

UNIVERSIDADE DE SÃO PAULO

Escola de Engenharia de São Carlos

Estimativa da evapotranspiração em
uma área remanescente de Cerrado
sensu stricto utilizando metodologias
de Sensoriamento Remoto e Eddy
Covariance

Alessandra Campos dos Santos

Orientador: Prof. Dr. Edson Cezar Wendland

ALESSANDRA CAMPOS DOS SANTOS

Estimativa da evapotranspiração em uma área remanescente de Cerrado *sensu stricto* utilizando metodologias de Sensoriamento Remoto e *Eddy Covariance*

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Hidráulica e Saneamento da Escola de Engenharia de São Carlos, da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Doutor em Ciências: Engenharia Hidráulica e Saneamento.

Orientador: Prof. Dr. Edson Cezar Wendland

VERSÃO CORRIGIDA

São Carlos

2023

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes da EESC/USP com os dados inseridos pelo(a) autor(a).

C198e Campos dos Santos, Alessandra
Estimativa da evapotranspiração em uma área remanescente de Cerrado sensu stricto utilizando metodologias de Sensoriamento Remoto e Eddy Covariance / Alessandra Campos dos Santos; orientador Edson Cezar Wendland. São Carlos, 2023.

Tese (Doutorado) - Programa de Pós-Graduação em Engenharia Hidráulica e Saneamento e Área de Concentração em Hidráulica e Saneamento -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2023.

1. Evapotranspiração. 2. Cerrado. 3. Eddy Covariance. 4. TSEB. I. Título.

FOLHA DE JULGAMENTO

Candidata: Engenheira **ALESSANDRA CAMPOS DOS SANTOS**.

Título da tese: "Estimativa da evapotranspiração em uma área remanescente de Cerrado sensu stricto utilizando metodologias de Sensoriamento Remoto e Eddy Covariance".

Data da defesa: 15/09/2023.

Comissão Julgadora

Resultado

Prof. Titular Edson Cezar Wendland
(Orientador)
(Escola de Engenharia de São Carlos/EESC-USP)

APROVADA

Prof. Dr. Davi de Carvalho Diniz Melo
(Universidade Federal da Paraíba/UFPB)

REPROVADA

Profa. Dra. Kelly Cristina Tonello
(Universidade Federal de São Carlos/UFSCar)

APROVADA

Prof. Dr. Murilo Cesar Lucas
(Universidade Estadual de Campinas/UNICAMP)

APROVADA

Dra. Vanessa de Arruda Souza
(Universidade Federal de Santa Maria/UFSM)

REPROVADA

Coordenador do Programa de Pós-Graduação em Engenharia Hidráulica e Saneamento:
Prof. Assoc. **Juliano Jose Corbi**

Presidente da Comissão de Pós-Graduação:
Prof. Titular **Carlos De Marqui Junior**

AGRADECIMENTOS

Gostaria de expressar minha gratidão, primeiramente a mim mesma, pela persistência, força e resiliência nos vários momentos que pensei em desistir. A possibilidade de concluir esta Tese de Doutorado foi a vitória mais desafiadora na minha jornada pessoal e profissional.

Agradeço à minha família, que tanto sentiram a minha falta nesses mais de 400 km de distância, mas que nunca deixaram de me apoiar, de me ajudar e de acreditar em mim. À minha mãe Soneide, ao meu pai Milton, e à minha irmã Camila.

Aos meus avós paternos, Onita e Milton (*in memoriam*), os quais passei boa parte da minha infância e adolescência, e que certamente contribuíram para que eu chegasse até aqui.

Ao meu primo Alexandre (*in memoriam*), que foi como um irmão mais velho. Foi por meio dele que eu ouvi falar pela primeira vez em pesquisa, mestrado e doutorado. No meu 2º ano de faculdade ele me perguntou: “*Quando você vai começar uma Iniciação Científica? Nas férias eu vou te ajudar a escrever um projeto sobre o Bosque de Araguari*”. Pena que esse depois nunca chegou. Mas seu exemplo permanece em mim até hoje.

Ao meu orientador, Prof. Dr. Edson Cezar Wendland, por ter me recebido no LHC, e pelo suporte no desenvolvimento do projeto.

Ao técnico do LHC, Roberto Bergamo, por toda a ajuda nos campos do IAB, sempre muito prestativo e companheiro com todos os membros do laboratório.

As secretárias do SHS, Maria Auxiliadora (Sá), Rosemeire (Rose) e Priscila, sempre dispostas a ajudar.

À Livia, ao Jamil e ao Alex Kobayashi, que me receberam tão bem na minha chegada ao LHC, me acolheram e me apresentaram ao IAB e ao *Eddy Covariance*.

Aos colegas da USP, LHC e WadiLab: Alan, Rubens, Érick, Hélio, Dimaghi, André Ballarin, Jullian, Luis Bertotto, Yuri, Pedro, Marcus, Kalyl, Jean, Felipe Augusto, Tassiana, Thalita, Lizeth, Marina Bitar, Mariana, Hailton César, Gabriela, Camila,

Natália, Luciana, e tantos outros, que tornaram a caminhada da pós-graduação um pouco mais leve.

As amigas da “Vila do Chaves”, Denici e Raquel, pelas conversas, desabafos, encontros e amizade.

À Patricia Leme (Pazu), educadora da EESC em 2018, que ministrou uma palestra no meu primeiro semestre em São Carlos, que foi muito importante para a minha trajetória.

Ao Marcelo Miky, técnico do Laboratório de Recursos Hídricos em 2019, que mesmo sem saber, me deu suporte quando eu precisei.

Ao Gabriel Mini e ao Daniel Mário, pela ajuda na parte de programação, códigos e Python. Vocês foram fundamentais!

Ao meu psicólogo, Eduardo, que foi essencial na minha vida nesses últimos 5 anos. Me ajudou a passar por momentos difíceis, sempre buscando minha evolução.

As minhas amigas do SESI de Santa Rita do Passa Quatro, Amanda, Camila e Juliana, pelo incentivo, conversas e companheirismo.

Aos meus vizinhos, Marcelo e Alison, que fizeram meus dias na “Vila do Chaves” mais felizes e engraçados. Além dos deliciosos almoços e jantares!

Ao meu namorado Vitor, meu maior e melhor incentivador! Obrigada por sempre estar ao meu lado em todos os momentos e a nunca me deixar desistir!

Aos meus três amores felinos, Julie, Jack e Sushi, meus eternos companheirinhos!

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Processo nº 1801696 e nº 88882.328917/2019-01. Também contou com recursos financeiros da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) - Processo nº 2015/03806-1.

E a todos que passaram pela minha vida ao longo desses últimos 5 anos e me ajudaram de alguma forma, meu muito obrigada! Ninguém faz nada sozinho!

*“Medicine, Law, Business, Engineering
These are noble pursuits, and necessary to sustain life
But poetry, beauty, romance, love
These are what we stay alive for”*

Dead Poets Society, 1989

RESUMO

SANTOS, A. C. **Estimativa da evapotranspiração em uma área remanescente de Cerrado *sensu stricto* utilizando metodologias de Sensoriamento Remoto e *Eddy Covariance***. Tese (Doutorado). Escola de Engenharia de São Carlos, Universidade de São Paulo, 2023.

A evapotranspiração rege a regulação e a troca de água entre a superfície terrestre e a atmosfera de áreas florestais. O seu monitoramento é fundamental para compreender o papel no ciclo da água. Porém, há incertezas na sua determinação, e ainda são escassos os estudos realizados em áreas com vegetação heterogênea, como o Cerrado brasileiro. O objetivo principal desse estudo é estimar valores diários de evapotranspiração em uma área remanescente de Cerrado *sensu stricto* localizada no município de Itirapina/SP, Brasil. Para isso, foi utilizado dados de evapotranspiração medidos pelo método *Eddy Covariance* (EC) e, também, estimativas feitas pelo modelo *Two Source Energy Balance - Dual Time Difference* (TSEB-DTD), baseado em dados de sensoriamento remoto. Foi analisado o período entre 2019 e 2020, e os principais resultados estimados pelo modelo TSEB-DTD apontaram uma superestimação quando comparados com os valores observados pelo método EC. O viés médio foi de 4,5 mm dia⁻¹, o RMSE médio foi de 5,5 mm dia⁻¹, o CV dos dados estimados pelo TSEB-DTD foi de 47%, o CV do método EC foi de 26% e o valor médio do ρ foi de aproximadamente 0,6 para a área analisada. A ET média modelada (8,3 mm dia⁻¹) foi cerca de 2,8 vezes maior que a observada (3,1 mm dia⁻¹). Os resultados alcançados reforçam a necessidade da continuidade de pesquisas que possam aprimorar e testar as metodologias disponíveis que avaliam a evapotranspiração do Cerrado. Portanto, o uso de mais de uma técnica para estimar variáveis hidrológicas é indicado, em especial, para regiões com vegetação heterogênea. Vale ressaltar a importância da continuidade no monitoramento, a fim de se obter uma série contínua de dados de evapotranspiração.

Palavras-chave: Evapotranspiração. Eddy Covariance. Cerrado. TSEB. DTD.

ABSTRACT

SANTOS, A. C. **Estimation of evapotranspiration in a remaining area of Cerrado sensu stricto using Remote Sensing and Eddy Covariance methodologies.** Tese (Doutorado). Escola de Engenharia de São Carlos, Universidade de São Paulo, 2023.

Evapotranspiration governs the regulation and exchange of water between the Earth's surface and the atmosphere in forested areas. Monitoring it is crucial to understanding its role in the water cycle. However, uncertainties exist in its determination, and studies in areas with heterogeneous vegetation, such as the Brazilian Cerrado, are still limited. The main objective of this study is to estimate daily evapotranspiration values in a remnant area of Cerrado sensu stricto located in Itirapina/SP, Brazil. To achieve this, evapotranspiration data measured by the Eddy Covariance (EC) method and estimates from the Two Source Energy Balance - Dual Time Difference (TSEB-DTD) model, based on remote sensing data, were used. The period between 2019 and 2020 was analyzed, and the main results estimated by the TSEB-DTD model indicated an overestimation when compared to values observed by the EC method. The mean bias was 4.5 mm day^{-1} , the mean RMSE was 5.5 mm day^{-1} , the coefficient of variation (CV) for TSEB-DTD estimated data was 47%, the EC method's CV was 26%, and the mean ρ value was approximately 0.6 for the analyzed area. The modeled average ET (8.3 mm day^{-1}) was about 2.8 times higher than the observed (3.1 mm day^{-1}). The results emphasize the need for continued research to improve and test available methodologies for Cerrado evapotranspiration assessment. Therefore, the use of more than one technique to estimate hydrological variables is recommended, especially in regions with heterogeneous vegetation. It is crucial to highlight the importance of ongoing monitoring to obtain a continuous series of evapotranspiration data.

Keywords: Evapotranspiration. Eddy Covariance. Brazilian savannah (Cerrado). TSEB. DTD.

LISTA DE ILUSTRAÇÕES

Figura 1. Fitofisionomias do Bioma Cerrado.....	27
Figura 2. Tipos de analisadores de gases.	31
Figura 3. Tipos de arranjo dos transdutores dos anemômetros sônicos.....	31
Figura 4. Rede de resistências em série do modelo DTD.....	36
Figura 5. Uso de imagens de satélites em órbita polar (Terra e Aqua) pelo DTD.....	38
Figura 6. Localização da área de estudo.....	39
Figura 7. Torre de monitoramento (a) e vista aérea da área de Cerrado <i>sensu stricto</i> (b).....	41
Figura 8. Analisador de gases (H ₂ O e CO ₂) de caminho aberto e anemômetro sônico 3D integrados (IRGASON® <i>Campbell Scientific</i>).....	41
Figura 9. Localização da torre no Cerrado e distância de abrangência dos sensores.....	42
Figura 10. Série de evapotranspiração medida pelo método <i>Eddy Covariance</i> (ET _{RFR}) e predita pelo modelo TSEB-DTD (ET _{pred}).....	73
Figura 11. Viés estatístico aplicado nos dados estimados e observados.....	77
Figura 12. RMSE aplicado nos dados estimados e observados.....	78
Figura 13. Coeficiente de correlação de Pearson (ρ) aplicado nos dados estimados e observados.....	80

LISTA DE TABELAS

Tabela 1. Detalhamento das variáveis monitoradas e instrumentação utilizada.....	43
Tabela 2. Características do sensor MODIS dos satélites Aqua e Terra.....	44
Tabela 3. Detalhes dos produtos MODIS utilizados na pesquisa.....	44
Tabela 4. Métricas estatísticas aplicadas nos resultados gerados pelo modelo TSEB-DTD (ET_{pred}) em comparação com os dados de referência (ET_{RFR}).....	74

SUMÁRIO

1. INTRODUÇÃO	21
2. OBJETIVOS	23
2.2 OBJETIVO GERAL	23
2.3 OBJETIVOS ESPECÍFICOS	23
3. REVISÃO BIBLIOGRÁFICA	24
3.1 CERRADO	24
3.2 EVAPOTRANSPIRAÇÃO	28
3.3 FLUXOS TURBULENTOS E MEDIÇÕES COM O MÉTODO <i>EDDY COVARIANCE</i>	29
3.4 USO DE IMAGENS DE SENSORIAMENTO REMOTO PARA ESTIMAR EVAPOTRANSPIRAÇÃO	33
3.5 MODELO TWO SOURCE ENERGY BALANCE (TSEB)	35
3.6 MODELO DUAL TEMPERATURE DIFFERENCE (DTD)	36
4. METODOLOGIA	39
4.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO	39
4.2 INSTRUMENTAÇÃO DA ÁREA DE ESTUDO	40
4.3 ESTIMATIVA DA EVAPOTRANSPIRAÇÃO UTILIZANDO TÉCNICAS DE SENSORIAMENTO REMOTO	43
4.3.1 <i>Dados MODIS (Moderate Resolution Imaging Spectroradiometer)</i>	43
4.3.2 <i>Aplicação do modelo Two Source Energy Balance (TSEB)</i>	45
4.3.3 <i>Aplicação do modelo Dual Temperature Difference (DTD)</i>	56
4.3.4 <i>Extrapolação dos fluxos instantâneos para diários</i>	59
4.4 DETERMINAÇÃO DA EVAPOTRANSPIRAÇÃO UTILIZANDO O MÉTODO <i>EDDY COVARIANCE (EC)</i>	60
4.4.1 <i>Pré-processamento dos dados</i>	61
4.4.2 <i>Processamento dos dados</i>	61
4.4.3 <i>Controle de qualidade</i>	63
4.4.4 <i>Determinação da área de contribuição ou footprint</i>	64
4.4.5 <i>Preenchimento de falhas</i>	64
4.5 ANÁLISES ESTATÍSTICAS DOS RESULTADOS	64
4.6 PERÍODO DE DADOS ESTIMADOS PELO TSEB-DTD	67
5. RESULTADOS E DISCUSSÃO	68
5.1 MANUAL DO USUÁRIO DO PYTSEB	68
5.2 SÉRIE DE ET ESTIMADA E OBSERVADA	68
5.3 AVALIAÇÃO DA METODOLOGIA TSEB-DTD	73
5.3.1 <i>Viés</i>	75
5.3.2 <i>Raiz do Erro Quadrático Médio (RMSE)</i>	76
5.3.3 <i>Coefficiente de variação (CV)</i>	77
5.3.4 <i>Coefficiente de correlação de Pearson (ρ)</i>	78
5.4 OBSERVAÇÕES E LIMITAÇÕES	79
6. CONCLUSÃO	81
6.1 RECOMENDAÇÕES E TRABALHOS FUTUROS	83
REFERÊNCIAS	84
APÊNDICE A – DOCUMENTAÇÃO DO ALGORITMO CUSTOMIZADO DO PYTSEB-DTD USANDO IMAGENS MODIS E DADOS DO EDDY COVARIANCE	94
ANEXO I – CÓDIGO PYTSEB	121
ANEXO II – RESULTADOS DA EVAPOTRANSPIRAÇÃO MEDIDA PELO SISTEMA <i>EDDY COVARIANCE</i>	122

1. INTRODUÇÃO

A evapotranspiração (ET) consiste em um dos principais processos de movimentação e troca de água em um ecossistema. Grande parte da precipitação que cai na superfície terrestre volta para a atmosfera através da evapotranspiração (Sun et al., 2016; Cristiano et al., 2015; Oki; Kanae, 2006; Allen et al., 1998). Em áreas de florestas, como o Cerrado *sensu stricto*, a cobertura vegetal influencia a quantidade de umidade no ar, fazendo com que os valores de evapotranspiração representem mais de 60% da precipitação (Oliveira et al., 2015).

A ET é um dos componentes que geram mais incertezas no fechamento do balanço hídrico. Em áreas de Cerrado *sensu stricto*, ainda são necessários valores de referência desta variável (Anache et al., 2019; da Paz et al., 2014). Além disso, poucos estudos brasileiros monitoraram sazonalmente a ET no Cerrado utilizando metodologias diretas de medição. Um exemplo foi Cabral et al. (2015), que avaliaram esse componente com o método *Eddy Covariance* ao longo de 3 anos em uma área localizada no Parque Estadual Vassununga, em São Paulo.

O monitoramento e a análise da ET são questões essenciais na compreensão da interação entre a superfície terrestre, a vegetação e a atmosfera. Uma vez que, um dos principais serviços ecossistêmicos produzidos por áreas de florestas como o Cerrado é o de regulação do microclima local, através do constante retorno da água para a atmosfera (Anache et al., 2019). Além disso, o estudo da ET também é importante para outras aplicações, como a formulação e execução de planos de gerenciamento dos recursos hídricos e para modelagens hidrológicas e meteorológicas (Kumar; Jat; Shankar, 2012).

O uso de metodologias diretas para determinação da evapotranspiração, como o *Eddy Covariance* (EC), cresceu muito nos últimos anos, principalmente pelo aprimoramento dos anemômetros sônicos e o desenvolvimento de analisadores de gases de resposta rápida. A utilização desse método fornece medições diretas do fluxo de vapor de água e de outros gases (CO₂, CH₄) em alta frequência, e pode ser aplicado em diversos tipos de vegetação natural e culturas agrícolas plantadas (Anapalli et al., 2018; Cabral et al., 2015; Kljun et al., 2015; Burba, 2013).

Outras abordagens que também vêm crescendo nos estudos de evapotranspiração em escalas maiores, são as baseadas em observações espaciais. Isso é possível graças ao

avanço no sensoriamento remoto óptico e térmico e ao aumento crescente da disponibilidade de satélites que fornecem informações sobre a superfície terrestre (Baldocchi et al., 2019; Cristiano et al., 2015; Anderson et al., 2011; Mu et al., 2011). Estudos relacionam o uso das medições de fluxo realizadas pelo EC para validarem e compararem os resultados encontrados pelas técnicas de sensoriamento remoto (Baldocchi et al., 2019; Knipper et al., 2019; Yang et al., 2018; Yang et al., 2017). Porém, a relação entre as duas metodologias ainda é pouco difundida em áreas de Cerrado brasileiro.

Os modelos que utilizam sensoriamento remoto para estimar a evapotranspiração ainda apresentam imprecisões ao serem aplicados em regiões heterogêneas como o Cerrado. Essa limitação ocorre principalmente em função da grande diversidade da vegetação, topografia, tipos de solo e disponibilidade de água presentes nesses ambientes (Bezerra et al. 2023). Assim, torna-se fundamental avançar nos estudos que utilizam essa metodologia, a fim de se obter cada vez mais dados e estimativas precisas de parâmetros em áreas heterogêneas. Além disso, é importante destacar a relevância da aplicação desse método em regiões carentes de estações de monitoramento ou de sensores para a medição da evapotranspiração, tornando possível a realização de estudos em regiões remotas ou de difícil acesso.

Dessa forma, o principal objetivo desta tese de doutorado é determinar valores diários para a evapotranspiração em uma área de Cerrado *sensu stricto*, utilizando metodologias combinadas: o sistema *Eddy Covariance* e um modelo matemático baseado em dados provenientes de imagens de sensoriamento remoto.

2. OBJETIVOS

2.2 Objetivo Geral

O objetivo geral foi determinar valores diários de evapotranspiração em uma área remanescente de Cerrado *sensu stricto*.

2.3 Objetivos Específicos

- (i) Implementar e adaptar o modelo matemático *Two Source Energy Balance - Dual Time Difference* (TSEB-DTD), baseado em produtos de sensoriamento remoto, usando linguagem de programação e código livre pyTSEB;
- (ii) Produzir um manual para utilização do pyTSEB;
- (iii) Avaliar e comparar os resultados da evapotranspiração diária obtidas pelo método baseado em sensoriamento remoto (TSEB-DTD) com os dados medidos por meio do método *Eddy Covariance* (EC);
- (iv) Analisar sazonalmente a evapotranspiração do Cerrado *sensu stricto*.

3. REVISÃO BIBLIOGRÁFICA

3.1 Cerrado

O Cerrado brasileiro tem grande parte da sua distribuição sobre o Planalto Central, sendo o segundo maior bioma do país e a segunda maior região biogeográfica da América do Sul, superado apenas pela Floresta Amazônica (Ribeiro; Walter, 1998). Sua abrangência é de aproximadamente 2 milhões de km², cobrindo cerca de 25% do território brasileiro, passando pelos estados de Goiás, Tocantins, Mato Grosso, Mato Grosso do Sul, São Paulo, Minas Gerais, Bahia e Distrito Federal. Seu território também se estende suavemente em partes adjacentes da Bolívia e do Paraguai (Machado et al., 2004). Entretanto, a cobertura do solo nas regiões ocupadas por este bioma sofre constantes reduções desde a década de 1970, quando o Cerrado se tornou uma importante fronteira agrícola no Brasil. Em 2018, 42,73% das áreas de silvicultura e 44,61% das áreas agrícolas brasileiras situavam-se nas extensões do bioma Cerrado (PRODES Cerrado, 2021).

Segundo o estudo realizado pelo MapBiomas Fogo, entre o ano 2000 e 2019, 41% da extensão do Cerrado foi atingida pelo menos uma vez por queimadas, sendo 76% dessa área ocupada por vegetação nativa. De acordo com o Relatório Anual do Desmatamento no Brasil, em 2019, o Cerrado foi o segundo bioma que mais perdeu vegetação nativa no Brasil, cerca de 408,6 mil hectares, ficando atrás apenas da Amazônia, com 770 mil hectares, (MapBiomas, 2022). Neste mesmo ano, o Brasil teve 6.484,41 km² de vegetação nativa suprimida no Cerrado, destes, 6,11 km² apenas no estado de São Paulo (PRODES Cerrado, 2021).

A vegetação do Cerrado é condicionada, basicamente, por fatores climáticos (temperatura, pluviosidade e umidade relativa) e tipo de substrato. A presença de invernos secos e verões chuvosos caracteriza o clima do bioma, com valores médios anuais de precipitação entre 1200 e 1800 mm, concentradas de outubro a março, com uma uniformidade pluviométrica em toda sua extensão. A temperatura média durante a maior parte do ano permanece entre 21 e 27 °C, mas pode chegar a extremos de 18 e 40 °C (Ferreira et al., 2018). No seu substrato, predominam os latossolos, ocorrendo ainda solos concrecionários em grande parte de sua distribuição (Ribeiro; Walter, 1998).

Quanto à classificação fitofisionômica, os diferentes critérios utilizados geram extensas discussões (Ribeiro; Walter, 1998), sendo a terminologia básica definida por Ribeiro et al. (1983) e aprimorada por Ribeiro e Walter (2008) a mais consagrada na literatura. Assim, o Cerrado pode ser enquadrado em formações florestais, savânicas e campestres. A primeira é dividida em Mata Ciliar e Mata de Galeria (com fisionomias associadas a cursos de água, que podem ocorrer em terrenos bem drenados ou mal drenados) e Mata Seca e Cerradão (ocorrem nos interflúvios, em terrenos bem drenados). As formações savânicas são classificadas em Cerrado denso, Cerrado *stricto sensu*, Cerrado ralo, Parque de Cerrado, Palmeiral, Vereda e Cerrado rupestre. E as formações campestres são denominadas Campo rupestre, Campo sujo e Campo limpo. As fitofisionomias são ilustradas na Figura 1.

O Cerrado *stricto sensu*, do latim sentido restrito, caracteriza-se pela presença de árvores baixas, troncos com cascas de cortiça grossa, fendida ou sulcada, inclinadas, tortuosas, com ramificações irregulares e retorcidas, e geralmente com evidências de queimadas, além de folhas rígidas e coriáceas. Estão presentes, também, arbustos e subarbustos distribuídos aleatoriamente, com algumas espécies capazes de rebrotarem após queima ou corte. Durante o período chuvoso, os estratos subarborescentes tornam-se exuberantes devido ao seu rápido crescimento. Quando ocorre sua retirada, a área fica susceptível a problemas de erosão, principalmente em áreas sobre areias quartzosas (Ribeiro et al., 1983).


O Cerrado brasileiro é reconhecido como um dos biomas com maior biodiversidade do mundo (ICMBio, 2020), com a presença de diversos ecossistemas e uma flora com mais de 10 mil espécies, sendo aproximadamente 4.400 endêmicas. Tal complexidade paisagística e ecológica permite a este bioma ser considerado um *hotspot* da biodiversidade mundial. Apesar de sua importância para a diversidade de espécies e a provisão de serviços ecossistêmicos, o Cerrado sofre um alto grau de degradação ambiental, tornando este bioma um *hotspot* também em questões de luta pela conservação.

A abrangência do Cerrado também possui grande impacto nos recursos hídricos do país, sendo o local de origem das grandes regiões hidrográficas brasileiras. Em sua área de distribuição, encontram-se as três maiores bacias hidrográficas da América do Sul, Tocantins-Araguaia, São Francisco e Prata. Segundo Lima e Silva (2007), a

contribuição do Cerrado para a disponibilidade hídrica brasileira é fundamental, uma vez que 14% de toda a vazão que percorre a rede hidrográfica brasileira tem origem em áreas de Cerrado. No que se refere a água subterrânea, o Cerrado tem um papel indispensável nos sistemas de recarga do aquífero Guarani, maior manancial de água doce subterrânea transfronteiriço do mundo (Ribeiro; Walter, 2008).

O manejo da biomassa da vegetação que recobre este bioma é um recurso válido e de grande impacto para a produção hídrica. Entretanto, são desconhecidas, em grande parte, as influências hidrológicas e ecológicas, que as mudanças no uso do solo podem acarretar (Lima; Silva, 2007). Por possuir uma estação seca, que dura entre 5 e 6 meses na média, a demanda evaporativa do Cerrado é maior nesse período, diminuindo a disponibilidade de água no solo e causando estresse hídrico na vegetação (Rodrigues et al., 2014). Assim, é relevante a compreensão das relações entre a vegetação desse bioma e os componentes do ciclo hidrológico, dentre elas, as perdas por evapotranspiração.

Figura 1. Fitofisionomias do Bioma Cerrado.



3.2 Evapotranspiração

A evapotranspiração (ET) é a combinação dos processos de evaporação e transpiração. O primeiro refere-se à perda de água das superfícies de água, como lagos, rios e oceanos; do solo e do dossel da vegetação. O segundo consiste na perda fisiológica de água pelos tecidos das plantas, como resultado do processo de fotossíntese (Allen et al., 1998). A ET desempenha um papel importante na manutenção do ciclo hidrológico em escala global, uma vez que, mais de 60% da precipitação que ocorre na superfície terrestre retorna para a atmosfera através dos processos de evaporação e transpiração (Oki; Kanae, 2006). A ET pode ser afetada por fatores meteorológicos, como radiação solar, temperatura do ar, umidade relativa do ar, velocidade do vento; e por mudanças no uso do solo, como a supressão de florestas para plantio de culturas em larga escala (Katul; Novick, 2009). Este último fator pode alterar drasticamente as taxas de ET de uma área, e conseqüentemente, gerar mudanças nas componentes do balanço hídrico, e alterações qualitativas dos recursos hídricos, como aumento das cargas totais de sedimentos (Sun et al., 2016).

A ET consiste em um dos principais processos reguladores e de troca de água em áreas de florestas. Porém, esse processo é complexo, principalmente devido à heterogeneidade da vegetação, composta por diferentes espécies de árvores e arbustos, em uma distribuição espacial variada. Essa heterogeneidade pode afetar também o microclima local, outro fator que influencia a evapotranspiração (Sun et al., 2016). A evaporação ocorre principalmente pelo dossel da vegetação e também pela superfície, enquanto as folhas das árvores são as principais responsáveis pela transpiração (Cristiano et al., 2015). Em florestas com dossel fechado, geralmente a maior parcela da ET é proveniente da transpiração da vegetação e da evaporação devido à interceptação do dossel e da serapilheira. Dessa forma, a evaporação do solo comumente representa uma parcela menor da ET nesse tipo de ecossistema (Domec et al., 2012).

A ET também vincula o ciclo hidrológico, energético e do carbono em uma floresta. A energia que atinge a Terra, na forma de radiação solar, é refletida e sofre transformações. O fluxo de calor latente representa a evaporação da água do solo, da superfície e das plantas, enquanto o fluxo de calor sensível corresponde aos gradientes de temperatura. No ciclo hidrológico, a evapotranspiração representa a evaporação e a

transpiração das plantas. No ciclo do carbono, a evapotranspiração pode justificar a variabilidade sazonal da produtividade líquida do ecossistema, uma vez que esta depende da respiração do ecossistema (Sun et al., 2016).

O monitoramento e a estimativa de valores de ET em florestas são fundamentais para entender o ciclo da água, o ciclo energético e o ciclo biogeoquímico (Baldocchi et al., 2001). Em vários métodos, a ET é estimada como sendo a diferença entre a precipitação e o escoamento superficial, considerando séries longas de medições, e desprezando alterações no armazenamento de água em uma escala de tempo longa. Porém, essa estimativa pode gerar incertezas nos valores de evapotranspiração (Teuling, 2018). Contudo, há outras formas de realizar observações e estimativas da troca de água por evapotranspiração de uma determinada área ou ecossistema, através de diversas técnicas e metodologias presentes na literatura. Alguns exemplos são: *Eddy Covariance*, razão de Bowen, lisímetros, balanço hídrico, imagens de sensoriamento remoto, isótopos estáveis, modelos matemáticos, entre outros (Wang; Dickinson, 2012).

3.3 Fluxos turbulentos e medições com o método *Eddy Covariance*


O físico e engenheiro mecânico, Osborne Reynolds, foi o responsável por estabelecer a fundamentação teórica que, posteriormente, deu origem à metodologia da Covariância de Vórtices Turbulentos, ou *Eddy Covariance* (EC) (Reynolds, 1895). Porém, devido à falta de instrumentação e equipamentos adequados na época, a aplicação deste método ocorreu pela primeira vez apenas em 1926, por meio de uma pesquisa conduzida por Scrase (1930), que estudou a transferência de momento utilizando instrumentação analógica simples. Ao longo das décadas, a metodologia foi se desenvolvendo e mais estudos foram sendo realizados. Nos anos 1980, o surgimento de anemômetros sônicos e espectrômetros de infravermelho comerciais, e o desenvolvimento de analisadores de gases de resposta rápida, permitiram a medição de fluxos 24 horas por dia, ao longo de todo o ano (Baldocchi, 2003). Atualmente, o EC é uma metodologia mundialmente difundida e consolidada (Burba, 2013; Aubinet; Vesala; Papale, 2012; Baldocchi et al., 2001), e está presente na FLUXNET, uma rede global de torres micrometeorológicas que medem e disponibilizam os dados de trocas de dióxido de carbono, vapor de água e energia entre a atmosfera e os ecossistemas terrestres. São

mais de 500 torres de fluxo em funcionamento distribuídas em todos os continentes (FLUXNET, 2019).

