UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de Sorocaba

PROGRAMA DE PÓS-GRADUAÇÃO em
Ciências Ambientais

AMAZONINO LEMOS DE CASTRO

ANÁLISE DA EVAPOTRANSPIRAÇÃO, ÍNDICES BIOFÍSICOS E O USO DA TERRA EM UMA BACIA HIDROGRÁFICA

Sorocaba
2023

UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de Sorocaba

PROGRAMA DE PÓS-GRADUAÇÃO em
Ciências Ambientais

AMAZONINO LEMOS DE CASTRO

ANÁLISE DA EVAPOTRANSPIRAÇÃO, ÍNDICES BIOFÍSICOS E O USO DA TERRA EM UMA BACIA HIDROGRÁFICA

Tese apresentada como requisito ao Programa de Pós-Graduação em Ciências Ambientais para a obtenção do título de Doutor em Ciências Ambientais da Universidade Estadual Paulista "Júlio de Mesquita Filho" na Área de Concentração em Geoprocessamento e Modelagem Matemática Ambiental

Orientador: Prof. Dr. Roberto Wagner Lourenço

Sorocaba
2023

C355a

Castro, Amazonino Lemos de
Análise da evapotranspiração, índices biofísicos e o uso da terra em uma bacia hidrográfica / Amazonino Lemos de Castro. -- Sorocaba, 2023
118 p. : il., tabs., mapas

Tese (doutorado) - Universidade Estadual Paulista (Unesp), Instituto de Ciência e Tecnologia, Sorocaba
Orientador: Roberto Wagner Lourenço

1. Manejo sustentável em bacia hidrográfica. 2. NDVI e NDWI por meio de dados SAR. 3. Regressão multivariada. 4. Transporte hídrico para atmosfera. 5. Evapotranspiração real. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca do Instituto de Ciência e Tecnologia, Sorocaba. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Sorocaba

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: ANÁLISE DA EVAPOTRANSPIRAÇÃO, ÍNDICES BIOFÍSICOS E O USO DA TERRA EM UMA BACIA HIDROGRÁFICA

AUTOR: AMAZONINO LEMOS DE CASTRO
ORIENTADOR: ROBERTO WAGNER LOURENÇO

Aprovado como parte das exigências para obtenção do Título de Doutor em CIÊNCIAS AMBIENTAIS, área: Diagnóstico, Tratamento e Recuperação Ambiental pela Comissão Examinadora:

Prof. Dr. ROBERTO WAGNER LOURENÇO (Participaçao Virtual)
Departamento de Engenharia Ambiental / Instituto de Ciencia e Tecnologia Campus de Sorocaba Unesp

Prof. Dr. MIQUÉIAS LIMA DUARTE (Participaçao Virtual)
Instituto de Educação Agricultura e Ambiente (IEAA) / Uni AM)

Documento assinado digitalmente
gov.br
MIQUEIAS LIMA DUARTE
Data: 04/07/2023 17:08:57-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. DARLLAN COLLINS DA CUNHA E SILVA (Participaçao Virtual)
Departamento de Engenharia Ambiental / Unesp ICT Sorocaba

Prof. Dr. ADMILSON IRIO RIBEIRO (Participaçao Virtual)
Departamento de Engenharia Ambiental / Unesp - Campus Sorocaba

Dr LEONARDO AMORA NOGUEIRA (Participaçao Virtual)
Departamento de Química / Universidade Federal Fluminense

Documento assinado digitalmente
gov.br
LEONARDO AMORA NOGUEIRA
Data: 04/07/2023 17:06:04-0300
Verifique em https://validar.iti.gov.br

Sorocaba, 04 de julho de 2023

DEDICATÓRIA

Aos meus pais Alcides Texeira de Castro (in memoriam) e Olendina Lemos Ferreira.

A minha querida esposa, Keith Soares Valente.

Aos meus filhos, Arthur Soares de Castro e Sophia Soares de Castro.

Às minhas queridas irmãs, Cídia (in memoriam), Verônica, Sebastiana e Francinete.

Ao meu orientador Prof. Dr. Roberto Wagner Lourenço.

A todos que de alguma forma me incentivaram e suportaram a minha ausência, durante todo esse período, dando-me forças para vencer mais esse desafio em minha vida.

HONESTAMENTE DEDICO.

AGRADECIMENTOS

A Deus, Nossa Senhora Aparecida, Nossa Senhora da Conceição e Santa Filomena que me fortaleceram na fé católica para enfrentar as provações, desafios e me deram coragem para sonhar e realizar o sonho de vencer mais esta grandiosa batalha.

A minha querida e amada esposa, Keith Soares Valente, pelo apoio, compreensão e companheirismo durante toda nossa caminhada. Ao meu filho Arthur por ser tão compreensivo, especial e amável. À minha queria e amada filha Sophia, que mesmo ainda estando no ventre de sua mãe, me proporcionou uma força gigantesca que me incentivou a lutar pela conclusão dessa pesquisa.

Aos meus pais Alcides Texeira de Castro (in memoriam) e Olendina Lemos Ferreira, pela incessante doação e incentivos nunca enfraquecidos; às minhas queridas irmãs: Francinete Castro, Sebastiana Castro, Verônica Castro e Cídia Castro (in memoriam); aos meus irmão Bruno e Tiago; aos meus tios e tias e ainda aos meus sobrinhos: Ranielly, Jonathan, Huana, Paulo Daniel, Riann, Juninho, José, João e Helena.

Aos meus amigos e amigas de Novo Aripuanã e aos membros do Instituto Xiu por compartilharem dos mesmos objetivos e valores necessários para uma sociedade mais humana e fraterna.

Ao meu orientador Prof. Dr. Roberto Wagner Lourenço (China) por ter compartilhado comigo seus conhecimentos, ter me incentivado a sempre buscar o melhor para a pesquisa, pelos momentos de conversa e descontração no caminho de Ibiúna, que contribuíra par o meu crescimento pessoal e profissional. Obrigada por tudo!

Ao LABGEMM do qual tive a honra de fazer parte, principalmente a todas as pessoas que tive o prazer de conviver como a Bruna, Hetiany, Letícia, Camille, Miqueias, Jocy, Fábio, Jomil e Darllan, especialmente a Giovana, que sempre esteve a disposição para ajudar a todos.

À UNESP, professores do Programa de Pós-graduação em Ciências Ambientais e servidores pelo suporte, especialmente ao Carlos e todos que atuam na secretaria da pós-graduação por serem sempre muito atenciosos e dispostos a ajudar.

Aos membros da banca examinadora pela dedicação, parceria e pelas valiosas contribuições nessa pesquisa. Sei do esforço de cada um para participar de bancas. Fico muito agradecido por compartilharem comigo um pouco de vossas expertises, objetivando a construção de uma pesquisa de qualidade.

À UFAM/IEAA por incentivar os seus servidores no processo de qualificação contínua e crescimento pessoal e profissional, a fim de retornar a sociedade um serviço de excelência. A todos os colegas professores, TAEs e estudantes.

Aos amigos Jorge, Luciana, Raolin, Kelly, Carlos, Meire, Martins, Anderson, Paulo, Pietro, Lucivaldo, Raniere, Joyce, Janderson, Eber, Mário, Luiz Octávio, Benone e a todos que de maneira direta ou indiretamente contribuíram para a realização deste trabalho e que não foram citados no texto.

"O que destrói o ser humano é a política sem princípios, prazer sem compromissos, riqueza sem trabalho, sabedoria sem caráter, negócios sem moral, ciência sem humanidade e oração sem caridade"

-Mahatma Gandhi-

RESUMO

A gestão de bacias hidrográficas pode ser realizada de diversas formas, especialmente considerando os avanços tecnológicos e científicos atuais. A análise das variáveis ambientais que impactam diretamente o funcionamento e equilíbrio dos ecossistemas proporciona o entendimento da dinâmica ambiental, em particular as relacionadas à variabilidade climática do ambiente regional e local. Entre essas variáveis, destaca-se a evapotranspiração real (ETa), que representa uma das formas de recarga hídrica da atmosfera. Além disso, os índices biofísicos (NDVI, NDWI, SAVI e IAF), que estão relacionados aos processos fenológicos da vegetação e ao uso da terra, cumprem um papel fundamental no equilíbrio dos ecossistemas. Nesse contexto, o objetivo desta pesquisa foi analisar a relação entre os índices biofísicos, o uso e a ocupação da terra com a ETa na Bacia Hidrográfica do rio Sorocabuçu. Para o mapeamento do uso da terra e a obtenção dos índices biofísicos, foram utilizadas imagens de satélite do Sentinel-2B, Sentinel-1A e dados meteorológicos do ERA5-*Land*. Os dados provenientes dos sensores Radar de Abertura Sintética (*Synthetic Aperture Radar* - SAR) não são afetados pela presença de fatores atmosféricos como nuvens, por exemplo, o que permite a aquisição de informações de forma contínua. Dessa forma, utilizou-se os dados do Sentinel-1 (SAR) para estimar o NDVI e NDWI entre os anos de 2019 e 2020 em uma área experimental. Foram construídos quatro modelos de regressão (RL, SVM, RF e ANN) para estimar os índices de vegetação com base nos dados de retroespalhamento do SAR como variáveis independentes e os índices NDVI e NDWI obtidos por meio do Sentinel-2 como variáveis dependentes. Esses modelos foram implementados por meio da Validação Cruzada (*Cross-Validation*), e suas métricas de desempenho e testes estatísticos foram avaliados para determinar o modelo mais adequado. De maneira similar, os índices biofísicos foram admitidos a uma outra análise de regressão linear com múltiplas variáveis, utilizando NDVI, NDWI, SAVI e IAF como variáveis independentes, e ETa como variável dependente. Os resultados indicaram uma dinâmica média superior a 0,7 entre os dados SAR e os índices de vegetação convencional. A análise da relação entre a ETa e os índices biofísicos revelou correlações moderadas, fortes e muito fortes ao longo dos meses, demonstrando que a estimativa precisa da ETa é fundamental para compreender a função vital da vegetação na disponibilidade e gestão dos recursos hídricos. Isso reforça a importância das práticas de manejo ambiental na gestão das bacias hidrográficas.

Palavras-chave: Manejo sustentável em bacia hidrográfica; NDVI e NDWI por meio de dados SAR; Regressão multivariada; Transporte hídrico para atmosfera; Evapotranspiração real.

ABSTRACT

Watershed management can be accomplished in several ways, especially considering current technological and scientific advances. The analysis of environmental variables that directly impact the functioning and balance of ecosystems provides an understanding of environmental dynamics, in particular those related to the climatic variability of the regional and local environment. Among these variables, real evapotranspiration (ETa) stands out, which represents one of the forms of water recharge in the atmosphere. In addition, biophysical indices (NDVI, NDWI, SAVI and IAF), which are related to the phenological processes of vegetation and land use, play a fundamental role in the balance of ecosystems. In this context, the objective of this research was to analyze the relationship between biophysical indices, land use and occupation with ETa in the Sorocabuçu River Basin. To map land use and obtain biophysical indices, satellite images from Sentinel-2B, Sentinel-1A and meteorological data from ERA5-Land were used. The data coming from the Synthetic Aperture Radar (SAR) sensors are not affected by the presence of atmospheric factors such as clouds, for example, which allows the acquisition of information continuously. Thus, Sentinel-1 (SAR) data were used to estimate NDVI and NDWI between the years 2019 and 2020 in an experimental area. Four regression models (RL, SVM, RF and ANN) were constructed to estimate vegetation indices based on SAR backscattering data as independent variables and NDVI and NDWI indices obtained through Sentinel-2 as dependent variables. These models were implemented through *Cross-Validation*, and their performance metrics and statistical tests were evaluated to determine the most appropriate model. Similarly, the biophysical indices were admitted to another linear regression analysis with multiple variables, using NDVI, NDWI, SAVI and IAF as independent variables, and ETa as the dependent variable. The results indicated an average dynamic higher than 0.7 between the SAR data and the conventional vegetation indices. The analysis of the relationship between ETa and biophysical indices revealed moderate, strong and very strong correlations over the months, demonstrating that the accurate estimation of ETa is fundamental to understand the vital function of vegetation in the availability and management of water resources. This reinforces the importance of environmental management practices in watershed management.

Keywords: Sustainable management in a watershed; NDVI and NDWI through SAR data; Multivariate regression; Water transport to atmosphere; Real evapotranspiration.

LISTAS DE FIGURAS

Figura 1 - Localização da área de estudo. 32

Figura 2 - Bandas espectrais do instrumento MSI e Resolução Espacial do Sentinel-2A. 34

Figura 3 - Fluxograma de descrição da metodologia aplicada. 45

Figura 4 - Localização da sub-bacia hidrográfica no município de Paranapanema/SP. 47

Figura 5 - Desempenho dos modelos de regressão na previsão do NDVI (a, b, c, d) e NDWI (e, f, g, h). 56

Figura 6 - Diferença média nos níveis dos modelos com base no teste de Bonferroni a 95% de confiança para o NDVI (a, b, c, d) e NDWI (e, f, g, h). 57

Figura 7 - Comparação entre NDVI observado e previsto (a-b) e NDWI observado e previsto (c-d) para o mês de fevereiro de 2019, bem como o observado e previsto para os meses de outubro de 2019 (e-f, g-h), e maio de 2020 (i-j, k-l). 58

Figura 8 - Gráficos de dispersão de NDVI observado e previsto para o mês de fevereiro de 2019 (a), outubro de 2019 (b) e maio de 2020 (c), e NDWI observado e previsto para o mês de fevereiro de 2019 (d), outubro de 2019 (e) e maio de 2020 (f). 58

Figura 9 - Estatística descritiva do NDVI para o ano de 2020. 60

Figura 10 - Espacialização do NDVI para o ano de 2020. 61

Figura 11 - Estatística descritiva do NDWI para o ano de 2020. 63

Figura 12 - Espacialização do NDWI para o ano de 2020. 64

Figura 13 - Estatística descritiva do SAVI para o ano de 2020. 65

Figura 14 - Espacialização do SAVI para o ano de 2020. 66

Figura 15 - Estatística descritiva do IAF para o ano de 2020. 67

Figura 16 - Espacialização do IAF/LAI para o ano de 2020. 69

Figura 17 - Uso e ocupação da terra para o ano de 2020 na BH do rio Sorocabuçu. 70

Figura 18 - Estatística descritiva da ETa para o ano de 2020. 73

Figura 19 - Espacialização da ETa no ano de 2020 na BH do rio Sorocabuçu. 74

Figura 20 - Transporte hídrico para atmosfera por meio da ETA no ano de 2020 na BH do rio Sorocabuçu. 76

Figura 21 - Análise da correlação dos índices biofísicos com evapotranspiração real..... 77

LISTAS DE TABELAS

Tabela 1 - Informações das cenas utilizadas para processamento. 34
Tabela 2 - Classes de uso da terra na área, suas características e o padrão de cor RGB. 36
Tabela 3 - Valores adotados para o fator "L". 38
Tabela 4 - Valores de referência para classificação o NDVI..... 39
Tabela 5 - Padronização das classes e paleta de cores..... 40
Tabela 6 - Valores de referência para classificação do NDWI..... 41
Tabela 7 - Padronização das classes e paleta de cores. 41
Tabela 8 - Padronização das classes e paleta de cores utilizadas nos mapas de ETa. 44
Tabela 9 - Polarizações VV, VH e variáveis secundárias utilizadas para implementação nos modelos de regressão. 49
Tabela 10 - Estatística descritiva do conjunto de dados de treinamento e teste. 53
Tabela 11 - Métricas de desempenho dos modelos de regressão. 55

LISTAS DE SIGLAS E ABREVIATURAS

ANOVA	Análise da variância
APA	Área de Proteção Ambiental
BH	Bacia hidrográfica
BOA	*Bottom-Of-Atmosphere*
CDS	*Copernicus Climate Data Store*
CX	Cambissolos Háplicos
DAEE	Departamento de Águas e Energia Elétrica
DN	*Digital Numbers*
ESA	Agência Espacial Européia - *European Space Agency*
ET	Evapotranspiração
ET_0	Evapotranspiração de referência
ETa	Evapotranspiração real
ET_C	Evapotranspiração de cultura
ET_P	Evapotranspiração potencial
EVI	Índice de Vegetação Aprimorado
EW	Faixa extralarga - *Extra-Wide Swath*
***f*PAR**	Radiação fotossinteticamente ativa
GM	Gleissolos Melânico
GNDVI	Índice de Vegetação por Diferença Normalizada Verde
GRD	Detecção ao nível do solo - *Ground Range Detected*
IAF	Índice de área Foliar
IW	Faixa ampla interferométrica - *Interferometric Wide Swath*
LVA	Latossolos Vermelho-Amarelo
MAE	Erro Médio Absoluto
MSE	Erro Médio Quadrático
MSI	Índice de Estresse por Umidade*
MSI	Instrumento Multiespectral**
NDVI	Índice de Vegetação por Diferença Normalizada
NDWI	Índice de Água por Diferença Normalizada
OLCI	*Ocean and Land Color Instrument*

PLS	Regressão por Mínimos Quadrados Parciais (*Partial Least Squares*)
R^2	Coeficiente de determinação
REM	Radiação eletromagnética
RMSE	Raiz Quadrática do Erro Médio Absoluto
RS	Razão Simples
SAFER	Algoritmo Simples para Recuperação da Evapotranspiração - *Simple Algorithm for Evapotranspiration Retrieving*
SAR	Radar de Abertura Sintética - *Synthetic Aperture Radar*
SAVI	Índice de Vegetação Ajustado do Solo
SCUT	Sistema Básico de Classificação da Cobertura e do Uso da Terra
SEBAL	Algoritmo de Balanço de Energia de Superfície para Terra - *Surface Energy Balance Algorithm for Land*
SIG	Sistemas de Informações Geográficas
SIRGAS	Sistema de Referência Geocêntrico para as Américas
SLC	Complexo de visual único - *Single Look Complex*
SLSTR	*Sea and Land Surface Temperature Radiometer*
SM	Mapa de tiras - *Stripmap*
SNAP	*Sentinel Application Platform*
SR	Sensoriamento Remoto
SWIR	*Short Wave Infra-Red*
TOA	*Top-Of-Atmosphere*
Ts	Temperatura de superfície
TST	Temperatura da Superfície Terrestre
USGS	*United States Geological Survey*
UTM	Universal Transversa de Mercator
VNIR	*Visible and Near-Infra-Red*

SUMÁRIO

1 INTRODUÇÃO 18

2 OBJETIVOS 19

2.1 Objetivo Geral 19

2.2 Objetivos Específicos 19

3 REVISÃO DE LITERATURA 20

3.1 Bacia hidrográfica como unidade de planejamento 20

3.2 A importância do manejo ambiental na bacia hidrográfica 20

3.3 Evaporação, transpiração e evapotranspiração 22

3.3.1 Tipos de evapotranspiração 22

3.4 Sistema de informações geográficas (SIG) e manejo ambiental 23

3.5 Índices e variáveis biofísicas no manejo de bacias hidrográficas 24

3.5.1 Índice de vegetação por diferença normalizada (NDVI) 25

3.5.2 Índice de água por diferença normalizada (NDWI) 25

3.5.3 Índice de vegetação ajustado ao solo (SAVI) 26

3.5.4 Índice de área foliar (IAF/LAI) 26

3.5.5 Albedo de superfície 27

3.5.6 Temperatura da superfície terrestre (TST) 27

3.5.7 Evapotranspiração real (ETa) 28

3.6 Programa Copernicus e principais missões Sentinel 28

3.7 Estimativa de índices de vegetação por meio de dados SAR 30

4 MATERIAL E MÉTODOS 32

4.1 Área de estudo 32

4.2 Aquisição e processamento de dados 33

4.3 Mapeamento da cobertura e uso da terra 35

4.4 Estimativa dos índices biofísicos 37

4.4.1 Índice de Vegetação Ajustado ao Solo - SAVI 37

4.4.2 Índice de Área Foliar - IAF 38

4.4.3 NDVI e NDWI 39

4.4.4 Estimativa da ETa 42

4.4.4.1 Estimativa da contribuição hídrica por classe de uso e ocupação da terra 45

4.5 Análise estatística dos dados 45

4.6 Metodologia para a estimativa do NDVI e ndwi por meio de dados SAR 46

4.6.1 Aquisição e processamento de dados 48

4.6.2 Índices de vegetação por modelo preditivos 50

4.6.3 Análise de desempenho dos modelos 52

5 RESULTADOS E DISCUSSÃO 53

5.1 Estimativa do NDVI e NDWI por meio de dados SAR 53

5.2 NDVI na bacia hidrográfica do rio Sorocabuçu 60

5.3 NDWI na bacia hidrográfica do rio Sorocabuçu 62

5.4 SAVI na bacia hidrográfica do rio Sorocabuçu 65

5.5 IAF na bacia hidrográfica do rio Sorocabuçu 67

5.6 Uso e ocupação da terra e cobertura vegetal na bacia hidrográfica do rio Sorocabuçu 70

5.7 ETa na bacia hidrográfica do rio Sorocabuçu 72

5.7.1 Contribuição da eta no transporte de água para a atmosfera na bacia hidrográfica do rio Sorocabuçu 75

5.8 Análise estatística (regressão linear múltipla) 77

6 CONCLUSÕES 80

REFERÊNCIAS 83

APÊNDICE A - *Script* para a estimativa do NDVI e NDWI por meio de dados SAR no software R 98

APÊNDICE B - Script para a estimativa da ETa por meio do pacote Agriwater no software R**.....**104

APÊNDICE C - Script dos parâmetros estatísticos da análise de regressão multivariada entre os índices biofísicos, uso da terra e a ETa**.....**108

APÊNDICE D - Resíduos, coeficientes, erro padrão e níveis de significância dos índices biofísicos para cada mês do ano de 2020 em relação a ETa**.....**110

1 INTRODUÇÃO

No atual momento da humanidade o planeta já emitiu diversos sinais de que é preciso agir de maneira sustentável, diminuir os efeitos do consumo indiscriminado dos recursos naturais e realizar a gestão integrada e consciente dos biomas existentes.

A catástrofes de alcance global frequentemente se associam ao modo como o ser humano administra o ambiente que o cerca. Mesmo no contexto de uma era caracterizada por avanços tecnológicos nos mais variados segmentos científicos, o consumismo exacerbado e a forma de interação com o meio ambiente determinam a duração de diversas matérias-primas.

A gestão dos recursos naturais pode ser realizada de diversas formas dentro da unidade básica de gestão e planejamento que são as bacias hidrográficas, porém, todas as metodologias passam pela necessidade de se ter informações precisas e atualizadas sobre a área a ser gerenciada. Dessa maneira, entender as diversas variáveis, o tipo de relação entre elas, a qualidade da informação fornecida e sua aplicabilidade, figura-se como um método real e eficiente no processo de tomada de decisão e subsídio técnico para o manejo dos recursos existentes dentro do limite da área a ser gerida (SALLES et al., 2008).

Dentre muitas variáveis ambientais, algumas possuem maior influência no funcionamento e equilíbrio dos ecossistemas, sendo uma das principais a evapotranspiração, que é a maneira pelo qual se abastece a atmosfera com água, e consequentemente possui influência direta no ciclo hidrológico e climático, responsável pela circulação da água em toda a biosfera (GHARBIA et al., 2018). A evapotranspiração sofre influência direta da temperatura de superfície (Ts), parâmetro importante nos modelos ambientais que se refere a troca de energia e água entre a superfície e a atmosfera (SOUZA e SILVA 2005) e, contribui com a evaporação do solo, além da cobertura vegetal e o uso e ocupação da terra, que está relacionado com a transpiração vegetal nos ecossistemas.

A água em quantidade e qualidade adequada no ambiente, assim com os nutrientes necessários para a nutrição das plantas, revela as condições fisiológica das plantas e do ambiente onde ela está inserida. Em situações de normalidade em áreas de floresta e agricultáveis, parte da água advinda da precipitação infiltra no solo, sendo que a maior parte é absorvida pelas raízes dos vegetais e relançada na atmosfera pela transpiração, isso influência diretamente nos índices de qualidade e quantidade da vegetação (FEARNSIDE, 2004).

Atualmente, uma das tecnologias mais utilizadas para estudar parâmetros biofísicos dos ecossistemas são as ferramentas de geoprocessamento e sensoriamento remoto, em especial os índices biofísicos, que usam transformações de bandas espectrais do espectro eletromagnético,

através de medidas da reflectância dos alvos na superfície terrestre para determinar, entre outras informações, a qualidade e a quantidade da vegetação dos ecossistemas, além disso, a escala em que as informações são coletadas permitem inferências e previsões em escala regional, figurando como uma poderosa metodologia para subsidiar a gestão ambiental e diversas áreas.

Nesse contexto, esta pesquisa foi realizada utilizando-se diversos indicadores biofísicos como o NDVI, NDWI, SAVI e IAF para expressam o vigor fenológico da biomassa no local, bem como o uso e cobertura da terra em uma bacia hidrográfica para estudar suas relações com a Evapotranspiração Real - ETa na Bacia Hidrográfica do Rio Sorocabuçu em Ibiúna-SP.

2 OBJETIVOS

2.1 Objetivo Geral

Contribuir com o aprimoramento da utilização de índices biofísicos, uso da terra e cobertura vegetal na gestão e tomada de decisão em bacias hidrográficas por meio de dados orbitais e a utilização de geoprocessamento, e assim fornecer subsídios para práticas de desenvolvimento sustentável na Bacia Hidrográfica do Rio Sorocabuçu.

2.2 Objetivos Específicos

i. Elaborar o mapeamento de classificação de uso da terra do ano de 2020 para a análise da dinâmica territorial na BH e sua influência na Evapotranspiração Real (ETa);

ii. Estimar a contribuição da ETa em relação aos diversos usos e ocupação da terra na BH do Rio Sorocabuçu no transporte de água para a atmosfera;

iii. Propor uma metodologia para a estimativa do NDVI e NDWI com base em imagens de Radar de Abertura Sintética (*Synthetic Aperture Radar* – SAR) para a estimativa desses índices em períodos com alto percentual de cobertura de nuvens;

iv. Produzir mapas de índices biofísicos (NDVI, NDWI, SAVI e IAF) e de ETa para o ano de 2020 e realizar análise da correlação entre variáveis na BH estudada.

3 REVISÃO DE LITERATURA

3.1 Bacia hidrográfica como unidade de planejamento

Levando em consideração a definição presente na Política Nacional de Recursos Hídricos, Lei n° 9.433 de 1997, também conhecida como Lei das Águas, uma bacia hidrográfica (BH) pode ser definida como uma unidade básica de estudo e gestão. Este conceito foi ganhando maior lastro a medida que mais pesquisas sobre o assunto foram sendo realizadas, de modo a expressar de forma técnica área que possui importância ambiental singular.

Uma BH pode ser também definida como uma unidade fisiográfica tendo como delimitação de perímetro os seus divisores de água que delimitam topograficamente a sua área de drenagem, que converge para um curso d'água principal (QUEIROZ et al., 2009), e tendo em vista que são nas BHs que estão inseridos os conglomerados urbanos, elas são consideradas como unidades básicas para se realizar o planejamento visando o desenvolvimento de forma sustentável de uma região (BERTONI e LOMBARDI NETO 2014).

