruijt, B., de Oliveira, P.J., Zanchi, F.B., Silva, R.L., Hodnett, M.G., Gash, J.H.C., Elbers, J.A., Waterloo, M.J., Cardoso, F.L., Kabat, P., 2004. Comparative measurements and seasonal variations in energy and carbon exchange over forest and pasture in South West Amazonia. *Theor. Appl. Climatol.* 78. <https://doi.org/10.1007/s00704-004-0041-z>
- Vörösmarty, C.J., McIntyre, P.B., Gessner, M.O., Dudgeon, D., Prusevich, A., Green, P., Glidden, S., Bunn, S.E., Sullivan, C.A., Liermann, C.R., Davies, P.M., 2010. Global threats to human water security and river biodiversity. *Nature* 467, 555–561. <https://doi.org/10.1038/nature09440>
- Vos, K., Splinter, K.D., Harley, M.D., Simmons, J.A., Turner, I.L., 2019. CoastSat: A Google Earth Engine-enabled Python toolkit to extract shorelines from publicly available satellite imagery. *Environ. Model. Softw.* 122, 104528. <https://doi.org/10.1016/j.envsoft.2019.104528>
- Wagener, T., Sivapalan, M., Troch, P.A., McGlynn, B.L., Harman, C.J., Gupta, H. V., Kumar, P., Rao, P.S.C., Basu, N.B., Wilson, J.S., 2010. The future of hydrology: An evolving science for a changing world. *Water Resour. Res.* 46. <https://doi.org/10.1029/2009WR008906>
- Wang, Y., Ma, J., Xiao, X., Wang, X., Dai, S., Zhao, B., 2019. Long-Term Dynamic of Poyang Lake Surface Water: A Mapping Work Based on the Google Earth Engine Cloud Platform. *Remote Sens.* 11, 313. <https://doi.org/10.3390/rs11030313>

- Wilson, K., Goldstein, A., Falge, E., Aubinet, M., Baldocchi, D., Berbigier, P., Bernhofer, C., Ceulemans, R., Dolman, H., Field, C., Grelle, A., Ibrom, A., Law, B., Kowalski, A., Meyers, T., Moncrieff, J., Monson, R., Oechel, W., Tenhunen, J., Valentini, R., Verma, S., 2002. Energy balance closure at FLUXNET sites. *Agric. For. Meteorol.* 113, 223–243. [https://doi.org/10.1016/S0168-1923\(02\)00109-0](https://doi.org/10.1016/S0168-1923(02)00109-0)
- Wu, J., Lakshmi, V., Wang, D., Lin, P., Pan, M., Cai, X., Wood, E.F., Zeng, Z., 2020. The Reliability of Global Remote Sensing Evapotranspiration Products over Amazon. *Remote Sens.* . <https://doi.org/10.3390/rs12142211>
- Yang, Y., Shang, S., Jiang, L., 2012. Remote sensing temporal and spatial patterns of evapotranspiration and the responses to water management in a large irrigation district of North China. *Agric. For. Meteorol.* 164, 112–122. <https://doi.org/https://doi.org/10.1016/j.agrformet.2012.05.011>
- Zhang, C., Di, L., Yang, Z., Lin, L., Hao, P., 2020. AgKit4EE: A toolkit for agricultural land use modeling of the conterminous United States based on Google Earth Engine. *Environ. Model. Softw.* 129, 104694. <https://doi.org/https://doi.org/10.1016/j.envsoft.2020.104694>
- Zhang, K., Ma, J., Zhu, G., Ma, T., Han, T., Feng, L.L., 2017. Parameter sensitivity analysis and optimization for a satellite-based evapotranspiration model across multiple sites using Moderate Resolution Imaging Spectroradiometer and flux data. *J. Geophys. Res. Atmos.* 122, 230–245. <https://doi.org/10.1002/2016JD025768>
- Zhang, X., Wu, J., Wu, H., Li, Y., 2011. Simplified SEBAL method for estimating vast areal evapotranspiration with MODIS data. *Water Sci. Eng.* 4, 24–35. <https://doi.org/https://doi.org/10.3882/j.issn.1674-2370.2011.01.003>
- Zhou, Y., Dong, J., Xiao, X., Liu, R., Zou, Z., Zhao, G., Ge, Q., 2019. Continuous monitoring of lake dynamics on the Mongolian Plateau using all available Landsat imagery and Google Earth Engine. *Sci. Total Environ.* 689, 366–380. <https://doi.org/https://doi.org/10.1016/j.scitotenv.2019.06.341>