O EC é uma das abordagens mais precisas disponíveis, até a presente data, para a medição e monitoramento de fluxos verticais de gases, como CO₂, CH₄ e N₂O, vapor de água, calor e momento. A medição dos fluxos entre o solo, a vegetação, terrenos urbanos, industriais e a atmosfera, pode ser realizada em áreas de tamanhos variados, podendo amostrar extensões relativamente grandes, e por diferentes períodos (horas, dias, estações e anos) (Burba, 2013). Por outro lado, sua aplicação só é consistente em ocasiões em que as condições atmosféricas permanecem constantes, e ainda, as áreas de estudo devem ser caracterizadas por terrenos relativamente planos, se estendendo horizontalmente por pelo menos 100 vezes a altura da vegetação (Baldocchi et al., 2001).


O sistema EC é constituído por um analisador de gases e um anemômetro sônico. O analisador de gases pode ser de caminho aberto, de caminho fechado ou fechado (Figura 2). A escolha entre os três modelos depende, principalmente, da disponibilidade de energia e da ocorrência de chuvas no local de monitoramento. O de caminho aberto é o mais econômico, porém, sua principal limitação é a perda de dados durante eventos de precipitação. O anemômetro sônico pode ser encontrado em três designs diferentes, de acordo com o arranjo físico dos transdutores (Figura 3). Este dispositivo mede a velocidade do vento nos três componentes vetoriais (u , v , w), a partir da velocidade do som, utilizando a componente vertical (w) no cálculo do fluxo (Burba, 2013).

Figura 2. Modelos de analisadores de gases.



Fonte: Burba (2013).

Figura 3. Modelos de anemômetros sônicos.



Fonte: Burba (2013); Campbell Scientific (2020) e Nova Lynx (2020).

O EC é o único método de medição direta de fluxos, sem a necessidade de suposições sobre a difusividade dos vórtices, ao contrário de outras metodologias presentes na literatura, que estimam os fluxos (Lee; Massman; Law, 2005). As medições de fluxos de vapor de água e gases, utilizando o EC, geralmente ocorrem na camada limite atmosférica (Aubinet; Vesala; Papale, 2012). Stull (1988) definiu a camada limite atmosférica como a parte da troposfera que é diretamente influenciada pela presença da superfície terrestre. Assim, ela responde a forçantes da superfície, como resistência ao atrito, evapotranspiração, transferência de calor e emissão de poluentes, em uma escala de tempo de uma hora ou menos. A espessura da camada limite atmosférica varia em relação ao tempo e ao espaço.

Os fluxos de vapor de água e gases permanecem aproximadamente constantes ao longo da camada limite, e a turbulência atmosférica é o mecanismo de transporte dominante (Aubinet; Vesala; Papale, 2012). A turbulência consiste em redemoinhos irregulares de movimento, chamados turbilhões, sobrepostos uns aos outros, e é ela que permite que a camada limite responda as forçantes da superfície (Stull, 1988). A densidade de fluxo vertical de CO₂, de calor latente (λE) e de calor sensível (H) entre a vegetação e a atmosfera são proporcionais à covariância média entre a velocidade vertical (w') e as respectivas flutuações escalares (c') de CO₂, vapor de água e temperatura. Valores negativos na densidade dos fluxos representam transferência de energia e massa para a superfície. Já o contrário, valores positivos na densidade dos fluxos, representam transferência de energia e massa para a atmosfera. (Baldocchi et al., 2001). Os fluxos são normalmente medidos em alta frequência, entre 10 e 20 Hz, e em média, em intervalos de 30 minutos (Cabral et al., 2015).

Outros conceitos importantes na medição dos fluxos com o EC é o de *footprint* e *fecht* (bordadura). O primeiro corresponde à área contra o vento da torre, onde os fluxos gerados são registrados pelos sensores. Em outras palavras, representa a extensão espacial da área de contribuição para medição de fluxo turbulento (Kljun et al., 2015). O segundo, geralmente representa a distância da torre ao descrever o *footprint*. O tamanho do *footprint* pode aumentar conforme a altura de medição se torna maior, quando a rugosidade da superfície decrescer e quando a estabilidade térmica atmosférica mudar de instável para estável (Burba, 2013). As informações sobre a extensão espacial do *footprint* e a localização da torre são especialmente importantes em locais com vegetações

heterogêneas, de forma a abranger toda a área de interesse (Kljun et al., 2015; Sogachev et al., 2005).

Apesar de ser uma metodologia usada mundialmente, a utilização do EC para determinar os fluxos de vapor de água e gases necessita da realização de uma série de correções e processamento dos dados brutos, principalmente aqueles provenientes de sistemas de caminho aberto, pois há perda de dados durante eventos de precipitação. Como consequência, é preciso realizar, também, o descarte ou preenchimento das falhas da série de dados monitorados (Amiro, 2009). Assim, é comum o uso de outras metodologias complementares ao *Eddy Covariance*, que auxiliam no monitoramento e na estimativa de valores de evapotranspiração. Metodologias que utilizam técnicas de sensoriamento remoto também são comumente empregadas, e estão descritas com mais detalhes no tópico seguinte.

3.4 Uso de imagens de sensoriamento remoto para estimar evapotranspiração

Imagens de infravermelho térmico (TIR - *Thermal InfraRed*) fornecem informações importantes sobre as propriedades biofísicas das plantas, como a abertura e fechamento dos estômatos, estruturas celulares responsáveis por regular as taxas de transpiração, que podem sofrer grandes variações no tempo e no espaço. Da mesma forma, o processo de evaporação do solo também possui uma marca térmica, em consequência da variação de calor. Portanto, imagens TIR com resoluções moderadas a altas (até 100 m) tornam-se instrumentos úteis na identificação e entendimento dos fluxos de água na superfície terrestre (Anderson et al., 2012).

Métodos de sensoriamento remoto baseados em dados de TIR são cada vez mais utilizados para estimativas de evapotranspiração, principalmente devido ao aumento da disponibilidade de satélites que fornecem essas informações, como GOES (*Geostationary Operational Environmental Satellite*), MODIS (*Moderate Resolution Imaging Spectroradiometer*), AVHRR (*Advanced Very High Resolution Radiometer*), ATSR (*Along Track Scanning Radiometer*), ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*), LDCM (*Landsat Data Continuity Mission*), entre outros (Anderson et al. 2011). A temperatura da superfície terrestre (LST - *Land surface temperature*), produto que pode ser derivado a partir de imagens TIR, constitui um

importante componente no balanço de energia da superfície, além de exercer uma função essencial na partição da energia entre os fluxos turbulentos de calor latente e sensível (Cammalleri et al., 2014).

O sensor MODIS foi lançado em 1999 com o satélite Terra, e em 2002 com o satélite Aqua, fazendo parte do Sistema de Observação da NASA. Estes satélites são caracterizados por possuírem órbita polar, além de possuírem alta resolução temporal, realizando observações a cada 1 ou 2 dias. Por outro lado, sua resolução térmica efetiva varia entre 1000 e 2000 m, dependendo do ângulo de visão (Anderson et al., 2012). Já a série Landsat teve seu início na segunda metade da década de 1960, em um projeto desenvolvido pela NASA. O Landsat 1 foi lançado para o espaço em 1972, sendo o primeiro da série direcionado para atuar em pesquisas de recursos naturais. O último satélite da série lançado foi o Landsat 8, em 2013, possuindo os sensores OLI (*Operational Land Imager*) e TIRS (*Thermal Infrared Sensor*), sendo esse último responsável por coletas de dados na faixa do infravermelho termal. Possui resolução temporal de 16 dias e resolução espacial de 100 metros, podendo ser reamostrada para até 30 metros (INPE, 2019).

O MOD16A2, produto do MODIS, é usualmente utilizado para estimativas de evapotranspiração (Mu et al., 2011). Sua versão 6 (MOD16A2v006) constitui um conjunto de dados de evapotranspiração acumulada de 8 dias e com resolução espacial de 500 m (USGS, 2020). Este produto foi validado utilizando 46 torres de monitoramento do método *Eddy Covariance*, sendo a grande maioria localizada na América do Norte. Porém, possui apenas duas validações na América do Sul, em locais próximos à Linha do Equador (Cristiano et al., 2015; Melo et al., 2021).

Uma das principais desvantagens do uso de imagens de sensores de infravermelho termal, é que suas medições não conseguem penetrar as nuvens. Isso pode causar uma descontinuidade na aquisição dos dados de temperatura, e conseqüentemente, nas estimativas de evapotranspiração. Contudo, alguns procedimentos podem ser empregados a fim de minimizar essa limitação, como técnicas de interpolação de dados. Além de imagens termais em dias sem nuvens, utiliza-se também, dados meteorológicos medidos em terra (Song et al., 2018).

Em pesquisas desenvolvidas em escala de bacia hidrográfica, imagens TIR do MODIS para geração de dados de evapotranspiração são importantes e válidas. Por outro


lado, a resolução mais refinada do Landsat 8 (até 30 metros) é essencial para estudos em que o sinal térmico do satélite deve estar associado a uma característica ou processo da superfície terrestre (Anderson et al., 2012).

3.5 Modelo Two Source Energy Balance (TSEB)

O *Two Source Energy Balance* (TSEB) (Normana; Kustas; Humes, 1995) é um modelo físico amplamente usado em estudos que utilizam dados de sensoriamento remoto visando calcular o balanço de energia da superfície da Terra (Song et al., 2018; Andreu et al., 2018; Barker et al., 2018; Castelli et al., 2018; Guzinski et al., 2018; Guzinski et al., 2014; Guzinski et al., 2013). O princípio do TSEB é relacionar a temperatura radiométrica da superfície terrestre com os fluxos superficiais de calor latente e sensível, levando em consideração o ângulo de visão do satélite e as características do dossel da vegetação (Normana; Kustas; Humes, 1995).

A temperatura radiométrica da superfície terrestre é diferente da temperatura aerodinâmica. Isso se deve ao fato de que a temperatura do solo e da vegetação contribuem proporcionalmente para a temperatura aerodinâmica de acordo com suas respectivas resistências ao transporte turbulento. Dessa forma, não é possível considerar que a temperatura aerodinâmica seja igual à radiométrica. No modelo TSEB, a temperatura radiométrica (Trad) é calculada em função das temperaturas do solo (Ts) e do dossel (Tc), considerando também a fração de cobertura vegetal aparente no ângulo de visão do sensor térmico ($f(\theta)$) (Normana; Kustas; Humes, 1995). O TSEB assume a interação entre os fluxos vindos da vegetação (Hc) e do solo (Hs) por meio de uma rede de resistências em série (Ra, Rs, Rx) (Normal et al. 1995), como mostra a Figura 4.

Figura 4. Rede de resistências em série do modelo DTD.



Fonte: Adaptado de Normal et al. (1995).

Além da questão da sensibilidade do modelo ao gradiente de temperatura entre a temperatura radiométrica da superfície terrestre e a temperatura do ar, o uso do TSEB possui limitações quanto a disponibilidade de dados de satélites geostacionários que fazem a cobertura da região de estudo (Guzinski et al., 2018).

Devido aos pontos mencionados, alguns estudos utilizaram o TSEB em conjunto com o modelo *Dual Temperature Difference* (DTD) (Guzinski et al., 2013; 2014). Essa associação tem o objetivo de viabilizar a utilização de dados provenientes de satélites em órbita polar, substituindo a LST e a temperatura do ar medidas em um único momento por uma medição diferencial de temperatura no tempo, entre dois horários diferentes durante o dia.


3.6 Modelo Dual Temperature Difference (DTD)

O modelo *Dual Temperature Difference* (DTD) usa o esquema de modelagem do balanço de energia de duas fontes (TSEB) regido por observações de sensoriamento remoto das mudanças diurnas de temperatura da superfície terrestre (LST) para estimar os fluxos de energia da Terra. O DTD funciona medindo a diferença de reflectância entre duas imagens de satélite capturadas em dois momentos diferentes do dia. Essa diferença de reflectância é então relacionada às mudanças nas propriedades da vegetação, como o índice de área foliar e a cobertura vegetal fracionária, usando um modelo matemático (Norman et al., 2000).

A formulação do DTD exige as mesmas entradas do TSEB, mas em dois tempos de observações distintas. O primeiro, t_0 , aproximadamente 1 hora após o nascer do sol, e o segundo, t_1 , aproximadamente 1 hora antes do meio-dia. No DTD, a medição do início da manhã (t_0) pode ser substituída por uma observação noturna, com degradação mínima nos fluxos. Desse modo, é possível utilizar o DTD com satélites em órbita polar, que possuem passagens noturnas e diurnas sobre a superfície da Terra (Guzinski et al., 2014).

Desse modo, é possível utilizar as estimativas de LST diurnas e noturnas fornecidas pelo sensor MODIS, presentes nos satélites Aqua e Terra, substituindo a medição de temperatura matinal pela medição noturna do Aqua. O DTD faz uso da diferença de temperatura entre as observações t_0 , quando os fluxos de calor da superfície são mínimos, e a segunda medição, t_1 e/ou t_1' , onde os fluxos atingem valores mais elevados (Guzinski et al., 2014), conforme apresentado na Figura 5.

Figura 5. Uso de imagens de satélites em órbita polar (Terra e Aqua) pelo DTD.



Fonte: Autor (2021).

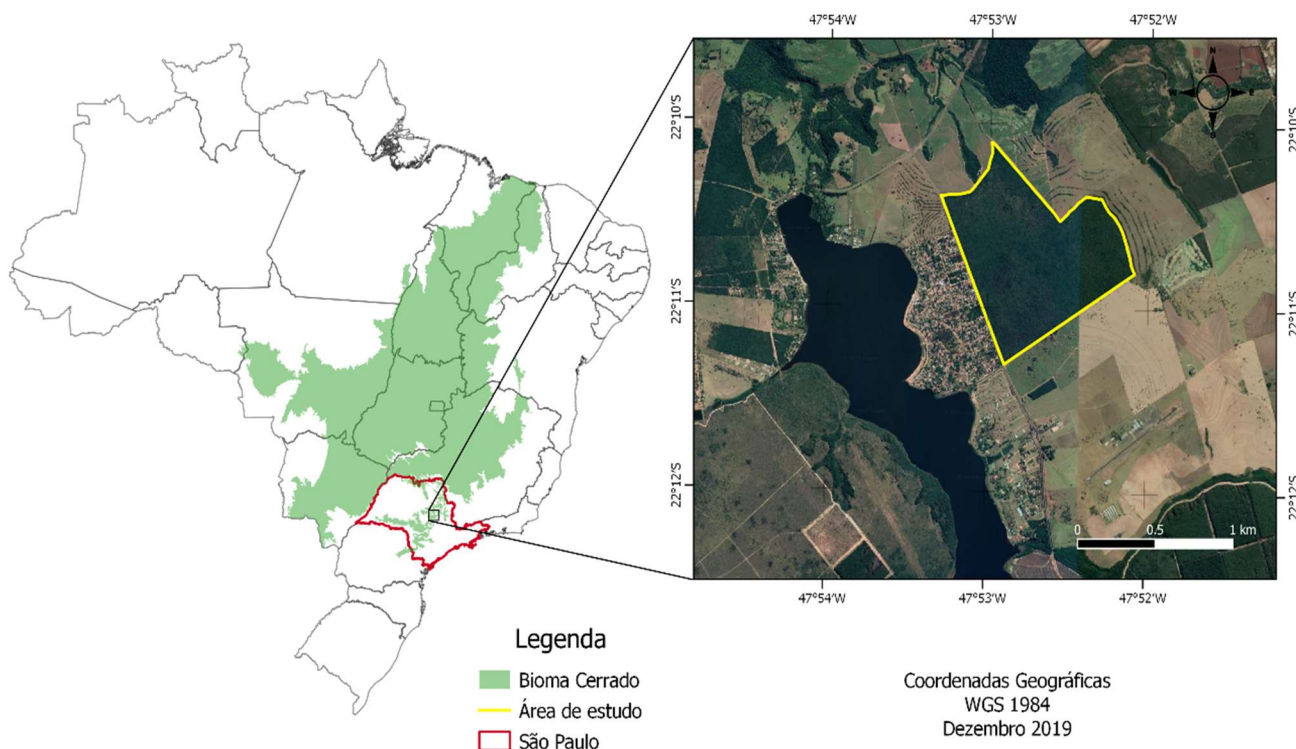
O modelo DTD tem se mostrado eficaz na estimativa de parâmetros biofísicos da vegetação e nas estimativas de fluxo de calor em uma ampla gama de ambientes, incluindo florestas, pastagens e campos agrícolas (Guzinski et al., 2013). Ele é particularmente útil em áreas onde medições diretas são difíceis de se obter. Outro ponto positivo é o fato de se poder usar satélites polares, expandindo a área de atuação do modelo em regiões de latitudes elevadas (Guzinski et al., 2013). No entanto, o modelo DTD apresenta algumas limitações, como sua sensibilidade a efeitos atmosféricos e sua incapacidade de estimar com precisão as propriedades da vegetação em áreas com topografia complexa (Song et al., 2018).

4. METODOLOGIA

4.1 Caracterização da área de estudo

Esta pesquisa de doutorado foi realizada em uma área remanescente de Cerrado *sensu stricto* de aproximadamente 330 hectares, localizada no município de Itirapina, na região central do estado de São Paulo, entre os paralelos 22°11' e 22°10' (latitude sul) e os meridianos 47°53' e 47°52' (longitude oeste) com elevação aproximada de 780 m (Figura 6). A área de Cerrado está situada em uma região de afloramento do Sistema Aquífero Guarani (SAG), o maior reservatório transfronteiriço de água subterrânea na América do Sul (Wendland; Barreto; Gomes, 2007). A área experimental pertence ao Instituto Arruda Botelho (IAB), que possui parceria desde 2011 com o Laboratório de Hidráulica Computacional (LHC) da Escola de Engenharia de São Carlos da Universidade de São Paulo (EESC-USP).

Figura 6. Localização da área de estudo.



Fonte: Google Earth (2019).

A região possui clima subtropical úmido (Cwa), segundo o sistema de classificação climática de Köppen, com inverno seco (abril até setembro) e verão quente e úmido (outubro até março) (Alvares et al., 2014). A precipitação média anual é de 1.485 mm, e a temperatura média anual é de 21,6 °C (Rosalem; Wendland; Anache, 2019). O solo é classificado, de acordo com o Sistema Brasileiro de Classificação de Solos (SiBCS), como Neossolo Quartzarênico Órtico (RQo) de textura arenosa em todo o perfil, com uma proporção de 85,7% de areia, 12,6% de argila e 1,7% de silte, e grupo hidrológico tipo A (Oliveira et al., 2015).

Em relação à florística, a área de estudo possui uma densidade total estimada de 15.522 indivíduos por hectare. A altura máxima encontrada de uma árvore foi de 12 metros, e o maior diâmetro de tronco de 34,7 cm. O Cerrado em questão possui cerca de 120 espécies arbustivas e arbóreas, indicando riqueza e representatividade. Algumas das espécies encontradas em maior abundância são: *Bauhinia rufa* (Bong.) Steudel, *Xylopia aromatica* (Lam.) Mart., *Miconia rubiginosa* (Bonpl.) A.DC., *Virola sebifera* Aubl., e *Myrcia guianensis* (Aubl.) DC (Reys et al., 2013).

4.2 Instrumentação da área de estudo

A área de estudo possui uma torre de monitoramento equipada com sensores meteorológicos (Figura 7), responsáveis pela medição da precipitação, temperatura do ar, umidade relativa do ar, direção e velocidade do vento, fluxos radiativo, atmosférico e turbulento, concentração de vapor d'água e radiação solar líquida (onda curta e onda longa). A torre, equipada com o sistema *Eddy Covariance* (Campbell Scientific's IRGASON® - Figura 8) e outros sensores, teve sua instalação concluída em julho de 2018.

Figura 7. Torre de monitoramento (a) e vista aérea da área de Cerrado *sensu stricto* (b).



Fonte: Autor (2021).

Figura 8. Analisador de gases (H_2O e CO_2) de caminho aberto e anemômetro sônico 3D integrados (IRGASON® *Campbell Scientific*).

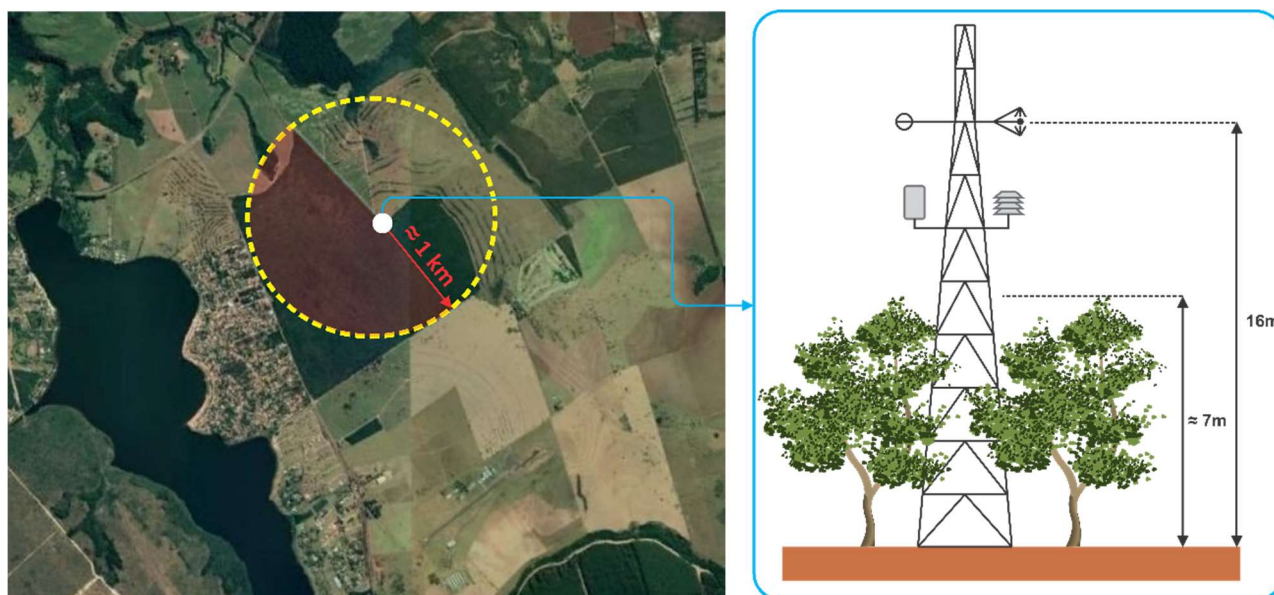


Fonte: Autor (2021).

Segundo Burba (2013), a posição mais apropriada para instalação da torre é na camada de fluxo constante, localizada cerca de 1,5 a 2 vezes a altura do dossel. A altura máxima de espécie arbórea encontrada no Cerrado foi de 12 metros, com uma média de 7 metros (Figura 9) (Reys et al. 2013). Logo, a torre foi instalada com uma altura de 24 metros, possibilitando ajustes na disposição dos equipamentos, de acordo com a necessidade. Instalações próximas ao dossel (subcamada de rugosidade) podem não representar o ecossistema de interesse, restringindo-se a distúrbios localizados. Já instalações muito acima do dossel (camada mista / 100-150 metros), podem dissociar-se da camada de fluxo constante, perdendo a representatividade da área de interesse (Burba, 2013).

Em relação à direção dos ventos, a torre está localizada em conformidade com a predominância de ventos oriundos do sul. Desse modo, sua instalação foi feita próxima da borda a favor do vento (norte) da área de interesse, aumentando a altura da medição, além de cumprir os requisitos de bordadura (*fetch*), a qual possui uma distância de cerca de 1 km do local da torre (Burba, 2013) (Figura 9).

Figura 9. Localização da torre no Cerrado e distância de abrangência dos sensores.



Fonte: Autor (2021); Google Earth (2021).

As variáveis e a instrumentação utilizada na área de estudo estão descritas com mais detalhes na Tabela 1.

Tabela 1. Detalhamento das variáveis monitoradas e instrumentação utilizada (Fonte: Autor, 2021).

Variável	Unidade	Sensor	Modelo	Faixa de medição	Erro máximo	Posição (m)
Temperatura	°C	Termohigrômetro	HMP155A	-80 a +60 °C	±0,45 °C	16
Umidade relativa	%	Termohigrômetro	HMP155A	0 a 100%	±1,7%	16
Precipitação	mm	Pluviômetro de bscula	TB4	0 a 700 mm h ⁻¹	±3%	16
Radia solar lquida	W m ⁻²	Saldoradimetro	Kipp & Zonen CNR4	±2000 W m ⁻²	±20 W m ⁻²	10
Fluxo de calor no solo	W m ⁻²	Fluxmetro	HFP01	±2000 W m ⁻²	-15 a +5%	-0,1
Umidade do solo	%	FDR	EnvironSCAN Sentek	0 a ~65%	±3%	-0,3
Presso atmosfrica	mbar	Barmetro	Vaisala CS106	500 a 1100 mbar	±1,5 mbar	16
Dire dos gases	graus	Anemmetro snico	IRGASON	0 a 360 °	±0,7 °	16
Velocidade dos fluxos de gases (vertical e horizontal)	m s ⁻¹	Anemmetro snico	IRGASON	0 a 30 m s ⁻¹	±1,8 m s ⁻¹	16
Fra molar seca (H ₂ O)	mol	Analizador de gases	IRGASON	0 a 72 mmol/mol	2%	16

Alm dos equipamentos instalados na torre de monitoramento, fez-se o uso de um datalogger (CR3000 Micrologger® Campbell Scientific), um mdulo de carto de memria (modelo CFM100) e 4 cartes de memria (modelo CFMC2G) para registro e armazenamento dos dados medidos pelos sensores do sistema *Eddy Covariance*.

4.3 Estimativa da evapotranspira utilizando tcnicas de sensoriamento remoto

4.3.1 Dados MODIS (*Moderate Resolution Imaging Spectroradiometer*)

Os dados de sensoriamento remoto que alimentaram o modelo *Dual Temperature Difference* (DTD) foram provenientes dos produtos derivados do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*), que est presente nos satlites Terra e Aqua. A escolha deste sensor foi devida, principalmente, pela presena de medies da

LST, principal dado de entrada do modelo DTD, e por seus registros quase diários da superfície da Terra.

As principais características do sensor MODIS presente nos satélites Terra e Aqua estão indicados na Tabela 2.

Tabela 2. Características do sensor MODIS dos satélites Aqua e Terra (Fonte: MODIS, 2022).

Satélite	Aqua	Terra
Operadora	NASA (EUA)	NASA (EUA)
Lançamento	Maio de 2002	Dezembro de 1999
Altitude	705 km	705 km
Inclinação	98,2°	98,2°
Órbita	Polar, heliossíncrona	Polar, heliossíncrona
Faixa imageada	2330 x 5000 km	2330 x 5000 km
Tempo de duração da órbita	99 minutos	99 minutos
Horário de passagem	~13h30 (Sul-Norte / Ascendente)	~10h30 (Norte-Sul / Descendente)
Período de revisita	1 – 2 dias	1 – 2 dias
Resolução espacial	1000 m	1000 m

Os produtos utilizados do MODIS estão descritos conforme a Tabela 3.

Tabela 3. Detalhes dos produtos MODIS utilizados na pesquisa (Fonte: MODIS, 2022).

Produto	Nome	Satélite	Resolução temporal	Tamanho do pixel
MOD11A1v061	<i>Land Surface Temperature and Emissivity</i>	Terra	Diário	1000 m
MYD11A1v061	<i>Land Surface Temperature and Emissivity</i>	Aqua	Diário	1000 m
MOD13A2v061	<i>Vegetation Indices (NDVI¹ e EVI²)</i>	Terra	16 dias	1000 m
MYD13A2v061	<i>Vegetation Indices (NDVI¹ e EVI²)</i>	Aqua	16 dias	1000 m
MOD15A2Hv061	LAI ³ e FPAR ⁴	Terra	8 dias	500 m
MYD15A2Hv061	LAI ³ e FPAR ⁴	Aqua	8 dias	500 m
MCD43A1v061	BRDF ⁵ e Albedo	Terra + Aqua	Diário	500 m

¹ Normalized Difference Vegetation Index
² Enhanced Vegetation Index
³ Leaf Area Index
⁴ Fraction of Photosynthetically Active Radiation
⁵ Bidirectional Reflectance Distribution Function

4.3.2 Aplicação do modelo *Two Source Energy Balance (TSEB)*

Para a aplicação do modelo TSEB, primeiramente algumas considerações foram feitas:

- Assumiu uma interação entre os fluxos de calor do solo e da vegetação em uma rede de resistência de fluxo em série.
- No estado inicial do modelo, foi considerado que a estabilidade atmosférica é neutra, o que significa que o comprimento de Obukhov (L) está se aproximando de $\pm \infty$ ($L \cong \pm \infty$). A estabilidade real da camada limite é posteriormente derivada iterativamente.

A temperatura radiométrica da superfície terrestre (T_R , em K) foi calculada por meio da temperatura de brilho, adquirida por imagens de satélite (produtos MODIS MOD11A1v061 e MYD11A1v061), e é expressa pela Equação 1.

$$T_R(\theta) = (f_C(\theta) * T_C^4 + [1 - f_C(\theta)] * T_S^4)^{\frac{1}{4}} \quad (1)$$

Em que:

T_C = temperatura do dossel (K);

T_S = temperatura da superfície do solo (K);

$f_C(\theta)$ = cobertura vegetal aparente no ângulo de visão do zênite do satélite (θ). É derivado do índice de área foliar (LAI), obtido por imagens de satélite (produtos MODIS MOD15A2Hv061 e MYD15A2Hv061).

Para um dossel homogêneo e com distribuição LAI esférica, pode-se aproximar $f_C(\theta)$ usando a Equação 2 (Norman et al., 2000).

$$f_C(\theta) = 1 - \exp\left(\frac{-0,5 * \Omega(\theta) * F}{\cos \cos(\theta)}\right) \quad (2)$$

Em que:

F = área foliar;

$\Omega(\theta)$ = fator de aglomeração da vegetação aparente no ângulo de visão do satélite (θ). $\Omega(\theta) < 1$ para vegetação agrupada (Guzinski et al., 2013). $\Omega(\theta)$ é encontrado por meio da Equação 3 (Kustas; Norman, 1999).

$$\Omega(\theta) = \frac{\Omega_0}{\Omega_0 + (1 - \Omega_0) * \exp(-2,2 * \theta^{3,8-0,46*D})} \quad (3)$$

Em que:

Ω_0 = fator de aglomeração no nadir. $\Omega_0 = 1$ para as áreas de cultivo e $\Omega_0 = 0,5$ para florestas de coníferas;

D = é a proporção entre a altura da vegetação e a largura da copa da planta. D = 1 para áreas de cultivo e D = 3,5 para florestas de coníferas.

Um limite máximo de 0,95 deve ser aplicado a $f_c(\theta)$, para garantir que uma fração do solo esteja sempre visível para o sensor. Sem esse limite, o T_s calculado pelo modelo pode apresentar valores extremos e, portanto, inadequados (Guzinski et al., 2014).

A radiação líquida que chega ao solo e à vegetação (RN) é calculada como sendo a soma de seus componentes de onda curta (R_S , Equação 4) e de onda longa (R_L , Equação 5). A radiação que entra e a radiação que sai são dadas pelas Equações 6 e 7, respectivamente.

$$R_S = R_{S,in} - R_{S,out} = R_{S,in}(1 - \alpha) \quad (4)$$

$$R_L = R_{L,in} - R_{L,out} \quad (5)$$

$$R_{L,in} = \epsilon_{atm} * \sigma * T_A^4 \quad (6)$$

$$R_{L,out} = \epsilon_{surf} * \sigma * T_R^4 + R_{L,in}(1 - \epsilon_{surf}) \quad (7)$$

Em que:

σ = constante de Stefan–Boltzmann ($\sigma = 5,670400(40) \times 10^{-8} \text{ W m}^{-2} \text{ K}^{-4}$);

α = é o albedo da superfície terrestre (solo e vegetação);

T_A = é a temperatura do ar (K);

T_R = é a temperatura radiométrica (LST, em K);

ϵ_{surf} = é a emissividade terrestre (solo e vegetação);

ϵ_{atm} = é a emissividade atmosférica, derivada de Brutsaert (1975) (Equação 8).

$$\epsilon_{atm} = 1,24 * \frac{ea^{0,14286}}{T_A} \quad (8)$$

Em que, ea = pressão de saturação do vapor de água no ar (kPa).