A configuração espacial das BHs permite a interação entre os componentes geológicos, geomorfológicos, hidroclimáticos, pedológicos e bioecológicos, propiciando uma relação entre o fluxo de matéria e energia (NASCIMENTO et al., 2008). Nesse sentido, as intervenções antrópicas causam diversos tipos de impactos nos componentes desse sistema, provocando a degradação da qualidade ambiental e o desequilíbrio dos meios físicos e biótico, alterando a dinâmica natural desse ecossistema (CHRISTOFOLLETI, 1999; FILGUEIRA DE SÁ et al., 2010), causados e agravados por mudanças no uso e ocupação do solo (SILVA e CORRÊA 2015).

Para a efetividade da BH com unidade de planejamento, deve-se levar em consideração que este ambiente contempla diferentes interesses, gerando inúmeros pontos de conflitos, levando em consideração as prerrogativas legais, considerando a atuação do estado como fiscalizador, bem como o entendimento das questões socioculturais e a ambientais de cada BH (CARVALHO 2020).

3.2 A importância do manejo ambiental na bacia hidrográfica

A situação ambiental das BHs reflete uma visão conjunta das ações antrópicas e suas condições naturais, que podem ser severamente agravadas pela falta de manejo integrado dos

meios físicos, bióticos e socioeconômicos. Segundo GUERRA (2006), os planos de manejo e gerenciamento de BH levam em consideração, em sua grande maioria, apenas aspectos relacionados a utilização dos recursos hídricos como a irrigação ou saneamento ou geração de energia. De certa forma um sistema incompleto, pois despreza-se a interrelação de componentes essenciais para o desenvolvimento sustentável, afetando a capacidade e os limites ambientais do bioma como um todo (GERRA 2006).

De acordo com Poleto (2019), no Brasil, 70% dos recursos hídricos são utilizados para irrigação, 11% para abastecimento urbano, 10% na dessedentação animal, 7% no uso industrial, e 2% no abastecimento rural. Sabemos que esses consumos, principalmente os relacionados a agricultura, poderiam ser otimizados, a utilização do manejo de forma adequado e integrada pode contribuir para a utilização de tal recurso de maneira sustentável, pois perde-se água de diversas formas nesses usos, como por exemplo a inserção de água na mesma quantidade em toda a área plantada, quando as necessidades hídricas podem ser diferentes dentro de uma mesma lavoura.

Nesse contexto, cita-se como exemplo os trabalhos de Silva (2011), que avaliou o estresse hídrico da vegetação no médio trecho da bacia hidrográfica do rio Ipojuca, utilizando o NDWI. Assim como Silva et al., (2017), também utilizou o mesmo índice biofísico para verificar a disponibilidade de água para a vegetação presente na Bacia Hidrográfica do Rio Una no município de Ibiúna-SP. Oliveira et al., (2010), avaliaram as mudanças no espaço e tempo na bacia hidrográfica do rio Moxotó-PE utilizando o NDWI e albedo de superfície.

Diversos índices biofísicos podem ser utilizados para otimizar o monitoramento de grandes áreas de plantio, principalmente pela praticidade de obtenção dos dados orbitais em detrimento da dificuldade de se obter dados em campo, dessa forma, pode-se ter acesso a diversas informações importantes de uma lavoura por meios dos índices. Alvino et al., (2021) investigaram diversos índices de vegetação para monitoramento de milho irrigado (NDVI - Índice de Vegetação por Diferença Normalizada; EVI - Índice de Vegetação Aprimorado; SAVI - Índice de Vegetação Ajustado do Solo; GNDVI - Índice de Vegetação por Diferença Normalizada Verde; SR - Razão Simples; NDWI – Índice de Água por Diferença Normalizada e MSI - Índice de Estresse por Umidade), obtendo-se resultados satisfatórios acerca da fenologia da cultura do milho, constando que tais índices podem ser usados para o manejo da lavoura.

A utilização de técnicas e metodologias que abarcam uma maior quantidade de ferramentas tecnológicas contribuem de forma efetiva e necessária ao manejo ambiental nas BHs, o monitoramento adequado, capacidade tecnologicamente avançada para identificar e

apontar possíveis locais sujeitos ou não a danos ambientais, figuram como importante ferramenta para a gestão e conservação da área (HAYASHI, SARDINHA e PAMPLIN, 2020).

3.3 Evaporação, transpiração e evapotranspiração

O ciclo hidrológico, aborda o movimento contínuo da água no planeta Terra descrevendo o movimento e mudanças de estado, de líquido para vapor, para estado sólido e retorno ao seu estado inicial (USGS, 2021). A evaporação e a transpiração propiciam a evapotranspiração, todos esses processos são componentes importantes do ciclo hidrológico, pois diversas outras variáveis dos ecossistemas possuem dependência direta a esses processos (ALLEN et al., 1998).

A evaporação, do ponto de vista ambiental, consiste na passagem da água do seu estado líquido para o estado de vapor utilizando como fonte de energia a radiação solar por meio de processos de difusão turbulenta e molecular (Tucci e Silveira 2020). Por outro lado, a transpiração, figura-se principalmente como uma atividade de transferência de massa e calor que ocorre de forma natural nas plantas, dissipando o calor proveniente da radiação fotossinteticamente ativa (*fPAR*) e da temperatura do ambiente (Zhu et al., 2022).

A combinação de perda hídrica por evaporação e transpiração, dão origem ao fenômeno de evapotranspiração (ET) (Stoy et al., 2019), processo de grande relevância ambiental, haja vista a capacidade de influenciar na movimentação da água contida na vegetação e no solo para a atmosfera (Wang et al., 2019; Chintala et al.; 2022).

3.3.1 Tipos de evapotranspiração

São quatro os principais tipos de evapotranspiração: evapotranspiração potencial (ET_P); evapotranspiração de referência (ETo); evapotranspiração de cultura (ET_C) e; evapotranspiração real (ET_a).

Em 1948 foi o sugerido o conceito de evapotranspiração potencial (ET_P) por Thornthwaite, que se refere ao valor máximo da água transferida da superfície do solo e da transpiração da água e das plantas de volta à atmosfera, em condições ideais, sendo que esse conceito está atualmente em desuso, pela dificuldade em sua obtenção, realizada por meio métodos empíricos (Thornthwaite, 1948).

De acordo com Allen et al., 1998 a evapotranspiração de referência (ETo) é aquela obtida em uma extensa área totalmente coberta com vegetação rasteira e uniforme, como um gramado, com altura variando entre 8 e 15 cm, suprimento de água adequado e sem interferência no calor sensível causado pelo ecótono de vizinhança. Assim a ETo representa as condições meteorológicas vigente, uma vez que ela depende basicamente de dados meteorológicos para a sua estimativa (Silva et al., 2021).

Semelhante a ETo, a evapotranspiração de cultura (ET_C) é obtida na fase de intenso desenvolvimento da vegetação em condições ideais de crescimento, suprimento hídrico e sem interferência no calor sensível pelo ecótono, dependendo de cada tipo de cultura por conta da área foliar e das condições meteorológicas vigentes (Venâncio et. al., 2019).

Caracterizada principalmente pela transferência hídrica da evaporação e transpiração, a evapotranspiração real (*ETa)* deve ser mensurada em condições de campo, uma vez que envolve todas as condições da superfície do solo, e por levar em consideração as reais características do ecossistema, normalmente apresenta valores menores que as evapotranspirações da cultura e potencial. A *ETa*, dentre todos os tipos de evapotranspirações aqui citadas, é a que mais está relacionada com o tipo de uso da terra, nesse sentido, a grande maioria das estimativas realizadas por meio de imagens orbitais possuem como objetivo os valores de *ETa* (Silva et al., 2021).

Nesse sentido, esta pesquisa utiliza as estimativas de *ETa* para o estudo e análise relacionados aos índices biofísicos e o uso da terra em bacia hidrográfica.

3.4 Sistema de Informações Geográficas (SIG) e manejo ambiental

Os Sistemas de Informações Geográficas (SIG) são definidos como um ambiente que faz a associação e interação de diversas fontes de dados, com o intuito de realizar edições, gerenciamento, análises e espacialização dos produtos (Fitz 2008).

Outro conceito difundido define o SIG como um software computacional, onde sua principal função é realizar operações algébricas com os dados geográficos e alfanuméricos, tendo como base algoritmos desenvolvidos para as mais variadas finalidades (Bossle 2016).

Com a evolução da capacidade computacional e avanço das técnicas de geoprocessamento, foi possível realizar análises robustas de dados georreferenciado, facilitado também pelo aperfeiçoamento e surgimento de novos softwares de SIG, tanto os pagos como gratuitos (Moreira 2011).

Nesse contexto, os SIG propiciam subsídios para a gestão integrada dos ecossistemas e biomas. Sua utilização permite a integração e análise de dados geográficos em grandes proporções, figurando como ferramenta importante para se fazer gestão, manejo e planejamento ambiental para a execução de ações em locais específicos (Campos, Piroli e Benini 2015). Abaixo traz-se algumas aplicações dessa vasta e crescente tecnologia relacionadas ao manejo ambiental com a utilização de SIG no Brasil e no mundo.

Alves et al., (2021), Analisaram as mudanças nas categorias de uso e cobertura do solo entre 1986 e 2016 com o intuito de obter dados para subsidiar estudos de planejamento e gestão de bacias hidrográficas e recursos hídricos, o estudo concluiu que ocorreu um decréscimo na área de vegetação natural e um aumento das áreas degradas na bacia hidrográfica estudada.

Elbeih (2021), avaliaram áreas de expansão agrícola nos desertos egípcios por meio de uma revisão usando sensoriamento remoto e SIG, como principais resultados os estudos resultaram em várias informações que ajudarão os gestores da região em processos de tomada de decisão e planejamento visando o desenvolvimento sustentável.

3.5 Índices e variáveis biofísicas no manejo de bacias hidrográficas

As alterações nas características naturais dos ecossistemas causadas por ações antrópicas que substituem ambientes naturais em cidades, áreas de cultivos ou por lâminas d'água para fins de preservação, impactam de forma efetiva o fluxo de energia, com efeitos diretos entre a superfície que recebe a radiação solar e a atmosfera, provocando alterações na quantidade de absorção e reflectância da energia no meio (Alves e Biudes 2012).

Estudar o balanço de energia de um ecossistema é fundamental para se determinar o saldo de radiação solar, que compreende a radiação de ondas curtas que chega do sol com as de ondas longas na atmosfera, para se realizar o monitoramento do clima e consequentemente a gestão ambiental em bacias hidrográficas (Lira Filho, Sousa e Iwata 2021).

O acesso a informações climáticas em éreas de pequeno porte pode ser realizado por meio das estações meteorológicas *in loco*, porém, para grandes áreas, como os limites de uma bacia hidrográfica, a estimativa de dados regionalizados é dificultada em razão dos altos custos de instalação e manutenção. Por meio do sensoriamento remoto, processamento digital de imagens e os SIGs, tornou-se possível estimar os parâmetros biofísicos como os índices de vegetação, albedo de superfície, evapotranspiração dentre outros, de áreas em escala regional (Freitas, Boggione e Kampel 2015).

Nesse sentido, os estudos dos índices biofísicos permitem análises de todo o ecossistema, produzindo dados de quantidade e qualidade da cobertura vegetal, facilitando a gestão e o entendimento dos processos hidrometeorológicos na bacia hidrográfica, figurando como uma excelente ferramenta para a gestão e tomada de decisão (Alves e Biudes 2012).

3.5.1 Índice de Vegetação por Diferença Normalizada (NDVI)

Proposto por Rouse et al. (1973), o Índice de Vegetação por Diferença Normalizada (NDVI - *Normalized Difference Vegetation Index*), nasceu da interação algébrica das bandas espectrais do vermelho e do infravermelho próximo por meio da equação de normalização de valores. Com o NDVI, é possível identificar situação da cobertura vegetal levando em consideração a atividade fotossintética ou vigorosidade das folhas, uma vez que a clorofila absorve a radiação eletromagnética na região do vermelho e o infravermelho próximo é dissipado nas estruturas celulares das folhas, torna-se possível tal inferência (Martinuzzi, 2008).

O NDVI consiste em uma ferramenta que permite o monitoramento da vegetação podendo ser utilizado para detectar diferentes fases fenologicas, crescimento, mudanças fisiológicas das folhas e períodos de senescência em escala regional, continental e global (PONZONI e SHIMABUKURO 2007).

Para a interpretação dos dados oriundos do NDVI, tem-se que seus valores variam em uma escala de -1 a 1, onde os valores de -1,00 a 0,00 correspondem a vegetação morta e/ou alvos não vegetais tais com corpos d'água e nuvens, valores > 0,00 a 0,33 corresponde a vegetação com estresse hídrico, valores de > 0,33 a 0,66 refere-se a vegetação moderadamente sadia, e de 0,66 a 1,00 vegetação sadia e com alta produtividade fotossintética (Mkhabela et al., 2011; Rafique et al., 2016; Lopes et al., 2020).

3.5.2 Índice de Água por Diferença Normalizada (NDWI)

Idealizado por Gao (1996), o Índice de Água por Diferença Normalizada (NDWI - *Normalized Difference Water Index*), utiliza as bandas do infravermelho próximo e infravermelho médio (0,86 μm e 1,24 μm) para mensurar a quantidade de água presente da estrutura fisiológica vegetal, facilitando inferências sobre a situação hídrica nos vegetais.

Assim com o índice biofísico falado no tópico anterior, o NDWI também é adimensional e varia de -1 a 1, sendo que os valores de -1,00 a -0,56 correspondem a ausência de vegetação, os

valores > -0,56 a 0,00 refere-se à vegetação seca, e valores > 0,00 a 1,00 correspondem a vegetação verde (Gao, 1996; Oliveira et al., 2010; Lopes et al., 2020; Sun et al., 2013).

3.5.3 Índice de Vegetação Ajustado ao Solo (SAVI)

Desenvolvido por Huete (1988), o Índice de Vegetação Ajustado ao Solo (SAVI - *Soil Adjusted Vegetation Index*), surgiu da necessidade de se diminuir a sensibilidade das propriedades ópticas do solo no NDVI, quando a área estudada não apresentava cobertura vegetal completa. Nesse sentido, para eliminar o efeito de fundo do solo, foi usado um fator "L" de ajuste do solo com base em um ponto convergente, para considerar as variações de cobertura do fundo solo (Gilabert et al., 2002; Ren et al., 2018).

Dentre as principais características do fator "L" propostos por Huete (1988), observa-se que seus valores variam em relação a densidade da vegetação e a possibilidade de reflectância do solo, sendo utilizado 0,25 quando a vegetação apresentar alta densidade, 0,5 média densidade e 1,0 para baixas densidades.

Os valores do SAVI variam de maneira semelhante com ao NDVI, ou seja, os valores próximos de zero indicam o solo sem cobertura vegetal, os valores negativos representam áreas úmidas ou corpos hídricos e, os valores positivos indicam a vegetação (ANDRADE et al., 2013).

3.5.4 Índice de Área Foliar (IAF/LAI)

Proposto inicialmente por Watson (1947), o Índice de Área Foliar (IAF/LAI - *Leaf Area Index*) pode ser definido como a razão entre a projeção da área foliar que realiza fotossíntese e a área do solo que apresenta cobertura vegetal. Esse índice é um parâmetro adimensional de grande relevância para se estudar as tendências biológicas e fisiológicas da vegetação, permitindo ainda observar o regime de crescimento e vigorosidade da vegetação (Arslan et. al., 2021).

O IAF é a fração de radiação fotossinteticamente ativa (0,4 a 0,7 μm) absorvida pela vegetação (*fPAR*) que caracteriza o funcionamento do dossel da vegetação e a capacidade de absorção de energia de um ecossistema (MYNENI et al., 2002; GAMEIRO et al., 2016).

No sentido de análise dos resultados, altos valores de IAF indicam alto desenvolvimento da vegetação, alta quantidade de biomassa e consequentemente alta taxa de fotossíntese e

produtividade, em razão da boa absorção da *fPAR* (BOUMAN, 1992; Verma et al. 1993; Liu, 2006).

3.5.5 Albedo de Superfície

Define-se como albedo de superfície a diferença da radiação eletromagnética (REM) incidente e a refletida pela superfície terrestre, possuindo influência direta nas características climáticas dos ecossistemas (Saher et al., 2021; Gueymard et al., 2019; Nicodemos et al., 1977).

As atividades antrópicas, principalmente as voltadas para o uso e ocupação da terra, seja em meio rural ou urbano, influenciam diretamente no albedo de superfície. Solo exposto ou mesmo áreas urbanizadas possuem uma grande capacidade de absorção de radiação incidente, dessa forma apresentam um baixo albedo e influenciam de forma efetiva para o aumento da temperatura e a taxa de evaporação da água (Schwarz et al., 2012; Upreti et al., 2017).

O manejo da vegetação e de áreas de agropecuária em uma BH, são de grande importância na regulação do albedo de superfície, pois apresentam uma capacidade natural regulatória no balanço de energia, sendo que mudanças no uso e ocupação do solo podem causar estresse hídrico e prolongar períodos de estiagem. (Evans et al., 2017; Pang et al., 2022).

Um outro fator que influencia negativamente no albedo de superfície é o teor de água do solo, pois altos índices de umidade causam o escurecimento do solo, aumentando a sua capacidade de absorção da REM, elevando também a taxa de evapotranspiração (Gascoin et al., 2009).

3.5.6 Temperatura da Superfície Terrestre (TST)

Sendo um dos parâmetros mais importantes nos processos físicos da superfície terrestre, a Temperatura da Superfície Terrestre (TST/LST – *Land Surface Temperature*), é um fenômeno que possui influência direta na interface superfície-atmosfera, e consequentemente, influenciando em diversas variáveis climáticas e ambientais dos ecossistemas (Sobrino et al., 2016; Zhang et al., 2019).

Os efeitos do uso e ocupação do solo são preponderantes nas mudanças do balanço de energia (Dutta et al., 2022), a TST pode ser alterada severamente em função do tipo de cobertura que recebe a REM, com efeitos no fluxo de calor sensível e latente, alterando o percentual de evapotranspiração, assim como os índices de precipitação (Moon et al., 2020).

Nesse sentido, o acesso a informações de TST por meio de Sensoriamento Remoto (SR), possibilitou realizar análises ambientais efetivas nos ecossistemas, sobretudo, em razão da ampla cobertura de revisitas regulares dos sensores orbitais (Yang et al., 2020). Sendo, portanto, o SR por satélite amplamente empregado para estimar a TST (Zhang et al., 2019).

3.5.7 Evapotranspiração Real (ETa)

Do ponto de vista biofísico, a Evapotranspiração (ET) pode ser definida como a soma das perdas hídricas por transpiração dos vegetais e a evaporação do solo (Stoy et al., 2019; Allen et al., 1998).

De acordo com Tucci e Silveira (2020), os principais métodos para a determinação da evapotranspiração são: os diretos por meio de levantamento de campo através de estações meteorológicas; baseados na temperatura e radiação; métodos combinados e; os que utilizam o balanço hídrico. Sendo que alguns desses métodos apresentam relativa dificuldade para a obtenção de resultados, haja vista que o levantamento de dados em campo é uma atividade onerosa, porém estes, figuram como os dados mais confiáveis.

Com os constantes avanços das geociências, métodos de determinação indireta utilizam combinações de dados orbitais oriundos de sensores ativos e passivos para a estimativa de dados de evapotranspiração, tarefa possível em razão de pesquisas na área e por conta dos constantes avanços em software, hardware, da melhoria nas resoluções espacial e temporal das imagens orbitais (Chen e Liu 2020).

Há diversos métodos existentes para a determinação de evapotranspiração por meio de dados orbitais, porém, uma vez que os dados coletados diretamente possuem alto custos e correspondem a áreas relativamente pequenas, vislumbra-se a necessidade de metodologias que possam estimar os dados de ET com precisão e confiabilidade, proporcionando informações de grande áreas para o manejo dos ecossistemas, e assim servir de subsidio para a gestão de forma sustentável do meio ambiente (Allam, et al. 2021).

3.6 Programa Copernicus e principais Missões Sentinel

Fundada em 1975, a Agência Espacial Européia (ESA – *European Space Agency*), já está a mais de 40 anos produzindo informações espaciais para a Europa e o mundo, por meio da cooperação de mais de 20 países, ela tem como objetivo principal a investigação científica do espaço sideral, com fins exclusivamente pacíficos (ESA, 2022).

A ESA possui diversos programas espaciais em operação, dentre eles o programa Copernicus que, para suprir as necessidades operacionais desse programa, foram desenvolvidas as missões Sentinel. Para o melhoramento das resoluções temporal, radiométrica e espacial, cada missão Sentinel foi baseada em uma constelação de dois satélites, todas carregando em suas plataformas uma gama de equipamentos tecnológicos como os instrumentos de imagens multiespectrais para monitoramento terrestre, oceânico e atmosférico e também instrumentos de radar, que realiza o sensoriamento durante o dia, noite e me condições atmosféricas adversas (Rodríguez-Benito, Navarro e Caballero, 2020; Fernández et al., 2022).

As seis diferentes missões Sentinel: Sentinel 1, Sentinel 2. Sentinel 3, Sentinel 4, Sentinel 5 e Sentinel 6, carregam o que há de mais tecnológico quando o assunto é exploração espacial, eles marcaram uma nova era na observação da Terra, pois fornecem dados em quantidade e qualidade adequadas que poderão ser utilizados por várias décadas (ESA, 2022).

Neste pesquisa, utilizou-se basicamente os dados orbitais das missões Sentinel 1, 2 e 3, nesse sentido, detalha-se a seguir algumas características técnicas dessas missões, principalmente no que tange informações como tipo de energia utilizada no processo de imageamento, tempo de revisita (resolução temporal), tamanho do pixel das imagens (resolução espacial), resolução radiométrica (quantidade de bits), resolução espectral (faixa do espectro que o sensor consegue imagear) e alguns equipamentos embarcados nas plataformas.

Dentre as seis missões Sentinel, algumas com lançamento previsto e a maioria já em órbita, quatro missões são compostas por sensores passivos que imageiam utilizando a radiação eletromagnética proveniente do Sol e duas missões são compostas por instrumentos de radar, que utilizam uma fonte de energia própria para imagear os alvos.

Os primeiros satélites das missões Sentinel, o Sentinel-1A, foi colocada em órbita no dia 03 de abril de 2014, cerca de dois anos depois, no dia 25 de abril de 2016, o Sentinel-2B foi lançado (Fernández et al., 2022). Os dois satélites foram lançados da base europeia na Guiana Francesa por meio de foguetes Soyuz (ESA, 2022).

Com o objetivo de reduzir o tempo de revisita dos sensores, os dois satélites da missão Sentinel-1, (A e B) foram projetados de forma idêntica, nesse sentido, ambos são radar de abertura sintética (SAR - *Synthetic Aperture Radar*) de banda C, o imageamento gera produtos em 2 níveis, sendo que no nível 1 apresentam dois topos - complexo de visual único (SLC- *Single Look Complex*) e detectado ao nível do solo (GRD - *Ground Range Detected*), já o nível 2 se referem a ferramentas específicas para estudos oceânicos (ESA, 2020).

A missão Sentinel-1 realiza a aquisição de dados de quatro maneiras – em mapa de tiras (SM- *Stripmap*), faixa ampla interferométrica (IW- *Interferometric Wide Swath*), faixa extra-

larga (EW- *Extra-Wide Swath*) e em Ondas (WV- *Wave*), sendo que SM, IW e EW estão disponíveis em polarização simples (HH ou VV) ou dupla (HH+HV ou VV+VH), já a WV propicia apenas polarização única (HH ou VV) é usado principalmente para monitoramento costeiro de área ampla, incluindo tráfego de navios, derramamento de óleo e monitoramento de gelo marinho (Fletcher, 2012). Com a combinação dos dois satélites (Sentinel-1A e B), possuem resolução temporal de 6 dias, e resolução espacial com 10 metros pixels quadrados de 10 × 10 m (Putri, Widyatmanti e Umarhadi, 2022).

Na missão Sentinel-2, também composta pelos satélites Sentinel-2A, lançado em 23 de junho de 2015 e Sentinel 2B em 7 de março de 2017, é uma missão de imagem multiespectral de alta resolução e ampla faixa, levando em sua plataforma o Instrumento Multiespectral (MSI) com 13 bandas espectrais, com resolução espacial de 10 m, 20 m e 60 m com tempo de revisita de cinco dias, considerando os dois satélites dessa família (Allam, 2021).

A missão Sentinel-3, como as demais, composta pelos satélites Sentinel-3A, lançado em 16 de fevereiro de 2016 e Sentinel-3B em 25 de abril de 2018, é uma missão voltada para a medição da topografia do fundo do mar, e a temperatura da superfície do mar e da terra com alta tecnologia, para isso, leva um suas plataformas diversos instrumentos como o OLCI - *Ocean and Land Color Instrument* que é um espectrômetro de imagem com resolução espacial de 300 m e resolução radiométrica de 14 bits (ESA, 2022). Além do SLSTR - *Sea and Land Surface Temperature Radiometer*, que possui resolução espacial de 1 km, com resolução temporal inferior a 1 dia (Aguirre-García et al., 2021).

3.7 Estimativa de índices de vegetação por meio de dados SAR

O mapeamento contínuo de índices de vegetação é de suma importância, pois servem de apoio a estudos sobre a mudanças climáticas, ciclo hidrológicos e biogeoquímicos, além de possibilitar o monitoramento da cobertura vegetal, detecção de mudanças na cobertura da terra, aprimoramento de técnicas de agricultura de precisão e consequentemente, aumento de produtividade agrícola, auxiliando na gestão dos recursos naturais e desenvolvimento sustentável (Huete et al., 2010; Orsini et al., 2020; Lopes et al., 2020).

Os dados obtidos com uso de sensores ópticos são amplamente utilizados para o monitoramento de índices de vegetação, entretanto, os sensores passivos possuem limitações quanto a presença de nuvens, inviabilizando o monitoramento da vegetação ao longo do ano (Mandal et al., 2020). Por outro lado, as imagens obtidas por radar constituem uma excelente fonte de dados, pois esses sensores não sofrem interferência de nuvens, o que possibilita o

monitoramento continuado da vegetação na superfície da terra em condições atmosféricas adversas (Mandal et al., 2020; Meyer, 2019).

A intensidade do sinal que é capturado pelos radares é utilizada para calcular o coeficiente de retroespalhamento (σ^0), que descreve as propriedades de espalhamento do terreno na direção da fonte de iluminação (Meyer, 2019). O retroespalhamento é governado pela superfície geométrica (rugosidade, cobertura vegetal), dielétrica (umidade do solo, conteúdo de água da vegetação), e demais propriedades relativas ao comprimento de onda, polarização e ângulo de incidência do pulso de radar (Vreugdenhil et al., 2018; Meyer, 2019; Nasirzadehdizaji et al., 2019). Dessa forma, os dados obtidos por radares são sensíveis aos estágios de crescimento e altura das plantas, constituindo uma fonte de dados com potencial para ser utilizados no monitoramento da biomassa acima do solo (Periasamy, 2018; Bai et al, 2020).