A parte iterativa do modelo começa a ser calculada, considerando, inicialmente, $|L| \rightarrow \infty$ (estabilidade atmosférica é neutra).

A velocidade de atrito do vento (u_*) é calculada pela Equação 9 (Brutsaert, 2005).

$$u_* = \frac{uk}{\ln\left(\frac{z_u - d_0}{z_{0M}}\right) - \psi_M\left(\frac{z_u - d_0}{L}\right) + \psi_M\left(\frac{z_{0M}}{L}\right)} \quad (9)$$

Em que:

u = medida da velocidade do vento à uma altura z_u ;

k = constante de von Karman;

d_0 = altura de deslocamento ($d_0 = 0,65 * h_C$; em que, h_C é a altura da vegetação);

L = comprimento de Obukhov;

z_{0M} = comprimento de rugosidade local para transporte de momento ($z_{0M} = 0,13 * h_C$);

ψ_M = função de correção de estabilidade de Monin-Obukhov, que é calculada pelas Equações 10 e 11 (Brutsaert, 2005).

Para $\zeta \geq 0$:

$$\psi_M(\zeta) = -6,1 * \ln(\zeta + (1 + \zeta^{2,5})^{\frac{1}{2,5}}) \quad (10)$$

Para $\zeta < 0$:

$$\begin{aligned} &\psi_M(y) \\ &= \ln(a + y) - 3by^{\frac{1}{3}} + \frac{ba^{\frac{1}{3}}}{2} * \ln\left(\frac{(1+x)^2}{1-x+x^2}\right) + 3^{\frac{1}{2}} * ba^{\frac{1}{3}} * \tan^{-1} * \left(\frac{2x-1}{3^{\frac{1}{2}}}\right) \\ &+ \psi_0 \end{aligned} \quad (11)$$

O valor de ζ é calculado usando a Equação 12:

$$\zeta = \frac{z_u - d_0}{L} \quad \text{ou} \quad \zeta = \frac{z_{0M}}{L} \quad (12)$$

Os valores de y e x são calculados pelas Equações 13 e 14, respectivamente:

$$y = -\zeta \quad (13)$$

$$x = \left(\frac{y^{\frac{1}{3}}}{a}\right) \quad (14)$$

O valor de ψ_0 é calculado pela Equação 15:

$$\psi_0 = -\ln(a) + 3^{\frac{1}{2}} * ba^{\frac{1}{3}} * \frac{\pi}{6} \quad (15)$$

Em que:

$$a = 0,33;$$

$$b = 0,41.$$

Na Equação 11 (Para $\zeta < 0$), o valor de y é limitado, tal que $y \leq b^{-3}$.

Em condição de estabilidade atmosférica neutra, quando $|L| \rightarrow \infty$, a função de correção de estabilidade é definida como 0.

Agora, são calculadas as resistências em série do modelo: resistência aerodinâmica ao transporte de calor na camada superficial (R_A), resistência ao transporte de calor da superfície do solo (R_S) e a resistência total da camada limite da copa das folhas (R_X).

O valor de R_A é estimado pela Equação 16 (Norman et al., 2000).

$$R_A = \frac{\ln\left(\frac{z_T - d_0}{z_{0H}}\right) - \psi_H\left(\frac{z_T - d_0}{L}\right) + \psi_H\left(\frac{z_{0H}}{L}\right)}{u_* k} \quad (16)$$

Em que, $\psi_H(\zeta)$ é a função de estabilidade de Monin-Obukhov para calor, calculada da mesma forma que $\psi_M(\zeta)$ para condições de estabilidade. Para condições de instabilidade, $\psi_H(\zeta)$ é calculada pela Equação 17 (Brutsaert, 2005).

Para $\zeta < 0$:

$$\psi_H(y) = \frac{1-d}{n} * \ln \left(\frac{c+y^n}{c} \right) \quad (17)$$

Em que:

$$y = -\zeta;$$

$$c = 0,33;$$

$$d = 0,057;$$

$$n = 0,78.$$

O valor de R_S é estimado pela Equação 18 (Norman et al., 2000).

$$R_S = \frac{1}{c_T + b * u_S} \quad (18)$$

Em que:

$$c_T = 0,006 \text{ ms}^{-1} \text{ para LAI} < 2 \text{ e } c_T = 0,004 \text{ ms}^{-1} \text{ para LAI} > 2;$$

$$b = 0,012;$$

u_S = velocidade do vento logo acima da superfície do solo, e é determinada pela velocidade do vento logo acima do dossel (u_C , Equação 19), conforme Equação 20 (Norman et al., 1995).

$$u_C = \ln \left(\frac{h_C - d_0}{z_{0M}} \right) * \frac{u_*}{k} \quad (19)$$

$$u_S = u_C * \exp \left(-a \left(1 - \frac{h_S}{h_C} \right) \right) \quad (20)$$

Em que:

$$a = 0,28 * (F * \Omega_0)^{\frac{2}{3}} * h_c^{\frac{1}{3}} * s^{-\frac{1}{3}};$$

s = tamanho da folha (m);

$h_s = 0,05$ m;

$h_c \geq 0,1$ m, na Equação 19.

O valor de R_x é estimado pela Equação 21 (Norman et al., 1995).

$$R_x = \frac{C'}{F} * \left(\frac{s}{u_d}\right)^{0,5} \quad (21)$$

Em que:

$C' = 90 \text{ s}^{1/2} \text{ m}^{-1}$;

u_d = velocidade do vento à altura $d_0 + z_{0M}$, e é derivada usando a equação de u_s (Equação 20), com $h_s = d_0 + z_{0M}$.

Após calcular as resistências, as temperaturas do solo (T_s), do dossel (T_c) e dentro do dossel (*inter-canopy*) (T_{AC}) são estimadas. Para isso, deve-se estabelecer a divergência de energia no dossel (ΔR_N).

Quando não se têm os valores de T_s e T_c , ainda na primeira iteração, os componentes de onda curta e onda longa da radiação líquida são agrupados, e a divergência é calculada de acordo com a Equação 22 (Norman et al., 2000).

$$\Delta R_N = R_N * \left(1 - \exp\left(\frac{-k * F * \Omega_0}{\sqrt{2 \cos(\theta_s)}}\right)\right) \quad (22)$$

Em que:

θ_s = é o ângulo zenital solar;

k = coeficiente de extinção. $k = 0,45$ para $LAI > 2$ e $k = 0,8$ para $LAI < 2$.

Nas iterações seguintes, a divergência da radiação de ondas curtas e longas é tratada explicitamente para que $\Delta R_N = \Delta R_S + \Delta R_L$. ΔR_S é calculado da mesma forma que ΔR_N na primeira interação, com R_N substituído por R_S . Já ΔR_L é calculado pela Equação 23 (Kustas; Norman, 1999).

$$\Delta R_L = \tau * (R_{L,sky} + R_{L,S} - 2R_{L,C}) \quad (23)$$

$R_{L,sky}$ = radiação de onda longa do céu (calculado pela Equação 6, de $R_{L,in}$);

$R_{L,S}$ e $R_{L,C}$ = são as radiações de ondas longas emitidas do solo e do dossel, respectivamente (calculadas usando a equação de Stefan-Boltzmann e T_C e T_S);

τ = transmissividade da vegetação ($\tau = 1 - \exp(-k_L * F)$);

$k_L = 0,7$ para $LAI > 1$ e $k_L = 0,95$ para $LAI < 1$.

A partir de ΔR_N , é possível estimar o fluxo de calor sensível do dossel (H_C), usando a Equação 24, que consiste em uma aproximação de Priestley-Taylor (Norman et al., 2000).

$$H_C = \Delta R_N * (1 - \alpha_{PT} * f_g * \left(\frac{sp}{sp + \gamma}\right)) \quad (24)$$

Em que:

sp = é a inclinação da curva de pressão de saturação (Anexo 3 de Allen et al., 1998);

γ = é a constante psicométrica (Anexo 3 de Allen et al., 1998).

Inicialmente, admite-se que a vegetação está transpirando à uma taxa potencial, com o parâmetro de Priestley-Taylor, $\alpha_{PT} = 1,26$.

Com o valor de H_C , é estimado a temperatura do dossel (T_C), com a Equação 25 (Norman et al., 1995).

$$T_C = T_{C,lin} + \Delta T_C \quad (25)$$

O valor de $T_{C,lin}$ é uma aproximação linear da temperatura do dossel, dado pela Equação 26.

$$T_{C,lin} = \frac{\frac{T_A}{R_A} + \frac{T_R}{R_S(1-f_\theta)} + \frac{H_C * R_X}{\rho * c_p} * \left(\frac{1}{R_A} + \frac{1}{R_S} + \frac{1}{R_X}\right)}{\frac{1}{R_A} + \frac{1}{R_S} + \frac{f_\theta}{R_S(1-f_\theta)}} \quad (26)$$

O valor de ΔT_C representa o fator de correção, dado pela Equação 27, e T_D é dado pela Equação 28.

$$\Delta T_C = \frac{T_R^4 - f_\theta * T_{C,lin}^4 - (1-f_\theta) * T_D^4}{4 * (1-f_\theta) * T_D^3 * \left(1 + \frac{R_S}{R_A}\right) + 4 * f_\theta * T_{C,lin}^3} \quad (27)$$

$$T_D = T_{C,lin} * \left(1 + \frac{R_S}{R_A}\right) - \frac{H_C * R_X}{\rho * c_p} * \left(1 + \frac{R_S}{R_X} + \frac{R_S}{R_A}\right) - T_A * \frac{R_S}{R_A} \quad (28)$$

A temperatura do solo (T_S) é estimada pela Equação 29.

$$T_S = \left(\frac{T_R^4 - f_\theta * T_C^4}{1 - f_\theta}\right)^{0,25} \quad (29)$$

E a temperatura inter-dossel (T_{AC}) é estimada pela Equação 30.

$$T_{AC} = \frac{\frac{T_A}{R_A} + \frac{T_S}{R_S} + \frac{T_C}{R_X}}{\frac{1}{R_A} + \frac{1}{R_S} + \frac{1}{R_X}} \quad (30)$$

Em que:

R_A , R_S e R_X são as resistências aerodinâmica, do solo e do dossel, respectivamente.

T_A , T_S e T_C são as temperaturas do ar, do solo e do dossel, respectivamente.

Agora, depois de calcular todas as resistências e temperaturas, pode-se estimar os fluxos de calor sensível (H_C) e latente (LE_C) do dossel, pelas Equações 31 e 32, respectivamente.

$$H_C = \rho * c_p * \frac{T_C - T_{AC}}{R_X} \quad (31)$$

$$LE_C = \Delta R_N - H_C \quad (32)$$

Agora, obtém-se os fluxos de calor sensível (H_S) e latente (LE_S) do solo, pelas Equações 33 e 34, respectivamente.

$$H_S = \rho * c_p * \frac{T_S - T_{AC}}{R_S} \quad (33)$$

$$LE_S = R_{N,S} - G - H_S \quad (34)$$

O valor de $R_{N,S}$ é dado pela Equação 35.

$$R_{N,S} = R_N - \Delta R_N \quad (35)$$

O fluxo de calor do solo (G) é calculado pela Equação 36 (Liebethal; Foken, 2007).

$$G = 0,3 * R_{N,S} - 35 \quad (36)$$

Os fluxos de calor sensível (H) e latente (LE) são calculados pela soma dos componentes do solo e do dossel, de acordo com as Equações 37 e 38, respectivamente.

$$H = H_C + H_S = \rho c_p * \frac{T_{AC} - T_A}{R_A} \quad (37)$$

$$LE = LE_C + LE_S \quad (38)$$

Após calcular os fluxos, é possível recalculer o comprimento de Obukhov (L), por meio da Equação 39 (Brutsaert, 2005).

$$L = \frac{u_*^3}{\frac{k * g}{T_A} * \left(\frac{H}{\rho * c_p} + 0,61 * T_A * \frac{E}{\rho} \right)} \quad (39)$$

Em que:

g = constante gravitacional ($g = 9,8 \text{ m s}^{-2}$);

E = taxa de evaporação da superfície (kg m^{-2}) (derivada de LE, usando o Anexo 3 de Allen et al. (1998)).

Agora, a parte iterativa do modelo é executada novamente, com o novo valor de L , até que este convirja a um valor estável.

Quando o valor de L se estabilizar, deve-se observar:

- Se $LE_S < 0$: transpiração do dossel foi superestimada, o valor de α_{PT} é reduzido e a parte iterativa do modelo é rodada novamente;
- Se $\alpha_{PT} = 0$ e LE_S ainda < 0 : considera-se que não há evaporação ou transpiração no pixel modelado (Norman et al., 1995). Nesse caso:
 - $LE = LE_S = LE_C = 0$
 - $\alpha_{PT} = 0$
 - $H_C = \Delta R_N$
 - Aplica-se o limite: $H \leq R_N - G$ (porque é implausível que em um dia seco sem evapotranspiração o fluxo de calor do solo seja negativo)
 - Se $H < R_N - G$: qualquer energia residual é atribuída a G (Norman et al., 1995).

4.3.3 Aplicação do modelo Dual Temperature Difference (DTD)

Antes da aplicação do modelo DTD, foi preciso atentar-se a algumas observações:

- Princípio do modelo: substituir os valores absolutos da LST e da temperatura do ar por temperaturas diferenciais no tempo, a partir da diferença entre uma observação de satélite noturna (dados Aqua) e uma diurna (dados Terra e Aqua) (Guzinski et al., 2013).
- A formulação original do DTD utiliza as resistências (R_A , R_S , R_X) em paralelo, mas neste estudo, as resistências são usadas em série, como também foi considerado na aplicação do modelo TSEB, descrito no tópico anterior (Guzinski et al., 2013).

- O modelo DTD utiliza muitas das equações do modelo TSEB, porém algumas equações-chaves foram modificadas. Estas são descritas com mais detalhes a seguir.

A principal equação do modelo DTD é derivada de Anderson et al. (1997) (Equação 40), e considera a diferença das temperaturas diurnas e noturnas, desconsiderando os fluxos insignificantes do começo da manhã e noturnos (Norman et al., 2000).

$$H_1 = \rho * c_p * \left(\frac{(T_{R,1}(\theta_1) - T_{R,0}(\theta_0)) - (T_{A,1} - T_{A,0})}{(1 - f_{\theta,1}) * (R_{A,1} + R_{S,1})} \right) + H_{C,1} * \left(1 - \frac{f_{\theta,1}}{1 - f_{\theta,1}} * \frac{R_{A,1}}{R_{A,1} + R_{S,1}} \right) \quad (40)$$

Em que:

Os subscritos 0 e 1 referem-se as observações noturnas e diurnas, respectivamente;

$f_{\theta,1}$ = calculado como no TSEB;

$H_{C,1}$ = fluxo de calor sensível do dossel. É derivado usando a Equação 24 do modelo TSEB (aproximação de Priestley-Taylor), com ΔR_N estimado com os componentes de ondas curtas e longas de R_N agrupados.

As resistências também são calculadas da mesma forma que no modelo TSEB. Apenas uma mudança foi feita, substituindo o termo $\frac{z_u - d_0}{L}$ (Equação 12) por uma aproximação do número de Richardson (Ri), que é calculado usando as observações diferenciais no tempo, expressa pela Equação 41 (Norman et al., 2000).

$$R_i = -g * \frac{z_u - d_0}{T_{A,1}} * \frac{(T_{R,1} - T_{R,0}) - (T_{A,1} - T_{A,0})}{u_1^2} \quad (41)$$

Uma nova formulação para estimar o H_1 é usada, considerando as resistências em série. Primeiro, toma-se uma aproximação linear da Equação 1 do modelo TSEB, combinando-a com as Equações 31, 33 e 37 do TSEB, expresso pela Equação 42.

$$T_R - T_A = H * \left(\frac{(1 - f_\theta) * R_S + R_A}{\rho * c_p} \right) + H_C * \left(\frac{f_\theta * R_X - (1 - f_\theta) * R_S}{\rho * c_p} \right) \quad (42)$$

A Equação 42 é aplicada duas vezes (observação noturna e diurna), e rearranjada para a forma da Equação 43.

$$\begin{aligned} H_1 = \rho * c_p * & \left(\frac{(T_{R,1}(\theta_1) - T_{R,0}(\theta_0)) - (T_{A,1} - T_{A,0})}{(1 - f_{\theta,1}) * R_{S,1} + R_{A,1}} \right) + H_{C,1} \\ & * \left(\frac{(1 - f_{\theta,1}) * R_{S,1} - f_{\theta,1} * R_{X,1}}{(1 - f_{\theta,1}) * R_{S,1} + R_{A,1}} \right) + H_0 * \left(\frac{(1 - f_{\theta,0}) * R_{S,0} + R_{A,0}}{(1 - f_{\theta,1}) * R_{S,1} + R_{A,1}} \right) \\ & + H_{C,0} * \left(\frac{f_{\theta,0} * R_{X,0} - (1 - f_{\theta,0}) * R_{S,0}}{(1 - f_{\theta,1}) * R_{S,1} + R_{A,1}} \right) \end{aligned} \quad (43)$$

Os dois últimos termos da Equação 43 podem ser omitidos, pois considera-se os fluxos noturnos mínimos (Guzinski et al., 2013 e 2014).

O fluxo de calor latente (LE_1) é calculado como sendo o residual dos outros fluxos (Equação 44).

$$LE_1 = R_{N,1} - H_1 - G_1 \quad (44)$$

O fluxo de calor no solo (G_1) é calculado segundo Santanello e Friedl (2003), dado pela Equação 45.

$$G_1 = R_{N,S} * A * \cos \left(2\pi \frac{t + 10800}{B} \right) \quad (45)$$

Em que:

$$A = 0,0074 * \Delta T_R + 0,088;$$

$$B = 1729 * \Delta T_R + 65013;$$

$$\Delta T_R = T_{R,1} - T_{R,0};$$

t = tempo entre o tempo de observação e o meio-dia solar (s);

$R_{N,S}$ = é a radiação líquida atingindo o solo se o sol está no nadir, dado por:

$$R_{N,S} = R_N * \exp(-k * F * \Omega_0);$$

k = 0,45 para LAI > 2 e k = 0,8 para LAI < 2;

Ω_0 = fator de aglomeração no nadir.

O fluxo de calor latente do solo ($LE_{S,1}$) é derivado como sendo o residual do balanço de energia do solo (Equação 46).

$$LE_{S,1} = (R_{N,1} - \Delta R_{N,1}) - (H_1 - H_{C,1}) - G_1 \quad (46)$$

Da mesma forma que no modelo TSEB, se $LE_{S,1} < 0$, considera-se que a transpiração do dossel foi superestimada, então, α_{PT} é reduzido e $H_{C,1}$, H_1 e $LE_{S,1}$ são recalculados. Se $LE_{S,1}$ ainda for < 0 e $\alpha_{PT} = 0$, é seguido o mesmo processo que foi apresentado para o modelo TSEB (Normal et al., 1995), descrito no tópico 4.3.2.

4.3.4 Extrapolação dos fluxos instantâneos para diários

Os fluxos de calor estimados pelo modelo TSEB-DTD consistem em valores instantâneos, isto é, no momento da passagem do satélite. Anderson et al. (1997) já encontraram diferenças de até 10% entre os valores instantâneos e os valores diários dessas estimativas. Para extrapolar o fluxo de calor latente instantâneo (LE em $W m^{-2}$) para um valor diário de evapotranspiração (ET em $mm dia^{-1}$), foi utilizado os fatores de conversão de Allen et al. (1998), descritos no guia de Evapotranspiração nº 56 da FAO (*Food and Agriculture Organization of the United Nations*).

A conversão se baseia no calor latente de vaporização da água à uma temperatura de $20^{\circ} C$ e densidade de $1000 kg m^{-3}$. Dessa forma, a seguinte relação foi aplicada: $1 LE (MJ m^{-2} dia^{-1}) = 0,408 ET (mm dia^{-1})$, sendo $1 W m^{-2} = 0,0864 MJ m^{-2} dia^{-1}$.

4.4 Determinação da evapotranspiração utilizando o método *Eddy Covariance* (EC)

Os fluxos turbulentos de vapor de água são monitorados pelo método da correlação de turbilhões, ou *Eddy Covariance* (EC). A instrumentação do sistema EC consiste em um analisador de gases de caminho aberto e um anemômetro sônico em um único sensor (Campbell Scientific's IRGASON[®]), e as medições são realizadas em alta frequência (20 Hz). O método EC determina a evapotranspiração (ET) utilizando a Equação 49.

$$ET = -\rho_{ar} \frac{0,622}{P_{atm}} \overline{w'e_a'} \quad (49)$$

Em que:

ρ_{ar} = massa específica do ar ($kg m^{-3}$);

P_{atm} = pressão atmosférica (kPa);

w' = velocidade vertical média do vento ($m s^{-1}$);

e_a' = pressão parcial média de vapor do ar (kPa);

w' e e_a' calculados a partir de valores medidos em um dado período.

O processamento dos dados de alta frequência foi realizado utilizando o *software* EddyPro v7.0.6 da LI-COR® Biosciences a partir do arquivo de metadata gerado pelo *software* EasyFlux® DL da Campbell Scientific. Utilizou-se também a ferramenta EC-LHC, desenvolvida na Dissertação de Mestrado de Alex Naoki Asato Kobayashi (Kobayashi, 2021). Os códigos escritos em Python, estão detalhados e disponibilizados em <<https://github.com/alexnaoki/EC-LHC>>.

Nos subtópicos seguintes são apresentados um breve resumo das etapas de pré-processamento e processamento dos dados. Todos os métodos e abordagens que foram usados nessa pesquisa estão amplamente descritos e detalhados em Kobayashi (2021).

4.4.1 Pré-processamento dos dados

A primeira etapa do pré-processamento consiste na remoção e filtragem de valores inválidos ou imprecisos (p.e.: valores NaN, picos anômalos e os limites dos equipamentos de medição). Esse procedimento é importante para que sejam utilizados apenas dados confiáveis, para não comprometer as análises dos fluxos medidos.

Em seguida, é realizada a rotação de coordenadas ou correção dos ventos horizontais. Essa rotação é feita para garantir que as medições dos fluxos estejam perpendiculares às linhas aerodinâmicas médias do terreno, ou seja, que a velocidade do vento vertical é nula (Baldocchi, 2019). Para isso, utilizou-se o método da Regressão Planar (Wilczak; Oncley; Stage, 2001), em que uma equação é ajustada para que a velocidade vertical média do vento fique próxima de zero.

4.4.2 Processamento dos dados

O primeiro passo do processamento dos dados é a aplicação da correção sônica ou SND (Schotanus; Nieuwstadt; De Bruin, 1983), que consiste na transformação da

temperatura sônica do ar em temperatura do ar real. Isso é necessário porque a medição da temperatura sônica não considera a presença de vapor d'água. A correção é feita utilizando a Equação 50:

$$T_C = \frac{T_S}{\frac{1 + 0,32 * \rho_{H_2O} * R * T_S}{p * 18,02}} \quad (50)$$

Em que:

T_S = temperatura sônica (K);

T_C = temperatura do ar real (K);

R = constante universal dos gases (8,314 462 618 J mol⁻¹ K⁻¹);

p = pressão do ambiente (atm);

ρ_{H_2O} = densidade da água (997 kg/m³).

Em seguida, são realizadas as correções espectrais, que são necessárias uma vez que não é possível o sistema EC não ter nenhum efeito sobre os fluxos medidos. Os equipamentos possuem uma resposta de captura de sinal do tipo discreto e não contínuo, além de não amostrarem exatamente a mesma parcela de ar simultaneamente (Moncrieff et al., 1997). De forma geral, a atenuação do fluxo é descrita por funções de transferência multiplicadas pelo co-espectro ideal. Foram aplicadas correções espectrais para os intervalos de baixa e alta frequências utilizando o método proposto por Moncrieff et al. (1997), cuja funções de transferência são a resposta do sensor, o intervalo médio e a separação dos sensores (anemômetro sônico e analisador de gases).

Por fim, tem-se a aplicação dos termos Webb-Pearman-Leuning (termos WPL) (WEBB; PEARMAN; LEUNING, 1980). Os termos WPL são usados para compensar as flutuações na densidade dos gases, resultante de flutuações na temperatura e conteúdo de vapor d'água. São adicionados aos valores do fluxo de água dois termos, o de diluição da água e o de expansão termal (Burba, 2013).

4.4.3 Controle de qualidade

Os dados de fluxos podem ser descartados por diversas razões, como mau funcionamento dos equipamentos e sensores, condições ambientais não satisfatórias para aplicação da metodologia, precipitação forte, ventos provenientes de área fora do campo de interesse, entre outros (Burba, 2013). O controle de qualidade tem como objetivo a classificação da qualidade dos fluxos medidos em um intervalo médio de 30 minutos. Nesse processo, é possível separar os dados em insatisfatórios, aceitáveis e ótimos.

Primeiramente, são aplicados o teste de estado estacionário e o teste das características integrais de turbulência. O primeiro avalia a variação dos parâmetros estatísticos dentro do intervalo de análise de 30 minutos (Vickers; Mahrt, 1997; Mahrt, 1998; Foken; Wichura, 1996). Já o segundo, verifica as características integrais de turbulência a partir de funções modelo dependentes do desvio padrão normalizado das componentes de velocidade do vento e dos escalares, e da estabilidade atmosférica (Kaimal; Finnigan, 1994; Foken; Wichura, 1996; Aubinet; Vesala; Papale, 2012). A partir do desempenho dos dois testes, os fluxos são classificados quanto ao grau de qualidade (boa ou ruim).

Depois, foi determinado o fechamento do balanço de energia (Equação 51), como forma de validação dos fluxos medidos pelo método EC. Isso porque, se a soma de todos os componentes do balanço de energia for zero, todas as transferências de energia foram devidamente contabilizadas, e os fluxos medidos corretamente (Burba, 2013).

$$R_N - H - LE - G \cong 0 \quad (51)$$

Em que:

R_N = radiação líquida ($W m^{-2}$);

H = fluxo de calor sensível ($W m^{-2}$);

LE = fluxo de calor latente ($W m^{-2}$);

G = fluxo de calor no solo (W m^{-2}).

4.4.4 Determinação da área de contribuição ou footprint

A área de contribuição, ou *footprint*, é a extensão responsável por gerar os fluxos medidos pelos equipamentos do sistema EC. Para determinar a origem dos fluxos, foi utilizado o método desenvolvido por Kljun et al. (2015), uma versão aprimorada de Kljun et al. (2004). O método é composto pelas seguintes etapas: (1) Cálculo da distância não dimensional contra o vento em função de x ; (2) Cálculo da parametrização do *Footprint* não dimensional; (3) Cálculo da função do *Footprint* integrada ao vento cruzado e ao desvio padrão; e (4) Cálculo do *Footprint* propriamente dito (Kljun et al., 2015). Para a implementação do método, foi utilizado o código na linguagem Python disponibilizado pelos autores.

4.4.5 Preenchimento de falhas

A série histórica de dados utilizada nessa pesquisa apresenta períodos sem medições, causados por falhas ou mau funcionamento dos equipamentos. Além disso, após a filtragem e remoção de valores inválidos ou nulos, esse período tende a aumentar. Essa fragmentação na série histórica é prejudicial, pois dificulta as análises temporais dos resultados (diária, mensal, anual). Na tentativa de amenizar esse problema, foram aplicados alguns métodos para preenchimento das falhas: (1) Variação diurna média; (2) Regressão linear múltipla; (3) Regressão logística ou *Random Forest*; (4) Redes neurais (NN); (5) Redes neurais densas (DNN); (6) Redes neurais recorrentes (RNN); (7) Redes de memória longa de curto prazo (LSTM); e (8) Equação de Penman-Monteith inversa.

4.5 Análises estatísticas dos resultados

As análises estatísticas foram realizadas para as estimativas de evapotranspiração, utilizando a linguagem de programação Python. Foram realizadas comparações estatísticas dos fluxos modelados (método *Two Source Energy Balance- Dual Temperature Difference*) com os fluxos medidos ou observados (método *Eddy Covariance*). As métricas utilizadas estão descritas ao longo desse tópico.

O viés ou *Bias* indica o erro sistemático, ou seja, a subestimativa ou superestimativa dos dados simulados, e é dado em $W m^{-2}$, mesma unidade dos fluxos (Equação 52).

$$VIÉS = \frac{\sum_{i=1}^n (P_i - O_i)}{n} \quad (52)$$

Em que:

O_i = dados observados ($W m^{-2}$);

P_i = dados simulados ou preditos ($W m^{-2}$);

n = número de dados.

A Raiz do Erro Quadrático Médio (RMSE) representa a medida do desvio médio entre o valor observado (real) e o simulado (predito). A RMSE apresenta valores do erro nas mesmas dimensões da variável analisada, neste caso, $W m^{-2}$. É expressa pela Equação 53.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (53)$$

Em que:

O_i = dados observados ($W m^{-2}$);

P_i = dados simulados ou preditos ($W m^{-2}$);

n = número de dados.

O coeficiente de variação (CV) analisa a dispersão, em termos relativos, de uma distribuição de probabilidade ou de uma distribuição de frequências, e é expresso em porcentagem (%), de acordo com a Equação 54.

$$CV = \frac{S}{\bar{X}} * 100 \quad (54)$$

Em que:

S = desvio padrão;

\bar{X} = média dos dados.

O coeficiente de correlação de Pearson (ρ) mede o grau da correlação linear entre duas variáveis quantitativas (x_i e y_i), e é expresso pela Equação 55.

$$\rho = \frac{\sum_i (x_i - \bar{x}) * (y_i - \bar{y})}{\sqrt{\sum_i (x_i - \bar{x})^2 * \sum_i (y_i - \bar{y})^2}} \quad (55)$$

Em que:

\bar{x} = média da variável x_i ;

\bar{y} = média da variável y_i .

Trata-se de um índice adimensional, que varia de -1 a 1, sendo:

$\rho = 1$: correlação perfeita positiva entre as duas variáveis;

$\rho = -1$: correlação perfeita negativa entre as duas variáveis;

$\rho = 0$: variáveis não possuem dependência linear uma com a outra. Quando $\rho = 0$, deve-se investigar utilizando outros métodos.

4.6 Período de dados estimados pelo TSEB-DTD

O modelo baseado em sensoriamento remoto aplicado foi o *Two Source Energy Balance - Dual Time Difference* (TSEB-DTD), por meio dos dados do sensor MODIS, e utilizando o código de livre acesso pyTSEB (Anexo I). A janela de aplicação foi baseada na disponibilidade de medições do sistema *Eddy Covariance* (EC), que é de 05/10/2018 a 21/01/2021 (Anexo II).

Por questões de falhas e problemas técnicos com os equipamentos instalados em campo, os dados de Kobayashi (2021) apresentam períodos sem medições da evapotranspiração e de outras variáveis meteorológicas, mesmo após aplicação de técnicas de preenchimento de falhas. Portanto, o período de 05/10/2018 a 21/01/2021 não é contínuo em termos de medições e aquisição de dados.

Por outro lado, os produtos derivados das imagens MODIS também apresentam descontinuidade, tal fato se explica principalmente por fatores como a cobertura por nuvens, que podem obstruir a visibilidade da superfície terrestre, e falhas técnicas durante a aquisição, transmissão ou processamento das imagens de satélite. Dessa forma, o TSEB-DTD gerou resultados apenas nos dias em que se possuía tanto dados meteorológicos quanto dados dos satélites. Logo, considerando a disponibilidade dos dados apontados, o TSEB-DTD gerou resultados entre 08/12/2019 e 25/11/2020. Desse período, desconsiderando os dados inválidos, foram geradas saídas para 144 dias.

Tais limitações são comuns em estudos baseados em sensoriamento remoto, pois, embora existam cada vez mais métodos de coleta de dados espaciais, como satélites, drones, aeronaves e estações terrestres, ainda é corriqueiro deparar-se com lacunas e inconsistências nos dados de sensoriamento remoto (Zakeri; Mariethoz, 2021).

5. RESULTADOS E DISCUSSÃO

5.1 Manual do usuário do pyTSEB

Um dos produtos dessa pesquisa de Doutorado foi a elaboração de um manual do usuário para aplicação e reprodução desse trabalho utilizando o código pyTSEB, disponível na íntegra no Apêndice II.

A documentação apresenta os dados de entrada requeridos pelo modelo, tanto os do sensor MODIS quanto os dados meteorológicos, as transformações realizadas, adaptações, forma de visualização dos resultados, principais saídas e observações relevantes. Além disso, o manual também apresenta um passo-a-passo de como instalar todos os recursos necessários para rodar o código corretamente no computador ou notebook.

A produção do manual não estava listada como um objetivo no início do trabalho, mas foi necessária, pois, apesar do pyTSEB ser um código de livre acesso, as informações nem sempre estão claras e disponíveis. Dessa forma, a presença de um manual torna-se o entendimento mais fácil.

5.2 Série de ET estimada e observada

De acordo com Kobayashi (2021), a série diária de evapotranspiração que forneceu o melhor resultado em termos de métricas estatísticas, foi a série preenchida

com o método *Random Forest* (ET_{RFR}). Dessa forma, a ET_{RFR} , também chamada de ET observada, foi utilizada nesta tese para fins comparativos com os resultados preditos pelo modelo TSEB-DTD (ET_{pred}).

Para a construção da série gerada pelo TSEB-DTD (apresentada na Figura 10), foram descartadas saídas menores ou iguais a zero, considerando improvável um dado de evapotranspiração zero ou negativo, e valores extremos acima do percentil de 99% (1% superiores dos dados). Estes valores foram considerados não aplicáveis (N/A) pois são pontos fora do padrão esperado ou exceções à tendência geral dos dados. A série histórica contendo os resultados de evapotranspiração observados (ET_{RFR}) e estimados (ET_{pred} e $ET_{pred/2,8}$) está apresentada no gráfico da Figura 10.

O valor médio estimado, ET_{pred} , para o período analisado foi de 8,3 mm dia⁻¹. Já a média observada, ET_{RFR} , foi de 3,1 mm dia⁻¹, para o mesmo período. É possível notar na Figura 10 que, mesmo seguindo uma tendência semelhante, os resultados gerados pelo TSEB-DTD são, em média, superestimados em mais de duas vezes em relação aos valores observados.

Para conseguir uma visualização na mesma escala dos valores observados (ET_{RFR}), foi aplicado um fator divisor de 2,8 na série de evapotranspiração estimada, resultando na $ET_{pred/2,8}$. O fator 2,8 é resultado da razão entre as médias dos dados. Agora, na mesma escala, é possível observar que, apesar de seguir uma tendência parecida, a série $ET_{pred/2,8}$ possui picos mais acentuados, tanto superiores quanto inferiores, quando comparado com o comportamento da ET_{RFR} . Por se tratar de medições em uma escala de tempo diária, a presença de picos é mais comum do que se fossem medições mensais ou anuais.

Em termos sazonais, o valor de evapotranspiração médio estimado pelo modelo TSEB-DTD nos meses de janeiro e fevereiro de 2020 (período chuvoso) foi de 10,8 mm dia⁻¹, enquanto nos meses de julho e agosto de 2020 (estiagem), essa média caiu para 4,8 mm dia⁻¹.

De acordo com Kobayashi (2021), a média da série de ET para o período chuvoso do ano de 2020 foi de 3,7 mm dia⁻¹, e para o período seco foi de 2,5 mm dia⁻¹. Analisando ambos os resultados, observa-se que a diferença mais acentuada entre a evapotranspiração estimada e observada se encontra no período chuvoso, em que as estimativas

superestimam em $7,1 \text{ mm dia}^{-1}$ os dados observados. Enquanto no período de estiagem a ET_{pred} superestima em $2,3 \text{ mm dia}^{-1}$ a ET_{RFR} .

A diminuição da ET durante os meses da estação seca, que no Cerrado pode durar desde maio a setembro, sugere que a disponibilidade reduzida de umidade pode limitar o processo de evapotranspiração, como consequência de uma combinação de fatores envolvendo a redução da evaporação do solo, da condutância estomática e do índice de área foliar da vegetação (Biudes et al., 2015; Giambelluca et al., 2009). Isso significa que há menor liberação de água pelo solo, as plantas reduzem a perda de água, enfrentando um aumento do estresse térmico, e, com o índice de área foliar reduzido, a taxa de transpiração das plantas pode diminuir.

Outros estudos realizados em áreas semelhantes do Brasil também avaliaram a evapotranspiração no Cerrado *sensu stricto*. Cabral et al. (2015) reportaram valores de evapotranspiração variando de 1 mm dia^{-1} para a estação seca (agosto de 2010) e de $7,1 \text{ mm dia}^{-1}$ na estação chuvosa (fevereiro de 2012), em uma área de Cerrado localizada a cerca de 80 km de distância da área de estudo.

Oliveira et al. (2015) realizaram uma estimativa da evapotranspiração por meio de um modelo empírico na mesma área de Cerrado *sensu stricto* abordada nesta pesquisa. O valor médio encontrado para a ET foi de $2,6 \text{ mm dia}^{-1}$ para a estação chuvosa e $1,9 \text{ mm dia}^{-1}$ para a estação seca.

Oliveira (2018) encontrou uma variação sazonal da evapotranspiração entre o período seco e chuvoso do ano de 2014 entre $2,7$ e $6,9 \text{ mm dia}^{-1}$, em uma região de Cerrado *sensu stricto* localizada na Reserva Ecológica do IBGE a 26 km de Brasília/DF.


Giambelluca et al. (2009) avaliaram duas áreas de Cerrado, do tipo denso e campo, na mesma região da Reserva Ecológica do IBGE em Brasília/DF, entre os anos de 2001 e 2003. No Cerrado denso, a média da ET para os meses de estiagem chegou a $2,5 \text{ mm dia}^{-1}$, e para os meses chuvosos alcançou $3,2 \text{ mm dia}^{-1}$. Já no Cerrado campo, a média da ET para os meses de estiagem chegou a $2,0 \text{ mm dia}^{-1}$, e para os meses chuvosos alcançou $2,9 \text{ mm dia}^{-1}$. No entanto, Giambelluca et al. (2009) destacam que os anos analisados foram períodos relativamente secos, com precipitações anuais abaixo de 80% da média.

Anache et al. (2019) avaliaram o balanço hídrico de áreas com diferentes coberturas do solo, onde a evapotranspiração foi estimada com base em variáveis como

temperatura, umidade relativa, radiação solar e umidade do solo. No Cerrado, as incertezas relativas da evapotranspiração estimada chegaram a 53%.

Dessa forma, é importante destacar que todas as medições de evapotranspiração contêm erros, podendo ocorrer tendências significativas de medição incorretas ou extrapolações nos conjuntos de dados. O fator humano também deve ser levado em consideração quando trabalhamos com métodos baseados em sensoriamento remoto, haja visto que, erros podem acontecer tanto com especialistas na área (5 a 15% de erro) quanto com pessoas que não possuem familiaridade com o tema ET (30 a 40% de erro). Além de erros relacionados ao mau funcionamento dos equipamentos, que giram em torno de 5 a 10% (Allen et al., 2011).

Figura 10. Série de evapotranspiração medida pelo método *Eddy Covariance* (ET_{RFR}) e predita pelo modelo TSEB-DTD (ET_{pred}).



Fonte: Autor (2023).

5.3 Avaliação da metodologia TSEB-DTD

Os valores de evapotranspiração preditos pelo modelo TSEB-DTD, ou ET_{pred} (mm dia^{-1}), foram comparados com as medições de ET observadas por meio da metodologia do *Eddy Covariance* (EC), ou ET_{RFR} (mm dia^{-1}) (Kobayashi, 2021).

Foram analisadas as métricas: viés, RMSE, coeficiente de variação dos dados de referência (ET_{RFR}), coeficiente de variação dos dados estimados (ET_{pred}) e coeficiente de correlação de Pearson (ρ). Os resultados estão descritos na Tabela 4.

Tabela 4. Métricas estatísticas aplicadas nos resultados gerados pelo modelo TSEB-DTD (ET_{pred}) em comparação com os dados de referência (ET_{RFR}) (Fonte: Autor, 2023).

X	Y	n	Viés (mm dia^{-1})	RMSE (mm dia^{-1})	Coeficiente de Variação ET_{RFR}	Coeficiente de Variação TSEB-DTD	Coeficiente de Correlação de Pearson (ρ)
0	0	118	4.192	5.745	0.253	0.599	0.566
0	1	111	4.565	6.148	0.267	0.604	0.633
0	2	80	171.774	766.667	0.265	4.296	-0.003
0	3	123	4.265	5.563	0.259	0.558	0.661
0	4	129	4.017	5.330	0.260	0.562	0.621
0	5	120	4.081	5.377	0.265	0.563	0.675
0	6	119	3.943	5.412	0.257	0.590	0.587
0	7	128	4.330	5.321	0.258	0.488	0.680
0	8	131	4.265	5.219	0.257	0.478	0.662
0	9	132	4.308	5.327	0.256	0.491	0.650
1	0	119	4.258	5.692	0.253	0.575	0.582
1	1	116	4.462	5.929	0.268	0.583	0.623
1	2	105	4.480	6.091	0.266	0.615	0.663
1	3	119	4.090	5.607	0.260	0.596	0.565
1	4	124	4.318	5.579	0.262	0.545	0.643
1	5	112	4.070	5.374	0.256	0.555	0.626
1	6	109	4.162	5.578	0.257	0.575	0.635
1	7	126	3.927	5.146	0.258	0.541	0.614
1	8	127	3.996	5.157	0.255	0.528	0.620
1	9	122	4.508	5.743	0.258	0.528	0.596
2	0	129	4.502	5.596	0.254	0.502	0.635
2	1	119	4.004	5.615	0.262	0.621	0.595

2	2	114	4.216	5.784	0.261	0.605	0.601
2	3	112	4.437	5.667	0.257	0.530	0.624
2	4	114	4.228	5.555	0.260	0.555	0.598
2	5	123	3.761	5.093	0.261	0.561	0.537
2	6	106	3.990	5.467	0.263	0.585	0.544
2	7	102	3.518	5.053	0.261	0.608	0.514
2	8	109	3.295	4.828	0.256	0.612	0.504
2	9	109	3.439	4.848	0.255	0.584	0.520
3	0	131	4.403	5.521	0.252	0.508	0.627
3	1	119	4.187	5.482	0.262	0.553	0.631
3	2	117	4.048	5.542	0.261	0.592	0.578
3	3	117	4.163	5.475	0.259	0.558	0.628
3	4	121	4.141	5.342	0.257	0.533	0.630
3	5	126	3.948	5.155	0.258	0.537	0.605
3	6	124	3.888	5.093	0.258	0.533	0.571
3	7	116	3.633	4.940	0.262	0.568	0.606
3	8	111	3.458	4.941	0.265	0.598	0.517
3	9	111	3.460	5.016	0.253	0.622	0.577
4	0	130	5.466	6.170	0.252	0.402	0.760
4	1	137	5.041	5.938	0.256	0.446	0.642
4	2	136	4.836	5.832	0.256	0.468	0.592
4	3	135	4.486	5.623	0.257	0.502	0.538
4	4	135	4.566	5.541	0.258	0.470	0.602
4	5	131	4.906	5.747	0.260	0.441	0.689
4	6	131	4.932	5.733	0.258	0.428	0.670
4	7	130	3.924	5.070	0.257	0.522	0.594
4	8	127	3.915	5.118	0.257	0.532	0.570
4	9	100	3.322	4.774	0.257	0.592	0.521
5	0	130	5.127	5.772	0.255	0.390	0.736
5	1	137	5.038	5.886	0.256	0.437	0.664
5	2	135	4.927	5.748	0.261	0.432	0.656
5	3	134	4.428	5.507	0.258	0.491	0.553
5	4	132	4.456	5.530	0.263	0.496	0.601
5	5	127	4.757	5.721	0.257	0.463	0.603
5	6	125	4.837	5.776	0.258	0.455	0.606
5	7	124	3.876	5.118	0.261	0.548	0.609
5	8	131	3.945	5.159	0.258	0.536	0.589
5	9	119	3.261	4.608	0.257	0.582	0.582
6	0	127	4.671	5.067	0.248	0.327	0.789
6	1	129	5.426	5.700	0.252	0.274	0.814
6	2	129	5.426	5.700	0.252	0.274	0.814
6	3	140	6.015	6.521	0.259	0.337	0.722
6	4	140	5.937	6.601	0.256	0.375	0.659
6	5	134	5.319	6.046	0.258	0.404	0.667

6	6	133	4.699	5.805	0.256	0.489	0.516
6	7	130	4.331	5.527	0.257	0.523	0.566
6	8	134	4.523	5.614	0.256	0.502	0.628
6	9	115	3.812	5.010	0.260	0.539	0.612
7	0	127	4.671	5.067	0.248	0.327	0.789
7	1	129	5.426	5.700	0.252	0.274	0.814
7	2	129	5.426	5.700	0.252	0.274	0.814
7	3	140	5.996	6.497	0.256	0.337	0.740
7	4	140	5.931	6.599	0.256	0.377	0.662
7	5	138	5.194	5.973	0.256	0.411	0.600
7	6	137	5.493	6.137	0.256	0.378	0.675
7	7	136	4.493	5.529	0.255	0.490	0.626
7	8	136	4.647	5.584	0.255	0.465	0.647
7	9	119	3.644	4.896	0.260	0.561	0.641
8	0	131	4.244	4.669	0.252	0.338	0.738
8	1	131	5.342	5.616	0.254	0.277	0.823
8	2	131	5.342	5.616	0.254	0.277	0.823
8	3	139	5.700	5.999	0.258	0.278	0.778
8	4	139	5.700	5.999	0.258	0.278	0.778
8	5	138	5.653	6.323	0.254	0.383	0.681
8	6	137	5.743	6.379	0.254	0.371	0.667
8	7	130	4.296	5.291	0.261	0.478	0.572
8	8	131	4.350	5.335	0.260	0.477	0.598
8	9	119	3.594	4.917	0.265	0.569	0.566
9	0	124	4.770	5.347	0.257	0.373	0.692
9	1	131	5.342	5.616	0.254	0.277	0.823
9	2	131	5.342	5.616	0.254	0.277	0.823
9	3	139	5.700	5.999	0.258	0.278	0.778
9	4	139	5.700	5.999	0.258	0.278	0.778
9	5	138	5.720	6.360	0.254	0.375	0.691
9	6	138	5.735	6.417	0.254	0.383	0.667
9	7	130	4.367	5.219	0.262	0.443	0.596
9	8	128	4.470	5.391	0.261	0.458	0.587
9	9	116	3.762	4.952	0.266	0.536	0.579


X: coordenada x
Y: coordenada y
n: número de dados

Cada métrica apresentada na Tabela 4 está descrita com mais detalhes nos subtópicos seguintes.

5.3.1 Viés

A métrica viés (*bias*) refere-se à tendência sistemática de um estimador para, em média, subestimar ou superestimar o parâmetro que está sendo estimado. Analisando o conjunto de pixels da imagem representada pela Figura 11, (coordenadas x e y), pode-se observar um viés médio de aproximadamente $4,5 \text{ mm dia}^{-1}$. Isso significa que o valor médio estimado da evapotranspiração está, em média, desviado em torno de 4,5 unidades da evapotranspiração observada (ET_{RFR}). Esse viés positivo indica que os valores estimados pelo modelo estão superestimados em comparação com os dados medidos.

Figura 11. Viés estatístico aplicado nos dados estimados e observados.



Fonte: Autor (2023).


O pixel de coordenadas (2, 0) destoa-se consideravelmente dos demais, com valor acima de 150 mm dia^{-1} , sugerindo uma possível falha na aquisição dos dados do satélite, impossibilitando o cálculo pelo modelo.

5.3.2 Raiz do Erro Quadrático Médio (RMSE)

A RMSE é uma medida de erro que quantifica o desvio entre as previsões do modelo e os valores observados. A métrica não fornece informações sobre a direção específica dos erros (subestimação ou superestimação). Mas, em geral, quanto menor for o valor da RMSE, melhor será a precisão do modelo.

Analisando o conjunto de pixels da imagem representada pela Figura 12, (coordenadas x e y), pode-se observar uma RMSE média de aproximadamente 5,5 mm dia⁻¹. Isso indica que as previsões do modelo estão, em média, desviadas em torno de 5 mm dia⁻¹ em relação aos valores observados (ET_{RFR}).

Figura 12. RMSE aplicado nos dados estimados e observados.



Fonte: Autor (2023).

Da mesma forma que ocorreu com o viés, o pixel de coordenadas (2, 0) destoa-se consideravelmente dos demais, com valor acima de 700 mm dia⁻¹, indicando uma possível deficiência na aquisição dos dados do satélite, prejudicando o cálculo pelo modelo.

5.3.3 Coeficiente de variação (CV)

O CV fornece uma medida relativa da variabilidade em relação à média e é útil para comparar a dispersão de diferentes conjuntos de dados. Ele indica o quanto os valores estão dispersos em relação à média da distribuição, permitindo avaliar a consistência ou a homogeneidade relativa das distribuições.

De acordo com o apresentado na Tabela 4, o valor médio do CV para os dados de referência (ET_{RFR}) foi de 0,26 ou 26%, sugerindo menor variabilidade relativa em relação à média, ou seja, que os valores da distribuição estão mais próximos da média e mais concentrados.


Ainda observando os dados da Tabela 4, o valor médio do CV para os dados estimados pelo TSEB-DTD (ET_{pred}) foi de 0,47 ou 47%. Esse valor um pouco maior que o referente ao CV dos dados de referência (ET_{RFR}), pode indicar que os valores da distribuição da ET_{pred} estão mais dispersos em torno da média, ou seja, pode sugerir uma maior variabilidade relativa em relação à média.

5.3.4 Coeficiente de correlação de Pearson (ρ)

O coeficiente de correlação de Pearson (ρ) é uma medida estatística que avalia a relação linear entre duas variáveis contínuas. Ele mede a força e a direção dessa relação linear, variando de -1 a 1.

De acordo com os dados da Tabela 4 e o conjunto de pixels da imagem representada pela Figura 13 (coordenadas x e y), pode-se observar um ρ médio de aproximadamente 0,6, indicando um valor moderadamente forte de correlação positiva. No contexto da evapotranspiração, isso indica que existe uma relação linear razoavelmente forte entre as variáveis em análise.

Figura 13. Coeficiente de correlação de Pearson (ρ) aplicado nos dados estimados e observados.



Fonte: Autor (2023).

Ainda observando a Figura 12, nota-se que a região que possui maior correlação está localizada fora da área de estudo. Valores de ρ igual a 0,9 são observados em uma região Sudoeste ao Cerrado, indicando um possível deslocamento dos resultados gerados pelo modelo TSEB-DTD.

Assim como ocorreu com o viés e o RMSE, o pixel de coordenadas (2, 0) difere-se consideravelmente dos demais, com valor de -0,003, sugerindo uma possível ausência ou erro na aquisição dos dados do satélite, comprometendo o cálculo pelo modelo.

5.4 Observações e limitações

Foram identificadas diversas observações pertinentes que merecem ser mencionadas. Essas observações fornecem *insights* adicionais e complementares aos resultados obtidos, contribuindo para uma compreensão mais abrangente do tema em questão. A seguir, destacamos algumas das observações mais relevantes que surgiram ao longo do desenvolvimento desta pesquisa.

A superestimação dos resultados de evapotranspiração gerados pelo modelo TSEB-DTD pode ter influência de uma combinação de fatores. O primeiro fator são os possíveis erros na modelagem. O TSEB-DTD é um modelo baseado em dados de sensoriamento remoto, e depende de uma série de algoritmos e equações para calcular os resultados. Além disso, uma gama extensa de dados de entrada é necessária para rodar o modelo de forma satisfatória. As limitações estão relacionadas à simplificação que o modelo precisa fazer, ou até mesmo pelo autor, por falta ou escassez de dados, podendo levar a estimativas imprecisas.

Outro fator limitante observado foi a heterogeneidade da vegetação do Cerrado em estudo, com mais de 120 espécies arbustivas e arbóreas (Reys et al., 2013). Os dados utilizados para representar a vegetação foram baseados em valores padrão para vegetação arbustiva, o que limita a consideração da ampla variedade de espécies e suas diferenças morfológicas e fisiológicas. Contudo, testes foram feitos no momento da modelagem usando o código pyTSEB, atribuindo diferentes valores para os dados de entrada relativos à vegetação, e pouquíssima diferença foi vista nos resultados. Então, isso pode indicar que, talvez os dados vegetativos usados no modelo não possuem um peso tão relevante no resultado gerado. Mas, para afirmar essa hipótese, mais estudos devem ser avaliados e testados na área de estudo, utilizando dados e parâmetros mais refinados.

Embora o Cerrado seja um dos biomas mais extensos e importantes do Brasil, ainda há uma enorme carência de estudos específicos sobre a evapotranspiração nesses ambientes. Um dos motivos, pode ser a complexidade e diversidade do bioma, dificultando a generalização e o estabelecimento de padrões abrangentes para a evapotranspiração dessa vegetação como um todo (Allen et al., 2011). Além disso, é importante ressaltar que o Brasil possui uma escassez de torres de fluxo instaladas em áreas de Cerrado (Oliveira et al., 2015), o que contribui para a deficiência de dados observados de evapotranspiração e outras variáveis meteorológicas nesse contexto.

Por isso, o uso de metodologias combinadas ainda é visto como a melhor opção para estudos sobre evapotranspiração em áreas complexas (Anderson et al. 2011), como o Cerrado. Dessa forma, na ausência de medições diretas realizadas pelas torres de fluxo, uma alternativa mais acessível se dá pelo uso de modelos empíricos, modelos matemáticos baseados em sensoriamento remoto, modelos baseados em transferência de calor e massa, entre outros. Contudo, o uso das diferentes metodologias deve ser

combinado com o controle de qualidade e avaliação dos dados, com o objetivo de produzir resultados precisos de evapotranspiração, condizentes com o objeto de estudo (Allen et al., 2011).

Estudos das componentes do balanço hídrico, que envolvem evapotranspiração, precipitação, escoamento superficial, armazenamento de água no solo, fluxo subsuperficial e percolação, ainda precisam avançar nas áreas de cobertura vegetal não alterada, como é o caso do Cerrado *sensu stricto*. Por envolver diversos fatores, a ET é uma medida carregada de incertezas, que pode levar a erros em estudos que dependam da sua contribuição (Anache et al., 2019; da Paz et al., 2014).

Todas as suposições feitas nessa pesquisa demandam por análises adicionais, que podem incluir outras formas de validação dos modelos que estimam a evapotranspiração. Um ponto a ser destacado é que a realização desse trabalho foi importante para abrir caminho para aplicações e testes de novas metodologias no Cerrado em questão.

Dessa forma, as observações destacam a importância contínua de pesquisas e estudos posteriores para ampliar o conhecimento sobre o tema. Elas fornecem uma base para investigações futuras e podem servir como ponto de partida para novas descobertas e avanços científicos.

6. CONCLUSÃO

No presente estudo, foi aplicado o modelo TSEB-DTD com o objetivo de estimar valores diários de evapotranspiração em uma área remanescente de Cerrado *sensu stricto*. Para isso, utilizou-se dados de sensoriamento remoto provenientes do sensor MODIS, presente nos satélites Terra e Aqua. As imagens do MODIS forneceram os dados de entrada necessários para alimentar o código pyTSEB, além de dados meteorológicos provenientes da torre de monitoramento instalada no Cerrado em questão. Além disso, também foi usado as medições diretas de fluxos de calor feitas pelos sensores do sistema *Eddy Covariance* (EC), com o objetivo de comparar com os resultados estimados pelo modelo TSEB-DTD.

Os resultados mostraram, em termos sazonais, uma variação da ET média estimada pelo TSEB-DTD de 10,8 mm dia⁻¹ para o período chuvoso e de 4,8 mm dia⁻¹ para o período de estiagem. Já os valores médios da ET observados por Kobayashi (2021) variaram de 3,7 mm dia⁻¹ no período chuvoso e 2,5 mm dia⁻¹ no período seco, para a mesma área e período analisados nesta pesquisa.

As métricas estatísticas avaliadas foram o viés, a Raiz do Erro Quadrático Médio (RMSE), o Coeficiente de variação (CV) e o Coeficiente de correlação de Pearson (ρ). O viés médio foi de 4,5 mm dia⁻¹, o RMSE médio foi de 5,5 mm dia⁻¹, o CV dos dados estimados pelo TSEB-DTD foi de 47%, enquanto o CV dos dados observados foi de 26%. Já o valor médio do ρ foi de aproximadamente 0,6 para a área analisada, chegando a 0,9 em uma região imediatamente à Sudoeste à área de estudo, sugerindo um possível deslocamento dos fluxos estimados pelo modelo.

Os resultados e as métricas estatísticas aplicadas apontaram uma superestimação dos dados estimados pelo TSEB-DTD quando comparados pelos observados por Kobayashi (2021) na mesma área de estudo. Além disso, os resultados encontrados pelo TSEB-DTD também são superestimados em relação a outros estudos em regiões semelhantes de Cerrado (Cabral et al., 2015; Giambelluca et al., 2009; Oliveira, 2018 e Oliveira et al., 2015).

A superestimação da evapotranspiração estimada pelo pyTSEB sugere que a aplicação de modelos baseados em sensoriamento remoto em áreas de Cerrado deve ser aprimorada. Tanto em relação aos dados de entrada, que são diversos e complexos, quanto em relação ao uso de outros modelos, a fim de testar diferentes metodologias, sensores e satélites, e avaliar qual se adequa mais à área de estudo e aos objetivos da pesquisa.

6.1 Recomendações e trabalhos futuros

Ainda há lacunas a serem preenchidas e demandas para novas pesquisas e trabalhos que busquem aprimorar as metodologias aplicadas, a fim de entender a complexidade dos processos hidrológicos e suas variáveis em áreas de vegetação heterogêneas e pouco exploradas, como o Cerrado brasileiro.

Trabalhos futuros na área remanescente de Cerrado *sensu stricto* o IAB deve continuar a serem conduzidos para entender melhor os processos do ciclo hidrológico e da troca de fluxos de calor entre a atmosfera e áreas de vegetação heterogêneas, em especial a evapotranspiração, por ser uma variável complexa e interligada a várias outras. Entendendo melhor os processos físicos dessas componentes, é possível melhorar os modelos matemáticos, deixando-os cada vez mais robustos e com possibilidade de gerar resultados mais factíveis.

O aperfeiçoamento e a continuidade nas medições com o sistema *Eddy Covariance* (EC) também é outro ponto relevante para o sucesso dos futuros trabalhos. Primeiro, porque ainda há poucas torres de monitoramento de fluxos no bioma Cerrado, então a continuidade da série de medições é importante para a contribuição da rede de pesquisas nessas vegetações. Em segundo, apenas um trabalho foi conduzido utilizando os dados do EC na área de estudo (Kobayashi, 2021), abrindo oportunidades para explorar e manipular esses dados. E, em terceiro, a série histórica referente ao sistema EC do Cerrado do IAB é relativamente curta, visto que, após a sua instalação, em 2018, houve vários incidentes e problemas técnicos, deixando extensos períodos com falhas contínuas nas medições. Tais falhas, mesmo aplicando métodos de preenchimento, não conseguem preencher todas as lacunas.

A performance do modelo TSEB-DTD deve ser testada com sensores de nova geração, visto que os satélites Terra e Aqua já estão rodando além do tempo de vida que foram projetados. Outros modelos matemáticos baseados em sensoriamento remoto também podem ser aplicados, buscando diversificar e testar novas metodologias, a fim de verificar qual se adequa melhor e reproduz resultados mais consistentes para a área de estudo.

Além disso, também é recomendado o uso de sensores com resoluções espaciais mais refinadas, principalmente quando a área de estudo é uma vegetação heterogênea. Porém, sabe-se que nem sempre tais dados estão disponíveis para as pesquisas, mas com o avanço da tecnologia e, conseqüentemente, das técnicas de sensoriamento remoto, espera-se que as informações sejam cada vez mais acessíveis para fins de pesquisa.

REFERÊNCIAS

ALLEN, R. G.; PEREIRA, L. S.; HOWELL, T. A.; JENSEN, M. E. Evapotranspiration information reporting: I. Factors governing measurement accuracy. **Agricultural Water Management**, v. 98, p. 899-920, 2011.

- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. (1998). **FAO Irrigation and drainage paper N° 56** - Crop evapotranspiration (Guidelines for computing crop water requirements). FAO, 1998.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAROVEK, G. (2014). Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2014.
- AMIRO, B. (2009). Measuring boreal forest evapotranspiration using the energy balance residual. **Journal of Hydrology**, v. 366, p. 112-118, 2009.
- ANACHE, J. A. A.; WENDLAND, E. C.; ROSALEM, L. M. P.; YOULTON, C.; OLIVEIRA, P. T. S. (2019). Hydrological trade-offs due to different land covers and land uses in the Brazilian Cerrado. **Hydrology and Earth System Sciences**, v. 23, p. 1263-1279, 2019.
- ANAPALLI, S. S.; FISHER, D. K.; REDDY, K. N.; WAGLE, P.; GOWDA, P. H.; SUI, R. (2018). Quantifying soybean evapotranspiration using an eddy covariance approach. **Agricultural Water Management**, v. 209, p. 228-239, 2018.
- 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 Sensing of Environment**, v. 60, p. 195-216, 1997.
- ANDERSON, M. C.; NORMAN, J. M.; MECIKALSKI, J. R.; OTKIN, J. A.; KUSTAS, W. P. (2007a). A climatological study of evapotranspiration and moisture stress across the continental United States based on thermal remote sensing: 1. Model formulation. **Journal of Geophysical Research**, v. 112, p. 1-13, 2007.
- ANDERSON, M. C.; KUSTAS, W. P.; NORMAN, J. M. (2007b). Upscaling Flux Observations from Local to Continental Scales Using Thermal Remote Sensing. **Agronomy Journal**, v. 99, p. 240-254, 2007.
- ANDERSON, M. C.; KUSTAS, W. P.; NORMAN, J. M.; HAIN, C. R.; MECIKALSKI, J. R.; SCHULTZ, L.; GONZÁLEZ-DUGO, M. P.; CAMMALLERI, C.; D'URSO, G.; PIMSTEIN, A.; GAO, F. (2011). Mapping daily evapotranspiration at field to continental scales using geostationary and polar orbiting satellite imagery. **Hydrology and Earth System Sciences**, v. 15, p. 223-239, 2011.
- ANDERSON, M. C.; ALLEN, R. G.; MORSE, A.; KUSTAS, W. P. (2012). Use of Landsat thermal imagery in monitoring evapotranspiration and managing water resources. **Remote Sensing of Environment**, v. 122, p. 50-65, 2012.
- ANDREU, A.; KUSTAS, W. P.; POLO, M. J.; CARRARA, A.; GONZÁLEZ-DUGO, M. P. Modeling Surface Energy Fluxes over a Dehesa (Oak Savanna) Ecosystem Using a Thermal Based Two Source Energy Balance Model (TSEB) II—Integration of Remote Sensing Medium and Low Spatial Resolution Satellite Images. **Remote Sensing**, v. 10(4), 558, 2018.