Recentemente, diversos estudos investigaram a relação entre as métricas de vegetação e umidade do solo com dados de retroespalhamento e demais variáveis secundárias obtidas a partir de dados de sensores ópticos na região espectral de micro-ondas. Os resultados indicam que a polarização cruzada Horizontal-Horizontal (HH) e Vertical-Vertical (VV) pode contribuir de forma significativa para a determinação desses atributos (Shen et al., 2015). Além do mais, resultados promissores foram observados recentemente por Chang et al. (2018); Filgueiras et al. (2019); Mandal et al. (2019) utilizando dados SAR do Sentinel-1 para a determinação de índices de vegetação.

4 MATERIAL E MÉTODOS

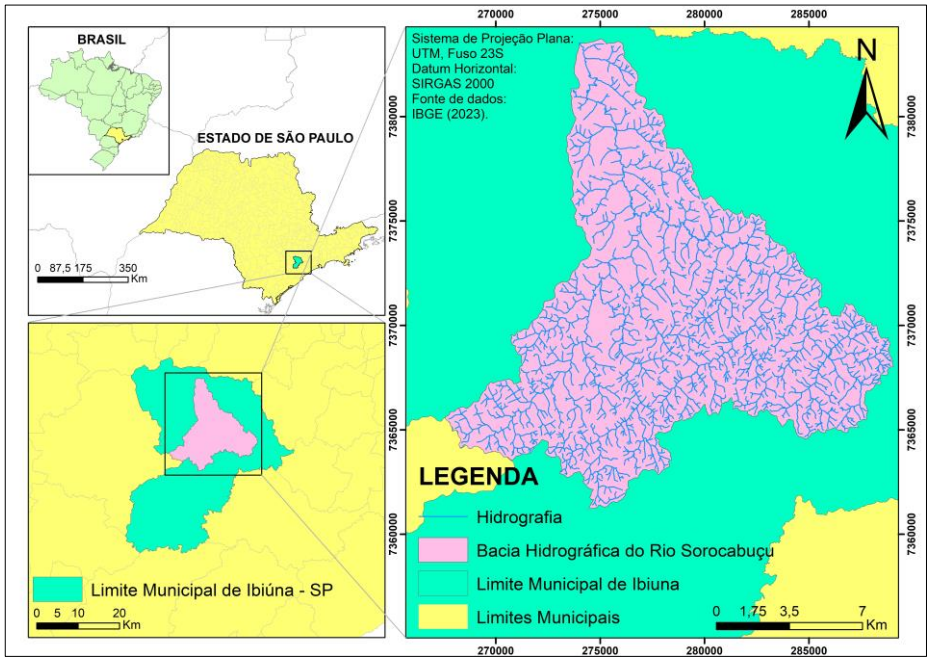
4.1 Área de estudo

O estudo foi realizado na Bacia Hidrográfica do Rio Sorocabuçu, localizada no município de Ibiúna-SP, situada na região centro oeste do Estado de São Paulo (Figura 1). Abacia hidrográfica possui aproximadamente 202 km², ocupando cerda de 22% da APA Itupararanga que abriga um importante remanescente da Mata Atlântica (São Paulo, 2010; Souza, 2021).

A área de estudo está inserida no município de Ibiúna-SP, no qual sua economia está fundamentada na produção agrícola, onde também estão localizados importantes cursos d`água responsáveis pelo abastecimento de importantes mananciais fundamentais na regularização do regime hidráulico de represas de energia e no abastecimento público de água na região para cerca de 1 milhão de habitantes (SALLES *et al.*, 2008).

De acordo com o DAEE (2020), a área possui pluviosidade mensal média de 124 mm, sendo janeiro o mês mais chuvoso, com precipitação de 235 mm, e agosto, o mês mais seco, com precipitação de 47 mm. A classificação climática é do tipo Cwa, predominantemente subtropical, e temperatura média anual de 19,3 C°, com máximas variando entre 26°C a 27°C e mínimas de 13,5°C a 14,5 °C (Dubreuil et al., 2018; EMBRAPA, 2019; e CIIAGRO, 2019).

Figura 1 - Localização da Área de Estudo.



Fonte: Elaborado pelo autor.

A região de Ibiúna tem sua economia fundamentada na produção agrícola, além de estar localizado os afluentes que dão origem ao rio Sorocaba, os rios Una, Sorocabuçu e Sorocamirim, formando o Reservatório de Itupararanga (SALLES et al., 2008).

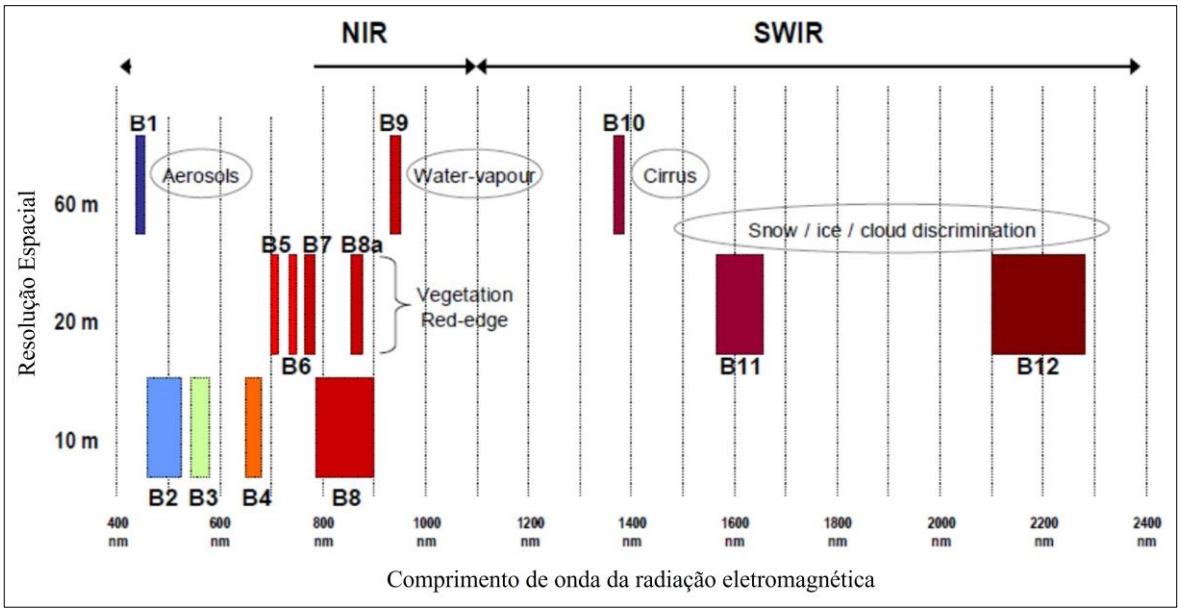
Segundo Rossi (2017), os tipos de solos predominantes na área de estudo são: os Latossolos Vermelho-Amarelo (LVA), presentes em 89% da área, com ocorrência comum em relevo ondulado e fortemente ondulado, são solos geralmente bem formados e profundos, em sua grande maioria; Gleissolos Melânico (GM), presente em 10% da área, solos comuns em relevos planos e são pouco profundos; e os Cambissolos Háplicos (CX), ocupam cerca de 1% da área, são encontrados em áreas com relevo ondulado e fortemente ondula e possuem textura argilosa.

4.2 Aquisição e processamento de dados

Os dados da constelação Sentinel-2 foram obtidos na Agência Espacial Européia *(European Space Agency - ESA*), por meio do portal *Scientific Data Hub – (HUB/ESA)*, que disponibiliza os dados das missões Sentinel de forma gratuita. Estes satélites possuem resolução radiométrica de 12 bits e o instrumento MSI que fornece produtos em 13 bandas do espectro eletromagnético do visível, infravermelho próximo e infravermelho de ondas curtas, com resolução espacial em 10 metros (B2, B3, B4, B8), seis bandas com 20 metros (B5, B6, B7, B8A, B11, B12) e três bandas com 60 metros (B1, B9, B10), conforme Figura 2 (FILGUEIRAS et al., 2019).

Os dados radiométricos dos pixels das cenas são fornecidas em *Top-Of-Atmosphere* (TOA) e o Imageamento realizado no nível 1C gera produtos em ortoimagem, que é uma imagem obtida por meio de um sistema digital de elevação projetado, com o objetivo de corrigir distorções atmosféricas, foi realizado a transformação para *Digital Numbers* (DN) por meio do plugin Sen2Cor 2.8 do *Sentinel Application Platform* - SNAP 9.0.0, software livre da própria ESA, obtendo-se dessa forma a reflectância na superfície em *Bottom-Of-Atmosphere* (BOA), procedimento necessário para corrigir as interferências oriundas de efeitos atmosféricos (TAS e ESA, 2021). Em seguida, foi realizado o recorte das cenas para o limite da bacia hidrográfica utilizando a ferramenta nativa do QGIS 3.22.9 por meio do menu Raster>Extrair>Recortar Raster pela camada de máscara, logo depois fez-se a reprojeção para UTM utilizando-se o Datum SIRGAS 2000, fuso 23 S.

Figura 2 - Bandas espectrais do instrumento MSI e Resolução Espacial do Sentinel-2A.



Fonte: Adaptado de TAS e ESA (2021).

Foram utilizadas 10 cenas da constelação Sentinel-2 para a obtenção do NDVI, NDWI, SAVI, IAF e do uso e ocupação da terra para o ano de 2020, bem como 2 cenas do Sentine-1 para estimativa do NDVI e NDWI para os meses de junho e dezembro. As informações técnicas dessas cenas estão expressas na Tabela 1. Todo o processamento dos dados Sentinel foi realizado na *Sentinel Application Platform* - SNAP 9.0.0 (ESA, 2022).

Tabela 1 - Informações das cenas utilizadas para processamento.

Sensor	Data	Grade Sentinel	Instrumento	Nível
Sentinel-2A	17/01/2020	23KKP	MSI	1C
Sentinel-2A	16/02/2020	23KKP	MSI	1C
Sentinel-2A	17/03/2020	22KHU	MSI	1C
Sentinel-2A	19/04/2020	23KKP	MSI	1C
Sentinel-2A	11/05/2020	22KHU	MSI	1C
Sentinel-1A	15/06/2020	22KHU	MSI	1C
Sentinel-2A	13/07/2020	22KGU	MSI	1C
Sentinel-2A	19/08/2020	22KGU	MSI	1C
Sentinel-2A	16/09/2020	22KGU	MSI	1C
Sentinel-2A	18/10/2020	22KGU	MSI	1C
Sentinel-2A	17/11/2020	22KGU	MSI	1C
Sentinel-1A	15/12/2020	22KGU	MSI	1C

Fonte: Elaborado pelo autor.

Após o processamento das cenas e obtenção dos índices biofísicos, foi criado uma malha com pontos regulares espacializado de 30 em 30 metros por meio do QGIS em sua ferramenta

nativa: Vetor>Investigar>Pontos regulares, delimitados pelo perímetro da bacia hidrográfica do Rio Sorocabuçu, totalizando 225.182 (duzentos e vinte e cinco mil cento e oitenta e dois) pontos na área da BH.

Por meio dessa malha foram extraídos pontos para cada mês do ano de 2020 para cada índice: NDVI, NDWI, SAVI, IAF, uso e cobertura da terra e ETa, utilizando-se o *Plugin Point sampling tool* disponibilizado por Jurgiel (2020), no banco de complementos do QGIS. Nesse sentido o total de amostras da pesquisa foi de 16.213.104 (dezesseis milhões duzentos e treze mil cento e quatro). A confecção e montagem das cartas e mapas utilizados na pesquisa foram produzidos no QGIS versão 3.22.9 - Białowieża (QGIS, 2022).

4.3 Mapeamento da cobertura e uso da terra

Para o mapeamento da cobertura e uso da terra referente ao ano de 2020, foi utilizado uma cena da constelação Sentinel-2, de resolução espacial de 10m, com localização na grade Sentinel pelo código T22KGU, obtida no dia 26 de setembro de 2020, sendo avaliada em composição colorida e em falsa cor, com as bandas mescladas em: 4R-3G-2B e 8R-4G-3B, respectivamente. Todo o mapeamento foi baseado na classificação de cobertura e uso da terra disponibilizado pelo IGC para o ano de 2010, produzido a partir de cenas do sensor Vexcel com resolução espacial de 45 centímetros (IGC, 2010).

Foi utilizado para a classificação do mapeamento da cobertura e uso da terra o Sistema Básico de Classificação da Cobertura e do Uso da Terra – SCUT, presente no Manual Técnicos de Uso da Terra do Instituto Brasileiro de Geografia e Estatística– IBGE em sua 3° Edição (IBGE, 2013).

Após a classificação realizada através da cena do Sentinel-2, foram identificadas as seguintes classes de uso: áreas urbanizadas; área de mineração; culturas temporárias; culturas permanentes; pastagens; silvicultura; área florestal; corpos d'água; área vegetacional perturbada e; área de várzea. Tendo em vista o nível de detalhamento das classes, considerou-se uma adaptação do nível 2 e suas subclasses do SCUT (IBGE, 2013), em seguida, foi realizada uma retificação das classes por meio do Google Earth Pro.

Para a produção do mapa de cobertura e uso da terra utilizou-se o padrão de cores de classe de mapeamento em RGB proposto no SCUT conforme Tabela 2 (IBGE, 2013). Todo o processamento e elaboração do para foi realizada no QGIS versão 3.22.9.

Tabela 2 - Classes de uso da terra na área, suas características e o padrão de cor RGB.

(continua)

Classes	Característica	Padrão RGB
Áreas urbanizadas	Vilas, cidade, complexos industriais, Áreas urbano-industrial, arruamentos, rodovias dentre outras;	R = 255 G = 168 B = 192
Área de mineração	Extração a céu aberto de material metálico e não metálico de forma artesanal ou industrial;	R = 173 G = 137 B = 205
Culturas temporárias	Graníferas e cerealíferas, bulbos, raízes e tubérculos, hortícolas e floríferas, espécies temporárias produtoras de fibras, oleaginosas temporárias, frutíferas temporárias, cana-de-açúcar, fumo, cultivos temporários diversificados, outros cultivos temporários (abóbora, trevo, forrageiro etc.);	R = 255 G =255 B =0
Culturas permanentes	Frutíferas permanentes, frutos secos permanentes, Espécies permanentes produtoras de fibras, oleaginosas permanentes, cultivos permanentes diversificados, outros cultivos permanentes;	R = 255 G = 214 B =0
Pastagens	Pecuária de animais de grande porte, pecuária de animais de médio porte, pecuária de animais de pequeno porte;	R = 205 G = 137 B =0
Silvicultura	Área de Reflorestamento ou cultivos agroflorestais;	R = 205 G = 173 B = 0
Área florestal	Unidades de conservação de proteção integral em área florestal; Unidades de conservação de uso sustentável em área florestal; Terra indígena em área florestal; Outras áreas protegidas em área florestal; Área militar em área florestal; Extrativismo vegetal em área florestal; Extrativismo animal em área florestal; Uso não identificado em área florestal;	R = 115 G = 168 B = 0

Tabela 2 - Classes de uso da terra na área, suas características e o padrão de cor RGB.

(continuação)

Corpos d'água	Unidades de conservação de proteção integral em corpo d'água continental; Unidades de conservação de uso sustentável em corpo d'água continental; Terra indígena em corpo d'água continental; Áreas militares em corpo d'água continental; Outras áreas protegidas em corpo d'água continental; Captação para abastecimento em corpo d'água continental; Receptor de efluentes em corpo d'água continental; Geração de energia em corpo d'água continental; Transporte em corpo d'água continental; Lazer e desporto em corpo d'água continental; Pesca extrativa artesanal em corpo d'água continental; Aquicultura em corpo d'água continental; Uso não Identificado em corpo d'água continental; Uso diversificado em corpo d'água continental;	R = 153 G = 194 B = 230
Área vegetacional perturbada	Ambiente com a presença de vegetação herbácea arbustiva de tamanho variados, podendo ter a presença de cobertura arbustiva em variado estágio de sucessional, geralmente proveniente dos impactos causados por atividades humanas.	R = 214 G = 255 B = 168
Área de várzea	Área que apresenta lençol freático a florando na superfície do solo ou com presença de vegetação arbustiva que permanece inundados boa parte do ano.	R = 178 G = 178 B = 178

Fonte: Adaptadas do SCUT/IBGE (2013).

4.4 Estimativa dos índices biofísicos

4.4.1 Índice de Vegetação Ajustado ao Solo - SAVI

Para determinação do SAVI foi utilizado a Equação 1 proposto por Huete (1988). O referido índice atua no atentamento das propriedades ópticas do solo como ocorrem comumente no NDVI em áreas com ausência de vegetação, par isso utiliza-se valores constante no fator "L" para diminuir a sensibilidade causada pela superfície do solo.

$$SAVI = (1 + L) * \frac{(\rho NIR - \rho RED)}{(\rho NIR + \rho RED + L)} \quad (1)$$

Sendo

SAVI o Índice de Vegetação Ajustado ao Solo; ρNIR é a banda do infravermelho próximo; ρRED é banda do vermelhor e; L é o fator de ajuste para a cobertura da superfície do solo.

Os valores comumente adotados para o fator "L", encontram-se na Tabela 3, bem como a indicação do tipo de cobertura. Ressalta-se que no âmbito desse estudo, haja vista a dinâmica das classes de uso obtidas através do mapeamento de cobertura e uso da terra, adotou-se o valor de L como 0,5.

Tabela 3 - Valores adotados para o fator "L".

Cobertura da superfície do solo	Valor do fator "L"
Vegetação densa	0,25
Vegetação com densidade intermediária	0,5
Vegetação com baixa densidade	1,0

Fonte: Adaptado de Huete (1988).

4.4.2 Índice de Área Foliar - IAF

O índice de área foliar (IAF) é a fração de radiação fotossinteticamente ativa (0,4 a 0,7 μm) absorvida pela vegetação (*fPAR*) que caracterizam o funcionamento do dossel da vegetação e a capacidade de absorção de energia (MYNENI et al., 2002). O IAF foi estimado conforme Allen et al. (2002) citado por GAMEIRO et al., 2016, conforme Equação 2.

$$IAF = -\frac{\ln\left(\frac{0{,}69 - SAVI)}{0{,}59}\right)}{0{,}91} \quad (2)$$

Sendo:

IAF é o Índice de Área Foliar e, SAVI é o Índice de Vegetação Ajustado ao Solo.

4.4.3 NDVI E NDWI

Para obtenção do NDVI e NDWI foram utilizados os dados do sensor Sentinel-2A, obtidos no portal *Scientific Data Hub* da Agência Espacial Européia (ESA). Essa constelação possui dois sensores e foi lançada em março de 2017, possuem ciclos de 10 dias e resolução espacial de 10 metros para as bandas B2, B3, B4 e B8, e sua resolução radiométrica é de 12 bits (FILGUEIRAS et al., 2019).

Foram utilizadas 12 cenas do satélite Sentinel-2A localizadas na grade do sensor para o Brasil na referência 22KHU, sendo uma para cada mês do ano de 2020 perfazendo-se um ciclo hidrológico completo, com variação entre os dias em razão da cobertura de nuvens, de acordo com as seguintes datas: 27/01/2020, 16/02/2020, 17/03/2020, 29/04/2020, 31/05/2020, 08/06/2020, 13/07/2020, 19/08/2020, 26/09/2020, 28/10/2020, 07/11/2020 e 20/12/2020.

As cenas foram processadas no *software* SNAP (versão 8.0.0) seguindo a metodologia descrita por Braun (2020), onde realizou-se correção das imagens do topo da atmosfera (*Top Of Atmosphere* – TOA), para a base da atmosfera (*Bottom Of Atmosphere* – BOA).

Para a obtenção do Índice de Vegetação por Diferença Normalizada – NDVI (Equação 3) de acordo com o método proposto por Rouse *et al*. (1973).

$$NDVI = \frac{\rho NIR - \rho Red}{\rho NIR + \rho Red} \quad (3)$$

Sendo ρNIR a reflectância da banda do infravermelho próximo e ρRed refletância da banda do vermelho do espectro visível, correspondendo as bandas 8 e 4 do Senstinel-2, respectivamente. O NDVI é um índice biofísico que apresenta grande sensibilidade para expressar os níveis de atividade fotossintética da vegetação, seus valores variam entre -1 e +1, par fins de análise deste estudo utilizou-se a classificação proposta por Melo *et al.* (2019) para esse índice, conforme mostra a Tabela 4.

Tabela 4 - Valores de referência para classificação o NDVI.

(continua)

INTERVALOS	CLASSES	CARACTERÍSTICAS
-1,00 -| -0,00	1	Correspondem a vegetação morta e/ou alvos não vegetais tais com corpos d'água e nuvens.

Tabela 4 - Valores de referência para classificação o NDVI.

(continuação)

0,00 -| 0,33	2	Áreas com vegetação rala, a exemplo da vegetação rasteira e de pastagens, formadas por vegetação com estresse hídrico.
0,33 -| 0,66	3	Áreas com vegetação esparsa, sendo exemplos as áreas de regeneração ou sucessão secundárias, moderadamente sadia.
0,66 -| 1,00	4	Áreas de vegetação mais dens, sadia e com alta produtividade fotossintética.

Fonte: Adaptado de Melo *et al.* (2019), Mkhabela et al. (2011), Rafique et al. (2016), e Lopes et al. (2020).

Após a obtenção do NDVI foram determinadas 4 (quatro) classes com base na literatura e nos valores máximos e mínimos obtidos na pesquisa, tendo uma melhor visualização do índice biofísico no período estudado, assim com a padronização das cores (RGB) das referidas classes, a fim de facilitar a comparação dos resultados entre os meses (Tabela 5). O processo de classificação e elaboração cartográfica foi realizada com uso do *software* QGIS versão 3.22.9 - Białowieża (QGIS, 2022).

Tabela 5 - Padronização das classes e paleta de cores.

CLASSES	INTERVALOS	PADRÃO DE COR (RGB)
1	-0,40 -| 0,30	(255, 67, 61)
2	0,30 -| 0,33	(252, 255, 157)
3	0,33 -| 0,66	(61, 167, 90)
4	0,66 -| 0,90	(0, 98, 38)

Fonte: Elaborado pelo autor.

Para a obtenção do Índice de Água por Diferença Normalizada – NDWI, foi utilizado a Equação 4, conforme proposto por Gao (1996).

$$NDWI = \frac{\rho\text{Green} - \rho NIR}{\rho Green + \rho NIR} \quad (4)$$

Onde ρNIR corresponde à refletância da banda do infravermelho próximo (banda 8 do Sentinel-2 e ρGreen a refletância da banda verde (banda 3 do Sentinel-2). O NDWI é amplamente utilizado para mensurar a quantidade de água presente da estrutura fisiológica

vegetal, figurando como uma excelente ferramenta para determinar as necessidades hídricas nos vegetais, é também um índice adimensional e varia de -1 a 1 par fins de análise deste estudo utilizou-se classificações adaptadas de Gao (1996); Oliveira et al., (2010); Lopes et al., (2020); Sun et al., (2013); e Melo *et al.*, (2019), conforme mostra a Tabela 6.

Tabela 6 - Valores de referência para classificação do NDWI.

INTERVALOS	CLASSES	CARACTERÍSTICAS
-1,00 -| -0,56	1	Correspondem a ausência de vegetação ou vegetação morta.
-0,56 -| 0,00	2	Áreas com vegetação seca.
0,00 -| 0,50	3	Correspondem a vegetação verde com boa quantitate de água em sua estrutura vegetal.
0,50 -| 1,00	4	Correspondem a vegetação verde com excelente quantitate de água em sua estrutura vegetal.

Fonte: Adaptado de Gao (1996), Oliveira et al. (2010), Lopes et al. (2020), Sun et al. (2013), e Melo et al. (2019).

Por fim, após a obtenção do NDWI foram determinas 8 (oito) classes com base na literatura e nos valores máximos e mínimos obtidos na pesquisa, bem com a padronização das cores (RGB) das referidas classes, facilitando a comparação dos resultados entre os meses (Tabela 7). O processo de classificação e elaboração cartográfica foi realizada com uso do software QGIS versão 3.22.9 - Białowieża (QGIS, 2022).

Tabela 7 - Padronização das classes e paleta de cores.

CLASSES	INTERVALOS	PADRÃO DE COR (RGB)
1	-0,40 -| -0,22	(122, 4, 3)
2	-0,22 -| -0,05	(217, 56, 7)
3	-0,05 -| 0,13	(254, 153, 44)
4	0,13 -| 0,30	(211, 232, 53)
5	0,30 -| 0,48	(100, 253, 106)
6	0,48 -| 0,65	(27, 208, 213)
7	0,65 -| 0,83	(71, 119, 240)
8	0,83 -| 1,00	(54, 66, 226)

Fonte: Elaborado pelo autor.

4.4.4 Estimativa da ETa

Para a estimativa da Evapotranspiração Real (ETa) foi utilizado o modelo SAFER - *Simple Algorithm for Evapotranspiration Retrieving (*Algoritmo Simples para Recuperação da Evapotranspiração), proposto por Texeira (2010). O modelo SAFER é uma adaptação da equação de Penman-Monteith para determinar a ETa de forma rápida e em larga escala, utilizando dados de albedo de superfície, NDVI e temperatura de superfície, obtidos sequencialmente a partir das equações que relacionaram dados dos sensores Sentinel-2 e dados meteorológicos.

O algoritmo SAFER não utiliza dados de pixels âncoras (quentes e frio) como nos modelos SEBAL (BASTIAANSSEN et al., 1998) e METRIC, que utiliza dados orbitais de sensores que possuem bandas termais, determina a temperatura de superfície por meio dos dados radiométricos (imagens multiespectrais) e dados agrometeorológicos (Texeira et al., 2017).

Para a aplicação do algoritmo SAFER foi utilizado o pacote "Agriwater" através do Software "R", desenvolvido por Ferreira Silva et al., (2019), utilizando-se como dados de entrada uma máscara no formato shapefile recobrindo a área de interesse, conjuntos de dados de evapotranspiração de referência (ET_0), radiação global (R_G), temperatura média do ar (T_A), e a refletâncias do satélite Sentinel-2.

As equações utilizadas na execução do algoritmo SAFER no R, para estimar a ETa, são baseadas na modelagem da razão $\frac{ET_a}{ET_0}$, sendo que tal proporção foi calculada de acordo com as equações descritas abaixo (Equação 5) (Ferreira Silva et al., 2019; Texeira, 2010).

$$\frac{ET_a}{ET_0} = exp\left[a + b\left(\frac{T_0}{\alpha_0 NDVI}\right)\right] \quad (5)$$

Onde ET_a é a evapotranspiração real, ET_0 é a evapotranspiração de referência, α_0 é o albedo da superfície, T_0 é a temperatura da superfície e $NDVI$ é o índice de vegetação por diferença normalizado, calculado pela razão da diferença entre as refletividades planetárias do infravermelho próximo (ρnir) e vermelho (ρred) e sua soma.