- AUBINET, M.; VESALA, T.; PAPALE, D. (2012). **Eddy Covariance: A Practical Guide to Measurement and Data Analysis**. Springer Atmospheric Sciences, 2012.
- BALDOCCHI, D. D.; FALGE, E.; GU, L.; OLSON, R.; HOLLINGER, D.; RUNNING, S.; ANTHONI, P.; BERNHOFER, CH.; DAVIS, K.; EVANS, R.; FUENTES, J.; GOLDSTEIN, A.; KATUL, G.; LAW, B.; LEE, X.; MALHI, Y.; MEYERS, T.; MUNGER, W.; OECHEL, W.; PAW U, K. T.; PILEGAARD, K.; SCHMID, H. P.; VALENTINI, R.; VERMA, S.; VESALA, T.; WILSON, K.; WOFYSY, S. (2001). FLUXNET: A New Tool to Study the Temporal and Spatial Variability of Ecosystem-Scale Carbon Dioxide, Water Vapor, and Energy Flux Densities. **Bulletin of the American Meteorological Society**, v. 82, p. 2415-2434, 2001.
- BALDOCCHI, D. D. (2003). Assessing the eddy covariance technique for evaluating carbon dioxide exchange rates of ecosystems: past, present and future. **Global Change Biology**, v. 9, p. 479-492, 2003.
- BALDOCCHI, D. D.; DRALLE, D.; JIANG, C.; RYU, Y. (2019). How Much Water Is Evaporated Across California? A Multiyear Assessment Using a Biophysical Model Forced With Satellite Remote Sensing Data. **Water Resources Research**, v. 55, p. 2722-2741, 2019.
- BARKER, J. B.; NEALE, C. M. U.; HEEREN, D. M.; SUYKER, A. E. Evaluation of a hybrid reflectance-based crop coefficient and energy balance evapotranspiration model for irrigation management. **American Society of Agricultural and Biological Engineers**, v. 61(2), p. 533-548, 2018.
- BERGER, S.; BLIEFERNICHT, J.; LINSTÄDTER, A.; CANAK, K.; GUUG, S.; HEINZELLER, D.; HINGERL, L.; MAUDER, M.; NEIDL, F.; QUANSAH, E.; SALACK, S.; STEINBRECHER, R.; KUNSTMANN, H. (2019). The impact of rain events on CO₂ emissions from contrasting land use systems in semi-arid West African savannas. **Science of the Total Environment**, v. 647, p. 1478-1489, 2019.
- BEZERRA, U. A.; CUNHA, J.; VALENTE, F.; NÓBREGA, R. L. B.; ANDRADE, J. M.; MOURA, M. S. B.; VERHOEF, A.; PEREZ-MARIN, A. M.; GALVÃO, C. O. STEEP: A remotely-sensed energy balance model for evapotranspiration estimation in seasonally dry tropical forests. **Agricultural and Forest Meteorology**, v. 333, 2023.
- BIUDES, M. S.; VOURLITIS, G. L.; MACHADO, N. G.; ARRUDA, P. H. Z.; NEVES, G. A. R.; LOBO, F. A.; NEALE, C. M. U.; NOGUEIRA, J. S. Patterns of energy exchange for tropical ecosystems across a climate gradient in Mato Grosso, Brazil. **Agricultural and Forest Meteorology**, v. 202, p. 112-124, 2015.
- BRUTSAERT, W. (2005) **Hydrology, an Introduction**. Cambridge University Press, Cambridge, 618 p.
- BURBA, G. (2013). **Eddy Covariance Method for Scientific, Industrial, Agricultural and Regulatory Applications**. LI-COR® Biosciences: Lincoln, USA. 345 p. ISBN 978-0-615-76827-4.

- CABRAL, O. M. R.; 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. **Journal of Hydrology: Regional Studies**, v. 4, p. 22-40, 2015.
- CAMMALLERI, C.; ANDERSON, M. A.; GAO, F.; HAIN, C. R.; KUSTAS, W. P. (2013). A data fusion approach for mapping daily evapotranspiration at field scale. **Water Resources Researcher**, v. 49, p. 4672-4686, 2013.
- CAMMALLERI, C.; ANDERSON, M. A.; GAO, F.; HAIN, C. R.; KUSTAS, W. P. (2014). Mapping daily evapotranspiration at field scales over rainfed and irrigated agricultural areas using remote sensing data fusion. **Agricultural and Forest Meteorology**, v. 186, p. 1-11, 2014.
- CAMPBELL SCIENTIFIC. (2020). **3-D Sonic Anemometer**. Available in: <<https://www.campbellsci.com.br/cs3>>. Acesso em: janeiro de 2020.
- CASTELLI, M.; ANDERSON, M. C.; YANG, Y.; WOHLFAHRT, G.; BERTOLDI, G.; NIEDRIST, G.; HAMMERLE, A.; ZHAO, P.; ZEBISCH, M.; NOTARNICOLA, C. Two-source energy balance modeling of evapotranspiration in Alpine grasslands. **Remote Sensing of Environment**, v. 209, p. 327-342, 2018.
- CRISTIANO, P. M.; CAMPANELLO, P. I.; BUCCI, S. J.; RODRIGUEZ, S. A.; LEZCANO, O. A.; SCHOLZ, F. G.; MADANES, N.; FRANCESCANTONIO, D. D.; CARRASCO, L. O.; ZHANG, Y. J.; GOLDSTEIN, G. (2015). Evapotranspiration of subtropical forests and tree plantations: A comparative analysis at different temporal and spatial scales. **Agricultural and Forest Meteorology**, v. 203, p. 96-106, 2015.
- DA PAZ, A. R.; COLLISCHONN, W.; BRAVO, J. M.; BATES, P. D.; BAUGH, C. (2014). The influence of vertical water balance on modelling Pantanal (Brazil) spatio-temporal inundation dynamics. **Hydrological Processes**, v. 28, p. 3539-3553, 2014.
- DIJK, A. V. (2002). Extension to 3D of “The Effect of Line Averaging on Scalar Flux Measurements with a Sonic Anemometer near the Surface” by Kristensen and Fitzjarrald. **Journal of Atmospheric and Oceanic Technology**, v. 19, p. 80-82, 2002.
- DINGMAN, S. L. 2002. **Physical Hydrology**. Prentice Hall, Upper Saddle River, 646p.
- DOMEC, J. C.; SUN, G.; NOORMETS, A.; GAVAZZI, M. J.; TREASURE, E. A.; COHEN, E.; SWENSON, J. J.; MCNULTY, S. G.; KING, J. S. (2012). A comparison of three methods to estimate evapotranspiration in two contrasting loblolly pine plantations: age-related changes in water use and drought sensitivity of evapotranspiration components. **Forest Science**, v. 58, p. 497-512, 2012.
- EMBRAPA. **Bioma Cerrado**. Fitofisionomias do Bioma Cerrado. Disponível em: <<https://www.embrapa.br/cerrados/colecao-entomologica/bioma-cerrado>>. Acesso em: janeiro de 2023.

- FERREIRA, D. H. L.; BADINGER, A.; TENDOLINI, J. C. (2018). Distribuições de tendências sazonais de temperatura média e precipitação nos biomas brasileiros. **Revista Brasileira de Meteorologia**, v. 33, n. 1, p. 97-113, 2018.
- FLUXNET. (2019). **Overview**. Available in: <https://daac.ornl.gov/cgi-bin/dataset_lister.pl?p=9>. Acesso em: novembro de 2019.
- FOKEN, T.; LEUNING, R.; ONCLEY, S. R.; MAUDER, M.; AUBINET, M. Corrections and Data Quality Control. In: AUBINET, M.; VESALA, T. et al. (2012). **Eddy Covariance: A Practical Guide to Measurement and Data Analysis**. Dordrecht Heidelberg London New York: Springer, 2012. ISBN 978-94-007-2350-4.
- GAO, F.; MASEK, J.; SCHWALLER, M.; HALL, F. (2006). On the blending of the Landsat and MODIS surface reflectance: predicting daily Landsat surface reflectance. **Geoscience and Remote Sensing, IEEE Transactions**, v. 44, p. 2207-2218, 2006.
- GIAMBELLUCA, T. W.; SCHOLZ, F. G.; BUCCI, S. J.; MEINZER, F. C.; GOLDSTEIN, G.; HOFFMANN, W. A.; FRANCO, A. C.; BUCHERT, M. P. Evapotranspiration and energy balance of Brazilian savannas with contrasting tree density. **Agricultural and Forest Meteorology**, v. 149, p. 1365-1376, 2009.
- GUZINSKI, R.; ANDERSON, M. C.; KUSTAS, W. P.; NIETO, H. SANDHOLT, I. Using a thermal-based two source energy balance model with time-differencing to estimate surface energy fluxes with day–night MODIS observations. **Hydrology Earth System Sciences**, v. 17, p. 2809-2825, 2013.
- GUZINSKI, R.; NIETO, H.; JENSEN, R.; MENDIGUREN, G. Remotely sensed land-surface energy fluxes at sub-field scale in heterogeneous agricultural landscape and coniferous plantation. **Biogeosciences**, v. 11, p. 5021-5046, 2014.
- GUZINSKI, R.; NIETO, H.; EL-MADANY, T.; MIGLIAVACCA, M.; CARRARA, A. Validation of fine resolution land-surface energy fluxes derived with combined sentinel-2 and sentinel-3 observations. *In*: IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium, 2018, Valencia. **Anais [...]**. Valencia: Feria Valencia Convention & Exhibition Center, 2018, p. 8711-8714.
- HORST, T. W.; LENSCHOW, D. H. (2009). Attenuation of Scalar Fluxes Measured with Spatially-displaced Sensors. **Boundary-Layer Meteorology**, v. 130, p. 275-300, 2009.
- ICMBio – Instituto Chico Mendes de Conservação da Biodiversidade. **Biodiversidade do Cerrado**. Available in: <<http://www.icmbio.gov.br/cbc/conservacao-da-biodiversidade/biodiversidade.html>>. Acesso em: janeiro de 2020.
- INPE – Instituto Nacional de Pesquisas Espaciais. (2019). **Geração de imagens Landsat**. Available in: <<http://www.dgi.inpe.br/documentacao/satelites/landsat>>. Acesso em: novembro de 2019.

- KAIMAL, J. C.; CLIFFORD, S. F.; LATAITIS, R. J. (1989). Effect of finite sampling on atmospheric spectra. **Boundary-Layer Meteorology**, v. 47, p. 337-347, 1989.
- KATUL, G.; NOVICK, K. (2009). Evapotranspiration. **Encyclopedia of Inland Waters**, p. 661-667, 2009.
- KLJUN, N.; CALANCA, P.; ROTACH, M. W.; SCHMID, H. P. (2015). A simple two-dimensional parameterisation for Flux Footprint Prediction (FFP). **Geoscientific Model Development**, v. 8, p. 3695-3713, 2015.
- KNIPPER, K. R.; KUSTAS, W. P.; ANDERSON, M. C.; ALFIERI, J. G.; PRUEGER, J. H.; HAIN, C. R.; GAO, F.; YANG, Y.; MCKEE, L. G.; NIETO, H.; HIPPS, L. E.; ALSINA, M. M.; SANCHEZ, L. (2019). Evapotranspiration estimates derived using thermal-based satellite remote sensing and data fusion for irrigation management in California vineyards. **Irrigation Science**, v. 37, p. 431-449, 2019.
- KOBAYASHI, A. N. A. **Rotinas computacionais de processamento de dados de Eddy Covariance para determinação da evapotranspiração em fragmento de Cerrado sensu stricto**. Dissertação (Mestrado em Hidráulica e Saneamento) - Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, p. 125. 2021.
- KORMANN, R.; MEIXNER, F. (2001). An Analytical Footprint Model For Non-Neutral Stratification. **Boundary-Layer Meteorology**, v. 99, p. 207-224, 2001.
- KUMAR, R.; JAT, M.; SHANKAR, V. (2012). Methods to estimate irrigated reference crop evapotranspiration - a review. **Water Science and Technology**, v. 66, p. 525-535, 2012.
- KUSTAS, W. P.; NORMAN, J. M. (1999). Evaluation of soil and vegetation heat flux predictions using a simple two-source model with radiometric temperatures for partial canopy cover. **Agricultural and Forest Meteorology**, v. 94, p. 13-29, 1999.
- KUSTAS, W. P.; NORMAN, J. M. (2000). A two-source energy balance approach using directional radiometric temperature observations for sparse canopy covered surfaces. **Agronomy Journal**, v. 92, p. 847-854, 2000.
- LEE, X.; MASSMAN, W.; LAW, B. (2005). **Handbook of Micrometeorology: A Guide for Surface Flux Measurement and Analysis**. Kluwer Academic Publishers. XIV, 250 p. 2005.
- LIANG, S. Overview: Recent progress in Remote Sensing of Earth's Energy Budget. **Comprehensive Remote Sensing**, v.5, p. 1-31, 2018.
- LIMA, J. E. F. W.; SILVA, E. M. da. (2007). **Estimativa da contribuição hídrica superficial do Cerrado para as grandes regiões hidrográficas brasileiras**. In: Simpósio Brasileiro de Recursos Hídricos, São Paulo.
- MACHADO, R. B.; RAMOS NETO, M. B.; PEREIRA, P.; CALDAS, E.; GONÇALVES, D.; SANTOS, N.; TABOR, K.; STEININGER, M. (2004).

Estimativas de perda da área do Cerrado brasileiro. Conservação Internacional do Brasil, Brasília.

MAPBIOMAS. **Notícias.** Disponível em: <<https://mapbiomas.org/noticias>>. Acesso em: janeiro de 2022.

MELO, D. C. D. et al. Are Remote Sensing Evapotranspiration Models Reliable Across South American Ecoregions? **Water Resources Research**, v. 57(11), 2021.

MODIS. **Data Products.** Disponível em: <<https://mapbiomas.org/noticias>>. Acesso em: janeiro de 2022.

MONCRIEFF, J. B.; MASSHEDER, J. M.; DE BRUIN, H.; ELBERS, J.; FRIBORG, T.; HEUSINKVELD, B.; KABAT, P.; SCOTT, S.; SOEGAARD, H.; VERHOEF, A. (1997). A system to measure surface fluxes of momentum, sensible heat, water vapour and carbon dioxide. **Journal of Hydrology**, v. 188, p. 589-611, 1997.

MONTGOMERY, R. B. (1947). Viscosity and thermal conductivity of air and diffusivity of water vapor in air. **Journal of Meteorology**, v. 4, p. 193-196, 1947.

MOORE, C. J. (1986). Frequency response corrections for eddy correlation systems. **Boundary-Layer Meteorology**, v. 37, p. 17-35, 1986.

MU, Q.; HEINSCH, F. A.; ZHAO, M.; RUNNING, S. W. (2011). Development of a global evapotranspiration algorithm based on MODIS and global meteorology data. **Remote Sensing of Environment**, v. 111, p. 519-536, 2007.

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. **Agricultural and Forest Meteorology**, v. 77, p. 263-293, 1995.

NORMAN, J. M.; ANDERSON, M. C.; KUSTAS, W. P.; FRENCH, A. N.; MECIKALSKI, J.; TORN, R.; DIAK, G. R.; SCHMUGGE, T. J.; TANNER, B. C. W. (2003). Remote sensing of surface energy fluxes at 101-m pixel resolutions. **Surface Water and Climate**, v. 39, p. 1-18, 2003.

NOVA LYNX. (2020). **WindMaster RA 3D Sonic Anemometer.** Available in: <<https://novalynx.com/store/pc/WindMaster-RA-3D-Sonic-Anemometer-p1215.htm>>. Acesso em: janeiro de 2020.

OKI, T.; KANAE, S. (2006). Global Hydrological Cycles and World Water Resources. **Science**, v. 313, p.1068-1072, 2006.

OLIVEIRA, B. S. **Otimização do modelo METRIC para estimativas de evapotranspiração no Cerrado brasileiro.** Tese (Doutorado em Sensoriamento Remoto) - INPE, São José dos Campos, p. 224, 2018.

OLIVEIRA, P. T. S.; WENDLAND, E. C.; NEARING, M. A.; SCOTT, R. L.; ROSOLEM, R.; ROCHA, H. R. (2015). The water balance components of

undisturbed tropical woodlands in the Brazilian Cerrado. **Hydrology and Earth System Sciences**, v. 19, p. 2899-2910, 2015.

PRODES CERRADO. **Monitoramento do Desmatamento no Cerrado Brasileiro por Satélite**. Disponível em: <<http://cerrado.obt.inpe.br/>>. Acesso em: maio de 2021.

ROSALEM, L. M. P.; WENDLAND, E. C.; ANACHE, J. A. A. (2019). Understanding the water dynamics on a tropical forest litter using a new device for interception measurement. **Ecohydrology**, v. 12, 2019.

REYNOLDS, O. (1895). On the dynamical theory of incompressible viscous fluids and the determination of the criterion. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, p. 123-164, 1895.

REYS, P.; CAMARGO, M. G. G.; GUARATINI, M. T. G.; TEIXEIRA, A. P.; ASSIS, M. A.; MORELLATO, L. P. C. (2013). Estrutura e composição florística de um Cerrado sensu stricto e sua importância para propostas de restauração ecológica. **Hoehnea**, v. 40, n. 3, p. 449-464, 2013.

RIBEIRO, F.; SANO, S. M.; MACÊDO, J.; SILVA, A (1983). **Os principais tipos fitofisionômicos da região dos Cerrados**. Planaltina: EMBRAPA-CPAC. 28 p.

RIBEIRO, J. F.; WALTER, B. M. T. (1998). **Fitofisionomias do bioma Cerrado**. In: Cerrado: ambiente e flora. Planaltina: EMBRAPA - CPAC, 89-166.

RIBEIRO, J. F.; WALTER, B. M. T. (2008). As principais fitofisionomias do bioma Cerrado. **Cerrado: ecologia e flora**, v. 1, p. 151-212, 2008.

RODRIGUES, T. R.; VOURLITIS, G. L.; LOBO, F. D. A.; DE OLIVEIRA, R. G.; NOGUEIRA, J. D. S. 2014. Seasonal variation in energy balance and canopy conductance for a tropical savana ecosystem of south central Mato Grosso. **Brazil. J. Geophys. Res. Biogeosciences**, v. 119, p. 1-13.

SABBATINI, S.; MAMMARELLA, I.; ARRIGA, N.; FRATINI, G.; GRAF, A.; HÖRTNAGL, L.; IBROM, A.; LONGDOZ, B.; MAUDER, M.; MERBOLD, L.; METZGER, S.; MONTAGNANI, L.; PITACCO, A.; REBMANN, C.; SEDLÁK, P.; ŠIGUT, L.; VITALE, D.; PAPAŁE, D. (2018). Eddy covariance raw data processing for CO₂ and energy fluxes calculation at ICOS ecosystem stations. **International Agrophysics**, v. 32, p. 495-515, 2018.

SCHOTANUS, P.; NIEUWSTADT, F. T. M.; DE BRUIN, H. A. R. (1983). Temperature measurement with a sonic anemometer and its application to heat and moisture fluxes. **Boundary-Layer Meteorology**, v. 26, p. 81-93, 1983.

SCRASE, F. J. (1930). **Some Characteristics of Eddy Motion in the Atmosphere**. Meteorological Office: London, 1930.

SEMMENS, K. A.; ANDERSON, M. C.; KUSTAS, W. P.; FENGGAO; ALFIERI, J. G.; MCKEE, L.; PRUEGER, J. H.; HAIN, C. R.; CAMMALLERI, C.; YANG, Y.; XIA, T.; SANCHEZ, L.; ALSINA, M. M.; VÉLEZ, M. (2016). Monitoring daily

evapotranspiration over two California vineyards using Landsat 8 in a multi-sensor data fusion approach. **Remote Sensing of Environment**, v. 185, p. 155-170, 2016.

SHAPLAND, T. M.; SNYDER, R. L.; PAW U, K. T.; MCELDRONE, A. J. (2014). Thermocouple frequency response compensation leads to convergence of the surface renewal alpha calibration. **Agricultural and Forest Meteorology**, v. 189-190, p. 36-47, 2014.

SHELTON, M. L. 2009. **Hydroclimatology – Perspectives and applications**. Cambridge.

SHUTTLEWORTH, W. J.; WALLACE, J. S. (1985). Evaporation from sparse crops-An energy combination theory. **Quarterly Journal of the Royal Meteorological Society**, v. 111, p. 839-855, 1985.

SOGACHEV, A.; LECLERC, M. Y.; KARIPOT, A.; ZHANG, G.; VESALA, T. (2005). Effect of clearcuts on footprints and flux measurements above a forest canopy. **Agricultural and Forest Meteorology**, v. 133, p. 182-196, 2005.

SONG, L.; LIU, S.; KUSTAS, W. P.; NIETO, H.; SUN, L.; XU, Z.; SKAGGS, T. H.; YANG, Y.; MA, M.; XU, T.; TANG, X.; LI, Q. (2018). Monitoring and validating spatially and temporally continuous daily evaporation and transpiration at river basin scale. **Remote Sensing of Environment**, v. 219, p. 72-88, 2018.

STULL, R. B. (1988). **An Introduction to Boundary Layer Meteorology**. Kluwer Academic Publishers, The Netherlands, 1988.

SUN, G.; DOMEK, J. C.; AMATYA, D. M. (2016). **Chapter 3: Forest Evapotranspiration: Measurements and Modelling at Multiple Scales**. In: Forest Hydrology: Processes, Management and Assessment. CABI Publishers, U.K, 32-50. 19 p.

TANNER, C. B.; THURTELL, G. W. (1969). **Anemometer measurements of Reynolds stress and heat transport in the atmospheric surface layer science lab**. US Army Electronics Command - Atmospheric Sciences Laboratory TR ECOM 66-G22-F, pp. R1-R10.

TEULING, A. J. (2018). A Forest Evapotranspiration Paradox Investigated Using Lysimeter Data. **Vadose Zone Journal**, v. 17, 2018.

USGS - United States Geological Survey. (2020). **Search Data Catalog - MOD16A2v006**. Available in: <<https://lpdaac.usgs.gov/products/mod16a2v006/>>. Acesso em: janeiro de 2020.

WANG, K.; DICKINSON, R. E. (2012). A review of global terrestrial evapotranspiration: observation, modeling, climatology, and climatic variability. **Reviews of Geophysics**, v. 50, 2012.

- WEBB, E. K.; PEARMAN, G. I.; LEUNING, R. (1980). Correction of flux measurements for density effects due to heat and water vapour transfer. **Quarterly Journal of the Royal Meteorological Society**, v. 106, p. 85-100, 1980.
- WENDLAND, E. C.; BARRETO, C.; GOMES, L. H. (2007). Water balance in the Guarani Aquifer outcrop zone based on hydrogeologic monitoring. **Journal of Hydrology**, v. 342, p. 261-269, 2007.
- YANG, Y.; ANDERSON, M. C.; GAO, F.; HAIN, C. R.; SEMMENS, K. A.; KUSTAS, W. P.; NOORMETS, A.; WYNNE, R. H.; THOMAS, V. A.; SUN, G. (2017). Daily Landsat-scale evapotranspiration estimation over a forested landscape in North Carolina, USA, using multi-satellite data fusion. **Hydrology and Earth System Sciences**, v. 21, p. 1017-1037, 2017.
- YANG, Y.; ANDERSON, M. C.; GAO, F.; HAIN, C. R.; NOORMETS, A.; SUN, G.; WYNNE, R. H.; THOMAS, V. A.; SUN, L. (2018). Investigating impacts of drought and disturbance on evapotranspiration over a forested landscape in North Carolina, USA using high spatiotemporal resolution remotely sensed data. **Remote Sensing of Environment**, 2018.
- ZAKERI, F.; MARIETHOZ, G. A review of geostatistical simulation models applied to satellite remote sensing: Methods and applications. **Remote Sensing of Environment**, v. 259, 2021.

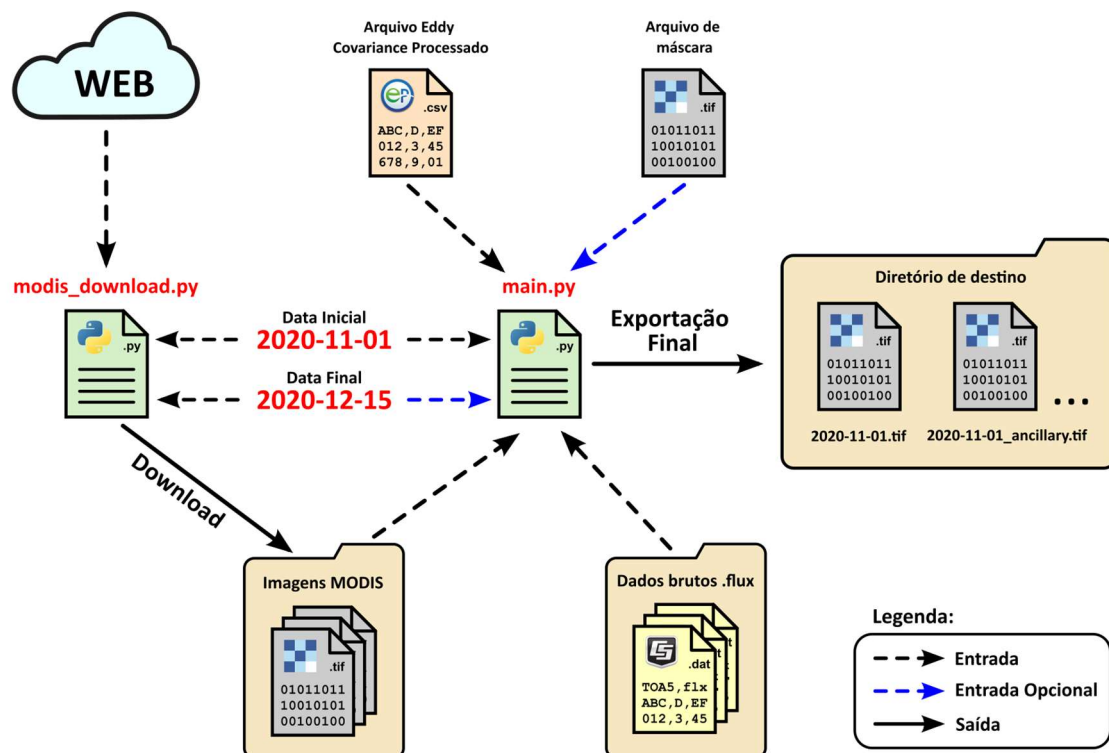
APÊNDICE A – Documentação do algoritmo customizado do pyTSEB-DTD usando imagens MODIS e dados do Eddy Covariance

1. DESCRIÇÃO GLOBAL DO ALGORITMO

O objetivo do desenvolvimento desse algoritmo foi adaptar a utilização das imagens MODIS dentro da biblioteca pyTSEB, visto que as imagens necessitam de conversões e alterações nos dados para corresponder aos tipos de entradas da biblioteca pyTSEB. Da mesma maneira, foram desenvolvidos classes e *scripts* para a leitura e conversão de unidades dos dados do *Eddy Covariance*.

As entradas do modelo são compostas por vários produtos derivados de imagens do sensor MODIS (veja a seção [3.1.2. Produtos MODIS utilizados neste trabalho](#)), e dados provenientes das medições do sistema *Eddy Covariance* (Veja a seção [3.2. Arquivos de Eddy Covariance](#)). Os *scripts* que foram desenvolvidos se resumem em: *modis_download.py*, para efetuar o download dos produtos MODIS e o *main.py* que é o script principal para executar o algoritmo (Figura 1).

Figura 1. Fluxo para execução dos algoritmos (Fonte: Autor, 2021).



A Figura 1 representa como acontecerá o fluxo para execução dos algoritmos. Primeiramente, é necessário fazer o download das imagens MODIS no período de interesse a partir do *script modis_download.py*. Com as imagens salvas no computador, além dos arquivos do *Eddy Covariance* (Processados e Brutos), é feito o processamento usando o *script main.py*. A saída é composta de duas imagens com extensão *.TIFF*. A primeira é a saída principal, com os fluxos de calor (4 canais), e a imagem auxiliar com outros 14 canais de informações mais detalhadas (veja a seção [6. Saídas do algoritmo PyTSEB](#)).

2. DADOS DE ENTRADA DO ALGORITMO

Conforme citado, o algoritmo recebe dois tipos de dados principais: as imagens MODIS e os dados do *Eddy Covariance*. Nas seções seguintes serão abordados como funcionam os dois tipos de entrada.

2.1. Imagens MODIS

Para que o modelo TSEB funcione, são necessárias algumas informações provenientes de dados de satélite, como por exemplo a temperatura do solo (LST) e índices vegetativos (EVI, NDVI e LAI). Informações detalhadas sobre os produtos MODIS podem ser encontradas pelo link: <https://modis.gsfc.nasa.gov/data/dataproduct/>.

2.1.1. Nomenclatura das imagens MODIS

É utilizado uma convenção para nomear os arquivos MODIS. A partir da sua nomenclatura, é possível obter informações, como: tipo do produto, localização e data de produção. Abaixo segue um exemplo de como os dados são organizados.

MOD13Q1.A2007225.h28v06.006.2007245083237.hdf

- **Nome do produto abreviado (levar em conta essa data)**
- **Data da aquisição em data Juliana (A-YYYYDDD)**
- **Identificador de localização geográfica (horizontal 28 e vertical 06)**
- **Versão da coleção**
- **Data Juliana da produção da imagem (YYYYDDDDHHMMSS)**
- **Extensão do arquivo (HDF - Hierarchical Data Format)**

O prefixo dos produtos MODIS são categorizados da seguinte forma:

- **MOD**: Produtos MODIS do satélite TERRA.
- **MYD**: Produtos MODIS do satélite AQUA.
- **MCD**: Produto combinado entre MODIS TERRA e AQUA.

2.1.2. Produtos MODIS utilizados neste trabalho

A Tabela 1 apresenta a identificação e principais características dos produtos MODIS utilizados nesse trabalho.


Tabela 1. Descrição das características dos produtos MODIS utilizados na pesquisa (Fonte: Autor, 2021).

Dado fornecido	Nome do produto	Resolução espacial	Tempo de revisita	Camadas utilizadas	Download
LAI	MCD15a3hv006	500 m	4 dias	Lai_500m	link
LST e emissividade	MOD11a1v006	1 km	1 dia	LST_Day_1km LST_Night_1km Day_view_angl Night_view_ang QC_Day QC_Night	link
	MYD11a1v006	1 km	1 dia	Clear_day_cov Clear_night_cov	link
NDVI e EVI	MOD13a1v006	500 m	16 dias ¹	500 m 16 days NDVI 500 m 16 days EVI	link
	MYD13a1v006	500 m	16 dias ¹		link
¹ O produto MOD13a1v006 e MYD13a1v006 tem uma defasagem de 8 dias de um em relação ao outro, ou seja, sempre há uma leitura alternada entre os produtos a cada 8 dias.					

2.1.3. Horário de leitura das imagens MODIS

O sensor MODIS está presente em dois satélites, que foram programados para passar sobre a Terra com uma defasagem de mais ou menos 12 horas entre eles. O satélite AQUA possui sua passagem no sentido Sul para o Norte ao longo do Equador no período da tarde, já o satélite TERRA, possui sentido Norte para o Sul ao longo do Equador no período da manhã. A Figura 2 mostra as leituras em relação ao horário de cada um.


Figura 2. Horário das passagens dos satélites TERRA e AQUA sobre a Terra (Fonte: Autor, 2021).



2.1.4. Sistema de coordenadas Sinusoidal

O sistema de coordenadas sinusoidal é utilizado em vários satélites. No caso do sensor MODIS, as coordenadas de cada região são determinadas de acordo com a Figura 3, sendo h as coordenadas horizontais, e v as verticais.

Figura 3. Coordenadas utilizadas no sensor MODIS



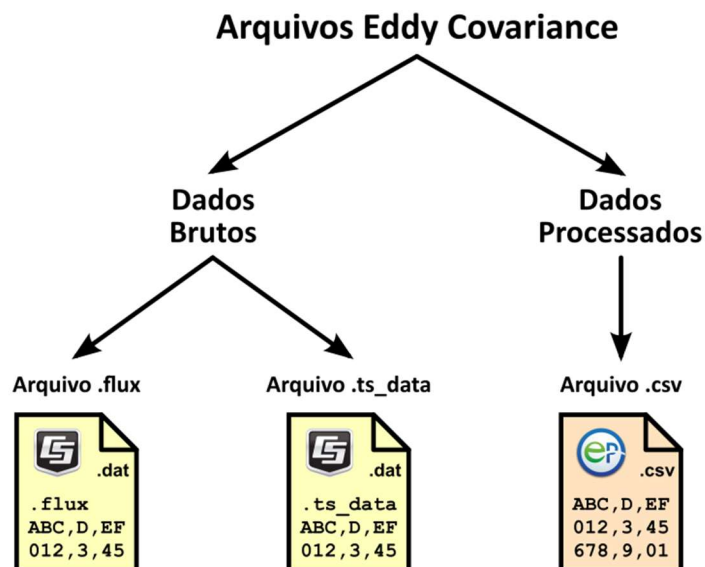
A área de interesse estudada neste trabalho está localizada nas coordenadas **h13v11** (marcadas em vermelho na Figura 3), e elas são importantes para escolher quais imagens disponíveis dos produtos MODIS devem ser utilizadas.

2.2. Arquivos do *Eddy Covariance*

O algoritmo do pyTSEB utiliza três arquivos provenientes dos dados das medições do *Eddy Covariance*. Alguns tratam de informações brutas coletadas pela torre do *Eddy Covariance*, e outros arquivos são resultados de dados já processados a partir do *software* Eddy Pro (como foi

explicado no subtópico 4.4 do tópico METODOLOGIA). A Figura 4 mostra um esquema da organização dos arquivos utilizados nesse trabalho.

Figura 4. Esquema dos arquivos com dados do Eddy Covariance (Fonte: Autor, 2021).



Nas seções subsequentes estão as especificações de cada arquivo e quais as colunas que foram utilizadas, respectivamente.

2.2.1. Dados brutos

Os arquivos descritos a seguir são dados provenientes diretamente das medições do *Eddy Covariance* (dados brutos), antes de serem processados pelo *software* EddyPro.

2.2.1.1. Arquivo *ts_data*

O arquivo *ts_data* contém dados referentes a algumas informações do ambiente, como velocidade e direção do vento, pressão atmosférica, temperatura do ar e pressão de vapor. O arquivo contém a extensão *.dat*, com a seguinte nomenclatura (valores em vermelho variam de acordo com o registro).

TOA5_11341.ts_data_134_2021_01_27_1009.dat

De acordo com o [manual de operação](#) (página 39) do sistema *Eddy Covariance*, disponibilizado pela *Campbell Scientific*, a Tabela 2 mostra os dados de aquisição.

Tabela 2. Dados de aquisição medidos pelo sistema Eddy Covariance (Fonte: Autor, 2021).

Nome da coluna no arquivo	Unidade	Descrição	Observação
TIMESTAMP	string	É a data e hora em que o registro foi gerado Formato padrão: AAAA-MM-DD hh:mm:ss	-
RECORD	inteiro	Número incremental que identifica cada leitura	-
Ux	m/s	Velocidade do vento no eixo X	Calcular a velocidade pelo módulo das componentes
Uy	m/s	Velocidade do vento no eixo Y	
Uz	m/s	Velocidade do vento no eixo Z	
Ts	°C	Temperatura Sônica	É preciso transformar para Kelvin para que funcione no TSEB
diag_sonic		Flag de Diagnóstico Sonico	-
CO₂	mg/m ³	Densidade de CO ₂	-
H₂O	g/m ³	Densidade de H ₂ O	-
diag_irga		Flag de Diagnóstico de gás	-
amb_tmpr	°C	Temperatura do ar	É preciso transformar para Kelvin (K) para que funcione no TSEB
amb_press	kPa	pressão do ar	É preciso transformar para milibar (mb) para que funcione no TSEB
CO₂_sig_strgth	razão	Força do sinal de CO ₂	-
H₂O_sig_strgth	razão	Força do sinal H ₂ O	-

2.2.1.2. Arquivo flux

O arquivo flux contém dados referentes a algumas informações do ambiente, como velocidade e direção do vento, pressão atmosférica, temperatura do ar e pressão de vapor. O arquivo contém a extensão .dat, e com a seguinte nomenclatura (valores em vermelho são variáveis de acordo com o registro):

TOA5_11341.flux_2019_04_16.dat

O arquivo contém mais de 100 colunas de dados no total, e a Tabela 3 mostra somente as colunas utilizadas no algoritmo.

Tabela 3. Dados do arquivo *flux* utilizados no pyTSEB (Fonte: Autor, 2021).

Nome da coluna no arquivo	Tipo	Descrição	Observação
TIMESTAMP	String formatada	Data e horário em que o registro foi gerado. O Formato padrão: AAAA-MM-DD hh:mm:ss	-
Rs_incoming_Avg	W/m ²	Radiação de ondas curtas de entrada	É utilizado para o parâmetro S_dn do PyTSEB
RI_incoming_Avg	W/m ²	Radiação de ondas longas de entrada	É utilizado para o parâmetro L_dn do PyTSEB

2.2.2. Dados processados

De acordo com a documentação [EddyPro](#), a Tabela 4 mostra somente as colunas utilizadas a partir dos dados processados do sistema *Eddy Covariance*.

Tabela 4. Dados processados pelo EddyPro utilizados pelo pyTSEB (Fonte: Autor, 2021).

Nome da coluna no arquivo	Tipo	Descrição	Observação
date	String formatada	Data final do período de média calculada. Formato padrão: AAAA-MM-DD	-
time	String formatada	Hora final no do período de média calculada. Formato padrão: hh:mm	-
air_temperature	K	Temperatura média do ar ambiente, calculada pela leitura de alta frequência ou estimada pela temperatura sônica ou ambas.	-

air_pressure	Pa	Média da pressão de ar ambiente, calculada pela leitura de alta frequência da pressão do ar ou estimada baseada na altitude local (pressão barométrica)	Nota: Para funcionar como entrada do PyTSEB, é necessário transformar para milibar aplicando a multiplicação por 0.01
e	Pa	Pressão parcial de vapor de água ambiente	
wind_speed	m s-1	Velocidade média do vento	-

3. INSTALAÇÃO

3.1. Instalação do Python Anaconda

Considerando o uso no sistema operacional *Windows*, é recomendado que seja instalado o python [Anaconda](#) antes de instalar os demais componentes. Depois da instalação do Anaconda, é necessário que se faça a instalação do [PyTSEB](#).

Primeiramente, deve-se fazer o download do código disponível no github para um diretório conhecido. Abra um Anaconda prompt (como descrito no [manual](#)), e irá abrir uma janela com o nome do ambiente entre parênteses, como demonstrado abaixo:

The image shows a screenshot of the Anaconda Prompt window. The title bar reads "Anaconda Prompt (anaconda3) Prompt de comando específico do Python Anaconda". The main window content shows a black terminal with a red prompt character and the text "(base) C:\Users\User>". A red arrow points from the text "Nome do ambiente conda. (base) é o ambiente padrão" to the "(base)" part of the prompt.

Antes de configurar o ambiente de desenvolvimento, é necessário fazer o download e instalação do controlador de versão para fazer o download do código do pyTSEB, que será demonstrado na próxima subseção.

3.2. Instalação do git

O git é uma ferramenta de controle de versões que é utilizada para verificar os desenvolvimentos dos códigos em relação ao tempo. Essa ferramenta é extremamente útil para se obter a rastreabilidade e as modificações realizadas no código. A instalação do git é necessária para que seja possível fazer o download do código de maneira mais fácil.

No caso do Anaconda, deve-se executar o seguinte código no mesmo terminal citado na seção anterior:

```
conda install -c anaconda git -y
```

3.3. Download e instalação do código do pyTSEB

Com a instalação do git concluída, o próximo passo é fazer o download do código do pyTSEB e instalar seu ambiente de desenvolvimento. Com o terminal do conda aberto, digite o comando abaixo e aguarde o download terminar:

```
git clone https://github.com/hectornieto/pyTSEB.git
```

Agora, é necessário criar o ambiente de desenvolvimento do conda configurado com o pyTSEB. Esse ambiente é responsável por configurar as bibliotecas e variáveis de ambiente específicas para o uso do algoritmo. Sua função é separar outros ambientes de desenvolvimento sem que eles se misturem e provoquem incompatibilidades entre códigos. Para isso, execute os seguintes comandos e aguarde a instalação:

```
cd pyTSEB
```

```
conda env create -f environment.yml
```

```
conda activate pytseb
```

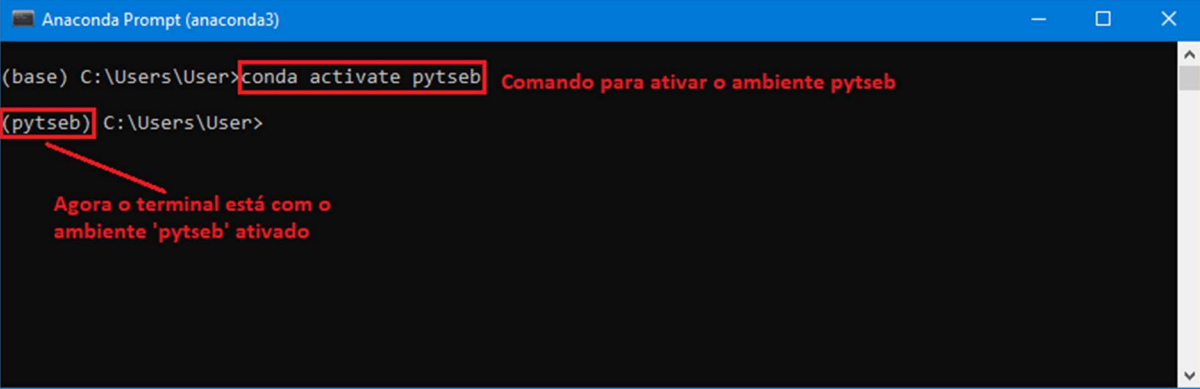
```
python setup.py install
```

3.4. Ativação do ambiente pyTSEB no conda

Após instalar e criar o ambiente, é necessário que o mesmo seja ativado para iniciar a instalação de outros componentes e posterior utilização. Para ativar o ambiente, utilize o comando:

```
conda activate pytseb
```

Para verificar qual ambiente o terminal está utilizado, observe a imagem abaixo como exemplo:



The screenshot shows a terminal window titled 'Anaconda Prompt (anaconda3)'. The prompt is '(base) C:\Users\User>'. The command 'conda activate pytseb' is entered and highlighted with a red box. To the right of the command, the text 'Comando para ativar o ambiente pytseb' is displayed in red. The prompt changes to '(pytseb) C:\Users\User>', which is also highlighted with a red box. A red arrow points from the text 'Agora o terminal está com o ambiente 'pytseb' ativado' to the new prompt. The text 'Agora o terminal está com o ambiente 'pytseb' ativado' is displayed in red below the prompt.

Uma observação importante que deve ser levada em consideração, é que esse comando deve ser executado toda vez que um terminal conda for aberto. Isso acontece porque as ferramentas para o funcionamento do código só estarão disponíveis nesse ambiente, e para que o mesmo funcione corretamente, ele deverá ser ativado.

3.5. Instalação do pyModis

Com a instalação do pyTSEB e configuração do ambiente, é necessário instalar a biblioteca pyModis para fazer o download das imagens MODIS. Dentro do mesmo terminal conda, utilize o seguinte comando:

```
pip install pymodis wxpython
```

Se a instalação dessas bibliotecas e dos passos anteriores forem bem-sucedidas, o script customizado estará pronto para execução. As instruções de uso estão descritas na próxima seção.

4. UTILIZAÇÃO DOS SCRIPTS

A organização dos arquivos e scripts necessários para utilizar o modelo pyTSEB estão descritas na Tabela 5.

Tabela 5. Arquivos utilizados para execução do pyTSEB (Fonte: Autor, 2021).

Arquivo / Diretório	Descrição
main.py	Arquivo principal onde será executado o modelo.
constants.py	Arquivo de constantes.
datasets	Diretório onde há as classes de manipulação das bases de dados.
ec_dataset.py	Classes e funções de manipulação dos arquivos do <i>Eddy Covariance</i> . Abertura de arquivos TOA5 (.ts_data e .flux) e arquivos processados pelo EddyPro.
modis_dataset.py	Classes e funções para a manipulação das imagens MODIS. Geração de imagens auxiliares e validação de valores.
tools	Diretório de ferramentas auxiliares.
extract_hdf.py	Script para extrair todas as imagens de um arquivo .HDF para um diretório. Todas as imagens exportadas estão no formato .TIF e poderão ser abertas no software QGIS. Esse script é utilizado como uma maneira de debug dos datasets que estão dentro do .HDF.
modis_download.py	Script para fazer o download das imagens MODIS. Esse script salva as imagens dos produtos MODIS no formato correto para ser lido no arquivo main.py.

4.1. Considerações

Para que o software funcione corretamente, é necessário que seja feito todo o procedimento de instalação descrito na seção [3. Instalação](#). Todos os exemplos disponíveis neste documento estão preparados para funcionar no Windows, no entanto, com algumas adaptações, é possível funcionar normalmente em outros sistemas operacionais.

Existem algumas particularidades presentes na execução da linha de comando. Para facilitar a didática desse documento, foram utilizados alguns artifícios das linhas de comando no Windows demonstrados nos blocos de código. Um artefato que foi utilizado foi o caractere ^, que funciona como quebra de linha, ou seja, quando é digitado ^ e tecla-se *enter*, a linha de comando pula a linha sem que haja descontinuidade no comando executado. Esse artifício é opcional, e o terminal do Windows irá ignorá-lo, pois ele serve apenas para indicar que houve uma quebra de linha. A imagem abaixo mostra como a janela de comando fica:


```

C:\Users\User>comando ^
Mais? argumento 1 ^
Mais? argumento 2 ^
Mais? argumento 3 ^

```

4.2. Ferramentas

Nos tópicos seguintes são descritos os scripts auxiliares que foram utilizados.

4.2.1. Extração do arquivo .HDF

Esse script está localizado em `tools/extract_hdf.py`. Essa ferramenta é utilizada quando há a necessidade de visualização das camadas internas presentes dentro do arquivo no formato .HDF. O script irá salvar as imagens contidas dentro do arquivo .HDF em um diretório da escolha do usuário. Caso o diretório não for escolhido, o script irá criar outro diretório dentro da localização do arquivo .HDF com o mesmo nome do arquivo, como mostrado na Tabela 6.

Observação: Não são atribuídos fatores de escala, offsets e transformações nas imagens extraídas por esse script.

Tabela 6. Extração de arquivos com extensão .HDF (Fonte: Autor, 2021).

Argumento	Tipo	Descrição
arquivo_entrada	Caminho de arquivo	É o caminho do arquivo .HDF para a extração.
--diretorio_saida	(opcional) Caminho de diretório	Caminho de exportação das camadas no formato .TIF. Nota: Caso o diretório de saída não seja informado, o script irá criar outro diretório dentro da mesma pasta do arquivo com o mesmo nome do arquivo mas sem a extensão.

Segue abaixo um exemplo de execução do script:

```
C:\Users\Usuario\Codigos>python tools/extract_hdf.py ^
```

```
D:\Imagens\MCD15A3H.A2020153.h13v11.006.2020160231848.hdf ^
--diretorio_saida D:\Imagens\destino
```

4.2.2. Download das imagens MODIS

Esse script é necessário para fazer o download dos produtos MODIS que serão utilizados na execução do modelo principal. O script é composto de uma adaptação do código do [pyModis](#), onde as imagens e os produtos MODIS são armazenados em um diretório no formato que o script main.py possa ler corretamente (Tabela 7).

Tabela 7. Adaptação do código pyModis (Fonte: Autor, 2021).

Argumento	Tipo	Descrição
output_folder	Diretório de saída	Caminho de saída onde serão salvos os produtos MODIS. Dentro desse diretório serão criados subdiretórios com os respectivos nomes de cada produto, assim como as imagens.
username	String	Nome de usuário utilizado para o login na plataforma NASA Earth Data .
password	String	Senha do usuário utilizada para fazer o login na plataforma NASA Earth Data .
start_date	String formatada	Data inicial para fazer o download dos produtos MODIS. O formato da string deverá obedecer o padrão de data da iso 8601, que no caso é AAAA-MM-DD (e.g. 2021-12-31).
end_date	String formatada	Data final para fazer o download dos produtos MODIS. O formato da string deverá obedecer ao padrão de data da iso 8601, que no caso é AAAA-MM-DD (e.g. 2021-12-31)
Nota: Caso a data inicial seja maior que a data final, o script irá gerar um erro na sua execução, ou seja, tenha certeza de que as datas estão na ordem e no formato correto.		

Segue abaixo um exemplo de execução do script:

```
C:\Users\Usuario\Codigos>python tools/modis_download.py ^
C:\Users\Usuario\destino_download ^
earth_data_username ^
```

```
earth_data_password ^
```

```
2020-11-05 ^
```

```
2020-11-25
```

4.3. Execução do modelo

O arquivo utilizado para executar o modelo é o main.py, que pode ser chamado a partir de linhas de comando (Tabela 8). Todos os resultados principais são gerados por esse script.

Tabela 8. Informações sobre o arquivo main.py (Fonte: Autor, 2021).

Argumento	Tipo	Descrição
--modis_dataset	Diretório	Diretório onde há as imagens obtidas pelo script de download. Caso o algoritmo não encontre a imagem desejada, um erro será mostrado ao usuário parando a execução do script.
--ec_processado	Caminho de arquivo ou diretório	Caminho das informações de Eddy Covariance previamente processadas. Essas informações podem ser compostas de apenas um arquivo ou um diretório com vários arquivos. Nota: Caso seja um diretório, é recomendado que tenha <i>apenas os arquivos de Eddy Covariance processados</i> para evitar problemas de decodificação dos arquivos.
--raw_flux	Caminho de arquivo ou diretório	Caminho das informações brutas das leituras de fluxo da torre de Eddy Covariance. Esse argumento pode ser o caminho de um arquivo ou um diretório com diversos arquivos, desde que sigam o padrão de nomenclatura abaixo: TOA5_11341.flux_2019_04_16.dat
--diretorio_saida	Caminho de arquivo ou diretório	É o diretório onde serão salvos os arquivos processados. Considerando que cada arquivo tem duas saídas disponíveis (saída principal e auxiliar), a nomenclatura dos arquivos utilizará o formato AAAA-MM-DD para organização das imagens e seguirá a seguinte regra: 2020-11-20.tif 2020-11-20_ancillary.tif Nota 1: Caso o arquivo já tenha sido processado, o

		<p>software irá sobrescrever-lo, e se caso o arquivo esteja aberto em algum software, o algoritmo irá falhar na sobrescrita, sendo assim <i>tenha certeza de que os arquivos de resultados não estão abertos em outros softwares</i> antes de processar novamente.</p> <p>Nota 2: Se o argumento --mascara for preenchido, o software irá criar um diretório adicional dentro da pasta de destino sendo chamado de cropped. Nesse diretório será salvo uma manipulação das imagens anteriores onde elas serão cortadas na extensão geográfica da máscara, e não da imagem toda, reduzindo seu tamanho e facilitando a visualização no QGIS.</p>
--data_inicio	String Formatada	<p>Data inicial para a execução do modelo.</p> <p>O formato da string deverá obedecer ao padrão de data da iso 8601, que no caso é AAAA-MM-DD (e.g. 2021-12-31).</p>
--data_final	String Formatada	<p>(Opcional) Data final para a execução do modelo.</p> <p>O formato da string deverá obedecer ao padrão de data da iso 8601, que no caso é AAAA-MM-DD (e.g. 2021-12-31).</p> <p>Nota: Caso esse argumento não seja preenchido, o software irá processar apenas o dia informado na -data_inicio</p>
--mascara	Caminho de arquivo	<p>(Opcional) Caminho da imagem de máscara. Caso esse argumento não seja definido, o software irá processar a imagem inteira.</p> <p>Nota 1: É esperado uma imagem .TIF no formato Byte (ou uint8), sendo que os pixels a serem processados deverão ter o valor 1 e os demais o valor 0.</p> <p>Nota 2: A imagem de máscara deverá ter o mesmo tamanho, projeção e localização geográfica de uma imagem LAI (Produto MCD15a3) para a respectiva área de estudo.</p>

Segue abaixo um exemplo de execução do script:

```
C:\Users\Usuario\Codigos>python main.py ^
--modis_dataset C:\Users\Usuario\modis_download ^
--cc_processado C:\Users\Usuario\arquivo_processado_eddypro.csv ^
--raw_flux C:\Users\Usuario\diretorio_arquivos_TOA5_flux ^
```

```

--diretorio_saida C:\Users\Usuario\diretorio_destino ^
--data_inicio 2020-10-01 ^
--data_final 2020-11-30 ^
--mascara C:\Users\Usuario\arquivo_mascara.tif

```

5. SAÍDAS DO ALGORITMO PYTSEB

A execução do main.py irá gerar duas imagens para cada dia. Uma é a imagem principal, que contém os dados de fluxo, e a outra é uma imagem auxiliar, que contém outras informações mais específicas. A visualização das bandas pode ser observada no *software* QGIS com facilidade, sendo que o resultado já está convertido para as respectivas unidades, citadas nas Tabelas 9 e 10.

Tabela 9. Saídas do modelo: imagem principal (Fonte: Autor, 2021).

Imagem Principal (sufixo: _main_output.tiff)		
Banda	Descrição	Unidade
1	Net radiation	W/m ²
2	Sensible heat flux	W/m ²
3	Latent heat flux	W/m ²
4	Soil heat flux	W/m ²

Tabela 10. Saídas do modelo: imagem auxiliar (Fonte: Autor, 2021).

Imagem Auxiliar (sufixo: _ancillary.tiff)		
Banda	Descrição	Unidade
1	Net shortwave radiation reaching the surface at time t1	W/m ²
2	Net longwave radiation reaching the surface at time t1	W/m ²
3	Net radiation divergence in the canopy at time t1	W/m ²
4	Canopy sensible heat flux at time t1	W/m ²

5	Canopy latent heat flux at time t1	W/m ²
6	Latent Heat Flux Partition (LEc/LE) at time t1	Razão
7	Canopy temperature at time t1	Kelvin
8	Soil temperature at time t1	Kelvin
9	Resistance to heat transport in the surface layer at time t1	s/m
10	Resistance to heat transport in the canopy surface layer at time t1	s/m
11	Resistance to heat transport from the soil surface at time t1 fluxes	s/m
12	Monin Obukhov Length at time t1	m
13	Friction velocity	m/s
14	<i>Quality flag</i> (Veja a seção: 6.1. Enumerador de indicação de qualidade da imagem de saída)	Adimensional

5.1. Enumerador de indicação de qualidade da imagem de saída

Conforme citado na Tabela 10, na banda de número 14 da imagem auxiliar, há um enumerador de qualidade da saída da imagem (Tabela 11). Esse enumerador descreve algumas situações que podem ocorrer caso os parâmetros calculados obtiveram resultados fora do esperado (p. e. fluxos negativos). O valor 255 representa os dados de pixel que devem ser descartados devido a problemas em algum cálculo (p. e. o comprimento de Monin-Obukhov tende ao infinito).

Tabela 11. Enumerador de qualidade da saída da imagem auxiliar (banda 14) (Fonte: Autor, 2021).

Valor	Descrição do enumerador
0	AI Fluxes produced with no reduction of PT parameter (i.e. positive soil evaporation)
1	Negative canopy latent heat flux, forced to zero (Only for model TSEB-2T)
2	Negative canopy sensible heat flux, forced to zero (Only for model TSEB-2T)
3	Negative soil evaporation, forced to zero (the PT parameter is reduced in TSEB-PT and DTD)
4	Negative soil sensible heat flux, forced to zero (Only for model TSEB-2T)
5	No positive latent fluxes found, G recomputed to close the energy balance ($G = R_N - H$)
10	All positive fluxes for soil only, produced using the one-source energy balance

	(OSEB) model.
15	No positive latent fluxes found using OSEB, G recomputed to close to energy balance $G = R_N - H$
255	Arithmetic error. <i>BAD data, it should be discarded.</i>
Nota: As descrições da tabela não foram traduzidas para evitar qualquer equívoco conceitual na interpretação do texto.	

6. VISUALIZAÇÃO DAS IMAGENS NO QGIS

Ao carregar a imagem no software QGIS, ele irá apresentar cores estranhas, visto que de fato ela não é uma imagem RGB. Para isso, sugere-se a visualização de sua simbologia para banda única, com escala de cinza ou pseudo cor. Para ver todos os canais de um pixel de uma só vez, deve-se usar a ferramenta para identificação das feições (ícone dentro do quadrado vermelho abaixo).



Depois, é só clicar em cima do pixel desejado, e uma aba será aberta na lateral direita com os dados e suas respectivas bandas. No exemplo abaixo, é possível visualizar as duas imagens carregadas no QGIS (main_output e ancillary_output).

Feição	Valor
0	2020-11-25
2020-11-25	
Banda 1	623.2626
Banda 2	265.06876
Banda 3	239.87318
Banda 4	118.320625
(Derivado)	
1	2020-11-25_ancillary
2020-11-25_ancillary	
Banda 01	767.3723
Banda 02	-144.10977
Banda 03	285.20364
Banda 04	66.27151
Banda 05	218.93213
Banda 06	0.9126995
Banda 07	304.42056
Banda 08	314.0207
Banda 09	9.366387
Banda 10	33.91138
Banda 11	63.797386
Banda 12	-35.647636
Banda 13	0.49924
Banda 14	0
(Derivado)	

7. CONFIGURAÇÕES AVANÇADAS

As configurações descritas nesta seção são correspondentes às modificações necessárias para que as imagens MODIS e as entradas do *Eddy Covariance* sejam convertidas e tratadas no formato que o pyTSEB deve receber os dados. Essas mudanças são, na sua maioria, conversão de unidades e tratamento nas imagens. Os dados contemplados nesta seção têm caráter informativo, com o objetivo de documentar quais as transformações que foram implementadas para o correto funcionamento do modelo.

7.1. Dicionário de dados de entrada da classe PyTSEB

Dicionário de argumentos de entrada para a classe pyTSEB onde o modelo será executado. Todos os dados de entrada devem ser tratados como indicados na coluna de descrição da Tabela 12.

Tabela 12. Descrição dos dados de entrada do modelo pyTSEB (Fonte: Autor, 2021).

Dicionário de entrada			
Chave	Tipo	Unidade	Descrição
T_R0	imagem ou float	Kelvin	<p>Temperatura da superfície (<i>ao amanhecer</i>), em kelvin.</p> <p>Utilizar a camada LST_Day_1km ou LST_Night_1km dos produtos MxD11A1. No caso do Brasil, as leituras de LST apropriadas para o uso são:</p> <ul style="list-style-type: none"> • Leitura Noturna do MOD11A1 (~ 22 e 23 h em São Carlos) • Leitura Noturna do MYD11A1 (~ 0 e 1 h em São Carlos) <p>Observação Importante: De acordo com o manual do usuário na tabela 9 na página 17, deve-se adicionar um fator de escala de 0.02 para que a imagem corresponda à temperatura na unidade Kelvin. Todos os valores que forem 0, devem ser ignorados.</p>
T_R1	imagem ou float	Kelvin	<p>Temperatura da superfície (<i>ao entardecer</i>), em Kelvin (Utilizado apenas quando o modelo <i>TSEB_2T</i>).</p> <p>Utilizar a camada LST_Day_1km ou LST_Night_1km dos produtos MxD11A1. No caso do Brasil, as leituras de LST apropriadas para o uso são:</p>

			<ul style="list-style-type: none"> • leitura Diurna do MOD11A1 (~ 10 e 11 h em São Carlos) • leitura Diurna do MYD11A1 (~ 12 e 13 h em São Carlos) <p>Observação Importante: De acordo com o manual do usuário na tabela 9 na página 17, deve-se adicionar um fator de escala de 0.02 para que a imagem corresponda à temperatura na unidade Kelvin. Todos os valores que forem 0, devem ser ignorados.</p> <p>Nota do PyTSEB: Quando o modelo for TSEB_2A, é necessário que tenha duas bandas: 1 = temperatura do dossel e 2 = temperatura do solo.</p>
VZA	imagem ou float	graus	<p>Ângulo Zenith de visão ou <i>View Zenith Angle</i> (VZA). Está relacionado ao ângulo de visão da observação da LST. No artigo de Guzinski et al. (2014, p. 5041), é utilizado na fórmula A1 do apêndice.</p> <p>Caso use as imagens MxD11A1, pode ser utilizada a partir da camada Layer Day_view_angl para observações diurnas ou Night_view_angl para observações noturnas</p> <p>Observação Importante: No artigo de Guzinski et al. (2014, p. 5041), o VZA é utilizado em radianos, e no produto MxD11A1 as informações são apresentadas em graus, sendo necessário um offset de -65 com fator de escala 1.0 (Ver manual do usuário pg 17). De acordo com os arquivos de exemplo do pyTSEB, as entradas devem ser em graus.</p> <p>Valor padrão: 0.0</p>
LAI	Imagem ou float	m ² /m ²	<p>Índice de Área Foliar ou <i>Leaf Area Index</i> (LAI).</p> <p>Pode ser utilizada a imagem do produto MCD15a3 na camada Lai_500m, sendo a mesma sem unidade de medida.</p> <p>Observação Importante: Os valores de preenchimento de 249 a 255 devem ser ignorados e transformados para NaN, pois são regiões observadas que não são pixels terrestres (água, gelo, área inundada e etc.). Mais detalhes no manual do usuário na tabela 6 da p. 10. Todos esses pixels devem ser tratados antes de entrar no pyTSEB. Da mesma maneira, é necessário aplicar um fator de escala de 0.1 como demonstrado no manual do usuário na tabela 4, p. 7.</p> <p>Nota: A camada CloudState indica se há a presença de nuvens.</p>

f_c	Imagem ou float	N/A	<p><i>Vegetation Fractional Cover.</i></p> <p>Observação Importante: Foi utilizado a mesma imagem definida em pelo parâmetro f_g.</p> <p>Valor padrão: 1.0</p>
h_C	imagem ou float	metros	<p>Altura do dossel.</p> <p>Pode ser utilizado uma imagem para definir as alturas.</p> <p>Valor padrão: 2.4 m Valor utilizado: 7 m</p>
f_g	imagem ou float	N/A	<p>Fração da vegetação que é verde.</p> <p>De acordo com Guszinski et. al (2013, p. 2812, eq. 10), o f_g é baseado na seguinte fórmula:</p> $f_g = 1.2 \frac{EVI}{NDVI}, 0 \leq f_g \leq 1.$ <p>Para o uso do EVI e NDVI, pode ser utilizado os produtos MxD13a1 nas camadas 500m 16 days EVI e 500m 16 days NDVI.</p> <p>Observação Importante: De acordo com o manual do usuário na tabela 1 da p. 9, ambos EVI e NDVI devem ser multiplicados pelo fator de escala de 10⁻⁴ sem offset. Os valores de -3000 devem ser ignorados.</p> <p>Nota: O produto MODIS Terra (MOD13a1) e MODIS Aqua (MYD13a1) têm uma defasagem de 8 dias, ou seja, apesar de que cada produto é uma média de 16 dias, há uma leitura intercalada entre ambos os satélites a cada 8 dias.</p> <p>Valor padrão: 1</p>
w_C	float	N/A	<p>Razão da altura da vegetação pelo diâmetro do dossel.</p> <p>Conhecido como a variável <i>D</i> na equação A2 do artigo de Guszinski et al. (2014, p. 5041), é definido por razão da altura da vegetação pela largura da copa da planta. Os autores definem os valores de:</p> <ul style="list-style-type: none"> • Áreas de cultivo: 1 • Coníferas: 3.5 <p>Nota 1: Campbell e Norman (1998, p. 274) descrevem uma tabela com as razões e fatores de aglomeração de algumas espécies de árvores conhecidas no Canadá e Estados Unidos.</p>

			<p>Nota 2: No código do pyTSEB, o parâmetro é utilizado no cálculo do fator de aglomeração em função do ângulo solar Zenith, ou Ω_{θ}, que por sua vez cita o artigo de Kustas e Normam (1999, p. 15).</p> <p>Valor padrão: 3.5</p>
input_mask	imagem ou int	N/A	<p>É utilizado para definir uma máscara na imagem.</p> <p>Caso não haja imagem, é necessário identificar como valor 0 para que seja feito o cálculo da imagem por completo.</p> <p>Observação Importante: Caso seja necessário o uso de uma imagem, deverá corresponder a resolução das outras imagens utilizadas. Nesse caso, deve-se respeitar a resolução da imagem LAI do produto MCD15a3, pois é a imagem com menor resolução (500 metros).</p>
Arquivos de saída			
Argumento	Tipo	Unidade	Descrição
output_file	path	N/A	<p>É o caminho de saída onde será salvo a imagem. No caso, será salva uma imagem principal e uma auxiliar.</p> <p>De acordo com a documentação web do pyTSEB, a ordem dos canais da imagem principal e auxiliar estão disponíveis na seção Saídas do algoritmo PyTSEB</p>
Dados meteorológicos			
Argumento	Tipo	Unidade	Descrição
DOY	int	N/A	Dia do ano. Deve ser colocado o valor de 1 a 365 ou de 1 a 366 para um ano bissexto.
time	imagem ou float	Hora decimal	<p>Hora da aquisição do dado LST.</p> <p>Observação Importante: Esse dado pode ser obtido a partir do horário de aquisição, ou pode ser a partir da camada Day_view_time ou Night_view_time das imagens LST, sendo que há a necessidade de multiplicar pelo fator de escala 0.1. É importante salientar que os pixels sem valor de LST não possuirão valores de hora válidos (situação de nuvem), ou seja, serão substituídos pelo <i>fill value</i> 255, que no caso é fora do intervalo válido de 0 a 240 (0 a 24 h)</p> <p>Nota: No código do pyTSEB, a definição do parâmetro <i>time</i> é a hora de observação para a LST.</p>
T_A0	Imagem ou float	Kelvin	Temperatura ambiente do ar ao amanhecer.