A temperatura de superfície T_0 foi obtida através da Equação de Stefan-Boltzmann, por meio da Equação 6:

$$T_0 = \sqrt[4]{\frac{\epsilon_A \sigma T_A + a_L \tau_W}{\epsilon_S \sigma}} \quad (6)$$

Onde, ϵ_A e ϵ_S são as emissividades atmosféricas e de superfície, σ é a constante de Stefan-Boltzmann, T_A é a temperatura média do ar, τ_W é a transmissividade atmosférica de ondas curtas e a_L é o coeficiente de regressão.

A evapotranspiração real ETa (mm dia^{-1}) foi obtida de acordo com a Equação 7:

$$ET_a = ET_0 \left(\frac{ET_a}{ET_0} \right) \quad (7)$$

Para o cálculo do balanço de radiação, utilizou-se a Equação 8:

$$R_N = H + LE + G \quad (8)$$

Onde R_N é a radiação líquida, G é o fluxo de calor no solo, LE é o fluxo de calor latente e H o fluxo de calor sensível. A radiação líquida R_N (W m^{-2} sr^{-1} μ m^{-1}) foi obtida pela equação de Slob de acordo com a Equação 9:

$$R_N = (1 - \alpha_0)R_G - \alpha_L \tau_{sw} \quad (9)$$

O fluxo de calor latente LE (MJ dia^{-1}) foi obtido por meio da Equação 10:

$$LE = ET_a \times 2.45 \quad (10)$$

O fluxo de calor no solo G(MJ dia^{-1}) foi estimado através de sua relação com a radiação líquida por meio da Equação 11:

$$G = R_N(3.98\ exp(-31.89\alpha_0)) \quad (11)$$

O fluxo de calor sensível H(MJ dia^{-1}) foi obtido como resíduo do balanço de energia utilizando-se da Equação 12:

$$H = R_N - LE - G \quad (12)$$

Para a aplicação do pacote Agriwater no "R" foi criado uma máscara no formato shapefile que recobriu toda a área a bacia hidrográfica do Rio Sorocabuçu, o polígono retangular utilizado com as seguintes coordenadas UTM nos vértices: Zona 23, N 7.399.714 m, E 260.921 m; N 7.400.435 m, E 294.388 m; N 7.344.753 m, E 262.075 m; N 7.345.186 m, E 295.398.

Os dados meteorológicos de evapotranspiração de referência (ET_0), radiação global (RG) e temperatura média do ar (T_A) foram obtidas por meio site *Copernicus Climate Data Store* – CDS, oriundo do sistema ERA5-Land, que fornece gratuitamente dados climáticos desde 1950 até o presente momento. O ERA5-Land possui uma cobertura global, com resolução temporal de 1 a 1 hora, resolução espacial nativa de 0,1° x 0,1° (9 km), e com 4 níveis de coleta em superfície, na camada 1: 0 - 7 cm, camada 2: 7 -28 cm, camada 3: 28-100 cm, camada 4: 100-289 com demais parâmetros definidos a 2 m sobre a superfície (CDS, 2019).

Para a aquisição dos dados meteorológicos sobre a área de estudo foi criado uma grade de pontos regulares no formato shape file abrangida pelos limites do polígono regular acima citado, em que foram igualmente espacializado a cada 1,5 km, perfazendo-se um total de 911 pontos amostrais sobre a região da bacia hidrográfica do Rio Sorocabuçu.

Os dados de refletâncias do satélite Sentinel-2, foram obtidos por meio dos dados descritos na Tabela da sessão 5.2. O pacote Agriwater foi executado por meio de Software "R" por meio da interface RStudio, após o processamento e estimativa da ETa os resultados foram reclassificados em 8 classes para melhor análise e visualização dos mapas, bem como padronizados em cores RGB conforme mostra a Tabela 8. O processo de reclassificação e elaboração temática dos mapas foram realizadas por meio do *software* livre QGIS versão 3.22.9 - Białowieża (QGIS, 2022).

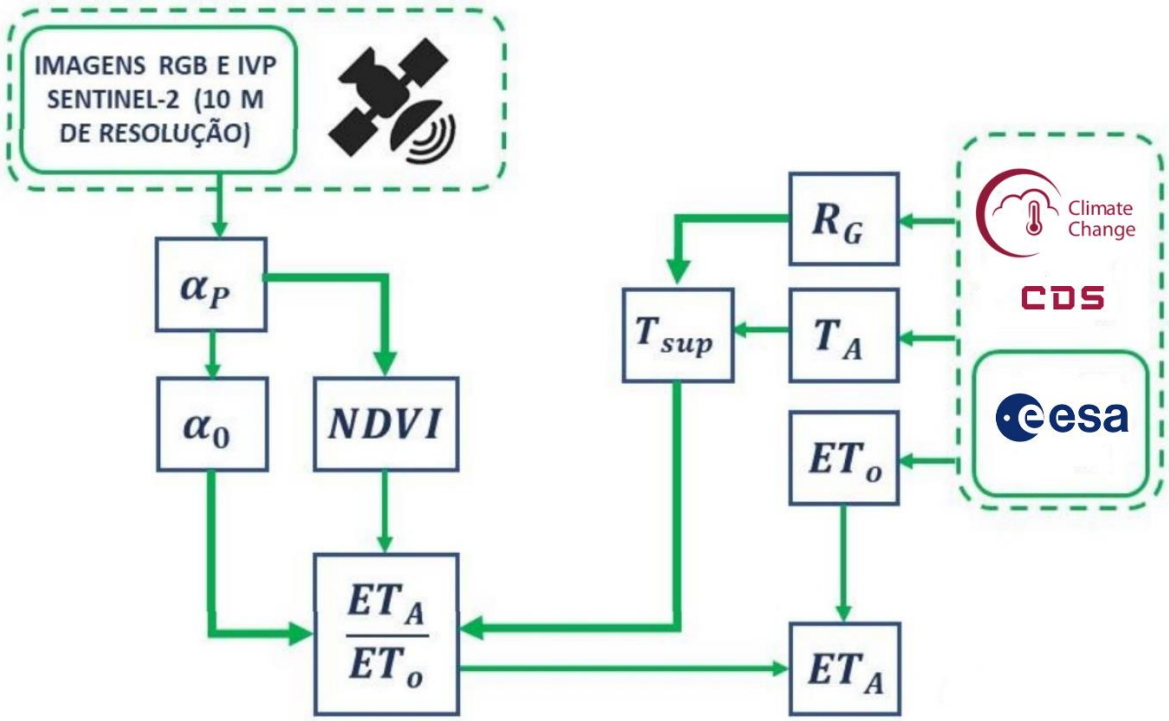
Tabela 8. Padronização das classes e paleta de cores utilizadas nos mapas de ETa.

CLASSES	**INTERVALOS**	**PADRÃO DE COR (RGB)**
1	0,00 -| 1,25	(208, 47, 5)
2	1,25 -| 2,50	(255, 125, 113)
3	2,50 -| 3,75	(212, 223, 59)
4	3,75 -| 5,00	(83, 245, 125)
5	5,00 -| 6,25	(41, 184, 235)
6	6,25 -| 7,50	(64, 97, 224)
7	7,50 -| 8,75	(37, 53, 213)
8	8,75 -| 10,0	(10, 10, 202)

Fonte: Elaborado pelo autor.

A Figura 3 resume a aplicação do algoritmo SAFER e o método de Monteith por meio do pacote Agriwater, que utiliza dados de reflectâncias das cenas dos sensores Sentinel-2 juntamente com dados meteorológicos (R_G, ET_0 e T_A), nesse estudo adquirido por meio de ERA5-Land, mostrando de forma resumida os passos e entrada de dados necessários para subsidiar ao algoritmo os dados necessários para a aplicação da metodologia. Obtendo-se como produto a modelagem em macro escala do balanço de radiação (R_N), fração evapotranspirativa e estimativa da ETa (FERREIRA SILVA et al., 2019).

Figura 3 - Fluxograma de descrição da metodologia aplicada.



Fonte: Adaptado de Ferreira Silva et al. (2019) e Magnoni (2021).

4.4.4.1 Estimativa da contribuição hídrica por classe de uso e ocupação da terra

Após a estimativa da ETa, foi realizado o cálculo para a estimativa de contribuição hídrica para a atmosfera por cada classe de uso e ocupação da terra na BH do Rio Sorocabuçu.

Foram utilizados os 12 (doze) produtos das imagens Raster de ETa geradas por meio do pacote Agriwater e, posteriormente, por meio da ferramenta Estatísticas Zonais do GRASS no QGIS, realizou-se o somatório dos valores de todos os pixels de cada imagem e para cada classe de uso e ocupação da terra, gerando uma estimativa total de água transferido para a atmosfera no ano de 2020, por meio da evapotranspiração na BH do rio Sorocabuçu.

4.5 Análise estatística dos dados

O método de análise multivariada propicia a redução de dados ou simplificação estrutural, ordenação e agrupamento, dependência entre variáveis, predição e teste de hipóteses (JOHNSON e WICHERN 2007).

Para estudar a relação entre as variáveis NDVI, NDWI, SAVI, IAF e uso da terra com a ETa foi utilizado uma análise multivariada (JEREZ, ALVES e TACHIBANA 2019). A

Equação 13 traz o modelo usado para a análise da regressão múltipla entre os parâmetros estudados.

$$ET_a = \{(a_1 + b_1 * NDVI) + (a_2 + b_2 * NDWI) + (a_3 + b_3 * SAVI) + (a_4 + b_4 * IAF) + (a_5 + b_5 * Uso)\} \quad (13)$$

Em que, ETa é a evapotranspiração real (mm.d-1); a e b são os coeficientes a serem estimados pelo método dos mínimos quadrados (coeficiente linear e angular, respectivamente), NDVI, NDWI SAVI e IAF são os índices de vegetação e o Uso são as classes de manejos de uso da terra presentes na bacia hidrográfica do rio Sorocabuçu.

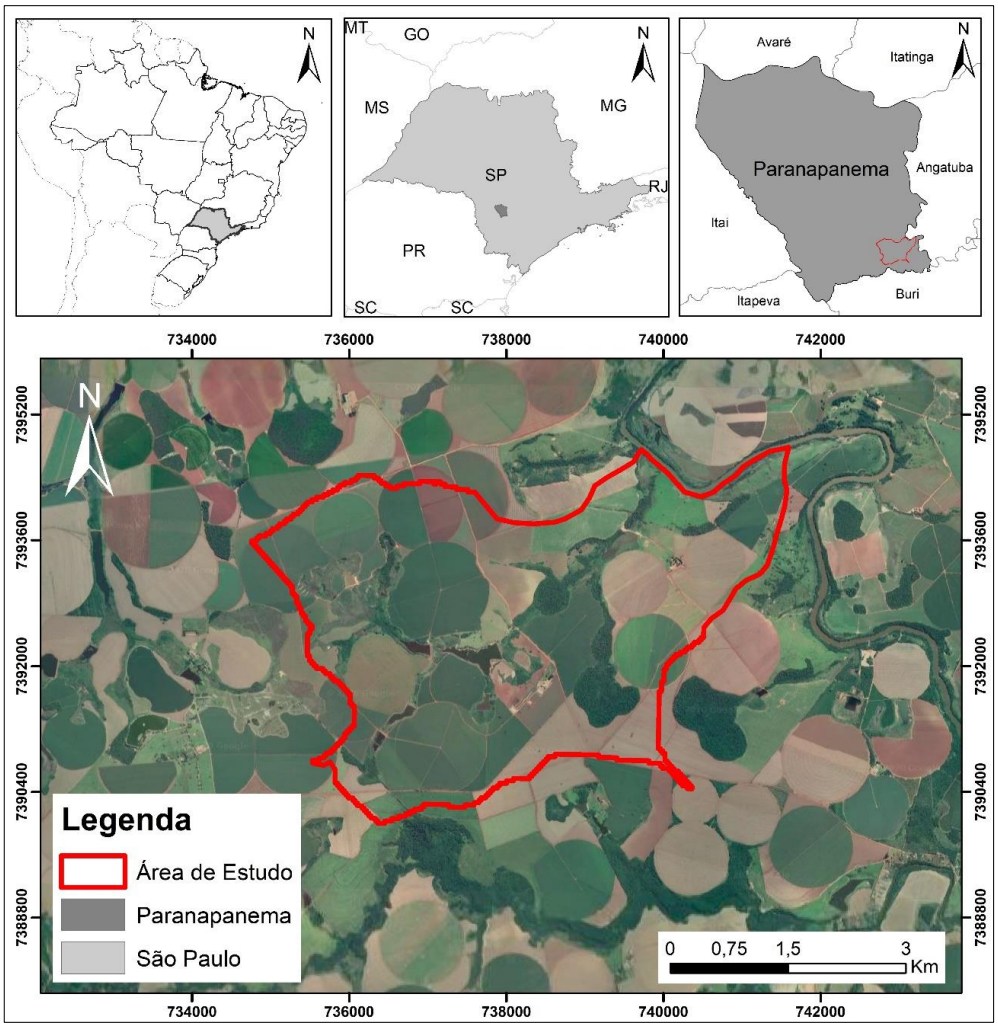
Na análise de regressão linear com múltiplas variáveis, verifica-se a relação entre as variáveis, sendo uma delas considerada dependente e as outras independentes, onde o objetivo é expressar uma variável dependente em termos das variáveis independentes, por meio de um modelo matemático. Essa análise é utilizada para estudar conjuntos de variáveis que se supõem ter uma relação de causa e efeito, permitindo a identificação do grau de influência das variáveis independente sobre a variável dependente (Yamamoto, 2020).

A análise estatística foi realizada por meio do software livre R versão 4.1.1 (R Core Team, 2021) e o software RStudio (RStudio Team, 2022) para as análises estatística dos dados e produção dos gráficos, onde analisou-se o nível de influência dos índices biofísicos e os usos da terra (variáveis independentes) na ETa (variável dependente) por meio do coeficiente de determinação (R^2). Além da utilização dos pacotes: "readxl" (Wickham e Bryan, 2019), para a leitura dos dados planilhados no formato .xlsx; e "ggplot2" (Wickham,2016), utilizado para a produção dos gráficos de interação da matriz de correlação. Para a extração dos dados contidos nos pixels foram utilizados os softwares SIG's ArcGis 10.6 e QGIS versão 3.22.9 - Białowieża (QGIS, 2022).

4.6 Metodologia para a estimativa do NDVI e NDWI por meio de dados SAR

Para fins de proposição e teste de uma metodologia visando a estimativa do NDWI e NDVI por meio de dados SAR, foi utilizado uma área de estudo corresponde a uma bacia hidrográfica localizado na região sudoeste do Estado de São Paulo (Figura 4).

Figura 4 - Localização da sub-bacia hidrográfica no município de Paranapanema-SP.



Fonte: Elaborado pelo autor.

A área está localizada entre as coordenadas UTM 7388800 a 7395200 m E, e 734000 a 742000 m S. Abrangendo uma área aproximada de 19,4 km², com clima regional do tipo Cfa - Clima subtropical - quente de inverno seco, com temperaturas médias anuais de 21,0 °C, e precipitação média anual de 1.407 mm (CEPAGRI, 2020).

Os solos predominantes são os Latossolos Distroférricos, sobre o qual desenvolvem, predominantemente atividades agrícolas intensiva providos de pivôs centrais para irrigação (Ranzini et al., 2014). Quanto a vegetação original da região, predominaram as Florestas estacional semidecidual, bem como vegetação de Cerrado e vegetação de várzea herbácea ao longo dos canais de drenagem (Cielo-Filho et al., 2009).

4.6.1 Aquisição e processamento de dados

Foram utilizados dados dos sensores Sentinel-1 e Sentinel-2 disponibilizados de forma gratuita pela Agência Espacial Européia (ESA), obtidos no portal *Scientific Data Hub*. As missões são compostas por uma constelação de dois sensores cada, sendo que o Sentinel-1A foi lançado pela ESA em abril de 2014, e o Sentinel-1B lançado em abril de 2016, cada sensor possui um ciclo de 12 dias, que quando combinada, possibilita uma revisada de 6 dias. Já o sensor Sentinel-2A foi lançado em junho 2015, e o Sentinel-2B foi lançado em março de 2017, possuem ciclos de 10 dias, quando combinado, possibilita uma revisada de 5 dias (ESA, 2020).

Ambos os satélites Sentinel-1 são equipados com um sensor do tipo Radar de Abertura Sintética *(Synthetic Aperture Radar* – SAR) que operam na banda C da faixa espectral de micro-ondas (frequência de 5,405 GHz), com suporte para obtenção de dados em polarização única (Vertical transmitida e Vertical recebida - VV, Horizontal transmitida e Horizontal recebida-HH) e polarização dupla (VV + VH ou HH + HV). Nesse estudo, foram obtidos dados no modo IW (*Interferometric Wide Swath Mode*) com polarização dupla (VV e VH), derivados do produto Nível 1 na forma GRD (*Ground Range Detected*), com resolução espacial de 5x20 metros (NAVARRO et al., 2016; ESA; 2020).

Os sensores da constelação Sentinel-2 são equipados por um Instrumento Multiespectral (*MultiSpectral Instrument* - MSI) que realiza a captura de dados em 13 bandas espectrais no intervalo do visível, infravermelho próximo (*Visible and Near-Infra-Red* - VNIR) e infravermelho de ondas curtas (*Short Wave Infra-Red* -SWIR), sendo que quatro bandas apresentam resolução espacial em 10 metros (B2, B3, B4 e B8), seis bandas com 20 metros (B5, B6, B7, B8A, B11 e B12) e três bandas com 60 metros (B1, B9 e B10), com resolução radiométrica de 12 bits (Filgueiras et al., 2019).

Para desenvolvimento deste estudo, buscou-se cenas imageadas em datas mais próximas possíveis e levando em consideração a ausência de nuvens na área de estudo para dados da constelação Sentinel-2. Nesse caso, obtiveram-se as combinações para os dias 14/02/2019, 12/10/2019 e 27/05/2020 para o Sentinel-1, e 09/02/2019, 12/10/2019 e 29/05/2020 e para o Sentinel-2.

O processamento de dados foi realizado no software SNAP (versão 8.0.0) seguindo a metodologia descrita por Braun (2020). Os dados do Sentinel-1 foram submetidos a uma calibração radiométrica, onde os valores das imagens são diretamente relacionados ao retroespalhamento da superfície (KAPLAN & AVDAN, 2018). Em seguida, foi aplicado o *Speckle Filtering* levando em conta o método de Lee et al. (2009) para remoção de ruído

pontilhado, procedimento necessário para não causar interferência na compreensão das respostas de retroespalhamento das feições da superfície (FILGUEIRAS et al., 2019). Posteriormente, os dados foram convertidos em escala de decibéis (dB), e, por fim, foi realizada a correção de efeitos geométricos dos dados de SAR do Sentinel-1 por meio do *Range Doppler Terrain Correction*, levando em consideração o modelo digital de elevação de 30 m. Em seguida, foram obtidas diversas variáveis secundárias encontradas na literatura (VAR1, VAR2, VAR3, VAR6, VAR7, VAR8, VAR9 e VAR10) bem como propostas neste estudo (VAR4 e VAR5), conforme apresentado na Tabela 9.

Tabela 9 - Polarizações VV, VH e variáveis secundárias utilizadas para implementação nos modelos de regressão.

Variáveis	Descrição	Autor
VV	Polarização Vertical-Vertical	-
VH	Polarização Vertical-Horizontal	-
VAR1	VH + VV	Han et al. (2019)
VAR2	VH - VV	Han et al. (2019)
VAR3	VH / VV	Vavlas et al. (2020)
VAR4	VH*VV	Proposta
VAR5	VH*VV / VH + VV	Proposta
VAR6	$(VH^2 - VV^2) / (VH^2 + VV^2)$	Han et al. (2019)
VAR7	Radar Vegetation Index Adapted (RVI)	Holtgrave et al. (2020)
VAR8	Razão Normalizada entre as polarizações (NRPB)	Filgueiras et al. (2019)
VAR9	Dual Polarization SAR Vegetation Index (DPSVI)	Periasamy (2018)
VAR10	Radar Vegetation Index for Sentinel-1 SAR (RVI4S1)	Mandal et al. (2020)

Fonte: Elaborado pelo autor.

Para os dados do Sentinel-2, foi realizada correção atmosférica e, em seguida, obteve-se o Índice de Vegetação com diferença Normalizada – NDVI, apresentado na Equação 14, e o Índice de Água com Diferença Normalizada-NDWI, ilustrado na Equação 15, conforme metodologia descrita por Rouse et al. (1973) e Gao (1996), respectivamente.

$$NDVI = \frac{\rho NIR - \rho Red}{\rho NIR + \rho Red} \quad (14)$$

$$NDWI = \frac{\rho\text{Green} - \rho NIR}{\rho Green + \rho NIR} \quad (15)$$

Onde ρNIR corresponde à refletância da banda do infravermelho próximo (banda 8 do Sentinel-2); ρRed corresponde a refletância da banda do vermelho (banda 4 do Sentinel-2) e $\rho Green$ a refletância da banda verde (banda 3 do Sentinel-2).

O NDVI e NDWI são índices adimensionais que variam de -1,00 a 1,00. Para o primeiro índice, os valores entre -1,00 a 0,00 correspondem a vegetação morta e/ou alvos não vegetais tais com corpos d'água e nuvens, valores > 0,00 a 0,33 corresponde a vegetação com baixa atividade fotossintética ou com estresse hídrico, valores de > 0,33 a 1,00 refere-se a vegetação com moderada a alta produtividade fotossintética (Mkhabela et al., 2011). Para o segundo índice, valores entre -1,00 a -0,056 refere-se áreas com ausência de vegetação, enquanto valores > -0,056 a 0,00 refere-se à vegetação seca, e valores > 0,00 a 1,00 correspondem a vegetação verde (Gao, 1996; Oliveira et al., 2010; Lopes et al., 2020).

Os dados obtidos foram reamostrado para a resolução espacial de 10 metros pelo método bilinear, onde o cálculo do novo valor do pixel é realizado pelo peso dos quatro pixels circundantes (ESA, 2021). Posteriormente, convertidos do formato matricial para vetor tipo ponto afim de extrair as informações dos pixels para a implementação dos algoritmos de regressão.

4.6.2 Índices de vegetação por modelo preditivos

Nesse estudo, foram aplicados quatro modelos preditivos de regressão para a determinação dos índices de vegetação a partir de dados de retroespalhamento do Sentinel-1 como variáveis independentes, e os índices NDVI e NDWI obtidos por meio do Sentinel-2 como variáveis dependentes. A modelagem de índices de vegetação a partir de dados de SAR do Sentinel-1 e dados ópticos do Sentinel-2, foi realizada pelos métodos de Regressão Linear (RL) por Mínimos Quadrados Parciais (*Partial Least Squares* - PLS), Máquina de Vetores de Suporte (Support Vector Machine - SVM), Floresta Aleatória (Random Forest - RF), e Redes Neurais Artificiais (Artificial Neural Networks - ANN).

A RL é o método estatístico mais comum utilizado em ciências da terra. Para fins práticos, a função de regressão linear PLS pode ser aproximada utilizando uma função polinomial representada por um modelo composto por N variáveis x correlacionáveis com y que pode ser expressa pela Equação 16.

$$y = b_0 + b_1 x_1 + b_2 x_2 + b_N x_N + e_y \quad (16)$$

Onde y representa a variável dependente ou resposta, b_i $(0,1,2..,N)$ os coeficientes de regressão que descrevem o efeito de cada termo calculado, x a variável independente ou explicativa, N o número de observações e e_y o ruído associado.

O algoritmo SVM é baseado na teoria de aprendizagem estatística (Cortes e Vapnink, 1995). O método é implementado tanto para classificação quanto para regressão. Para solução de problemas que envolvam regressão, o método SVM constrói um hiperplano que se encontra para tantos pontos de dados quanto possível, de forma a obter um hiperplano ideal, ou seja um hiperplano de margem máxima. Com a construção do hiperplano ideal é possível prever novos dados (Karatzoglou et al., 2006).

O algoritmo RF é um método de aprendizagem de máquina baseado em árvore de decisão que utiliza um treinamento supervisionado não paramétrico para a classificação e regressão (Breiman, 2001). As árvores de decisão são constituídas por ramos, nós e folhas, onde o nó raiz corresponde o input, os ramos representam parte da árvore responsável por decisões e cenários, enquanto as folhas correspondem o nó final ou output. Em regressão, o RF particiona recursivamente o espaço de observação com base nos atributos de dados levando em consideração um critério de divisão em cada nó com base no critério de erro de mínimo quadrado, e executa um preditor em nós de folhas (Santos et al., 2017).

As ANN correspondem a sistemas não lineares constituídos por processadores simples denominados de neurônios artificiais interconectados de forma ponderada. Em suma, uma ANN é composta por uma camada de entrada, uma ou mais camadas ocultas, e uma camada de saída (Haykin, 1994). O conhecimento é adquirido pela rede por meio do processo de aprendizagem que ocorre com as interações entre os neurônios por meio de pesos sinápticos. A capacidade de aprendizagem adaptativa faz da ANN um método muito empregado em problemas de classificação e regressão (Lee et al., 2020).

A implementação e avaliação da qualidade dos modelos foi realizada em linguagem de programação R. Os pacotes utilizados foram: *readxl* para leitura de dados (Wickham e Bryan, 2019), *e1071* para a implementação do SVM (Meyer et al., 2020), *randomForest* para a implementação do RF (Liaw e Wiener, 2002) e *neuralnet* para implementação do ANN (Fritsch et al., 2019). Ressalta-se que na etapa de construção dos modelos as variáveis primárias (VH e VV) e variáveis secundárias (VAR01 a VAR10) que não apresentaram correlação com nível de significância com $p < 0,05$ foram incluídas dos modelos e consequente mente descartadas.

4.6.3 Análise de desempenho dos modelos

Para avaliar a qualidade do ajuste e a generalização dos modelos, foram utilizados: o coeficiente de determinação (R^2), Erro Médio Absoluto (MAE), Erro Médio Quadrático (MSE) e Raiz Quadrática do Erro Médio Absoluto (RMSE), por meio do método de *Cross-validation* com dez dobras. Para isso, os dados foram divididos de forma aleatória em 80% para treinamento e o restante para validação do modelo. Nessa etapa, o método de *Cross-validation* utiliza quatro grupos de dados para treinamento e um para teste, de forma que esse processo é repetido até que cada um dos dez grupos seja utilizado como conjunto de teste (James et al., 2013). As Equações 17, 18, 19 e 20 refere-se ao R^2, MAE, MSE e RMSE.

$$R^2 = \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y}_i)^2} \tag{17}$$

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i| \tag{18}$$

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \tag{19}$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \tag{20}$$

Onde y_i refere-se os valores observados em cada ponto amostral, $\bar{y}_i$ o valor médio das observações e $\hat{y}_i$ o valor predito pelos modelos de regressão.

E por fim, foi realizado a análise da variância (ANOVA) e teste *post-hoc* de comparação múltiplas de Bonferroni com nível de significância de 0,05% para comparação entre os modelos de regressão visando identificar o modelo que apresentou o melhor desempenho. Realizando múltiplas análises estatísticas ao mesmo tempo, o teste de Bonferroni utilizando esta correção pós-hoc de comparação múltipla, indicado para análises que contemplam grande quantidade de dados, como a situação em questão.

5 RESULTADOS E DISCUSSÃO

5.1 Estimativa do NDVI e NDWI por meio de dados SAR

A Tabela 10 apresenta a estatística descritiva do conjunto de dados de treinamento e teste utilizado para as variáveis NDVI, NDWI e variáveis que apresentaram correlação significativa nos modelos propostos, tais como VV, VH, VAR4 e VAR5. Vale ressaltar quer as demais variáveis secundárias propostas por Han et al. (2019), Vavlas et al. (2020), Holtgrave et al. (2020), Filgueiras et al. (2019), Periasamy (2018) e Mandal et al. (2020), não foram utilizadas, uma vez que apresentaram baixo nível de significância quando implementadas nos modelos utilizados.

Tabela 10 - Estatística descritiva do conjunto de dados de treinamento e teste.

		Treinamento					Teste				
	Variáveis	**Min**	**Max**	**Med**	**STD**	**CV**	**Min**	**Max**	**Med**	**STD**	**CV**
02/2019	**NDVI**	-0,58	0,93	0,56	0,29	0,52	-0,52	0,93	0,56	0,28	0,51
	NDWI	-0,60	0,79	0,29	0,31	1,06	-0,59	0,78	0,29	0,31	1,07
	VV	-21,62	1,77	-10,99	2,18	-0,20	-21,18	-0,03	-11,00	2,17	-0,20
	VH	-27,08	-3,42	-17,45	2,63	-0,15	-26,83	-3,48	-17,45	2,62	-0,15
	VAR4	-11,45	540,37	196,72	67,38	0,34	0,12	531,92	196,78	67,08	0,34
	VAR5	-11,59	2,43	-6,73	1,18	-0,18	-11,49	-0,03	-6,73	1,18	-0,17
10/2019	**NDVI**	-0,65	0,94	0,43	0,29	0,67	-0,62	0,94	0,43	0,29	0,67
	NDWI	-0,68	0,78	0,17	0,28	1,62	-0,53	0,77	0,18	0,28	1,61
	VV	-23,41	1,84	-11,40	2,64	-0,23	-23,18	0,11	-11,38	2,62	-0,23
	VH	-27,84	-2,95	-18,32	2,92	-0,16	-27,52	-5,61	-18,30	2,91	-0,16
	VAR4	-11,90	625,91	215,58	81,32	0,38	-0,63	617,45	215,03	80,73	0,38
	VAR5	-12,48	2,56	-7,00	1,40	-0,20	-12,37	0,11	-6,99	1,39	-0,20
05/2020	**NDVI**	-0,64	0,94	0,56	0,26	0,46	-0,51	0,93	0,56	0,25	0,45
	NDWI	-0,70	0,82	0,32	0,28	0,86	-0,54	0,80	0,33	0,28	0,85
	VV	-22,40	2,61	-11,55	2,33	-0,20	-22,20	-0,92	-11,54	2,32	-0,20
	VH	-27,39	-3,06	-18,26	2,49	-0,14	-27,33	-3,40	-18,23	2,48	-0,14
	VAR4	-14,02	576,68	215,99	70,54	0,33	3,14	567,73	215,26	69,97	0,33
	VAR5	-12,06	5,08	-7,06	1,22	-0,17	-11,88	-0,73	-7,04	1,21	-0,17

Legenda: Min: mínimo; Max: máximo; Med: média, STD: desvio padrão; e CV: coeficiente de variação.
Fonte: Elaborado pelo autor.

Para o NDVI, no mês de fevereiro de 2019, os dados de treinamento e teste apresentaram valores máximos (0,93) e médios (0,56) iguais, com valores mínimos (-0,58 e -0,52), desvio padrão STD (0,29 e 0,28), e coeficiente de variação CV (0,52 e 0,51), próximos para o conjunto de treinamento e teste. Comportamento semelhante foi observado para o mês de outubro de 2019, pois apresentaram valores de STD e CV iguais e valores de mínimos, máximos e médios próximos. Do mesmo modo para o mês de maio de 2020, com valor igual para a média (0,56), e valores próximos para o máximo (0,94-0,93), STD (0,26-0,25) e CV (0,46-0,45), com exceção para os valores mínimos no qual foi observado a maior amplitude (-0,64 e -0,51).

Em relação ao NDWI, para o mês de fevereiro de 2019, observou-se valores mínimos (-0,60 e -0,59), máximos (0,79 e 0,78) e CV de (1,06 e 1,07) próximos para o conjunto de treinamento e teste, enquanto os valores de média (0,29) e STD (0,31) foram iguais. Comportamento semelhante foi observado para o mês de outubro de 2019, com valores de STD (0,28) iguais, e máximo (0,78 e 0,77), médio (0,17 e 0,18) e CV (0,62 e 0,61) próximos, e valor mínimo apresentando maior amplitude (-0,68 e -0,53). Em maio de 2020 os valores observados foram semelhantes, com valores iguais para o STD e próximos para máximo, médio e CV, com diferença mais expressiva para os valores mínimos (-0,70 e -0,54).

Em relação aos valores de retroespalhamento na polarização VV (em dB), em fevereiro de 2019, observou-se semelhança no conjunto de dados de treinamento e teste para os valores mínimo, médio e STD, com CV (-0,20) iguais e maior diferença para os valores máximos (1,77 e -0,03). Comportamento semelhante foi observado para o mês de outubro de 2019 e maio de 2020, com valores mínimos, médio e STD próximos, CV iguais, e com uma diferença mais expressiva para os valores máximos em outubro de 2019 (1,84 e 0,11) e maio de 2020 (2,61 e -0,92). Enquanto para os valores de retroespalhamento na polarização VH (em dB), observou-se que os valores de CV foram iguais, seguido de valores de mínimo, máximo, média e STD semelhantes entre os dados de treinamento e teste em todos os meses avaliados.

Apesar da variável VAR4 apresentar valores mais expressivos que VAR5 uma vez que foram obtidos a partir de funções algébricas distintas, ambas apresentaram CV iguais para os conjuntos de dados de treinamento e teste (com exceção do mês 02/2019 para VAR5), além de apresentarem média e STD com valores próximos (com exceção para média e STD que apresentaram valores iguais para VAR5 no mês 02/2019). Já os valores mínimos e máximos apresentaram diferenças mais expressivas em todos os meses para os dados de teste e treinamento.

A Tabela 11 apresenta o desempenho dos métodos de regressão utilizados na previsão do NDVI e NDWI para cada período avaliado. Esses modelos foram construídos a partir dos

índices obtidos com dados do Sentinel-2 (NDVI e NDWI) e correlacionados com os coeficientes de retroespalhamento obtidos com dados de SAR do Sentinel-1, sendo as polarizações VV e VH, bem como o produto VAR4 e VAR5 respectivamente.

Tabela 11 - Métricas de desempenho dos modelos de regressão.

		NDVI				NDWI			
	Modelos	**RL**	**SVM**	**RF**	**ANN**	**RL**	**SVM**	**RF**	**ANN**
02/2019	**R^2**	0,6199	0,6655	0,6454	0,6493	0,5745	0,6375	0,5830	0,6306
	MAE	0,0788	0,1681	0,0649	0,0634	0,1762	0,3113	0,1326	0,1418
	MSE	0,0161	0,0685	0,0138	0,0136	0,0454	0,1559	0,0328	0,0337
	RMSE	0,1268	0,2618	0,1174	0,1168	0,2130	0,3949	0,1811	0,1835
10/2019	**R^2**	0,8205	0,8543	0,8075	0,8203	0,7969	0,8135	0,7841	0,8096
	MAE	0,0662	0,1997	0,0516	0,0518	0,0550	0,0610	0,0543	0,0579
	MSE	0,0113	0,0998	0,0100	0,0093	0,0065	0,0075	0,0070	0,0067
	RMSE	0,1064	0,3159	0,0999	0,0965	0,0804	0,0866	0,0838	0,0818
05/2020	**R^2**	0,6876	0,7034	0,7019	0,7398	0,5901	0,6457	0,6290	0,6670
	MAE	0,1336	0,3207	0,1243	0,1182	0,1328	0,2039	0,1338	0,1284
	MSE	0,0310	0,1898	0,0323	0,0282	0,0286	0,0691	0,0312	0,0274
	RMSE	0,1760	0,4356	0,1797	0,1679	0,1692	0,2628	0,1766	0,1654

Legenda: RL: Regressão Linear; SVM: Support Vector Machine; RF: Random Forest; ANN: Artificial Neural Network.
Fonte: Elaborado pelo autor.

Observa-se que o modelo SVM apresentou o melhor R^2 (0,66) para previsão do NDVI no primeiro período, porém foi penalizado com os piores valores de MAE (0,16), MSE (0,06) e RMSE (0,26). O modelo RL apresentou resultados intermediários, com R^2 de 0,61 e valores de MAE, MSE e RMSE melhores que os observados pelo método SVM. Por outro lado, os modelos RF e ANN obtiveram desempenho semelhante, com leve vantagem do ANN sobre o RF, apresentando um R^2 de 0,64 seguidos dos menores valores de MAE, MSE e RMSE. O mesmo comportamento foi observado para o segundo período, sendo que o método SVM obteve o melhor R^2, porém, o método ANN apresentou melhor desempenho nos demais indicadores. No terceiro e último período, observou-se melhor desempenho geral do modelo ANN, com um R^2 de 0,73 e menores valores de MAE, MSE e RMSE respectivamente.

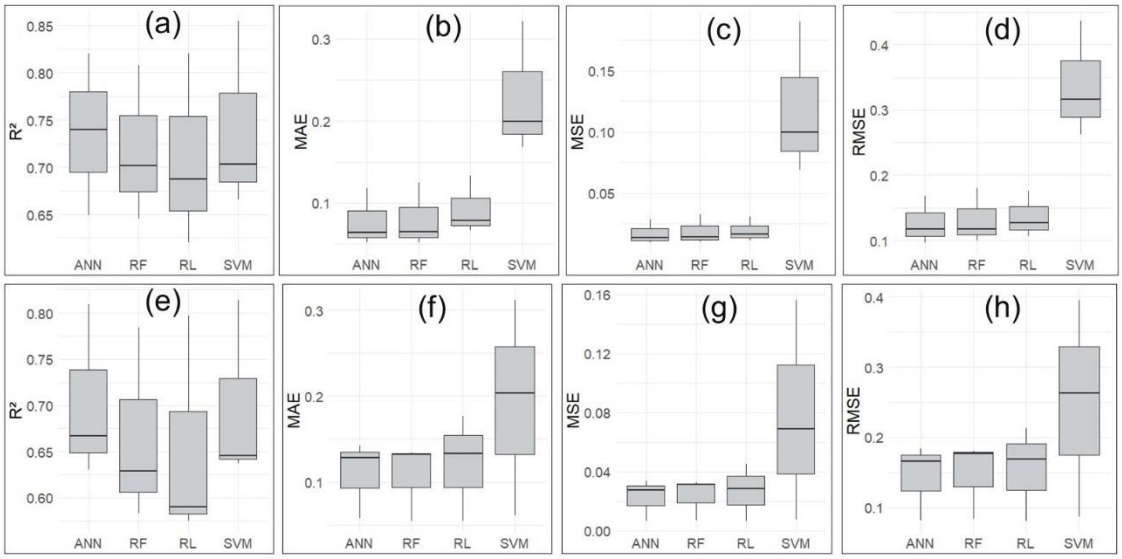
Em relação ao NDWI, os modelos apresentaram comportamento semelhantes aos observado no desempenho do NDVI para os três períodos avaliados. O método SVM apresentou os melhores valores de R^2, porém, sendo prejudicado pelos maiores valores dos indicadores de erro, seguido pelo método RL com desempenho intermediário, e desempenho semelhante entre

o RF e ANN, porém com uma leve vantagem do modelo ANN no que se refere aos valores de MAE, MSE e RMSE.

O modelo ANN apresentou o melhor desempenho geral entre os modelos utilizados levando em consideração os três períodos avaliados. Os valores de R^2 observados foram 0,65, 0,82 e 0,74 para os três períodos avaliados. Em ambos os modelos, os valores obtidos se aproximaram aos observados na literatura. Em uma área sobre diferentes usos do solo no Canadá, Mandal et al. (2020) obtiveram modelos ajustados com R^2 de 0,75 a 0,82 para previsão do NDVI por meio de RL. Já Bai et al. (2020) avaliando o potencial de previsão do NDVI com base em dados de SAR do Sentinel-1 em uma área sob cultivo de milho e trigo na China, obtiveram valores de R^2 de 0,62 com RL. Também por meio de RL, Han et al. (2019) obtiveram modelos ajustados com R^2 de 0,52 para estimar o teor de água (NDWI) em lavouras de trigo na China. Já Filgueiras et al. (2020) obteve valores de R^2 variando entre 0,93 a 0,97 em uma área de pivô central no Brasil utilizando o método de RF.

A Figura 2 apresenta os gráficos de boxplots que ilustram o resultado dos modelos de regressão utilizado e seus respectivos desempenhos na previsão do NDVI e NDWI. Pela análise gráfica é possível observar que, além da alta variabilidade dos coeficientes que são influenciados pelas diferentes condições observados nos meses avaliados.

Figura 5 - Desempenho dos modelos de regressão na previsão do NDVI (a, b, c, d) e NDWI (e, f, g, h).



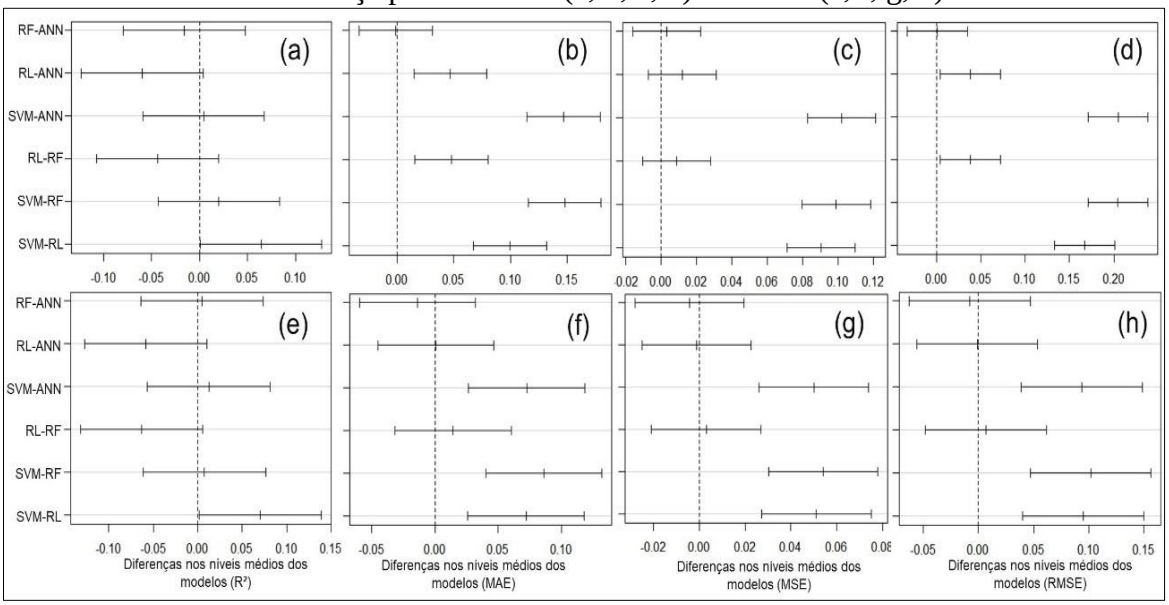
Fonte: Elaborado pelo autor.

O teste ANOVA indicou que o R^2, MAE, MSE e RMSE apresentam *p*-valor < 0,05, o que indica que podemos rejeitar a hipótese nula e concluir que o desempenho apresentado pelos modelos não é igual para a regressão do NDVI e NDWI. Entretanto, ao aplicar o teste de

Bonferroni foi possível observar dentre as métricas obtidas em cada modelo de regressão, apresentando os valores médios considerados iguais, maiores ou menores, o que serviu de base para indicar qual modelo apresentou melhor desempenho.

A Figura 6 mostra a diferença entre os níveis médios dos modelos para o teste de Bonferroni com nível de significância de 0,5%, sendo que as barras que cruzam a linha de origem na vertical indicam *p*-valor > 0,05, mostrando que não existe diferença significativa entre as métricas observadas, enquanto as barras deslocadas a esquerda e/ou a direita que não cruzam a linha de origem apresentam *p*-valor < 0,05, mostrando que existe diferença significativa. Além do mais, à medida que o ponto médio das barras se distancia da origem, é possível notar o desempenho de um modelo sobre outro, sendo possível verificar que o modelo SVM possuir melhor desempenho quando observado o coeficiente de determinação (R^2), entretanto o RF-ANN se sobressaem quando observado os valore de MAE, MSE e RMSE.

Figura 6 - Diferença média nos níveis dos modelos com base no teste de Bonferroni a 95% de confiança para o NDVI (a, b, c, d) e NDWI (e, f, g, h).

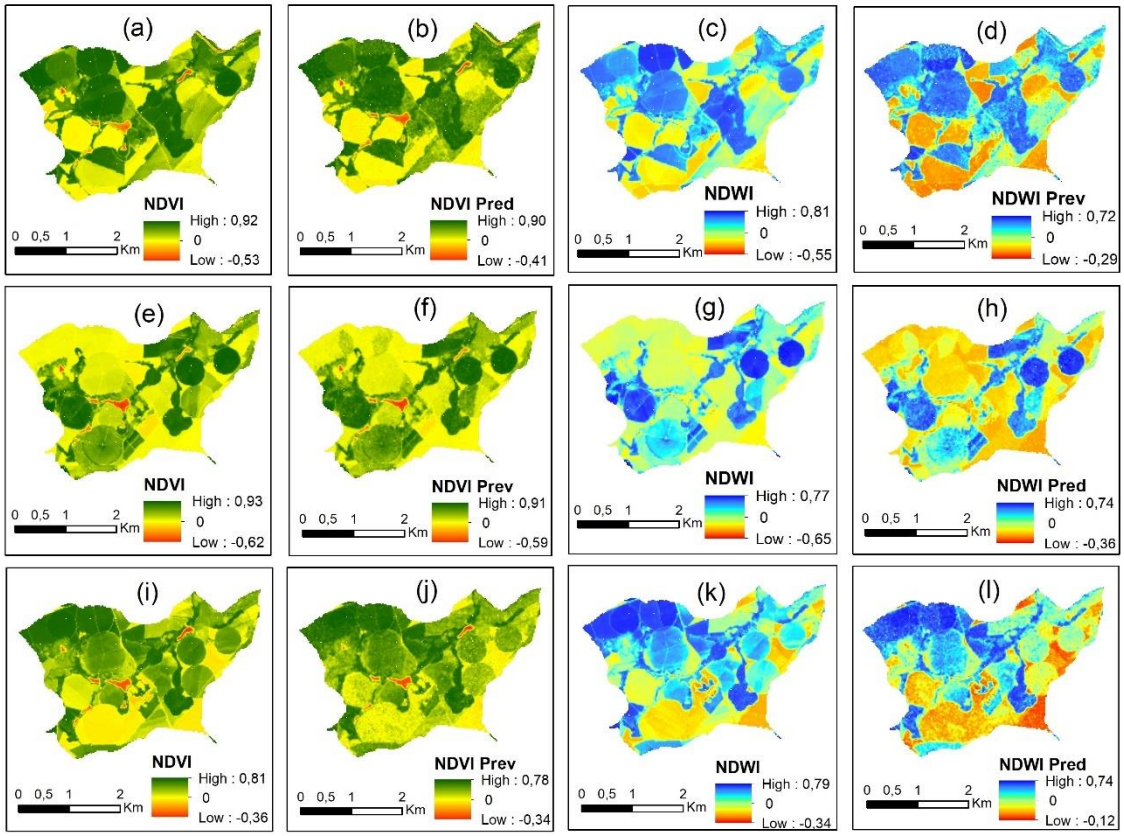


Fonte: Elaborado pelo autor.

A Figura 7 apresenta os valores de NDVI e NDWI observado com base nos dados do Sentinel-2 e o NDVI e NDWI previstos pelo modelo RF com base em dados de retroespalhamento do Sentinel-1.

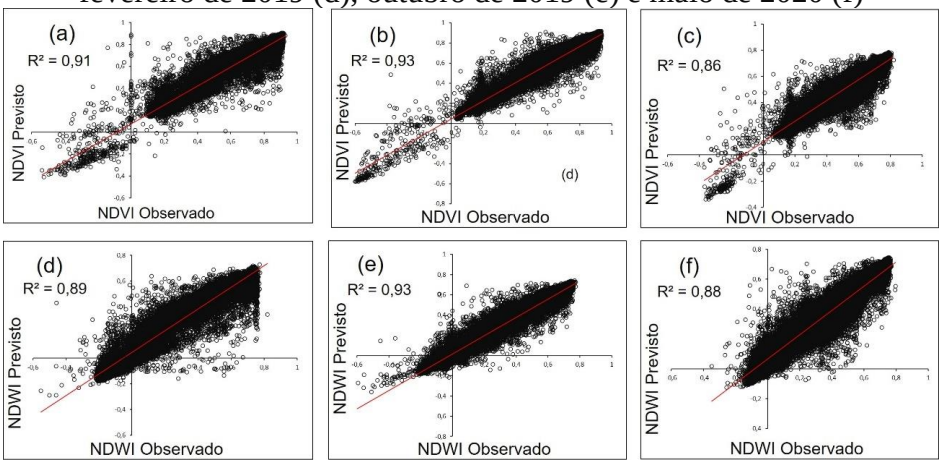
A Figura 8 apresenta o gráfico de dispersão entre os valores de NDVI e NDWI observados com base em dados do Sentinel-2 e previsto pelo modelo RF a partir de dados de retroespalhamento do Sentinel-1.

Figura 7 - Comparação entre NDVI observado e previsto (a-b) e NDWI observado e previsto (c-d) para o mês de fevereiro de 2019 (a-b, c-d), bem como o observado e previsto para os meses de outubro de 2019 (e-f, g-h), e maio de 2020 (i-j, k-l).



Fonte: Elaborado pelo autor.

Figura 8 - Gráficos de dispersão de NDVI observado e previsto para o mês de fevereiro de 2019 (a), outubro de 2019 (b) e maio de 2020 (c), e NDWI observado e previsto para o mês de fevereiro de 2019 (d), outubro de 2019 (e) e maio de 2020 (f)



Fonte: Elaborado pelo autor.

Nesse estudo, os baixos valores observados para o R^2 entre os meses 02/2019 e 05/2020 podem estar relacionados ao período de aquisição dos dados, que por sua vez sofrem interferência em função dos fatores climáticos, e da diferença de dias entre os dados obtidos

pelo Sentinel-1 e Sentinel-2. Os fatores climáticos interferem nas propriedades dielétricas, pois alteram a umidade do solo, influenciando no retroespalhamento do SAR (Meyer, 2019; Filgueiras et al., 2019), enquanto a diferença de dias entre o imageamento realizado pelo Sentinel-1 e Sentinel-2 podem interferir na correlação entre os dados, uma vez que a produtividade fotossintética sofre alterações significativa ao longo do tempo, principalmente em áreas de agricultura intensiva sob diversos níveis de irrigação, como observado na área de estudo.

Em relação a diferença de datas entre os dados de SAR do Sentinel-1 e dados ópticos do Sentinel-2, associados no primeiro mês, os dados obtidos pelo SAR e do sensor ótico possuem uma diferença de 5 dias (Sentinel-1 obtidos em 14/02/2019 e Sentinel-2 em 09/02/2019), enquanto no segundo mês, os dados foram obtidos na mesma data (12/10/2019), e no terceiro mês, com uma diferença de 2 dias (Sentinel-1 obtidos em 27/05/2020 e Sentinel-2 em 29/05/2020). Nesse caso, os melhores ajustes foram observados para os modelos gerados com base em dados obtidos na mesma data, seguindo pelos modelos gerados com dados de dois dias de diferença, e com pior desempenho, os modelos gerados com base nos dados com diferença de cinco dias.

Como o NDVI reflete as mudanças no conteúdo de clorofila no dossel da vegetação, e o NDWI reflete o conteúdo de água na vegetação (Gu et al., 2007), nesse caso, a relação entre o coeficiente de retroespalhamento e esses índices pode ser impactada com a alteração da umidade do solo em áreas descobertas ou com pouca vegetação, bem como em áreas de irrigação de pivô central podem interferir fortemente no retroespalhamento. Nesse estudo, os índices de precipitação foram marcantes nos três períodos avaliados, sendo que em fevereiro de 2019 (verão), a precipitação acumulada local foi de 143,70 mm, com temperatura média de 24,23°C, enquanto que em outubro de 2019 (primavera), a precipitação total foi de 9,41 mm, com temperatura média de 23,74°C, e em maio de 2020 (outono), com 20,55 mm, e temperatura média de 18,54°C (Agritempo, 2020), ou seja, ao menos nesse estudo, os períodos de maior precipitação correspondem aos menores ajustes do modelo de regressão.

Vale ressaltar que a radiação eletromagnética capturada pelo SAR na banda C não tem a capacidade de atravessar superfícies vegetadas (Meyer, 2019), entretanto, em áreas de cultivo agrícola, onde é comum a presença de solo exposto ou cobertura morta ou palha, constituída dos restos vegetais originados da cultura anterior, o coeficiente de retroespalhamento pode apresentar maior interação com o solo, de forma a ser influenciado pela umidade presente (Bousbih et al., 2017; Filgueiras et al., 2019). Além do mais, essa relação pode ser afetada pelo tipo da cultura, estado de fenologia e níveis de irrigação da cultura (Bai et al., 2020). Dessa

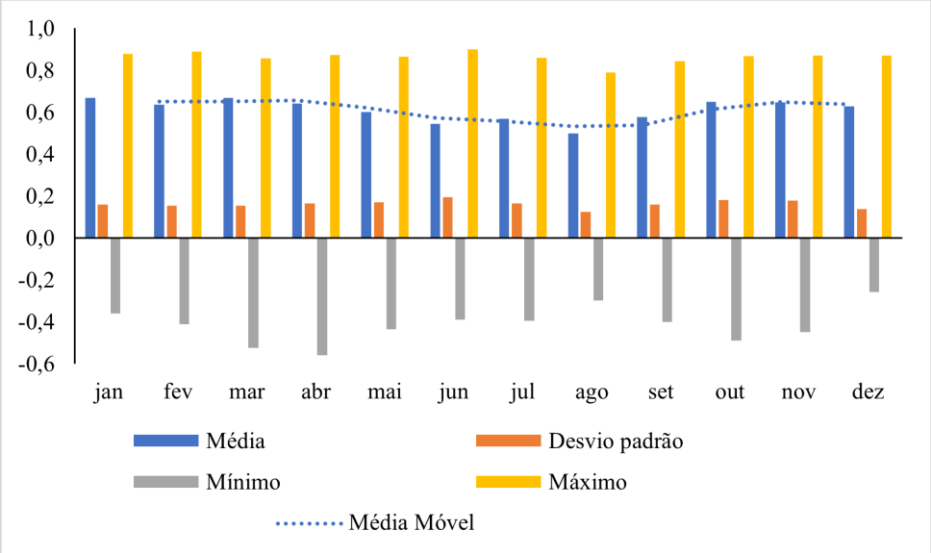
forma, em períodos de entressafra a relação entre o coeficiente de retroespalhamento do SAR e índices de vegetação podem apresentar alta variabilidade, uma vez que existe interferências significantes em função da inexistência de cobertura vegetal (Xu et al., 2020).