			Nota: Dados adquiridos a partir do <i>Eddy Covariance</i> .
T_A1	Imagem ou float	Kelvin	Temperatura ambiente do ar. Nota: Dados adquiridos a partir do <i>Eddy Covariance</i> .
S_dn	Imagem ou float	W/m ²	Radiação de onda curta de entrada. É utilizada para calcular o particionamento da radiação solar entre direta e difusa, visível e próximo nir, de acordo com o trabalho de Weiss e Norman (1984). Nota: A implementação do artigo acima foi inserida no código do pyTSEB .
u	Imagem ou float	m/s	Velocidade do vento. Nota: Dados adquiridos a partir do <i>Eddy Covariance</i> .
ea	Imagem ou float	mb	Pressão de vapor. Nota: Dados adquiridos a partir do <i>Eddy Covariance</i> .
p	Imagem ou float	mb	(Opcional) Pressão. Nota: Dados adquiridos a partir do <i>Eddy Covariance</i> .
L_dn	Imagem ou float	W/m ²	(Opcional) Radiação de onda longa. Nota: De acordo com a documentação do pyTSEB , o valor L_dn pode ser estimado pelo algoritmo caso ele não seja fornecido.
Seleção do modelo			
Argumento	Tipo	Unidade	Descrição
model	string	N/A	Tipo do modelo a ser utilizado no pyTSEB, dos quais: TSEB_PT: Kustas and Norman 1999 (Priestley-Taylor TSEB). DTD: Norman et al. 2003 (sendo esse o utilizado nesse trabalho). TSEB_2T: Component temperatures TSEB.
Descrição da localidade			
Argumento	Tipo	Unidade	Descrição
lat	float	grau decimal	Latitude do local de observação.
lon	float	grau decimal	Longitude do local de observação.

alt	float	m	Altitude do local de observação.
z_u	float	m	Altura do leitor de velocidade do vento.
z_T	float	m	Altura do leitor de temperatura do ar.
Propriedades Espectrais			
Argumento	Tipo	Unidade	Descrição
emis_C	float	N/A	Emissividade da folha. Essa emissividade e outras estão presentes na Tabela 2.8 do livro de Brutsaert et. al (1984, p. 64). Valor padrão: 0.98
emis_S	float	N/A	Emissividade do Solo. Essa emissividade e outras estão presentes na tabela 2.8 do livro de Brutsaert et. al (1984, p. 64). Valor padrão: 0.95
rho_vis_C	float	N/A	Reflectância visível da folha. Valor padrão: 0.07
rho_nir_C	float	N/A	Reflectância NIR da folha. Valor padrão: 0.32
tau_vis_C	float	N/A	Transmitância visível da folha. Valor padrão: 0.08
tau_nir_C	float	N/A	Transmitância NIR da folha. Valor padrão: 0.33
rho_vis_S	float	N/A	Reflectância visível do solo. Valor padrão: 0.15
rho_nir_S	float	N/A	Reflectância NIR do solo. Valor padrão: 0.25
Propriedades da Superfície			
Argumento	Tipo	Unidade	Descrição
alpha_PT	float	N/A	Valor inicial para transpiração de dossel de acordo com Priestley e Taylor.

			<p>Parâmetro presente no trabalho de Kustas e Norman (1999, p. 18).</p> <p>Valor padrão: 1.26</p>
x_LAD	float	N/A	<p>Distribuição da inclinação da folha LIDF (Campbell, 1990):</p> <p>1: Esférica LIDF 0: Vertical LIDF float(inf): Horizontal LIDF</p>
leaf_width	float	metro	<p>Comprimento efetivo de folha.</p> <p>Valor padrão: 0.1</p>
z0_soil	float	metro	<p>Comprimento de rugosidade do solo nu.</p> <p>É encontrado no artigo de Guzinski et. al (2014, p. 5041) e foi retirado de Norman et al. (2000).</p> <p>Valor padrão: 0.01</p>
landcover	int	N/A	<p>Cobertura primária do solo:</p> <p>1: Coníferas; 4: Folha larga; 6: Arbusto; 10: Grama/ Folha estreita; 12: Lavoura.</p> <p>Valor usado: 6</p>
Resistências			
Argumento	Tipo	Unidade	Descrição
resistance_for m	numérico	N/A	<p>Formulação das resistências.</p> <p>0: Kustas & Norman 1999; 1: Choudhury & Monteih 1998; 2: McNaughton & Van der Hurk 1995.</p> <p>Valor padrão: 0</p>
KN_b	float	N/A	<p>Parâmetro b da equação 5 de Kustas e Normam (1999).</p> <p>Valor padrão: 0.012</p>
KN_c	float	N/A	<p>Parâmetro c da equação 5 de Kustas e Normam (1999).</p>

			Valor padrão: 0.0025
KN_C_dash	float	N/A	Parâmetro de Kustas e Normam (1999). Valor padrão: 90
Opções Adicionais			
Argumento	Tipo	Unidade	Descrição
G_form	numérico	N/A	Tipo de cálculo de fluxo de calor do solo. 1: Estima G como a razão Rn_{soil} . $G_{ratio} = 0.35$; 0: Usa um valor de G constante. $G_{constant} = 0$; 2: Estima G por Santanello e Friedl. Valor padrão: 1
G_ratio	float	N/A	Valor padrão: 0.35
G_constant	float	N/A	Valor padrão: 0.0
G_amp	float	N/A	Valor padrão: 0.35
G_phase	float	N/A	Valor padrão: 3.0
G_shape	float	N/A	Valor padrão: 24.0
water_stress	bool		É considerado como falso, sem explicação do que pode ser. Valor padrão: False

7.2. Algumas observações dos dados

Durante o desenvolvimento, algumas dúvidas e conclusões parciais surgiram. Abaixo segue algumas considerações:

- 1) O **LAI** de entrada é o LAI efetivo, ou seja, não é necessário fazer a divisão pelo **f_c** conforme mostrado em Guzinski et al. (2014, p. 5041 apêndice A1).
- 2) O **f_c** é chamado de *Fractional Cover*. Ele está presente em Kustas e Norman (1999, p. 16). No [código do pyTSEB](#), ele é utilizado para calcular o Ω_0 que é o fator de aglomeração 0. No entanto, o aspecto mais intrigante dessa variável é que ela é utilizada no cálculo de LAI efetivo, que no caso utiliza o LAI_g/f_g e pode ser representado pela letra **F** em Guzinski et al. (2014, p. 5041). Apesar disso, no [código do pyTSEB](#), esse cálculo é feito com o **f_c** e não com **f_g**. Ou seja, o **f_c** no trecho do [código do pyTSEB](#) poderia ser um erro de digitação (um bug), no entanto, em outros pontos do código ([1](#) e [2](#)) o **f_c** também

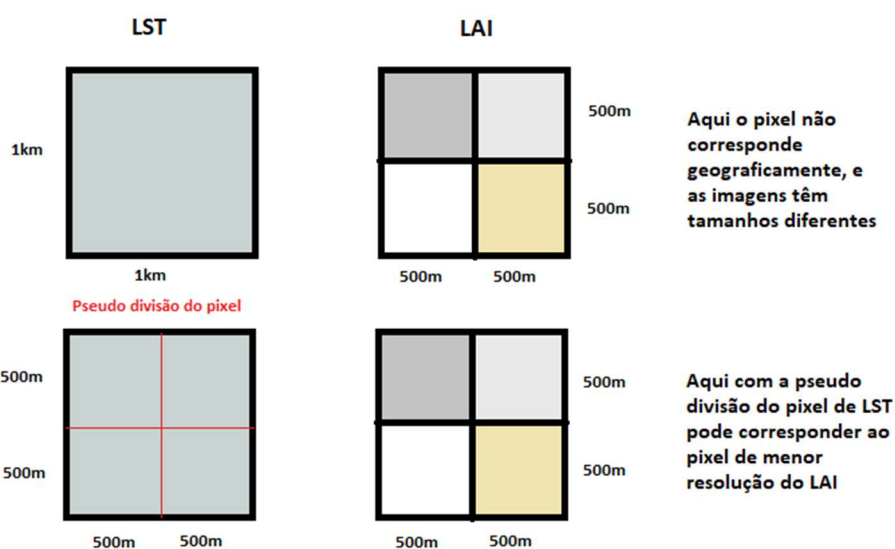
é utilizado para dividir o LAI, mas nos artigos é utilizado o f_g (Guzinski et. al. 2014, p 5041). Conclusão: o f_g e f_c podem ser a mesma variável.

7.3. Pseudo divisão dos rasters de LST e emissividade

De acordo com a imagem abaixo, foram feitas algumas modificações nos arquivos para a pseudo divisão dos pixels. O termo correto para tratamento de imagens é chamado de *upsampling*.

A implementação desse algoritmo foi necessária para que o pyTSEB pudesse fazer a correspondência entre o LST e o LAI. Essa necessidade surgiu devido a resolução da imagem LST ser o dobro da resolução do LAI, no entanto, ambas as imagens representam a mesma região geográfica. Resumidamente, o algoritmo duplica as colunas e linhas criando uma imagem com o dobro da resolução, e salva essa imagem com a mesma extensão geográfica. A exemplificação do algoritmo está presente na Figura 5.

Figura 5. *Upsampling* da imagem LST (Fonte: Autor, 2021).



ANEXO I – Código pyTSEB

O código utilizado no desenvolvimento dessa pesquisa de Doutorado, o *pyTSEB*, é de livre acesso e está disponível em: <https://github.com/hectornieto/pyTSEB>

ANEXO II – Resultados da evapotranspiração medida pelo sistema *Eddy Covariance*

Os dados de evapotranspiração medidos pelo sistema *Eddy Covariance* utilizados nessa pesquisa de Doutorado foram disponibilizados por Kobayashi (2021). Tais dados foram obtidos após a aplicação de algumas metodologias para preenchimento de falhas durante o período de coleta. Os métodos utilizados por Kobayashi (2021) para preencher as falhas foram: variação diurna média (ET_{MDV}), regressão linear múltipla (ET_{LR}), *random forest* (ET_{RFR}), Penman-Monteith inverso (ET_{PM}), rede neural densa (ET_{DNN}) e rede neural recorrente do tipo LSTM (ET_{LSTM}).

A tabela é o acumulado dos métodos na escala temporal diária em *mm*.

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2018-10-05	2.54	3.47	3.18	2.64	4.59	3.15
2018-10-06	2.64	2.72	2.6	1.88	3.66	2.34
2018-10-07	2.75	1.72	1.83		2.67	1.25
2018-10-08	2.81	1.92	1.82		2.82	1.24
2018-10-09	2.86	4.33	3.73		4.99	3.29
2018-10-10	2.92	3.54	3.5		4.24	3.69
2018-10-11	3	2.61	2.86	1.51	3.96	2.18
2018-10-12	3.03	4.74	3.8		5.38	3.49
2018-10-13	3.04	3.95	3.29		4.61	2.51
2018-10-14	3.02	3.47	3.25	1.87	4.21	2.62
2018-10-15	3.09	2.94	3.02		3.55	2.42
2018-10-16	3.28	3.93	3.46		4.69	2.89
2018-10-17	3.59	3.72	3.36		4.35	2.72
2018-10-18	3.7	4.82	4.56		5.72	3.85
2018-10-19	3.71	3.29	3.74	2.37	4.61	3.18
2018-10-20	3.75	3.06	3.82	2.87	4.03	2.91
2018-10-21	3.64	3.27	3.62	3.14	4.11	3.15
2018-10-22	3.57	3.59	3.76		4.56	3.23
2018-10-23	3.41	3.95	3.96		5	3.23
2018-10-24	3.11	1.47	1.57		2.15	1.25
2018-10-25	3.17	1.51	1.46		2.04	0.96
2018-10-26	3.21	3.06	3.01		3.89	2.51
2018-10-27	3.27	2.49	2.73		3.21	1.73
2018-10-28	3.37	3.21	3.6	3.15	4.05	2.63
2018-10-29	3.5	3.1	3.33	3.09	4	2.61
2018-10-30	3.54	4	3.86		5.01	3.51
2018-10-31	3.59	3.99	3.58		4.88	3.05
2018-11-01	3.79	3.46	3.65		4.53	2.26

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2018-11-02	3.6	4.26	4.12		5.12	2.94
2018-11-03	3.56	4.36	4.24		5.32	3.57
2018-11-04	3.5	3.58	4.01	0	4.78	3.18
2018-11-05	3.43	2.9	2.93	0	4.13	2.61
2018-11-06	3.32	3.7	3.71		4.72	3.15
2018-11-07	3.3	1.94	2.35	0	2.88	1.64
2018-11-08	2.89	1.22	2.24		2.64	1.36
2018-11-09	3.06	2.14	2.89		3.3	2.05
2018-11-10	3.08	2.58	2.9		3.49	2.11
2018-11-11	3.19	3.46	3.26		4.21	2.6
2018-11-12	3.52	4.94	4.65		5.77	4.13
2018-11-13	3.62	5.11	4.75		6	4.3
2018-11-14	3.6	4.54	4.05		5.3	3.3
2018-11-15	3.71	5.37	4.42	0	6.11	4.23
2018-11-16	3.83	5.04	4.61	0	6.19	4.43
2018-11-17	3.56	3.76	3.36		4.85	3.17
2018-11-18	3.4	3.36	3.22		4.21	2.39
2018-11-19	3.2	1.34	1.8		2.44	1.13
2018-11-20	2.89	2.39	2.87	0	3.58	2.2
2018-11-21	2.94	2.52	2.49	0	3.45	2.05
2018-11-22	2.98	2.88	3		3.82	2.37
2018-11-23	2.98	3.05	2.8		3.92	2.25
2018-11-24	3.23	3.03	3.31		4.11	2.31
2018-11-25	3.43	2.99	3.3		3.94	2.38
2018-11-26	3.37	3.13	3.52	0	4.33	2.86
2018-11-27	3.77	4.23	4.33	0	5.1	4.12
2018-11-28	3.62	4.12	4.18		4.94	3.78
2018-11-29	3.81	4.75	4.74		5.36	4.1
2018-11-30	3.81	4.07	3.8		5.02	3.36
2018-12-01	3.74	2.95	2.63		4.28	2.1
2018-12-02	3.83	3.77	4.13	2.78	4.94	3.17
2018-12-03	3.7	3.95	4.02	3.36	5.01	3.73
2018-12-04	3.65	4.38	4.27		4.82	4.05
2018-12-05	3.79	3.25	3.65		4.72	3.3
2018-12-06	3.69	3.5	3.78		4.62	2.59
2018-12-07	3.65	3.63	3.8	6.29	4.44	2.56
2018-12-08	3.63	3.38	3.72	3.71	4.43	2.95
2018-12-09	3.55	3.6	3.78		4.64	3.55

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2018-12-10	3.53	3.63	3.88		5	3.36
2018-12-11	3.9	3.84	3.95		5.34	3.26
2018-12-12	4.21	4.55	4.31		5.73	4.1
2018-12-13	4.39	4.36	4.39		5.45	3.56
2018-12-14	4.4	4.49	4.77		5.67	4.36
2018-12-15	4.41	4.34	4.52		5.51	4.06
2018-12-16	4.43	4.27	4.17		5.41	3.76
2018-12-17	4.62	5.16	4.77		5.87	4.05
2018-12-18	4.54	4.36	3.97		5.07	3.39
2018-12-19	4.61	3.75	3.63		4.72	3.05
2018-12-20	4.47	5.43	4.99		6.33	4.57
2018-12-21	4.52	4.82	4.53		5.78	3.88
2018-12-22	4.46	5.13	4.92		5.96	4.24
2018-12-23	4.38	3.95	3.63		4.9	3.24
2018-12-24	4.13	3.41	3.27		4.45	2.76
2018-12-25	3.97	2.69	2.68		3.64	2.18
2018-12-26	3.75	2.5	2.49		3.36	1.92
2018-12-27	3.87	3.93	3.64		4.97	3.44
2018-12-28	3.85	4.22	3.95		5.05	3.76
2018-12-29	4.1	5.24	4.67		5.84	4.48
2018-12-30	3.99	5.18	4.85		6.04	4.59
2018-12-31	4.13	4.9	4.93		6.09	4.71
2019-01-01	4.07	3.3	3.4	2.64	4.28	2.8
2019-01-02	3.84	4.66	3.89	3.74	5.15	3.8
2019-01-03	3.64	5.31	4.41	4.62	5.83	4.28
2019-01-04	3.39	3.52	3.11	2.56	4.2	2.75
2019-01-05	3.5	2.05	1.98	1.07	2.91	1.4
2019-01-06	3.56	2.87	2.63	1.96	3.56	2.08
2019-01-07	3.39	5.38	5.06	5.69	6.2	4.62
2019-01-08	3.69	4.63	3.74	4.4	5.22	3.69
2019-01-09	3.85	5.32	4.94	5.82	6.18	4.53
2019-01-10	4.41	5.14	5.01	6.61	6.08	3.85
2019-01-11	4.53	4.41	4.05	4.82	5.18	3.7
2019-01-12	4.96	3.87	3.98	3.48	4.94	3.76
2019-01-13	4.79	5.07	5.44	4.99	6.17	4.65
2019-01-14	4.75	4.8	4.64	5.64	5.76	4.81
2019-01-15	4.85	4.7	4.62	5.74	5.61	3.9
2019-01-16	4.84	4.02	3.95	4.72	4.94	3.28

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2019-01-17	4.74	3.38	3.68	4.33	4.6	2.7
2019-01-18	4.66	4.82	4.47	5.08	5.63	4.06
2019-01-19	4.58	4.91	4.41	5.32	5.55	4.21
2019-01-20	4.84	4.77	4.43	5.13	5.49	4.04
2019-01-21	4.55	5.49	4.85	5.85	6.37	4.43
2019-01-22	4.34	5.13	4.59	5.84	5.79	4.3
2019-01-23	4.33	4.27	4.38	4.2	5.3	4.04
2019-01-24	4.24	2.75	2.94	3.81	3.71	3.26
2019-01-25	4.27	2.99	3.11	4.34	3.7	2.01
2019-01-26	4.56	3.7	4.22	4.21	4.82	3.87
2019-01-27	4.45	3.91	4.06	4.53	5.01	3.39
2019-01-28	4.84	4.47	4.29	6.55	5.76	3.97
2019-01-29	5.12	4.67	4.65	7.11	6.14	3.89
2019-01-30	4.93	5.21	4.7	6.33	6.12	4.16
2019-01-31	5.14	4.83	4.54	6.12	5.83	4.79
2019-02-01	4.63	4.78	4.34	8.52	5.84	3.76
2019-02-02	4.29	5.01	4.62	8.11	6.03	3.61
2019-02-03	4.24	5.25	5.37	6.87	6.02	4.73
2019-02-04	4.19	3.13	3.69	4.34	4.2	4.05
2019-02-05	4.21	2.99	3.4	4.78	4.24	2.74
2019-02-06	4.32	1.64	1.91	1.79	2.66	1.49
2019-02-07	4.04	3.64	3.96	4.62	4.72	3.49
2019-02-08	4.1	4.4	4.78	6.3	5.65	4.3
2019-02-09	4.13	4.54	4.73	7.38	5.75	4.03
2019-02-10	3.74	4.65	4.48	6.55	5.79	3.82
2019-02-11	3.35	5.27	4.7	6.11	6.19	3.91
2019-02-12	3.08	2.68	2.51	2.9	3.73	1.99
2019-02-13	2.82	2.03	2.69	2.96	3.11	1.77
2019-02-14	2.69	3.27	3.44	5.3	4.53	2.87
2019-02-15	2.7	2.66	2.46	2.57	3.59	1.7
2019-02-16	2.64	2.31	2.24	1.77	3.03	1.39
2019-02-17	2.92	2.43	2.03	2.51	3	1.57
2019-02-18	2.8	3.1	3.02	3.29	4	2.19
2019-02-19	3.07	3.17	2.98	4.16	3.82	2.37
2019-02-20	3.18	3.06	2.96	3.05	3.91	2.67
2019-02-21	3.56	3.02	2.79	2.97	3.62	2.37
2019-02-22	3.64	3.16	3.12	3.01	4.08	2.82
2019-02-23	3.68	4.51	4	4.69	5.03	3.84

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2019-02-24	3.57	3.97	3.52	4.04	4.55	3.2
2019-02-25	3.58	4.76	4.27	4.57	5.47	3.77
2019-02-26	3.72	2.29	2.18	1.97	3.08	1.61
2019-02-27	3.75	3.4	3.51	2.99	4.31	2.72
2019-02-28	3.67	2.17	2.07	1.41	3.06	1.65
2019-03-01	3.38	1.53	1.57	0.95	2.46	1.03
2019-03-02	3.45	2.49	2.32	1.5	3.21	1.88
2019-03-03	3.5	2.85	2.81	1.72	3.75	2.42
2019-03-04	3.68	3.1	3.27	3.24	4.1	2.65
2019-03-05	3.81	3.25	3.03	2.86	4.14	2.71
2019-03-06	3.8	3.97	3.83	3.57	4.93	3.62
2019-03-07	3.54	2.65	2.61	2.35	3.45	2.16
2019-03-08	3.71	4.14	3.66	4	4.98	3.39
2019-03-09	3.71	4.58	4.04	4.19	5.41	3.8
2019-03-10	3.71	4.05	3.6	3.23	4.97	3.43
2019-03-11	3.76	2.83	3.12	2.3	3.72	2.42
2019-03-12	3.67	3.58	3.42	3.56	4.48	2.99
2019-03-13	3.43	4.15	3.73	3.46	4.85	3.39
2019-03-14	3.47	3.45	3.16	2.44	4.32	2.9
2019-03-15	3.63	3.55	3.45	2.55	4.5	3.09
2019-03-16	3.98	3.19	2.82	2.28	3.97	2.4
2019-03-17	4.06	4.36	3.82	3.42	5.05	3.46
2019-03-18	3.68	4.47	3.77	3.3	5.19	3.62
2019-03-19	3.56	4.67	4.53	3.36	5.52	3.74
2019-03-20	3.74	3.69	3.3	2.65	4.78	2.88
2019-03-21	3.69	2.3	2.79	1.87	3.54	2.11
2019-03-22	3.61	2.54	2.76	2.49	3.43	2.41
2019-03-23	3.31	3.37	3.62	3.35	4.45	3.26
2019-03-24	3.29	3.53	3.53	3.3	4.66	3.43
2019-03-25	3.37	3.98	3.83	4.8	4.89	3.54
2019-03-26	3.55	4.34	4.08	5.02	5.27	3.85
2019-03-27	3.55	3.69	3.69	3.65	4.73	3.33
2019-03-28	3.74	3.23	3.69	3.27	4.41	3.24
2019-03-29	3.75	3.01	3.36	3.17	4.11	3.14
2019-03-30	3.72	3.47	3.77	3.95	4.59	3.6
2019-03-31	3.71	3.7	3.99	4.27	4.73	3.65
2019-04-01	3.68	3.37	3.77	3.54	4.63	3.34
2019-04-02	3.78	3.67	3.63	3.66	4.82	3.52

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2019-04-03	3.76	3.41	3.72	4.07	4.35	2.62
2019-04-04	3.75	4.39	3.89	4.67	5.09	3.49
2019-04-05	3.51	4.55	3.69	3.21	5.01	3.16
2019-04-06	3.07	4.95	4.46	3.35	5.67	4.02
2019-04-07	2.96	3.37	2.72	1.92	3.78	2.33
2019-04-08	2.84	1.74	1.99	0.84	2.81	1.34
2019-04-09	2.86	2.02	2.47	1.67	3.07	1.91
2019-04-10	2.86	2.73	3.11	2.41	3.94	2.71
2019-04-11	2.86	3.27	3.31	2.86	4.29	3.1
2019-04-12	2.83	3.55	3.6	3.22	4.65	3.28
2019-04-13	3.09	2.79	2.99	2.28	3.77	2.26
2019-04-14	2.95	1.1	1.47	0.68	1.95	0.84
2019-04-15	3.22	3.29	3.25	2.27	4.29	2.94
2019-04-16	3.25	3.83	3.34	2.62	4.5	3.22
2019-04-17	3.22	3.14	3.02	2.35	4.27	2.85
2019-04-18	3.23	2.99	3.87	3.39	3.89	2.91
2019-04-19	3.2	2.94	3.55	3.23	3.93	2.99
2019-04-20	3.21	3.04	3.39	3.58	4.08	2.96
2019-04-21	3.4	3.45	3.81	4.17	4.56	2.92
2019-04-22	3.09	3.58	3.38	3.72	4.38	2.93
2019-04-23		2.89	2.82	2.05	3.79	2.52
2019-04-24		3.32	2.97	2.34	4.01	2.69
2019-04-25		3.9	3.6	3.09	4.89	3.3
2019-04-26		3.51	2.95	2.67	4.18	3.01
2019-04-27		3.83	3.32	3.13	4.7	3.22
2019-04-28		3.48	3.19	2.9	4.42	2.86
2019-04-29		2.55	2.62	2.01	3.45	2.41
2019-04-30		2.82	3.2	2.72	3.79	2.96
2019-05-01	2.32	2.5	2.51	2.44	3.29	2.19
2019-05-02	2.34	2.21	2.15	1.89	2.89	1.58
2019-05-03	2.34	3.55	3.19	2.68	4.33	2.79
2019-05-04	2.31	3.25	2.97	2.48	4.07	2.62
2019-05-05	2.26	3.57	3.17	2.63	4.31	3.1
2019-05-06	2.47	3.59	2.9	2.73	4.27	3.05
2019-05-07	2.43	2.83	2.65	2.07	3.56	2.45
2019-05-08	2.54	2.56	2.6	2.18	3.58	2.56
2019-05-09	2.55	3.04	3.09	2.17	3.93	2.76
2019-05-10	2.55	3.21	2.79	1.93	3.78	2.54

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2019-05-11	2.53	2.87	2.35	1.66	3.27	1.83
2019-05-12	2.41	3.68	2.95	2.52	4.24	3
2019-05-13	2.27	2.9	2.68	2.39	3.8	2.6
2019-05-14	2.26	2.8	2.54	1.98	3.47	2.59
2019-05-15	2.2	1.75	1.99	1.83	2.58	1.63
2019-05-16	2.17	1.75	1.91	1.7	2.57	1.57
2019-05-17	2.13	1.26	1.45	1.04	2.07	1.11
2019-05-18	2.06	1.41	1.81	0.89	2.03	1.2
2019-05-19	2.08	2.31	2.28	1.82	3.04	2.32
2019-05-20	2.11	2.35	2.49	2.09	3.12	2.38
2019-05-21	2	2.29	2.42	2.37	2.9	2.07
2019-05-22	2.01	2.42	2.66	2.83	3	2.11
2019-05-23	2.11	2.41	2.24	2.91	3.06	1.78
2019-05-24	1.99	1.51	1.63	1.28	2.05	0.88
2019-05-25	1.93	2.15	1.69	1.51	2.15	1.53
2019-05-26		2.38	2.45	2.24	2.73	1.75
2019-05-27	1.81	2.57	2.48	2.98	2.77	1.84
2019-05-28	2.03	2.87	2.74	2.79	3.68	1.82
2019-05-29	1.98	2.97	2.82	2.45	3.9	2.37
2019-05-30	2.02	3.18	2.96	2.59	4.1	2.48
2019-05-31	1.86	3.12	2.96	2.98	3.97	1.83
2019-06-01	1.98	2.86	2.52	2.32	3.7	2.18
2019-06-02	2.04	1.98	1.98	1.53	2.86	1.8
2019-06-03	2.04	0.71	0.9	0.54	1.52	0.67
2019-06-04	2.04	1.75	2.05	1.32	2.22	1.37
2019-06-05	2.04	2.04	2.14	1.57	2.45	1.52
2019-06-06	2.09	2.17	2.1	1.54	2.57	1.6
2019-06-07	2.18	2.19	2.18	1.94	2.92	1.53
2019-06-08	2.13	1.82	1.99	1.8	2.43	1.49
2019-06-09	2.14	2.13	2.18	1.78	2.67	1.83
2019-06-10	2.15	2.11	2.01	1.72	2.65	1.57
2019-06-11	2.24	2.32	2.35	2.26	3.21	1.78
2019-06-12		2.19	2.19	2.2	2.95	1.76
2019-06-13		2.53	2.51	2.28	3.5	1.79
2019-06-14		2.48	2.66	2.63	3.52	1.53
2019-06-15		2.25	2.38	2.4	3.2	1.77
2019-06-16		2.2	2.42	2.44	3.24	2.02
2019-06-17		1.76	1.99	1.82	2.67	1.57

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2019-06-18		2.18	2.14	2.09	2.92	1.63
2019-06-19		1.98	2.04	2.16	2.64	1.6
2019-06-20		2.2	2.16	2.28	3.01	1.91
2019-06-21	2.01	1.89	2.15	1.82	2.79	1.77
2019-06-22	2.03	1.97	2.14	1.65	2.9	1.92
2019-06-23	2.05	1.99	2.13	1.98	2.84	1.53
2019-06-24	1.9	2.28	2.24	2.13	2.85	1.75
2019-06-25	1.84	2.58	2.59	2.56	3.37	1.49
2019-06-26	1.82	2.78	2.73	2.84	3.46	1.49
2019-06-27	1.83	2.3	2.12	2.13	3.3	1.81
2019-06-28		2.45	2.53	2.39	3.17	1.72
2019-06-29		2.43	2.54	2.48	3.23	1.56
2019-06-30		2.53	2.58	2.28	3.3	1.78
2019-07-01		2.37	2.42	2.1	3.08	1.62
2019-07-02		2.4	2.33	2.07	2.77	1.4
2019-07-03				2.31		
2019-07-04				1.32		
2019-07-05				0.22		
2019-07-06				0.81		
2019-07-07				0.84		
2019-07-08				1.23		
2019-07-09				1.62		
2019-07-10				1.8		
2019-07-11				1.82		
2019-07-12				2.14		
2019-07-13				2.22		
2019-07-14				2.51		
2019-07-15				2.37		
2019-07-16				0.94		
2019-07-17				1.07		
2019-07-18				1.33		
2019-07-19				1.57		
2019-07-20				1.83		
2019-07-21				1.79		
2019-07-22				1.58		
2019-07-23				2.05		
2019-07-24				2.23		
2019-07-25				2.09		