5.2 NDVI na bacia hidrográfica do rio Sorocabuçu

O comportamento do NDVI para o ano de 2020 na BH do Rio Sorocabuçu, com exceção dos meses de junho e dezembro, que foram estimados por meio da metodologia proposta nesta pesquisa por meio de dados SAR, em razão do grande índice de nebulosidade na área de estudo nos meses supracitados, foram determinados por meio da metodologia proposta por Rouse *et al*. (1973).

Observou-se que as maiores variações de NDVI ocorreram nos últimos seis meses do ano, reafirmado pelos valores de desvio padrão apresentados na Figura 9, que mostra a distância do mesmo em relação aos valores médios, como picos para os meses de março e novembro, bem como a variação da média móvel, que expressa o comportamento ao longo de todo o ano levando em consideração os efeitos da sazonalidade sobre o índice biofísico.

Figura 9 - Estatística descritiva do NDVI para o ano de 2020.

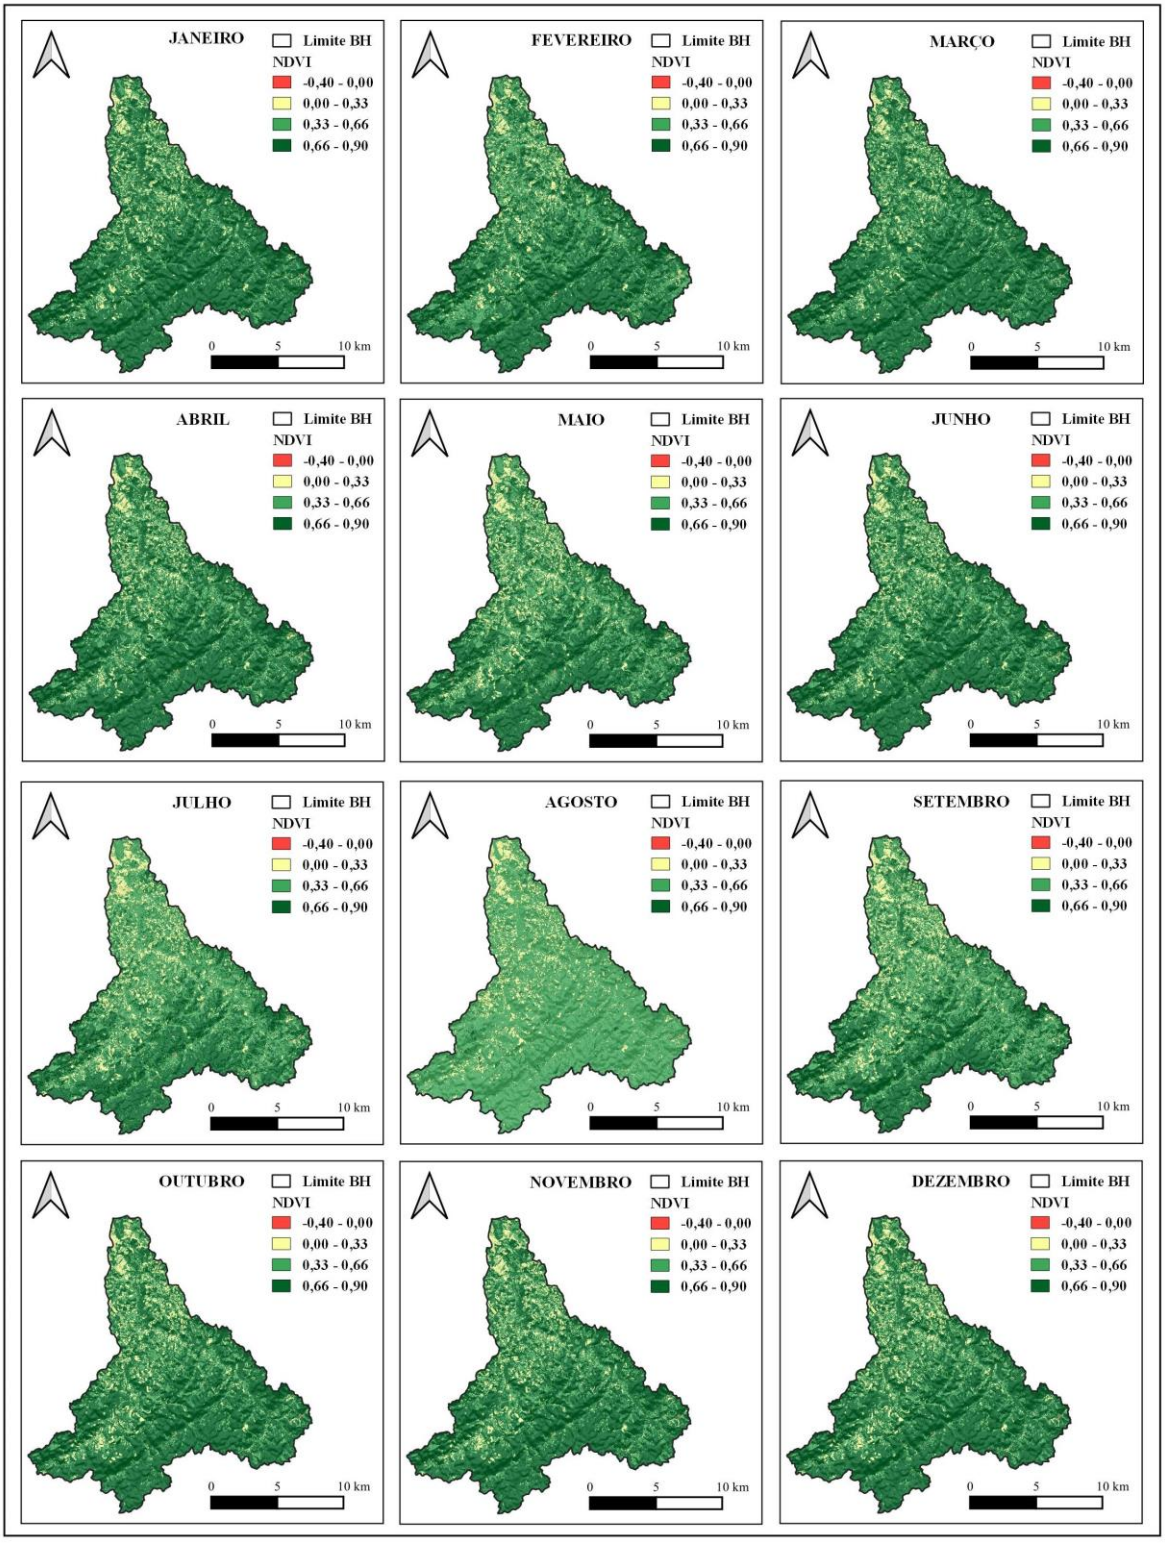


Fonte: Elaborado pelo autor.

Os menores valores de NDVI foram observados nos meses de abril, março, agosto e outubro, enquanto os maiores ocorreram no mês de junho, fevereiro e janeiro (Figura 10). Apesar da amplitude dos resultados observado pela comparação entre máximas e mínimas, de

modo geral os valores médios de NDVI permaneceram acima de 0,5 até próximo de 0,7, estando classificado como áreas de vegetação mais densa segundo Melo et al. (2019).

Figura 10 - Espacialização do NDVI para o ano de 2020.



Fonte: Elaborado pelo autor.

A espacialização dos valores de NDVI observado nos meses ao longo do ano de 2020 (Figura 10), evidenciaram a presença de uma grande área que apresenta característica vegetacional desenvolvida, bem como as nítidas alterações das atividades antrópicas, ainda assim, as variações da atividade fotossintética são sutis ao longo do ciclo hidrológico, tendo variações mais perceptíveis provavelmente em função do regime pluviométrico da região.

Ao analisar os meses de janeiro e julho (Figura 10), nota-se uma elevada produção fotossintética (NDVI médio variando entre 0,54 e 0,67), dentre esses meses, os maiores valores de NDVI foram observados nos meses de janeiro (0,88) e junho (0,90), os menores valores foi apresentado pelos meses de agosto (0,30) e dezembro (0,26), comportamento que pode ser justificado pelo fato de janeiro ser o mês mais chuvoso com valores médios de pluviosidade de 214,9 mm, e o mês mais seco ser agosto com valores médios de pluviosidade de 40,0 mm, de acordo com a EMBRAPA (2019).

Os resultados obtidos pelo mapeamento do Índice de Vegetação por Diferença Normalizada – NDVI com uso de dados do sensor Sentinel-2A indicaram alta confiabilidade e um grande potencial das imagens do sensor para o monitoramento fenológico ao longo no período avaliado conforme observado por Rezende *et al.* (2017). Uma vez contornada as limitações causadas por altos índices de nebulosidade em algumas épocas do ano por meio da metodologia proposta no item 5.6 desta pesquisa, melhora a capacidade de monitoramento e avaliação dos estágios de desenvolvimento vegetativo e produção fotossintética, uma vez que é possível ter informações ao longo de todo o ciclo hidrológico, o que é de grande importância para o monitoramento contínuo da vegetação.

5.3 NDWI na bacia hidrográfica do rio Sorocabuçu

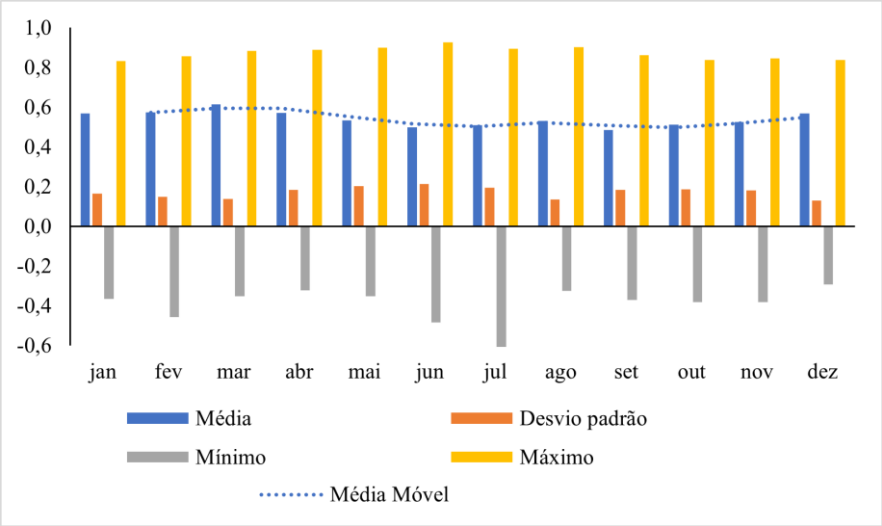
O NDWI para o ano de 2020 na bacia hidrográfica do rio Sorocabuçu apresentou valores que variaram de -0,37 a 0,92 com amplitude total entre os dados de 1,36. Da mesma forma como o índice apresentado anteriormente, apenas os meses de junho e dezembro foram estimados por meio da metodologia utilizando dados SAR, em razão da falta de imagens aptas a serem utilizadas nesses meses por conta das limitações das imagens óptica diante de elevados índices de nebulosidade.

A Figura 11 mostra de forma descritiva o panorama dos valores médios, desvio padrão, mínimos, máximos e a média móvel do NDWI ao longo do ano de 2020, onde é possível observar uma tendência de crescimento nos valores máximos, iniciando no mês de janeiro (0,83) até o mês de junho, que apresenta o maior valor para o ano (0,92), com indicativo de

redução a partir do mês de julho, reduzindo os seus valores até a menor máxima em dezembro (0,83).

Ao se observar os valores mínimos, o mês de julho que apresentou também um dos maiores valores máximos, apresentou o menor valor mínimo de NDWI (-0,7) durante o ano de 2020, seguido dos meses de fevereiro (-0,45) e junho (-0,48).

Figura 11 - Estatística descritiva do NDWI para o ano de 2020.



Fonte: Elaborado pelo autor.

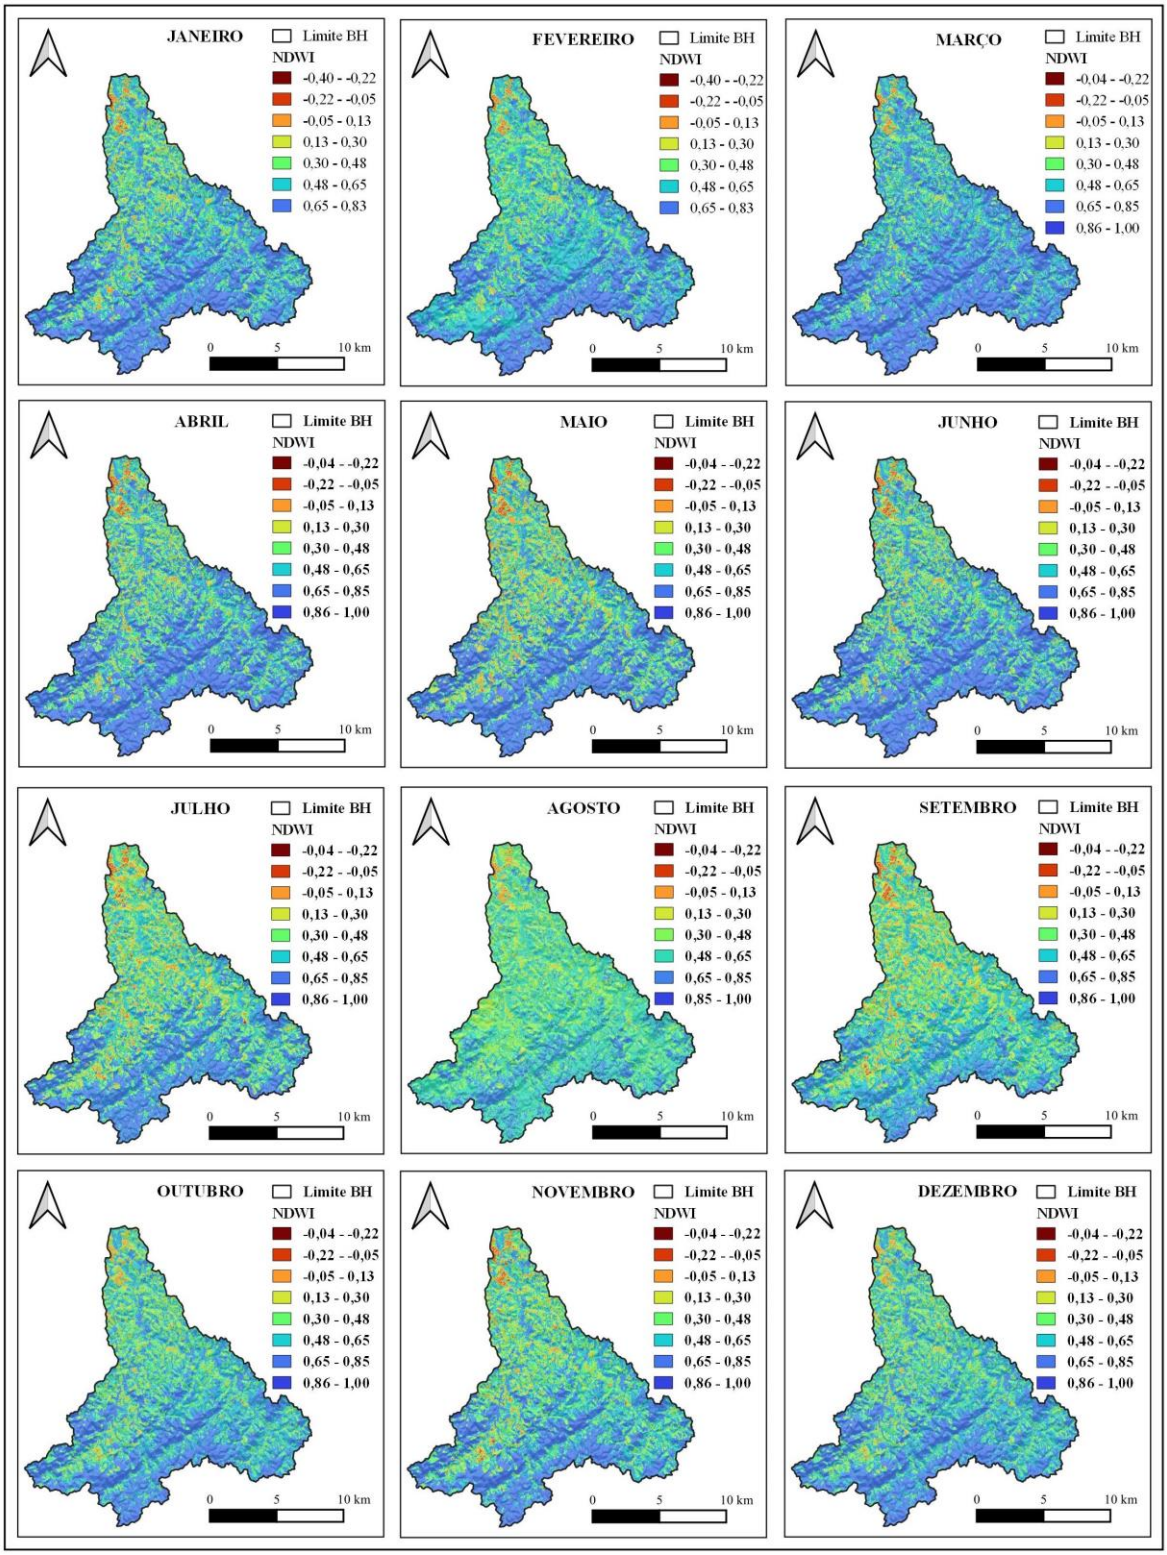
Quando se analisa os valores médios, observamos uma baixa amplitude entre a média máxima e mínima (0,2), que reflete também na baixa variação do desvio padrão, onde se observa a maior distância da média nos meses de março e dezembro, mas de modo geral mantendo uma baixa variação em relação à média expressa na Figura 11, durante todo o ano de 2020.

A Figura 12 mostra a espacialização do NDWI para o ano de 2020, onde observa-se de forma clara os maiores valores na parte sul, sudeste e sudoeste da BH, onde de acordo com a classificação do uso e cobertura da terra, estão localizadas as maiores áreas de florestas, com valores variando entre 0,6 e 1,0. Resultado semelhante ao estudo realizado por Holanda e Guerra (2010), que indicam para áreas de florestas valores entre 0,6 e 0,8, em áreas com florestas esparsadas 0,2 a -0,4 e em áreas degradas sem a presença de florestas os valores ficaram próximo de -1,0.

Nota-se na Figura 12 a influência das estações do ano ao longo do ciclo hidrológico, o período de maior precipitação vai do mês do início do mês outubro ao início de abril, observando-se na imagem os maiores valores de NWDI, enquanto o período de estiagem inicia-

se em meados de abril até meados de outubro, quando são notados os menores valores desse índice (EMBRAPA, 2019).

Figura 12 - Espacialização do NDWI para o ano de 2020.



Fonte: Elaborado pelo autor.

Além das marcantes características ditadas pelo clima, verifica-se ainda na porção mais ao norte da BH os reflexos da ação antrópica na região, onde se observa a ocorrência da maioria

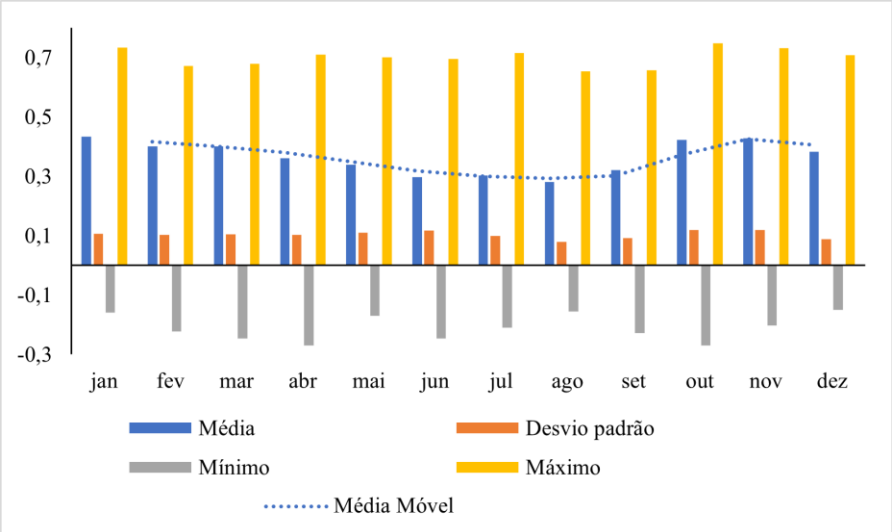
dos valores negativos ao longo de todo o ano, corroborando com o estudo de Oliveira et al., (2010), que observaram comportamento semelhante.

5.4 SAVI na bacia hidrográfica do rio Sorocabuçu

A Figura 13 mostra a estatística descritiva do SAVI para o ano de 2020 na BH do Rio Sorocabuçu, onde observou-se que as variações médias mensais acompanham a sazonalidade característica região, apresentando as maiores máximas nos meses de janeiro (0,73) e outubro (0,74), esses mesmos meses apresentaram também as maiores distância do desvio padrão em relação à média apresentados na Figura 13, que mostra a distância do mesmo em relação aos valores médios, bem como picos desse parâmetro para os meses de março e dezembro, assim como a flutuação da média móvel expressando a sazonalidade do ciclo hidrológico.

O Índice de Vegetação Ajustado ao Solo (SAVI - *Soil Adjusted Vegetation Index*) é recomendado como método de atenuação das propriedades ópticas do solo no NDVI, quando a área estudada não apresenta cobertura vegetal completa (Huete, 1988), nesse sentido, observou-se que as maiores variações de NDVI ocorreram nos últimos seis meses do ano, reafirmado pelos valores de desvio padrão apresentados na Figura 13, que mostra a distância do mesmo em relação aos valores médios, bem como picos desse parâmetro para os meses de março e dezembro, sendo ainda confirmado a alta similaridade visual quando comparado as Figuras 9 (NDVI) e Figura 14 (SAVI).

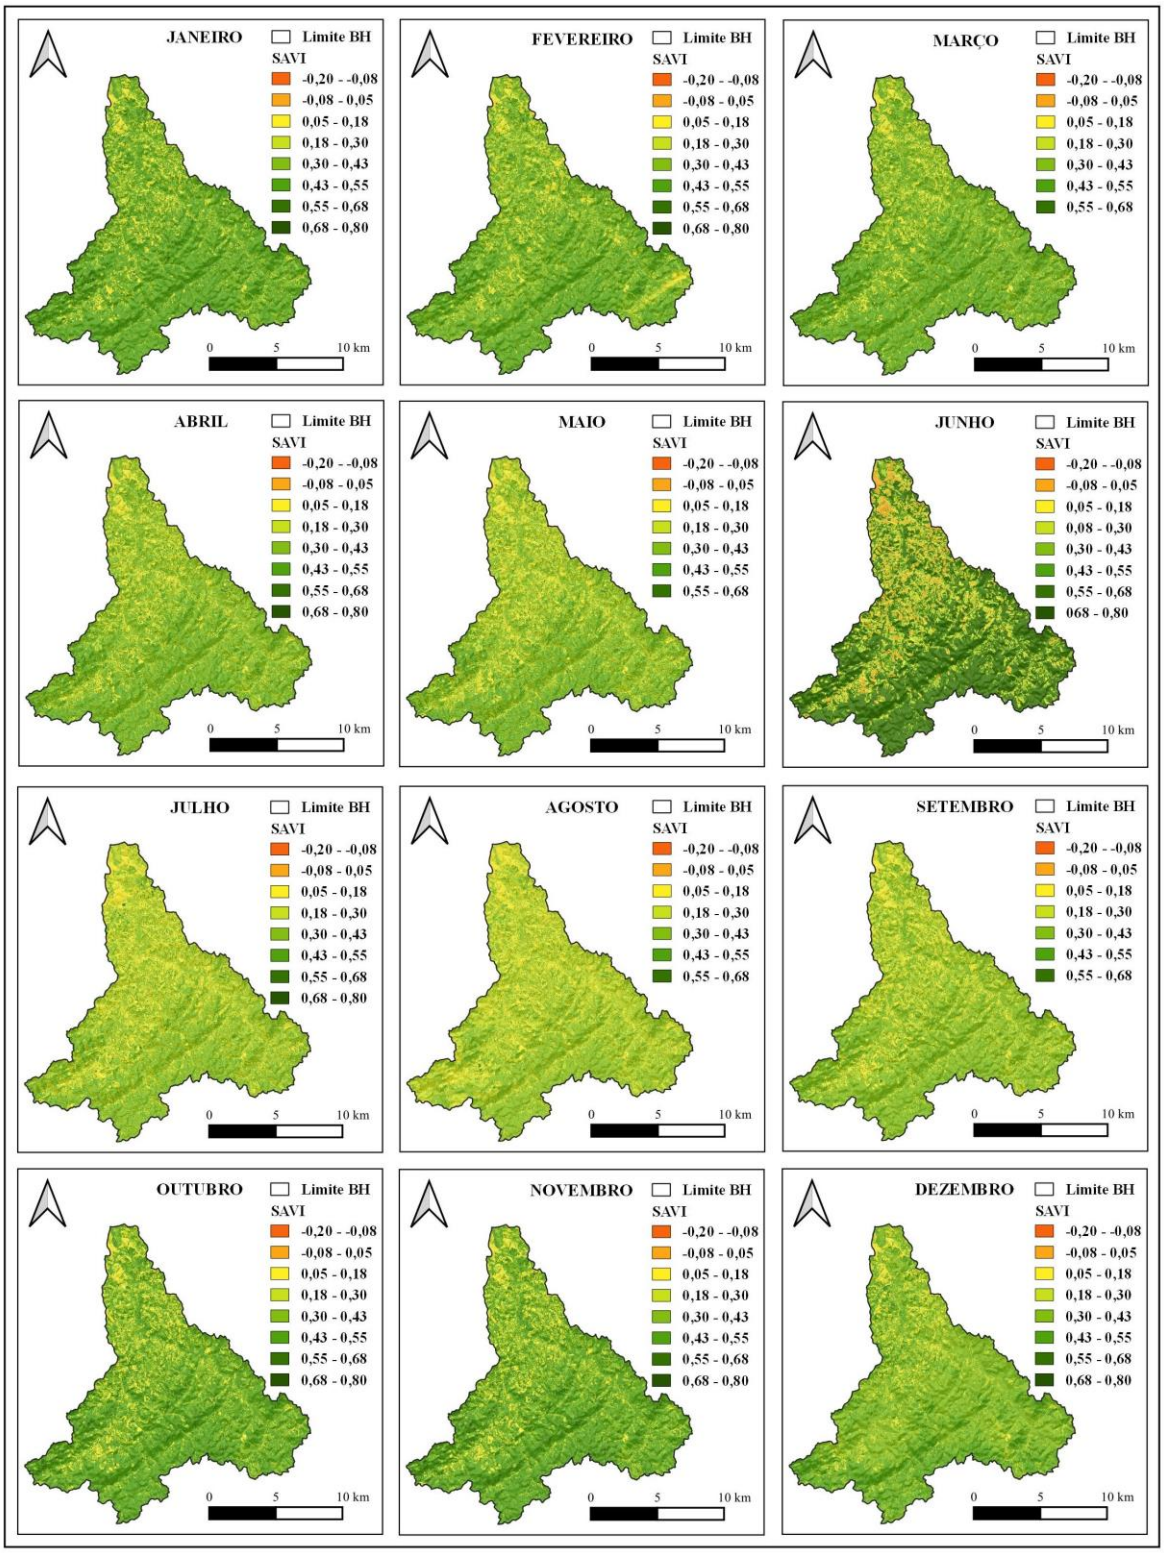
Figura 13 - Estatística descritiva do SAVI para o ano de 2020.



Fonte: Elaborado pelo autor.

A Figura 14 mostra o comportamento do SAVI durante todo o ano de 2020 na BH do Rio Sorocabuçu.

Figura 14 - Espacialização do SAVI para o ano de 2020.



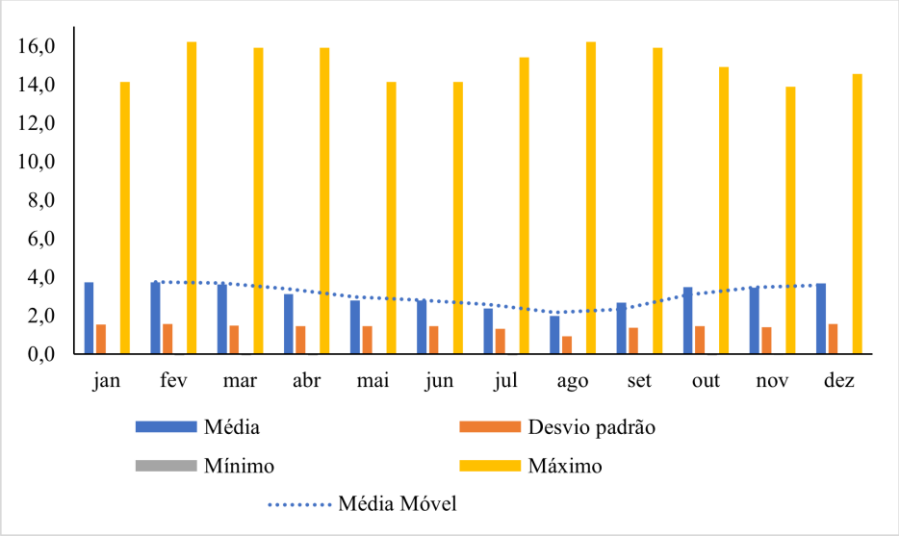
Fonte: Elaborado pelo autor.

É possível observar na Figura 14 a similaridade na distribuição espacial das imagens de SAVI com o NDVI do mesmo ano, nas duas figuras observa-se uma elevada produção fotossintéticas nos meses de janeiro a julho e no final do segundo semestre. Apesar da similaridade quando comparado os resultados de SAVI e NDVI, o segundo índice ainda apresentou maior fidelidade ao tipo de cobertura presente na BH do Rio Sorocabuçu quando comparado com o mapa de uso e cobertura da terra, uma vez que a pesar dos diversos tipos de uso, a referida bacia ainda apresenta na maioria da sua área a presença de cobertura vegetal, sendo o NDVI o índice biofísico mais indicado para analisar a saúde da vegetação, uma vez que o SAVI é recomendado para área que apresentam climas áridos e semiáridos com cobertura vegetal inferior a 40%, em razão da sua capacidade de reduzir os efeitos do solo desnudo nos resultados (Yildirim e Asik, 2018).

5.5 IAF na bacia hidrográfica do rio Sorocabuçu

O IAF é a quantidade foliar que realiza produção fotossintética e estima a vegetação presente sobre uma determinada área, permitindo inferências sobre o regime de crescimento e vigorosidade da vegetação (Arslan et. al., 2021). A Figura 15 mostra a análise descritiva do IAF para o ano de 2020 da BH do rio Sorocabuçu, localizados no município de Ibiúna-SP.

Figura 15 - Estatística descritiva do IAF para o ano de 2020.



Fonte: Elaborado pelo autor.

A distribuição do IAF ao longo do ano de 2020 apresentou valores médios semelhantes (IAF entre 2 e 4,5) que se repetem de janeiro a dezembro, notando-se também elevados valores

de máxima, com os maiores índices nos meses de fevereiro e agosto (16,2), assim como áreas que apresentam IAF=0 (janeiro, maio, junho, agosto, setembro e dezembro) e valores negativos (fevereiro, março, abril, julho, outubro e novembro).

Uma das principais preocupações na gestão de uma BH é a forma como se faz a gestão hídrica da mesma, nesse sentido, a integração do IAF a um modelo hidrológico contribui com o manejo da água dentro nas áreas ocupadas pela agricultura e em áreas que apresentam cobertura foliar natural (Paul et. al., 2021).

Ao analisar a Figura 16 que mostra a espacialização do IAF para a BH do rio Sorocabuçu para o ano de 2020, observa-se a relação do deste índice com o período em que ocorre maior índice pluviométrico na área de estudo, que se estende entre os meses de outubro a fevereiro, nesse intervalo, a média mensal de precipitação varia entre 40 a 219 mm (DAEE, 2019).

O IAF é um dos principais índices que fornece informações referente ao estado da vegetação, quando há floresta com elevada produção fotossintética ocorre também alta produção de biomassa, ou seja, produção de folhas, que interfere diretamente nesse índice, uma vez que, quanto mais folha existir por unidade de área, maior será o IAF, concomitante isso subintende-se que aquele ecossistema está recebendo as condições necessárias para suprir as características fenológica daquele ambiente (Gibelin et. al., 2006; Duchemin et al., 2006; Seo e Kim, 2021).

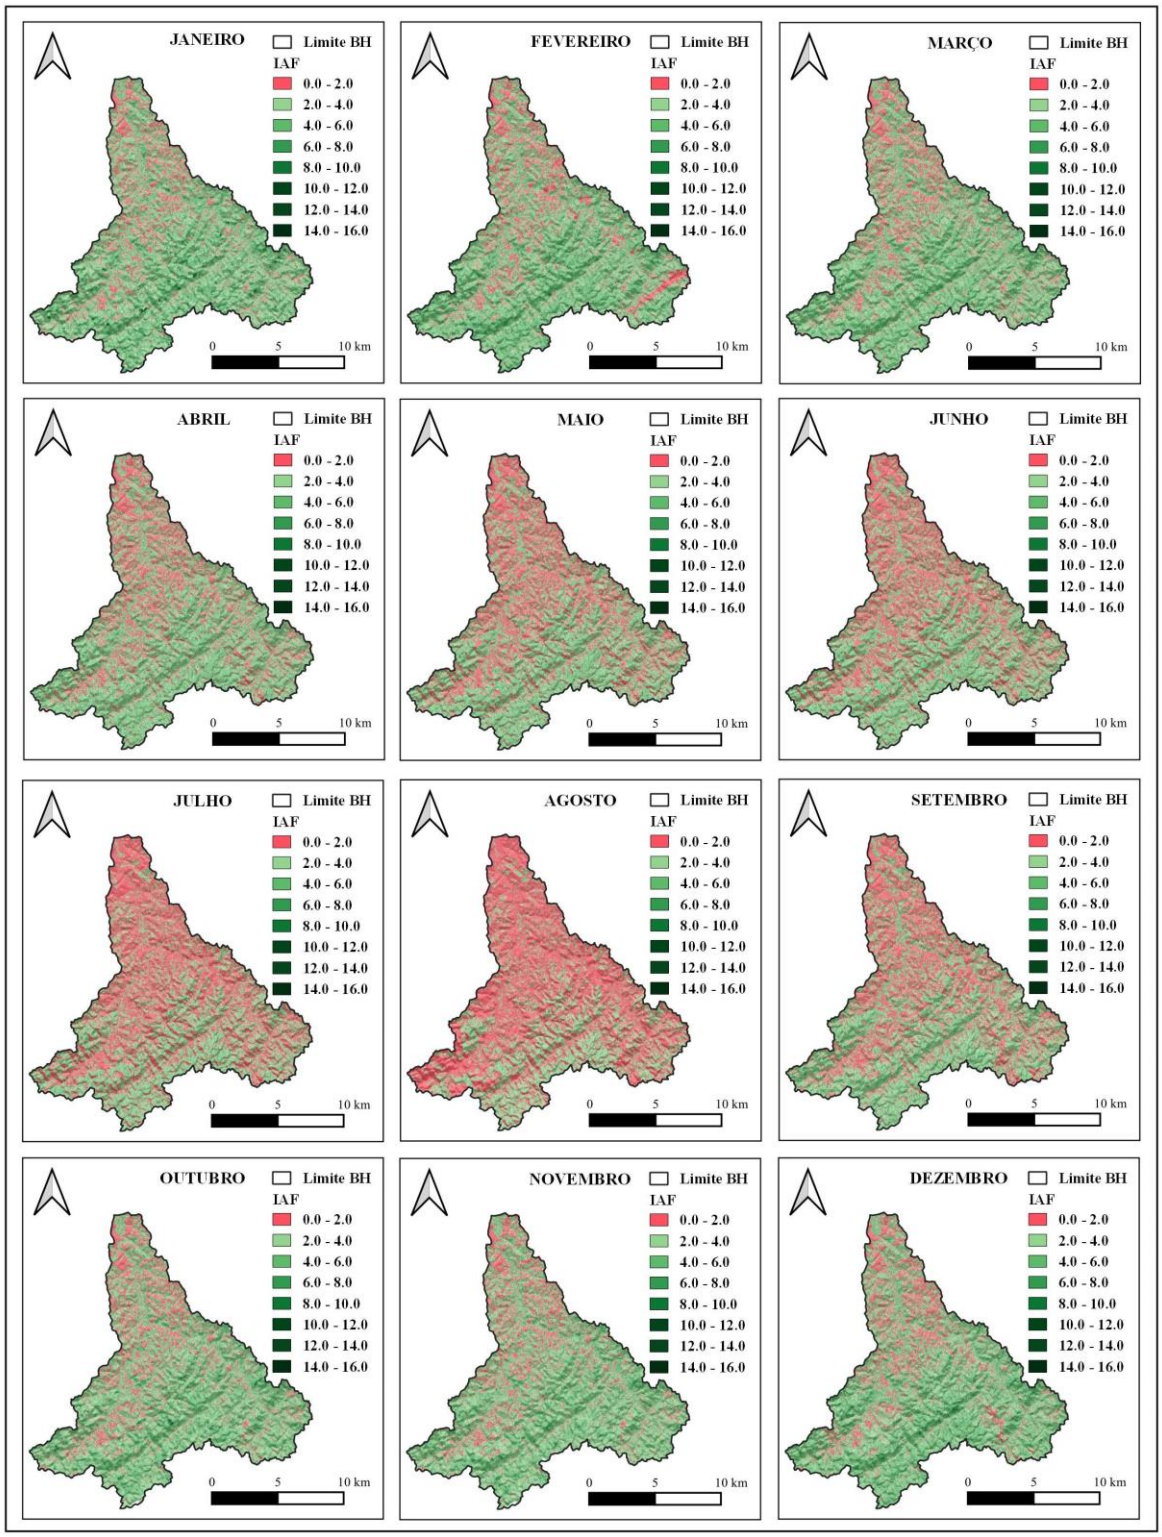
A BH do rio Sorocabuçu está inserida na Área da APA (Área de Proteção Ambiental) da represa de Itupararanga que foi criada pela Lei Estadual n° 10.100, com o objetivo de proteger a fauna, flora e recursos hídricos, por isso, impõe-se normas e restrições acerca do uso e ocupação da terra nas áreas de florestas de Mata Atlântica remanescentes dentro da unidade de conservação (SÃO PAULO, 1998).

Quando comparamos as Figuras 16 que mostra a espacialização do IAF ao longo do ano de 2020 e a Figura 17 que mapeia o uso e ocupação da terra também para o mesmo ano na BH do rio Sorocabuçu, nota-se que os maiores valores de IAF são observados nas áreas com a ocorrência de florestas, silvicultura, cultura permanente e cultura temporária, em razão da ocorrência de vegetação com maior porte arbóreo, uma vez que de acordo com a Fundação Florestal (2010), no perímetro da APA da represa de Itupararanga que abrange a área da BH do rio Sorocabuçu encontrasse o maior fragmento florestal primitivo do bioma Mata Atlântica das proximidades.

De acordo com Beu et. al., (2011), a proteção dos fragmentos florestais da região é de grande importância, uma vez que a BH do rio Sorocabuçu é um caudaloso afluente para a

represa de Itupararanga e somente seu curso d'água principal supri as necessidades hídricas da área urbana do município de Ibiúna-SP (SABESP, 2018).

Figura 16 - Espacialização do IAF/LAI para o ano de 2020.

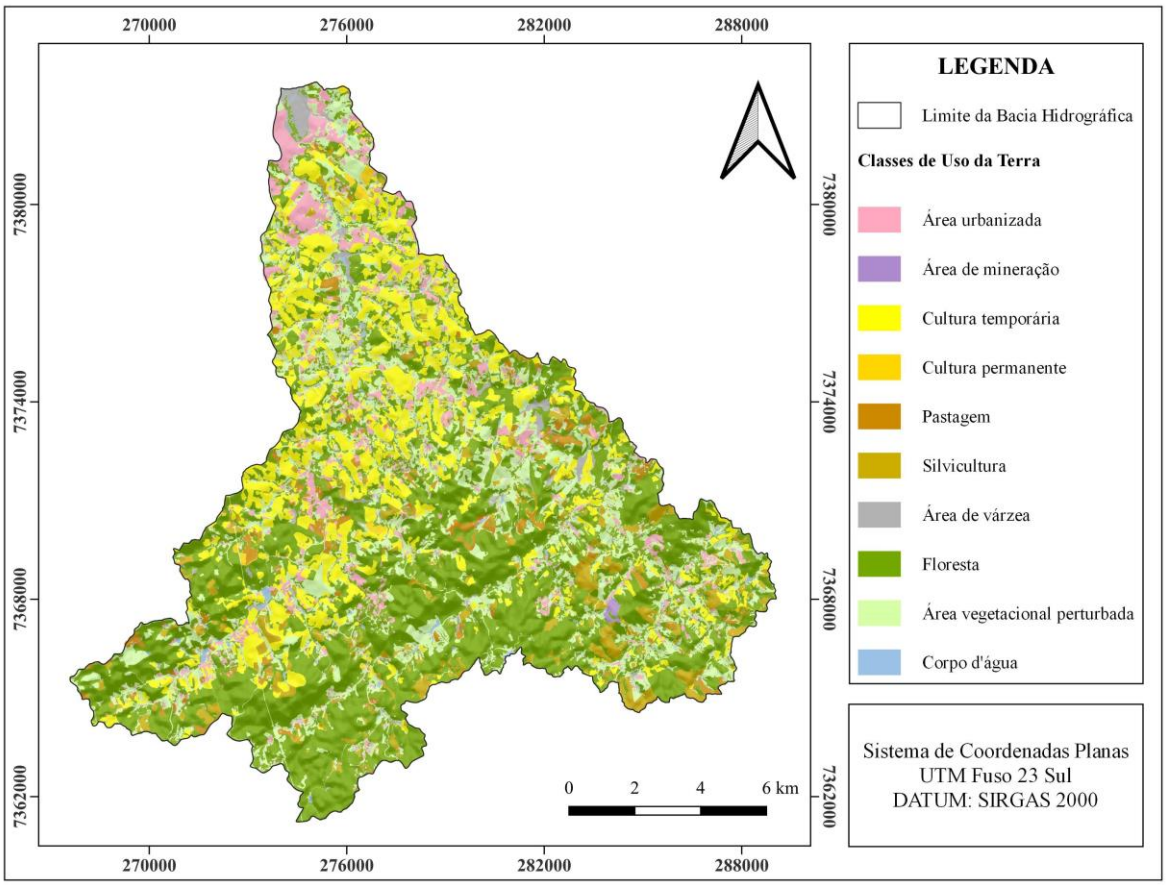


Fonte: Elaborado pelo autor.

5.6 Uso e ocupação da terra e cobertura vegetal na bacia hidrográfica do rio Sorocabuçu

A Figura 17 apresenta as subclasses da cobertura e uso da terra na BH do rio Sorocabuçu para o ano de 2020, em que a classificação evidenciou os seguintes percentuais da área da BH como: 0,13% área de mineração, 0,42% cultura permanente, 1,17% corpos hídricos, 1,42% área de várzea, 2,63 Pastagem, 6,88% silvicultura, 7,01% área urbanizada, 16,95 cultura temporária, 17,91 área vegetacional perturbada e 45,47% floresta.

Figura 17 - Uso e ocupação da terra para o ano de 2020 na BH do rio Sorocabuçu.



Fonte: Elaborado pelo autor.

A BH do rio Sorocabuçu possui uma área total de 202,76 Km^2, desse total, nota-se que mais da metade da área da BH (54,53%) é afetada por atividades antrópicas ou sofre pressão direta, como é o caso das áreas de vegetação perturbada que corresponde a cerca de 17,91% desse total. A parte norte, noroeste e sudoeste apresentam a maior ocorrência de mudança no uso e ocupação da terra, como as culturas temporárias que é o maior percentual de uso antrópico da BH com 16,95%, sendo precedido pelas áreas urbanizadas com 7,01%, silvicultura com 6,88% e pastagem com 2,63%.

Dentre as subclasses de uso estritamente antrópico, o menor quantitativo foi atribuído a área de mineração (0,13%) que corresponde a cerca de 0,26 Km^2 (25,5 hectares), que quando comparado aos estudos de Souza (2021), em que a cobertura de uso da terra na BH do rio Sorocabuçu para os anos de 2010 e 2019, apresentou valores de 0,01% em 2010, 0,11% em 2019 e nessa pesquisa (2020) 0,13%, nota-se um efetivo crescimento da atividade de lavra na região. De acordo com levantamentos, ocorre a extração de areia na região sudeste da BH do rio Sorocabuçu, área onde se localizam grande parte dos fragmentos florestais, recomendando-se ações de monitoramento e fiscalização, uma vez que tais atividades apresentam alta possibilidade de degradação ambiental, podendo assim intensificar a pressão antrópica sobre os remanescentes florestais da região.

A subclasse floresta, apresentou um percentual de 45,47% da área total da BH, sendo o maior percentual de uso não antrópicos da área estudada. Conforme apresentado na Figura 17, observa-se a ocorrência dessa subclasse predominantemente na parte sul da BH, em uma faixa evidente que vai do sudeste ao sudoeste. Duarte (2022), em sua pesquisa que investigou suscetibilidade à incêndios e queimadas utilizando um modelo baseado em inteligência artificial e sistema de inferência fuzzy na BH do rio Sorocabuçu, em sua classificação de uso e ocupação da terra, determinou que a subclasse floresta apresentou um percentual de 45,72 para o ano de 2019, evidenciando uma redução de 0,25%, se comparado ao ano de 2020. Uma das hipóteses para a predominância dos fragmentos florestais na parte sul da BH do rio Sorocabuçu são os aspectos fisiográficos da região, onde as cotas chegam a mais de 1.203 metros de altitude (SOUZA, 2021), apresentando maior dificuldade para o avanço das atividades antrópicas como a agropecuária, forçando assim a permanência dos fragmentos florestais nessa região, acorrendo o posto nas áreas de declividades menores como na parte mais ao norte da BH (Maia Júnior e Lourenço, 2020).

A BH do rio Sorocabuçu apresenta uma grande quantidade de pequenos produtores agrícolas, conforme observa-se na Figura 17, por meio da subclasse cultura temporária, que ocupa 16,95% da área, contribuindo economicamente com o município de Ibiúna-SP por meio da produção de legumes, hortaliças e frutos (LOPES et al., 2018), esse tipo de uso da terra encontra-se distribuído ao longo da área da BH, com predominância mais ao norte, noroeste e sudoeste, que de acordo com Luz et al., (2015), se justifica pela disponibilidade de uma boa rede de drenagem, o que facilita o processo de irrigação das culturas.

Do ponto de vista de contribuição hídrica para a atmosfera por evapotranspiração, a classificação de uso e ocupação da terra demonstrou um grande potencial explicativo, uma vez que somando os usos que apresentam cobertura vegetativa de porte arbóreo e consequentemente

maior capacidade de contribuição evaporativa, tem-se um percentual de 72,1% (0,42% de cultura permanente, 1,42% de área de várzea, 6,88% de silvicultura, 17,91 de área vegetacional perturbada e 45,47% de área de floresta), cada subclasse com diferente capacidade de contribuição, como mostrado no tópico 6.7.1 a seguir.

5.7 ETa na bacia hidrográfica do rio Sorocabuçu

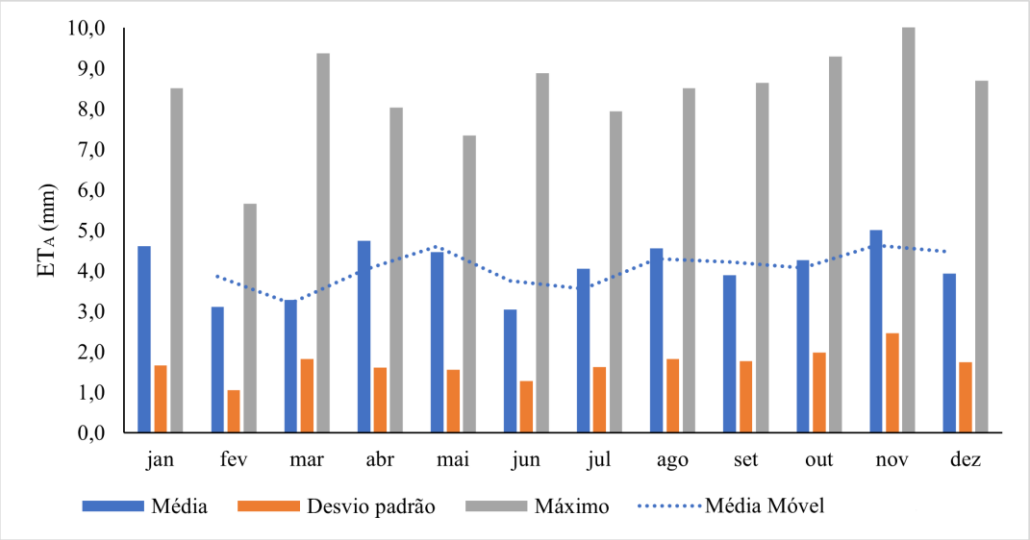
Nesse tópico, analisou-se a ETa estimada com dados da missão Copernicus coletados pela constelação de satélites Sentinel-2 e dados meteorológicos ERA5-Land utilizando o algoritmo SAFER por meio do pacote Agriwater no Software "R" (TEXEIRA, 2010; FERREIRA SILVA et al., 2019).

A evapotranspiração consiste em um processo fundamental para a manutenção do equilíbrio hídrico na Terra e para a regulação do clima, permitindo a circulação de água no ciclo da água, a partir do solo até a atmosfera. Por meio dos sensores Sentinel-2 da União Europeia é possível a monitorização da evapotranspiração em todo o mundo, utilizando-se de informações de alta resolução sobre a cobertura vegetal e a reflectância da superfície da terra, é possível realizar estimativa da quantidade de água que é liberada na atmosfera por meio da evapotranspiração (GUERSCHMAN et al., 2021).

A Figura 18 mostra de forma resumida a estatística descritiva mensal dos dados da ETa por meio das máximas, médias, desvio padrão e média móvel para o ano de 2020, sendo que os valores de mínimas foram suprimidos por serem zero. Notou-se que os maiores valores mensais de ETa para ano de 2020 foram estimados em janeiro (8,51 mm), março (9,37 mm), outubro (9,30 mm) e novembro com 10 mm, sendo esse o maior valor. Em relação aos valores médios, observou-se as maiores medias nos meses de janeiro (4,61 mm), abril (4,75 mm), maio (4,47 mm), agosto (4,56 mm) e novembro (5,01 mm), contudo o desvio padrão se manteve estável em um intervalo de 1,06 a 2,46 mm. Os menores valores médios foram verificados nos meses de junho (3,05 mm) e fevereiro (3,1 mm), respectivamente.

A ETa assim como diversos índices biofísicos, sofrem influência direta das características sazonais da região, a evapotranspiração de referência, a radiação global e a temperatura do ar contribuem para seu aumento ou diminuição. De acordo com Alvares et al., (2013), os valores médios mensais de temperatura do ar na região variam de 14 °C a 21,3 °C, sendo que a menor temperatura é recorrente no mês de julho e a maior no mês de fevereiro, mês em que se observou uma das menores médias de ETa ao longo do ano de 2020.

Figura 18 - Estatística descritiva da ETa para o ano de 2020.



Fonte: Elaborado pelo autor.