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2019-07-26				2.01		
2019-07-27				2.44		
2019-07-28				1.76		
2019-07-29				1.69		
2019-07-30				2.05		
2019-07-31				2.06		
2019-08-01				2.38		
2019-08-02				2.68		
2019-08-03				0.37		
2019-08-04				0.17		
2019-08-05				0.35		
2019-08-06				0.95		
2019-08-07				1.58		
2019-08-08				2.1		
2019-08-09				2.32		
2019-08-10				2.81		
2019-08-11				2.67		
2019-08-12				2.62		
2019-08-13				2.34		
2019-08-14				0.96		
2019-08-15				1.4		
2019-08-16				1.89		
2019-08-17				2.27		
2019-08-18				2.71		
2019-08-19				0.97		
2019-08-20				0.96		
2019-08-21				1.28		
2019-08-22				1.35		
2019-08-23				1.11		
2019-08-24				1.39		
2019-08-25				1.58		
2019-08-26				2		
2019-08-27				1.95		
2019-08-28				1.85		
2019-08-29				2.31		
2019-08-30				2.88		
2019-08-31				3.08		
2019-09-01				0.64		

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2019-09-02				0.99		
2019-09-03				0.63		
2019-09-04				1.05		
2019-09-05				0.79		
2019-09-06				1.03		
2019-09-07				1.9		
2019-09-08				2.45		
2019-09-09				2.52		
2019-09-10				2.91		
2019-09-11				3.18		
2019-09-12				3.46		
2019-09-13				1.79		
2019-09-14				1.82		
2019-09-15				2.32		
2019-09-16				2.92		
2019-09-17				3.25		
2019-09-18				3.33		
2019-09-19				2.4		
2019-09-20				1.4		
2019-09-21				1.25		
2019-09-22				1.16		
2019-09-23				1.33		
2019-09-24				1.59		
2019-09-25				0.22		
2019-09-26				0.3		
2019-09-27				1.09		
2019-09-28				1.31		
2019-09-29				1.64		
2019-09-30				2.15		
2019-10-01				5.16		
2019-10-02				6.13		
2019-10-03				5.01		
2019-10-04						
2019-10-05						
2019-10-06						
2019-10-07						
2019-10-08						
2019-10-09						

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2019-10-10						
2019-10-11						
2019-10-12						
2019-10-13						
2019-10-14						
2019-10-15						
2019-10-16						
2019-10-17						
2019-10-18						
2019-10-19						
2019-10-20						
2019-10-21						
2019-10-22						
2019-10-23						
2019-10-24						
2019-10-25						
2019-10-26						
2019-10-27						
2019-10-28						
2019-10-29						
2019-10-30						
2019-10-31						
2019-11-01						
2019-11-02						
2019-11-03						
2019-11-04						
2019-11-05						
2019-11-06						
2019-11-07						
2019-11-08						
2019-11-09						
2019-11-10						
2019-11-11						
2019-11-12						
2019-11-13						
2019-11-14						
2019-11-15						

2019-11-16						
------------	--	--	--	--	--	--

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2019-11-17						
2019-11-18						
2019-11-19						
2019-11-20						
2019-11-21						
2019-11-22						
2019-11-23						
2019-11-24						
2019-11-25						
2019-11-26						
2019-11-27						
2019-11-28						
2019-11-29						
2019-11-30	4.26					
2019-12-01	4.43					
2019-12-02	4.3					
2019-12-03	4.53					
2019-12-04	4.61	2.24	1.69		2.99	3.26
2019-12-05	4.62	2.4	2.19		3.19	3.83
2019-12-06	4.71	4.29	5.21	5.02	5.44	4.11
2019-12-07	4.33	4.35	4.58		5.47	4.03
2019-12-08	4.22	4	3.94		4.82	3.14
2019-12-09	4.46	2.78	2.28		3.48	2.6
2019-12-10	4.21	1.93	1.69		2.58	2.92
2019-12-11	4.07	3.43	3.11		4.15	2.86
2019-12-12	4.03	4.51	4.84		5.55	4.66
2019-12-13	4.2	3.98	4.17	2.34	4.79	3.22
2019-12-14	3.96	4.22	3.75		5.1	3.39
2019-12-15	3.88	5.06	4.66		5.64	3.47
2019-12-16	3.39	3.69	3.6		4.55	3.97
2019-12-17	3.21	2.45	2.32	1.8	2.59	3.03
2019-12-18	3.04	3.04	2.99		3.84	2.89
2019-12-19	3.01	2.88	2.76		3.34	3.16
2019-12-20	3.58	3.88	3.94		4.75	3.63
2019-12-21	4.46	2.69	2.41		3.26	2.2
2019-12-22	4.53	1.49	1.19		1.88	2.59
2019-12-23	4.73	4.39	5.03	4.38	5.39	4.24
2019-12-24						

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2019-12-25	4.67	4.9	5.33		6.04	4.75
2019-12-26	5.08	4.39	4.29		5.27	4.08
2019-12-27	5.02	5.1	5.15	4.64	6.26	4.68
2019-12-28	5.01	4.56	4.42		5.23	4.01
2019-12-29	4.82	4.94	4.87		5.83	4.38
2019-12-30	4.43	4.73	4.39		5.5	3.97
2019-12-31	4.08	4.36	3.84		5.07	3.61
2020-01-01	3.89	4.73	4.02		5.49	4.15
2020-01-02	3.95	3.37	3.04		4.23	4.26
2020-01-03	3.93	3.07	3.11	2.59	4	2.86
2020-01-04	3.94	3.72	3.91		4.51	4.2
2020-01-05	4.06	3.36	2.87		3.7	3.58
2020-01-06	4.22			3.94		
2020-01-07	4.41	4.79	4.33	3.51	5.34	4.46
2020-01-08	4.16	4.61	4.24	2.34	5.27	5.74
2020-01-09	3.87	3.82	3.15	2.75	4.31	3.32
2020-01-10	3.81	4.2	3.15	3.64	4.21	5.33
2020-01-11	3.7	5.08	4.23	2.76	5.55	3.89
2020-01-12	3.79	3.48	3.06	2.71	4.15	4.64
2020-01-13	3.88	3.52	3.13	2.95	3.93	2.95
2020-01-14	3.61	3.54	3.16	5.38	4.16	2.76
2020-01-15	3.77	5.3	4.93	5.16	6.02	4.5
2020-01-16	3.76	5.44	4.99	2.81	6.3	4.63
2020-01-17	3.92	3.11	2.79	4.35	3.98	2.66
2020-01-18	4.02	4.37	4.51	3.79	5.38	4.05
2020-01-19	3.92	4.01	3.88	3.58	4.83	3.47
2020-01-20	3.82	3.98	3.82	4.28	4.91	3.36
2020-01-21	4.14	4.26	4.13	2.5	5.12	3.94
2020-01-22	4.05	2.84	2.86	0.82	3.58	4.04
2020-01-23	4.21			3.03		4.17
2020-01-24	4.31	3.57	3.85	4.42	4.7	3.04
2020-01-25	4.34	3.8	4.34	5.81	4.54	3.87
2020-01-26	4.34	3.9	4.73	6.82	4.84	3.79
2020-01-27	4.39	4.49	4.3	5.44	4.88	3.77
2020-01-28	4.14	4.65	4.45	3.76	5.4	3.96
2020-01-29	3.93	4.2	3.78	2	4.87	3.55
2020-01-30	3.33	3.25	2.62	3.14	3.49	2.25
2020-01-31	3.32	4.26	3.29		4.53	4.66

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2020-02-01	3.29	2.86	2.18	1.78	2.79	5.04
2020-02-02	3.45	3.71	3.14	2.96	4.4	2.93
2020-02-03	3.41	2.49	2.21	2	2.9	3.57
2020-02-04	3.53	3.35	3.3	3.09	4.01	3.94
2020-02-05	3.62	3.46	3.33	2.69	3.99	3.96
2020-02-06	3.64	3.23	3.02	2.09	3.82	4.44
2020-02-07	3.23	3.31	3.29		3.99	4.07
2020-02-08	3.41	4.09	3.83		4.72	3.58
2020-02-09	2.57	3.36	3.26		4.17	3.44
2020-02-10	2.82					4.15
2020-02-11	2.7	1.45	1.75		1.95	1.82
2020-02-12	2.99	1.73	1.83	1.74	2.53	1.41
2020-02-13	3.05	3.11	3.51	3.48	4.18	3.06
2020-02-14	3.14			5.14		
2020-02-15	3.21	4.63	4.25	4.47	5.38	4.09
2020-02-16	3.57	5.3	4.75	5.13	5.92	4.35
2020-02-17	3.59	5.25	4.69	5.3	5.9	4.46
2020-02-18	3.64	5.04	4.38	4.1	5.5	4.28
2020-02-19	3.7	4.02	3.38	3.54	4.46	4.32
2020-02-20	3.79	4.27	4.12	3.8	4.95	4.34
2020-02-21	3.69	1.2	0.65	0.77	1.43	2.77
2020-02-22	3.68	3.06	3.42	2.6	3.89	2.76
2020-02-23	3.71	3.36	3.79	3.7	4.25	3.15
2020-02-24	3.6	2.43	2.02	2.02	2.8	3.03
2020-02-25	3.4	3.69	3.08	3.3	4.12	4.04
2020-02-26	3.17					3.56
2020-02-27	2.98	2.45	2.69		2.96	2.93
2020-02-28	3.34	1.18	1.57	1.25	1.8	1.4
2020-02-29	3.16	2.67	2.78	2.74	3.44	2.45
2020-03-01	3.32	2.88	3.25	2.71	3.85	2.54
2020-03-02	3.52	3.05	3.76	3.21	4.06	2.75
2020-03-03	3.68	2.74	2.68	2.66	3.51	2.64
2020-03-04	3.77	3.46	3.93	3.53	4.4	3.55
2020-03-05	3.83	3.17	3.97	3.76	4.01	3.15
2020-03-06	3.78	3.11	3.65	3.56	4.06	3.24
2020-03-07	4.01	3.28	3.64	4.08	4.09	3.3
2020-03-08	3.97	3.3	3.85	4.06	4	3.17
2020-03-09	3.84	3.45	3.58	3.83	4.41	3.32

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2020-03-10	3.92	3.54	3.75	4.34	4.53	3.25
2020-03-11	3.87	4.13	4.09	4.95	4.93	3.72
2020-03-12	3.69	4.05	4.1	4.55	4.84	3.63
2020-03-13	3.36	3.98	4.34	4.64	4.78	3.58
2020-03-14	3.19	4.31	4.23		5.22	3.79
2020-03-15	3.72	4.45	3.87		5.01	3.68
2020-03-16	3.57	4.28	4.02		4.95	3.65
2020-03-17	3.38					
2020-03-18	3.29					
2020-03-19	3.55	2.92	2.37		3.46	2.05
2020-03-20	3.58	3.26	2.55		3.99	3.42
2020-03-21	3.65	2.5	2.74		3.24	3.34
2020-03-22	3.67	3.05	4.04	3.59	3.99	3.34
2020-03-23	3.74	2.94	3.71	3.55	3.89	3.17
2020-03-24	3.81	2.86	3.6	3.9	3.72	2.93
2020-03-25	4.02	2.76	3.42		3.52	2.66
2020-03-26	3.84	2.81	3.49	4.08	3.84	2.77
2020-03-27	3.78	3.28	3.71		4.1	3.01
2020-03-28	3.82	3.26	3.3		4.2	3.55
2020-03-29	3.78					4.55
2020-03-30	3.69	3.36	3.56		4.38	3.33
2020-03-31	3.47	4.03	4.01		4.95	3.79
2020-04-01	3.47	4.07	4.01	3.42	5.15	3.88
2020-04-02	3.46	4.53	4.01		5.23	3.93
2020-04-03	3.43	3.93	3.44		4.9	3.18
2020-04-04	3.28	3.08	3.64		3.91	2.82
2020-04-05	3.18	3.37	3.63		4.23	2.97
2020-04-06	3.16	4.18	3.98		5.09	3.5
2020-04-07	3.27	2.28	2.22	1.51	2.98	1.82
2020-04-08	3.19	2.82	2.94	2.49	3.89	2.79
2020-04-09	3.21	2.85	3.09		3.56	2.51
2020-04-10	3.21	2.88	3.27		3.61	2.65
2020-04-11	3.19			2.94		
2020-04-12	3.03	2.94	3.38	2.9	3.93	2.89
2020-04-13	2.94	3.26	3.43		4.46	3.21
2020-04-14	2.92	0.8	0.8		1.2	0.71
2020-04-15	2.84	2.25	2.04		2.95	2.07
2020-04-16	2.62	2.46	2.44		3.31	2.32

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2020-04-17	2.49	2.85	3.25	2.64	3.95	2.89
2020-04-18	2.64	2.74	2.82	2.45	3.58	2.68
2020-04-19	2.91	2.47	2.57	2.36	3.34	2.44
2020-04-20	3	2.7	2.91		3.67	2.79
2020-04-21	2.97	2.8	3.14		3.71	2.78
2020-04-22	3.05	2.85	3.32		3.66	2.68
2020-04-23	3.07	2.81	3.16		3.59	2.59
2020-04-24	3.16	2.97	2.92		4	2.63
2020-04-25	3.14	2.93	3.16		3.98	2.49
2020-04-26	3.07	2.74	3.06		3.77	2.55
2020-04-27	3					
2020-04-28	2.9	2.56	2.64	3.2	3.27	2.23
2020-04-29	2.95	2.57	2.72	3.49	3.47	2.21
2020-04-30	2.84	2.54	2.78	3.35	3.44	2.16
2020-05-01	2.81	2.89	3.05	3.27	3.78	2.55
2020-05-02	2.72	2.75	2.98	3.33	3.43	2.11
2020-05-03	2.72	2.56	2.57	2.45	3.27	1.93
2020-05-04	2.57	2.58	2.6	2.48	2.97	2.09
2020-05-05	2.53	2.57	2.26	2.85	2.78	1.87
2020-05-06	2.44	2.49	2.42	2.93	3.06	1.41
2020-05-07	2.42	1.89	1.86	1.65	2.24	1.24
2020-05-08	2.33	2.38	2.38	2.16	2.8	1.81
2020-05-09	2.28	2.45	2.56	2.47	3.02	1.89
2020-05-10	2.23	2.51	2.43	2.81	3.11	1.68
2020-05-11	2.23	2.43	2.32	2.83	3.24	1.63
2020-05-12	2.14	2.42	2.29	2.86	2.98	1.6
2020-05-13	2.28	1.82	1.7	1.97	2.35	0.91
2020-05-14	2.34	1.71	1.64	1.2	2.24	1.37
2020-05-15	2.38	1.82	2.09	1.34	2.56	1.59
2020-05-16	2.42	2.18	2.56	2	2.91	2.15
2020-05-17	2.48	2.38	2.63	2.59	2.89	2.02
2020-05-18	2.55	2.55	2.57	3.16	3.21	2.01
2020-05-19	2.65	2.39	2.22	2.68	3.14	1.9
2020-05-20	2.62	2.37	2.39	2.75	3.38	1.64
2020-05-21	2.55	2.29	2.39	2.73	3.27	1.61
2020-05-22	2.33	2.65	2.79	2.7	3.55	1.6
2020-05-23				0.41		1.6
2020-05-24				0.61		

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2020-05-25				1.54		
2020-05-26				1.81		
2020-05-27		2.88	1.95	2.36	2.36	1.59
2020-05-28	1.89	2.81	2.08	2.38	2.53	1.51
2020-05-29	1.91	2.58	2.15	2.88	2.67	1.6
2020-05-30	1.85	2.46	1.97	2.88	2.63	1.45
2020-05-31	1.92	2.43	1.83	2.78	2.58	1.52
2020-06-01	1.93	2.47	2.17	2.27	2.79	1.64
2020-06-02	1.87	1.8	1.55	1.5	2.23	1.15
2020-06-03	1.89	1.68	1.88	1.18	2.33	1.42
2020-06-04	1.84	1.95	2.11	1.41	3.18	1.95
2020-06-05	1.9	1.99	2.16	1.25	3.26	1.51
2020-06-06	1.97	2.27	2.23	1.61	3.16	1.2
2020-06-07	2.04	1.91	1.81	1.08	2.81	2.44
2020-06-08	1.98	2.43	2.37	1.64	3.31	2.23
2020-06-09	2.06	2.47	2.54	1.6	3.3	1.99
2020-06-10	2.09	2.81	2.59	2.15	3.67	1.79
2020-06-11	2.14	2.72	2.5	2.53	3.68	1.73
2020-06-12	2.06	2.5	2.5	2.41	3.25	1.74
2020-06-13	2.04	2.55	2.59	2.85	3.47	1.92
2020-06-14	1.99	1.86	1.99	1.55	2.77	1.83
2020-06-15	2.01	1.97	2.11	1.68	2.79	1.79
2020-06-16	2.01	1.99	2.23	1.77	2.93	1.82
2020-06-17		2.1	2.2	1.68	3.1	1.86
2020-06-18		2.02	2.03	1.86	2.71	1.33
2020-06-19	1.92	2.07	2.12	1.93	2.83	1.64
2020-06-20	2.02	2.33	2.41	2.31	3.14	1.88
2020-06-21	1.85	2.32	2.53	2.34	3	1.59
2020-06-22	1.56	2.33	2.47	2.51	3.23	1.54
2020-06-23	1.45	1.91	1.82	1.93	2.51	1.15
2020-06-24	1.52			2.09		
2020-06-25	1.68			2.41		
2020-06-26	1.7	1.35	1.46	1	2.15	1.32
2020-06-27	1.7			0.28		
2020-06-28	1.63			0.94		
2020-06-29	1.62	1.94	1.95	1.41	2.56	1.41
2020-06-30	1.65	2.39	2.59	1.65	3.06	1.53
2020-07-01	1.64	1.96	1.69		1.7	1.72

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2020-07-02	1.64	2.96	1.9		1.99	1.54
2020-07-03	1.58	2.56	1.8		2.26	1.46
2020-07-04	1.59	2.56	2.16		2.6	1.69
2020-07-05	1.62	2.57	2.49		3.32	1.42
2020-07-06	1.74	2.62	2.63		3.59	1.57
2020-07-07	1.74	2.45	2.53		3.06	1.67
2020-07-08	1.87	2.57	2.71	1.99	2.9	1.59
2020-07-09	1.85	2.11	2.1		2.83	1.82
2020-07-10	1.87	2.51	2.3		2.86	1.52
2020-07-11	1.81	2.36	2.39		3.1	1.36
2020-07-12	1.84	2.51	2.52		3.2	1.39
2020-07-13	1.79	2.6	2.37	2.43	3.31	1.49
2020-07-14	1.78	2.27	2.1	1.72	3.11	1.94
2020-07-15	1.85	1.99	1.91	1.35	2.94	1.72
2020-07-16	1.86	2.26	2.2	1.6	3.03	1.74
2020-07-17	1.87	2.34	2.44	2.15	3.32	1.74
2020-07-18	1.88	2.32	2.44	2.11	3.2	1.65
2020-07-19	1.99	2.28	2.25	2.03	2.91	1.44
2020-07-20	2.02	2.42	2.32	2.27	3.16	1.53
2020-07-21	2.07	2.5	2.5	2.29	3.25	1.51
2020-07-22	2	2.54	2.52	2.46	3.14	1.75
2020-07-23	1.99	2.48	2.35	2.31	3.17	1.61
2020-07-24	2.05	2.47	2.45	2.35	3.08	1.46
2020-07-25	1.93	2.57	2.57	2.68	3.4	1.45
2020-07-26	1.85	2.34	2.35	2.03	3.07	1.67
2020-07-27	1.76	2.63	2.61	2.22	3.29	1.66
2020-07-28	1.8	2.71	2.51	2.58	3.5	1.57
2020-07-29	1.87	2.46	2.31	2.01	3.19	1.95
2020-07-30	1.84	2.13	1.85	1.52	2.6	1.43
2020-07-31	1.84	2.18	2.11	1.89	2.98	1.67
2020-08-01	1.87	2.25	2.28	1.59	3.02	1.96
2020-08-02	1.9	2.26	2.27	1.71	3.08	1.73
2020-08-03	1.96	2.24	2.3	1.8	3.13	1.61
2020-08-04	1.98	2.36	2.29	1.88	3.23	1.65
2020-08-05	1.97	2.39	2.35	1.93	3.28	1.68
2020-08-06	1.96	2.54	2.32	1.98	3.28	1.62
2020-08-07	1.95	2.63	2.29	1.97	3.2	1.53
2020-08-08		2.1	1.99	1.8	2.83	1.25

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2020-08-09	1.65	2.31	2.5	2.28	3.35	1.41
2020-08-10	1.57	2.78	2.58	2.42	3.35	1.46
2020-08-11	1.43	2.41	2.47	2.27	3.27	1.25
2020-08-12	1.39	2.97	2.86	2.71	3.57	1.58
2020-08-13	1.23	3.29	3.24	2.89	3.94	1.91
2020-08-14	1.23	3.23	2.89	2.87	4.02	1.46
2020-08-15	1.4	3.37	3.1	2.64	4.01	1.91
2020-08-16	1.44	1.62	1.28	1.09	2.14	0.75
2020-08-17	1.52	0.35	0.38	0.3	0.82	0.44
2020-08-18	1.51	1.74	1.7	1.04	2.19	1.31
2020-08-19	1.54	3.18	2.9	1.87	3.84	1.99
2020-08-20	2.07	1.99	1.78	1.12	2.46	1.17
2020-08-21	2.19			0.23		
2020-08-22	2.23			0.62		
2020-08-23	2.34			1.5		
2020-08-24	2.35	2.93	2.41	1.68	3.16	1.89
2020-08-25	2.39	2.99	2.25	1.71	3.14	1.86
2020-08-26	2.34	3.07	2.53	2.09	3.15	1.72
2020-08-27	2.21	3.07	2.67	2.38	3.54	1.92
2020-08-28	2.2	3.28	3.02	2.77	3.99	1.86
2020-08-29	2.28	3.31	2.96	2.89	4.07	1.79
2020-08-30	2.25	3.42	2.93	3.27	4.18	1.65
2020-08-31	2.26	3.26	2.68	2.49	4.32	2.09
2020-09-01	2.2	3.04	2.58	1.98	4.12	2.18
2020-09-02	2.23	2.97	2.57	1.91	3.84	2.04
2020-09-03	2.24	3.21	2.93	2.37	4.09	1.74
2020-09-04	1.98			2.35		
2020-09-05	1.98	2.97	2.59	2.56	3.86	1.71
2020-09-06	1.89	3	2.67	2.85	3.94	1.52
2020-09-07	1.95	3.23	2.72	2.65	3.75	1.76
2020-09-08	1.89	3.21	2.39	2.43	3.64	1.97
2020-09-09	1.85	3.24	2.45	2.36	3.94	1.81
2020-09-10	1.71	3.32	2.59	2.76	3.88	1.58
2020-09-11	1.68	3.47	2.69	3.16	3.91	1.39
2020-09-12	1.71	3.38	2.64	3.29	3.93	1.38
2020-09-13	1.75	3.2	2.68	3.08	4.19	1.37
2020-09-14	1.81	2.82	2.72	2.92	4.07	1.16
2020-09-15	1.7	3	2.34	2.04	3.89	1.94

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2020-09-16	1.66	3.05	2.81	2.28	3.72	1.81
2020-09-17	1.67	3.5	2.7	3.07	4.04	1.26
2020-09-18	1.67	3.06	2.35	2.26	3.78	1.58
2020-09-19	1.72	3.05	2.23	2.36	3.66	1.49
2020-09-20	1.73	1.87	1.69	1.07	2.7	1.32
2020-09-21	1.75	1.92	1.69	0.96	2.63	1.44
2020-09-22	1.79	1.57	2.02	0.77	2.18	1.25
2020-09-23	1.79	2.35	2.13	1.49	3.31	1.9
2020-09-24	1.81			1.84		
2020-09-25	2.02	3.34	2.65	2.38	4.12	2.51
2020-09-26	2.33	3.56	2.9	3.05	3.86	1.96
2020-09-27	2.52	4.01	3.17	3.55	3.88	1.51
2020-09-28	2.53	4.14	2.86	2.55	4.29	2.02
2020-09-29	2.62	4.41	3.2	2.7	5.05	2.68
2020-09-30	2.58	4.53	3.24	3.27	4.37	1.88
2020-10-01	2.55	4.92	3.4	7.28	4.99	1.7
2020-10-02	2.5	4.97	4.08	7.43	4.98	1.4
2020-10-03	2.44	4.81	3.31	6.01	5.56	2.29
2020-10-04	2.44	3.86	2.94	3.91	4.83	2.71
2020-10-05	2.18	4.72	3.52	5.91	4.66	2.6
2020-10-06	2.08	4.97	3.86	7.32	4.98	1.76
2020-10-07	1.92	4.83	3.59	7.69	4.76	1.65
2020-10-08	1.99	2.43	2.65	2.89	3.67	1.54
2020-10-09	2.04	2.86	2.58	2.63	3.69	2.1
2020-10-10	2.06	1.61	1.76	1.96	2.29	1.69
2020-10-11	2.07	2.88	2.69	4.24	3.28	1.91
2020-10-12	2.19			4.67		
2020-10-13	2.09	3.89	2.9	5.59	4.27	2.37
2020-10-14	2.09	4.1	2.93	6.12	4.6	1.82
2020-10-15	1.96			1.14		0.5
2020-10-16	1.93	1.39	1.63	1.72	2.23	0.91
2020-10-17	1.94	3.35	2.86	3.46	4.18	2.79
2020-10-18	2.11	3.57	3.41	3.84	4.54	2.71
2020-10-19	2.24	2.62	2.39	2.9	3.3	1.62
2020-10-20	2.57			1.74		
2020-10-21	2.82	3.61	3.79	3.34	4.62	3.12
2020-10-22	3.18	3.76	3.55	4.17	4.68	2.86
2020-10-23	3.27	3.51	3.59	3.88	4.12	2.96

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2020-10-24	3.12	2.31	2.33	1.52	3.04	2.12
2020-10-25	3.1	3.74	3.51	3.03	4.42	3.43
2020-10-26	3.16	3.83	3.48	3.78	4.62	3.16
2020-10-27	2.88	4.13	3.3	4.42	4.89	3.12
2020-10-28	2.85	4.2	3.49	5.5	4.57	2.69
2020-10-29	2.67	3.32	3.09	3.4	3.89	3.21
2020-10-30	2.55	1.62	1.73	1.18	2.49	1.38
2020-10-31	2.51	3.34	2.99	2.75	3.96	2.45
2020-11-01	2.41	3.19	2.46	2.18	3.46	2.28
2020-11-02	2.43	3.59	2.8	2.79	3.75	2.55
2020-11-03	2.57	3.19	2.74	2.83	3.61	2.26
2020-11-04	2.56	3.18	2.85	3.25	3.85	2.3
2020-11-05	2.71	3.28	2.94	3.18	3.72	2.45
2020-11-06	2.69	3.45	2.94	3.31	4	2.4
2020-11-07	2.71	3.74	3.06	4.14	4.14	2.6
2020-11-08	2.75	4	3.25	5.07	4.41	2.24
2020-11-09	2.94	4.71	3.51	5.33	4.94	2.71
2020-11-10	3.02	3.61	3.18	4.05	4.48	2.6
2020-11-11	3.12	3.53	3.26	0.92	4.38	3.31
2020-11-12	3.29	4.45	4.03	1.87	5.25	3.99
2020-11-13	3.6	3.48	3.33	0.98	4.32	3.45
2020-11-14	3.64	4.21	4.09	0.98	5.15	3.72
2020-11-15	3.76	4.81	4.34	0.83	5.78	3.98
2020-11-16	3.44	3.42	2.79	0.81	3.93	2.85
2020-11-17	3.55	3.44	2.76	0.83	4.34	3.97
2020-11-18	3.61	3.67	3.68	0.28	4.36	4.47
2020-11-19	3.77	2.19	2.53	0.78	3.07	2.3
2020-11-20	3.75	3.51	3.7	2.3	4.19	3.21
2020-11-21	3.77	3.54	3.7	2.6	4.33	3.05
2020-11-22	3.78	3.79	4.04	3.01	4.8	3.45
2020-11-23	3.96	3.68	3.79	3.17	4.7	3.18
2020-11-24	4.11	4.04	4.18	1.75	5.15	3.37
2020-11-25	4.18	4.37	3.98	0.52	5.16	3.18
2020-11-26	4.27	3.98	4.03	3.25	4.7	3.22
2020-11-27	4.41	4.05	4.39	3.06	4.96	3.94
2020-11-28	4.3	4.21	4.31	4.04	5.2	3.19
2020-11-29	4.37	4.58	4.59	4.89	5.34	3.19
2020-11-30	4.08	4.25	4.11	3.83	4.91	3.06

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2020-12-01	3.83	4.58	4.12	5.13	5.33	3.56
2020-12-02	3.74	3.52	3.45	3.77	4.26	3.38
2020-12-03	3.78	3.72	3.62	4.03	4.67	3.22
2020-12-04	3.62	5.14	4.86	5.86	6.03	4.29
2020-12-05	3.8	3.64	3.39	3.72	4.56	3.62
2020-12-06	3.79	2.67	2.87	2.41	3.42	2.98
2020-12-07	4.05			1.75		
2020-12-08	3.85	3.75	3.7	3.4	4.3	3.31
2020-12-09	3.65			2.83		
2020-12-10	3.57	3.62	3.73	3.86	4.71	3.45
2020-12-11	3.74	2.14	2.06	2.32	2.7	2.54
2020-12-12	3.68	3.19	3.12	2.61	3.81	2.76
2020-12-13	3.97	4.16	3.86	3.77	4.91	4.09
2020-12-14	3.92	3.53	3.3	3.19	3.96	4.02
2020-12-15	4.17	4.33	3.94	3.82	5.28	3.28
2020-12-16	4.32	4.1	3.87	3.73	4.8	3.54
2020-12-17	4.32	3.42	3.46	3.68	4.16	2.88
2020-12-18	4.17	4.74	4.7	4.64	5.19	4.27
2020-12-19	4.35	5.31	4.77	5.19	6.02	4.58
2020-12-20	4.53	3.99	3.64	3.66	4.8	2.9
2020-12-21	4.52	4.85	4.16	5.15	5.58	4.25
2020-12-22	4.21	3.79	3.83	2.93	4.72	3.78
2020-12-23	4.11	4.03	4.2	3.71	5.11	3.77
2020-12-24	4.14	3.92	4.14	4.2	5.16	3.74
2020-12-25	4.21	3.92	3.99	4.03	5.01	3.67
2020-12-26	4.14	3.72	3.76	3.89	4.35	3.52
2020-12-27	4.13			0.15		
2020-12-28	3.85	2.98	3.14	0.18	3.56	2.94
2020-12-29	3.74			0.71		
2020-12-30	3.65	3.8	3.97	0.09	4.49	3.65
2020-12-31	3.94			0.15		
2021-01-01	3.96			2.26		2.72
2021-01-02		3.01	2.85	2.41	3.71	3.12
2021-01-03		3.37	3.82	3.76	4.17	3.62
2021-01-04		4.04	3.94	4.65	4.39	3.47
2021-01-05		4.62	4.5	4.96	5.32	3.68
2021-01-06		4.56	3.83	4.61	5.03	3.48
2021-01-07		4.73	4.47	4.81	5.38	4.37

TIMESTAMP	ET_{MDV}	ET_{LR}	ET_{RFR}	ET_{PM}	ET_{DNN}	ET_{LSTM}
2021-01-08				3.53		
2021-01-09				3.76		
2021-01-10				2.78		
2021-01-11				3.58		
2021-01-12				2.92		
2021-01-13				1.98		
2021-01-14				2.49		
2021-01-15				2.23		
2021-01-16				3.15		
2021-01-17				2.18		
2021-01-18				3.31		
2021-01-19				3.01		
2021-01-20				4.47		
2021-01-21				5.53		
2021-01-22						



EESC • USP