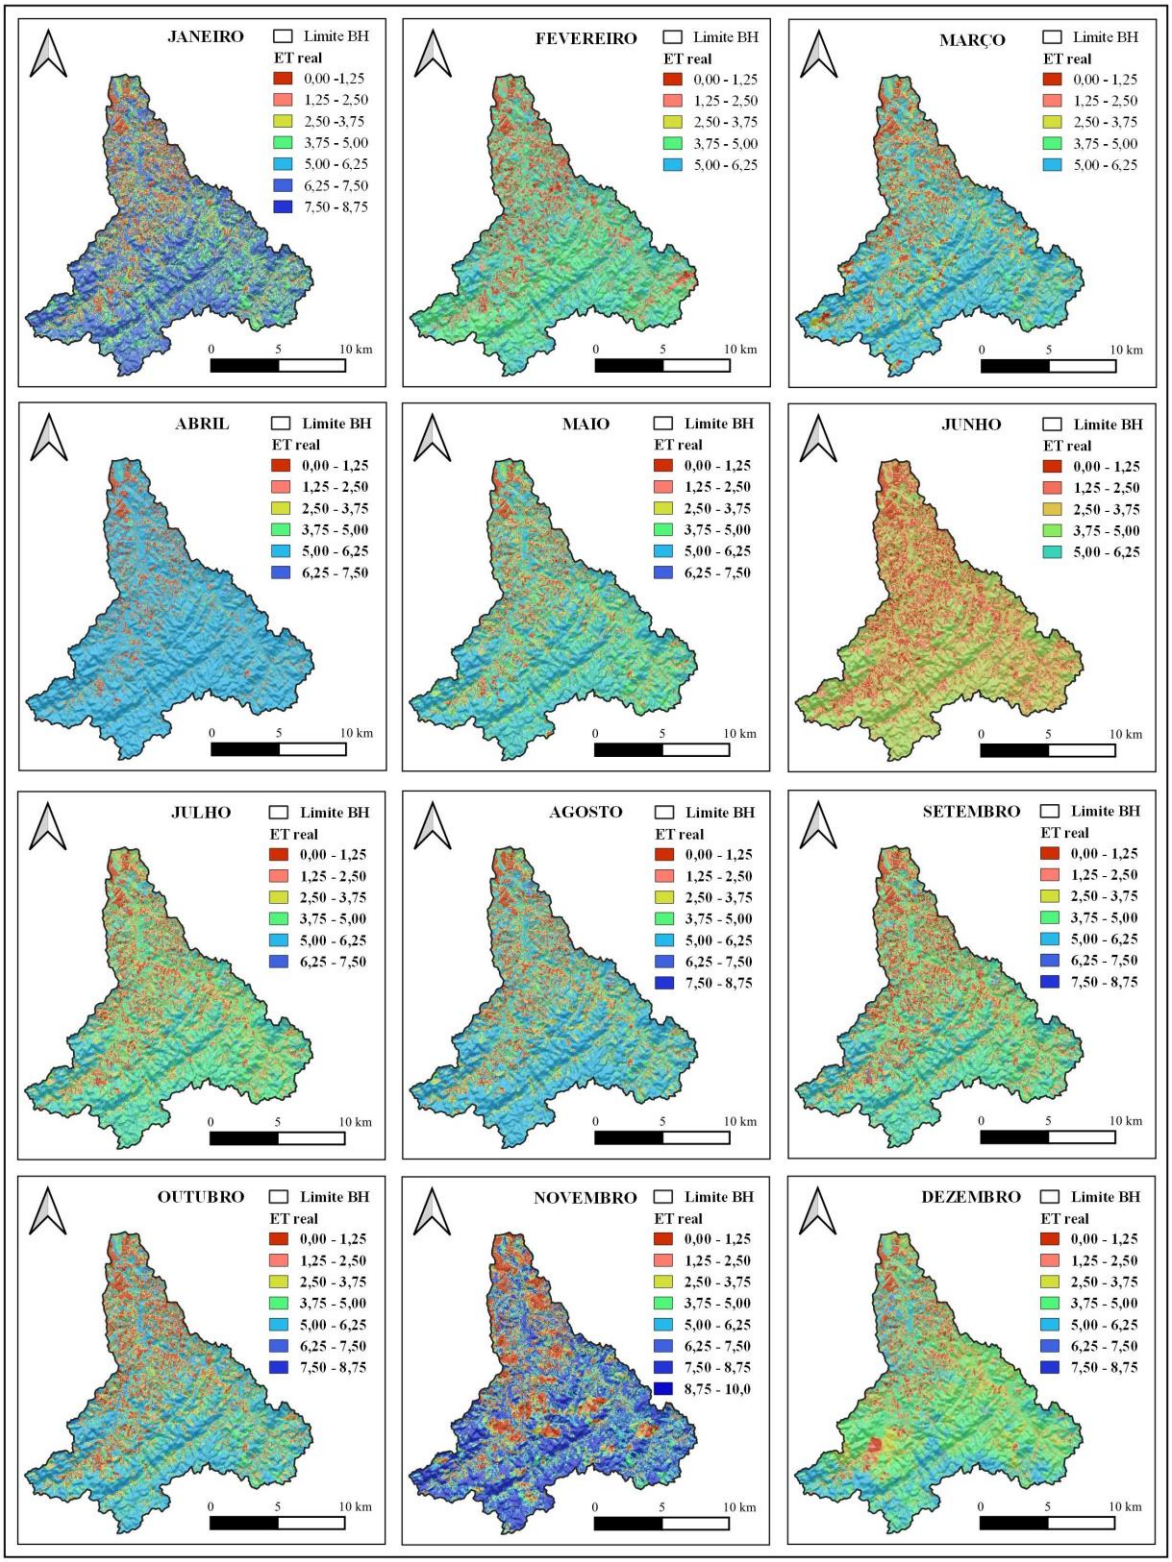
A Figura 19 apresenta a variação espaço-temporal da ETa no ano de 2020 na BH do rio Sorocabuçu, onde observa-se visualmente por meio dos mapas, os dados representados também na Figura 29, onde verifica-se que os meses de janeiro, abril e novembro apresentara os maiores índices médios de transporte de água para a atmosfera por meio da evapotranspiração. As maiores máximas foram ser observadas nos meses de novembro, março, janeiro, respectivamente, meses que apresentam altos índices pluviométricos, conforme descrito por Duarte (2022).

Os meses que apresentam menores valores de ETa foram observados nos mapas correspondentes aos meses de maio a setembro (Figura 19), onde com base na análise da sazonalidade anual, nota-se que esses são os meses de menor precipitação, na BH conforme descrito por Sousa (2021).

Outro aspecto observado e que fica perceptível nos mapas, é que em todos os meses em alguns pontos, independentemente da época do ano, os valores de ETa continuam baixos, esses pontos foram basicamente identificados como áreas urbanas, corpos hídricos, ou mesmo culturas temporárias, tal afirmativa confirma-se ao se analisar o mapa de uso e ocupação da terra para o ano de 2020 na BH do rio Sorocabuçu (Figura 17), visto no tópico anterior.

Os maiores valores médios foram observados nos meses de janeiro e novembro, onde verifica-se altos valores de ETa, verificando-se nos mapas mensais que na parte sudeste, sul e sudoeste da BH ocorrem as maiores quantidades de transporte hídrico. Nessa região da BH se localizam grande parte dos remanescentes florestais da APA de Itupararanga (MAIA JÚNIOR e LOURENÇO, 2020).

Figura 19 - Espacialização da ETa no ano de 2020 na BH do rio Sorocabuçu.



Fonte: Elaborado pelo autor.

É importante destacar que a análise do regime climático é fundamental para entender o comportamento das águas superficiais, subterrâneas e seu transporte para atmosfera em uma

bacia hidrográfica, bem como para planejar e gerenciar de forma eficiente os recursos hídricos. As informações sobre o clima, incluindo a temperatura, índices pluviométricos, evapotranspiração de referência e a temperatura do ar, podem ser monitoradas através de estações meteorológicas, porém, não foram encontrados esses dados para o ano de 2020 nas estações instaladas dentro da BH do rio Sorocabuçu no município de Ibiúna-SP, por esse motivo buscou-se dados por meio de sensoriamento remoto. A disponibilidade dessas informações pode contribuir de sobremaneira com o processo de manejo hídrico na região, sendo possível avaliar a disponibilidade de água para a geração de energia, agricultura e proteção dos remanescentes florestais existentes (Silva et al., 2017; Alvino et al., 2021).

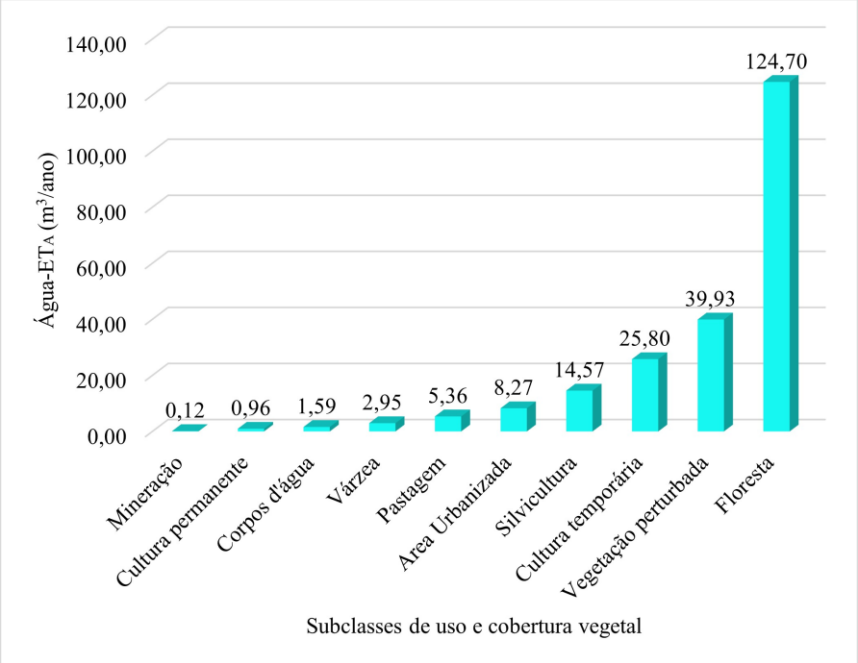
5.7.1 Contribuição da ETa no transporte de água para a atmosfera na Bacia Hidrográfica do Rio Sorocabuçu

Com base na estimativa da ETa na BH do Rio Sorocabuçu, analisou-se a contribuição de transporte hídrico anual por meio da evapotranspiração para cada subclasse de uso de solo dentro da área estudada. A Figura 20 mostra quantidade de água (m^3) transportado para a atmosfera por meio da ETa no ano de 2020, com a contribuição de cada subclasse de uso da terra. A estimativa total de água transportada para a atmosfera proveniente da BH do Rio Sorocabuçu foi de 224,25 m^3, desse total, 0,12 m^3 corresponde a mineração, 0,96 m^3 cultura permanente, 1,56 m^3 corpos d'água, 2,95 m^3 várzea, 5,36 m^3 pastagem, 8,27 m^3 área urbanizada, 14,57 m^3 silvicultura, 25,80 m^3 cultura temporária, 39,93 m^3 vegetação perturbada e 124,7 m^3 floresta, respectivamente.

De modo geral, todas as subclasses de uso da terra detectadas na área de estudo contribuem com o transporte hídrico para a atmosfera, porém, verificou-se que todos os usos que possuem influência antrópica impactam significativamente esse processo, pois a somatória de todos os usos antrópicos que apresentaram uma área de 10.531,17 ha, emitiram 95,02 m^3 de água, enquanto as três subclasses de ecossistemas naturais, com uma área de 9.744,67 ha, emitiram 129,23 m^3, mais que os usos antrópicos.

Dos valores supramencionados, incluiu-se como uso antrópico a subclasse de áreas vegetacional perturbada, que de acordo com Sousa (2021), são áreas abandonadas provenientes de usos antrópicos diversos em processo de regeneração, sendo que na BH do rio Sorocabuçu abrange uma área de 3.632,26 ha, e sozinha emitiu 39,93 m^3 de água, sendo a segunda subclasse que mais contribuiu com a quantidade total transportada.

Figura 20 - Transporte hídrico para atmosfera por meio da ETa no ano de 2020 na BH do rio Sorocabuçu.



Fonte: Elaborado pelo autor.

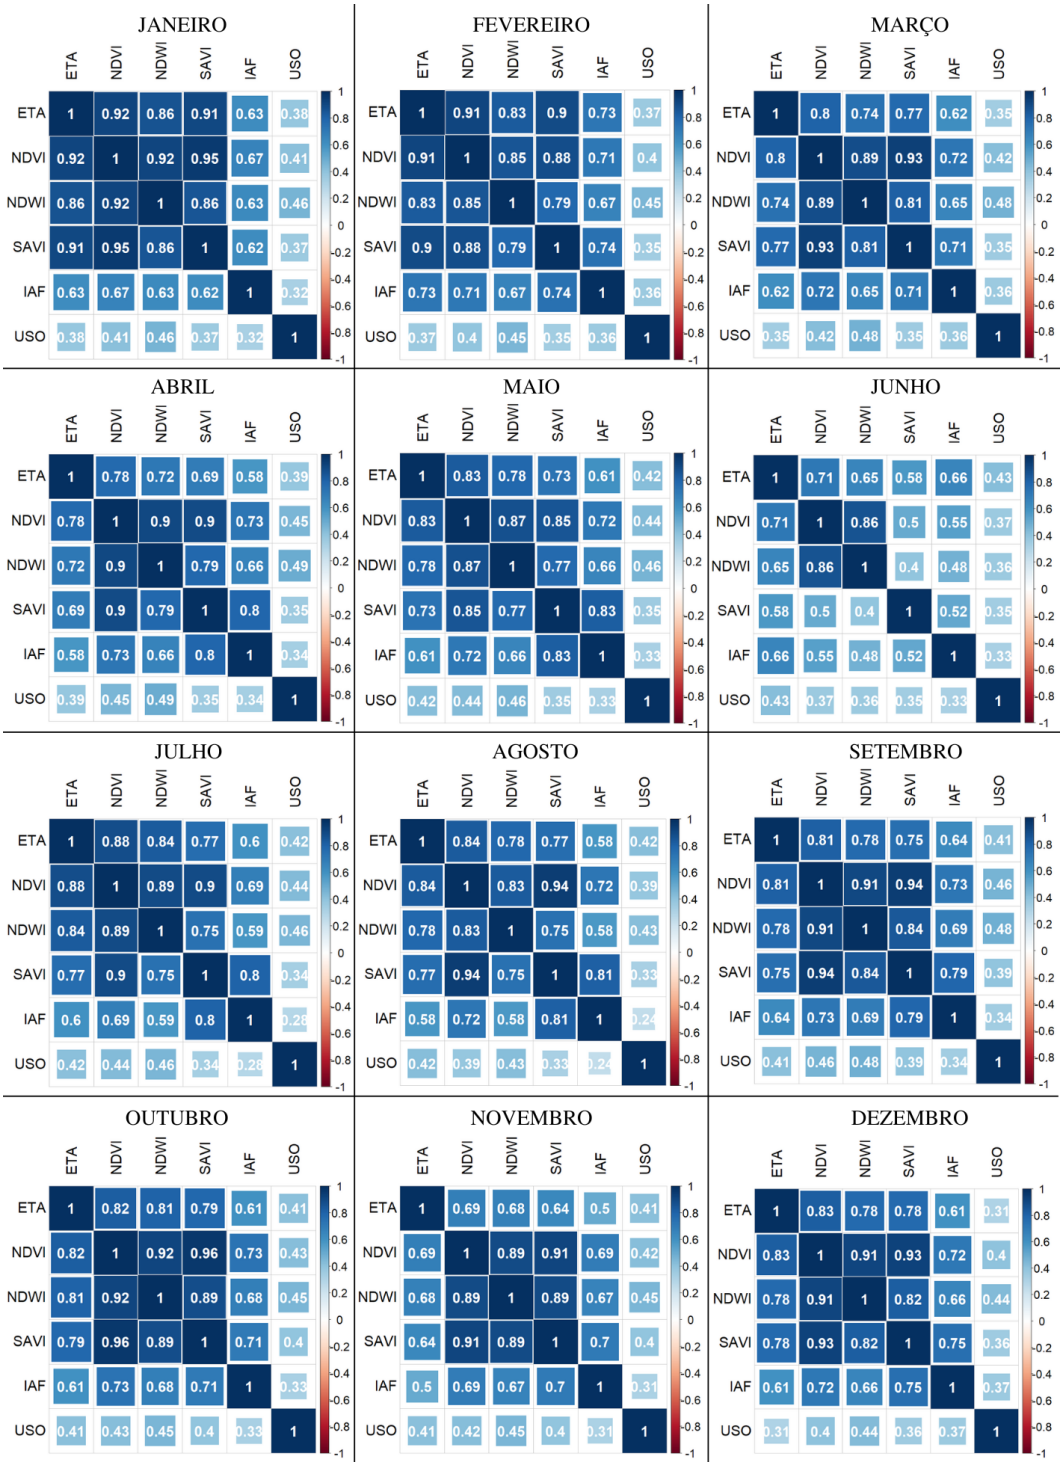
A subclasse que mais contribuiu com o transporte hídrico foi justamente a área florestal remanescente do bioma Mata Atlântica, pela classificação dos usos e ocupação da terra abrangeu uma área de 9.220,06 ha, e um transporte hídrico de 124,7 m^3. Quando se somou a contribuição de corpos d'água e área de várzea, que também são ecossistemas naturais, o total transportado foi de 129,23 m^3.

Diante dessa análise, verificou-se a evidente contribuição da vegetação na capacidade evaporativa na BH do rio Sorocabuçu. Thornthwaite (1948) já mencionava a importância da cobertura vegetal, a umidade do solo e o tipo de manejo adotado na influência de maiores ou menores quantidades de transporte de água para atmosfera. Assim como em outros biomas, como na floresta amazônica, as florestas contribuem para a manutenção das chuvas e da umidade local, regional e até a nível nacional (Marengo et al., 2018). De acordo com estudos de Jung et al., 2010 e Zhu et al., 2014 citado por Wang et al., (2019), cerca de 60% da formação de precipitação na atmosfera é proveniente da evapotranspiração e, em áreas com perfil florestal esse percentual pode chegar a cerca de 90%, características semelhantes a BH do Rio Sorocabuçu em Ibiúna-SP.

5.8 Análise estatística (regressão linear múltipla)

Para verificar a influência das variáveis na ETa, a Figura 21 mostra a análise da correlação de Pearson com os índices biofísicos estudados nesta pesquisa.

Figura 21 - Análise da correlação dos índices biofísicos com evapotranspiração real.



Fonte: Elaborado pelo autor.

Para verificar a relação dos índices biofísicos (NDVI, NDWI, SAVI, IAF) e o uso e ocupação da terra com a ETa, os dados obtidos foram submetidos a uma análise de regressão linear com múltiplas variáveis, onde a ETa foi determinada como variável dependente e as demais admitidas como variáveis independentes. De acordo com Asuero et al., (2006), a proximidade dos valores do coeficiente de correlação a ±1, indica uma forte associação linear positiva ou negativa entre as variáveis, enquanto valores próximos a zero sugerem baixa ou nenhuma associação linear entre elas. Os valores para a correlação de Pearson podem também ser classificada da seguinte forma: para valores iguais a 0 tem-se uma correlação nula; de 0 a 0,3 correlação fraca; de 0,3 a 0,6 correlação moderada; 0,6 a 0,9 correlação forte e; 0,9 a 1,0 correlação muito forte (CALLEGARI-JACQUES, 2009).

A Figura 21 mostra um panorama geral da influência dos índices biofísicos e o uso e ocupação da terra na ETa para cada mês do ano de 2020, nesse sentido, é possível observar o comportamento de cada uma das cinco variáveis. No mês de janeiro as maiores correlações foram observadas no NDVI (0,92) e SAVI (0,91), seguido do NDWI (0,86), sendo que no referido mês observou-se as maiores correlações com a ETa de todo o ano.

Em relação ao NDVI (Figura 10 – tópico 6.2), nota-se que ele apresentou exatamente em janeiro elevados valores, possivelmente proporcionado pela disponibilidade hídrica comum dessa época do ano concomitante a elevada produção fotossintética na região de Ibiúna-SP, município onde está inserido a BH do rio Sorocabuçu, contribuindo para justificar a correlação muito forte com a ETa (EMBRAPA, 2019). De forma análoga, o SAVI apresentou o mesmo comportamento, haja vista que esse índice também analisa a saúde fenológica da vegetação atenuando a interferência óptica causada pela reflectância do solo (HUETE, 1988; REN et al., 2018), justificando o segundo maior coeficiente para o mês de janeiro. Seguindo a mesma hipótese, o terceiro índice que apresentou uma forte correlação no mês de janeiro foi o NDWI (0,86), variável que está intrinsecamente relacionada à quantidade de água a nível celular na vegetação, e que tem relação direta com o potencial de transpiração das plantas, fator que contribui diretamente para aumentar os índices de evapotranspiração (LOPES et al., 2020; STOY et al., 2019).

Para o IAF, que permite inferências sobre a projeção do dossel vegetativo sobre o solo e a radiação fotossinteticamente ativa (*fPAR*) que a vegetação consegue absorver (GAMEIRO et al., 2016), observou-se no mês de fevereiro a maior correlação, sendo classificada como uma forte correlação (0,73) com a variável dependente, como se pode observar na Figura 16 – tópico 6.5, a distribuição espacial para o mês de fevereiro. Nos demais meses do ano a correlação permanece com uma correlação moderada a forte (CALLEGARI-JACQUES, 2009). De acordo

com Zhu et. al., (2022), o aumento da *fPAR*, da temperatura e da velocidade do vento influenciam positivamente nas quantidades de transpiração vegetal, justificando as correlações com esse índice biofísico.

O uso e ocupação da terra, apresentou uma correlação moderada com a ETa, sendo a variável independente que mostrou as menores correlações ao longo do ano. A melhor correlação para essa variável foi observada no mês de junho (0,43), seguido dos meses de maio, julho e agosto, com coeficiente de determinação de 0,42. Notou-se ainda que não houve uma associação dos melhores resultados à data da cena utilizada para realizar a classificação das subclasses de uso e ocupação da terra que foi do dia 26 de setembro de 2020, que apresentou para o referido mês uma correlação de 0,41.

Em diversos estudos que investigaram a estimativa da evapotranspiração por meio de dados orbitais, é sabido a influência das características do uso e ocupação da terra na determinação de percentuais maiores ou menores no transporte de água para atmosfera (GUERSCHMAN et al., 2021; STOY et al., 2019; ALLEN et al., 1998; TUCCI e SILVEIRA, 2020). Conforme o tópico 6.7.1 desta pesquisa, onde analisou-se a contribuição de cada subclasse de uso e ocupação da terra no transporte hídrico para a atmosfera, foi possível observar que nas áreas com a ocorrência de floresta ombrófila densa, pertencente ao bioma Mata Atlântica, foi a subclasse que mais contribuiu com os resultados de ETa e o consequente transporte de água para a atmosfera, nesse sentido, espera-se uma maior dependência dessa variável independente à dependente.

Nesse sentido, o resultado obtido, pode ser justificado pela baixa contribuição no processo de evapotranspiração de algumas subclasses como área de mineração, culturas permanentes e corpos hídricos, além disso, a entrada dos dados de usos e ocupação da terra na análise estatística é incialmente transformada em dados fatoriais e posteriormente ocorre o escalonamento dos dados para aplicação da estatística, o que também pode ter refletido no resultado das correlações.

Contudo, ao analisarmos Figura 21, em uma avaliação geral da correlação das variáveis independentes ao longo dos meses do ano de 2020, nota-se que todas foram classificadas como correlação: moderada (0,3 a 0,6), forte (0,6 a 0,9) e muito forte (0,9 a 1,0) de acordo com a classificação de Callegari-Jacques (2009). Nesse contexto, estudar a relação dos índices biofísicos atrelado a estimativa precisa da ETa figura-se como atividade essencial para o entendimento da importante função da vegetação na disponibilidade e gerenciamento dos recursos hídricos, o que essencial no emprego de práticas sustentáveis no processo de manejo e gestão de bacias hidrográficas (WAGLE, et, al., 2020).

6 CONCLUSÕES

Por meio do desenvolvimento desta pesquisa foi possível elaborar o mapeamento do uso da terra e cobertura vegetal do ano de 2020 proporcionando a análise da dinâmica territorial na BH do rio Sorocabuçu, constatando-se que 0,13% área de mineração, 0,42% cultura permanente, 1,17% corpos hídricos, 1,42% área de várzea, 2,63 Pastagem, 6,88% silvicultura, 7,01% área urbanizada, 16,95 cultura temporária, 17,91 área vegetacional perturbada e 45,47% floresta.

Através dos mapas de índices biofísicos de NDVI, NDWI, SAVI, e IAF foi possível compreender a relação de cada um desses parâmetros estudados para a BH ano de 2020 com a ETa. De modo geral a análise da correlação de Pearson das variáveis independentes ao longo dos meses do ano de 2020, mostraram que todas foram classificadas como correlação: moderada (0,3 a 0,6), forte (0,6 a 0,9) e muito forte (0,9 a 1,0), sendo que as maiores correlações foram observadas no NDVI (0,92) e SAVI (0,91), seguido do NDWI (0,86), apresentando comportamento semelhante ao longo dos demais meses do ano.

Na análise do potencial dos dados de SAR do Sentinel-1 para determinar o NDVI e NDWI em uma área sob diferentes usos da terra por meio de quatro técnicas de regressão (RL, SVM, RF e ANN), tendo como variáveis independentes os dados SAR e como variáveis dependentes os índices NDVI e NDWI obtidos por meio do Sentinel-2, método desenvolvido pela necessidade da estimativa desses índices em épocas do ano em que a cobertura de nuvem impedem tal tarefa, os resultados obtidos mostraram que existe correlação muito boa entre os coeficientes de retroespalhamento das polarizações VV e VH do SAR com o NDVI e NDWI obtidos por meio de dados do Sentinel-2 que utilizam a metodologia de Rouse et al. (1973) e Gao (1996), respectivamente.

Os modelos de regressão utilizados apresentaram desempenhos semelhante, com os melhores valores de R^2 para o SVM, porém os maiores valores de MAE, MSE e RMSE. O método RL apresentou desempenho intermediário, e os métodos RF e ANN obtiverem desempenhos considerados iguais, porém o teste de variância e *post hoc* que determinou a diferença média nos níveis dos modelos com base no teste de Bonferroni a 95% de confiança, para o NDVI e NDWI, concluiu que o método ANN apresentou melhor desempenho na determinação do NDVI e RF para NDWI, indicando que esses dados podem ser utilizados como complemento para o monitoramento fenológico da vegetação em períodos em que os sensores ópticos são limitados por condições atmosféricas adversas.

Vale ressaltar que o desempenho dos modelos de regressão pode ter sido influenciado pelas diferentes condições climáticas e datas de aquisição das cenas, uma vez que os piores desempenhos nos modelos foram observados justamente nos períodos com maiores índices de precipitação, associados ao maior intervalo entre a data de aquisição de dados do Sentinel-1 e Sentinel-2.

Com relação a estimativa da contribuição da ETa, dos diversos usos e ocupação da terra na BH do Rio Sorocabuçu, no transporte de água para a atmosfera, a maior contribuição foi observada na subclasse de floresta remanescente do bioma Mata Atlântica, que apresentou uma área de 9.220,06 ha, e um transporte hídrico de 124,7 m^3 de água por ano para a atmosfera, e quando se inclui todos os usos naturais (não antrópicos) nos cálculos a quantidade de água anual transferida chega a 129,23 m^3.

A partir dos dados orbitais do programa espacial Copernicus (Sentinel-1 e Sentinel-2) e dados meteorológicos do ERA5, ambos fornecidos pela Agência Espacial Europeia – ESA, por meio do emprego de técnicas de geoprocessamento e processamento de dados, foi possível produzir informações necessárias para compreender como a evapotranspiração é influenciada por fatores relacionados a mudança na cobertura e uso da terra, a alteração da temperatura e disponibilidade de água no solo e vegetação, evidenciando-se que a evapotranspiração aumenta em áreas onde há mais cobertura vegetal, enquanto sua redução é observada em áreas de degradação da cobertura florestal ou usos antrópicos diversos.

O pacote Agriwater se mostrou eficaz na estimativa da ETa utilizando dados do sensor Sentinel-2, mesmo sem a banda termal. Os dados meteorológicos do ERA5 também forneceram informações confiáveis, figurando-se como uma alternativa para áreas onde os dados de estações agrometeorológicas eletrônicas ou manuais são inexistentes, além da possibilidade de levantamento em escala regional de diversos parâmetros que fornecem informações de grande importância para diversos ecossistemas. Esses dados são fundamentais para a compreensão da interação entre a água, a vegetação e o clima, e para o desenvolvimento de políticas e ações de conservação e gestão que propiciam a preservação dos recursos naturais.

Como recomendações, em relação aos dados SAR , sugere-se que em estudos futuros, a análise de correlação entre os dados de sensores ópticos e radar com vista em determinação dos índices de vegetação, sejam realizadas levando em consideração as diferentes classes de uso da terra e vigor vegetativo definidos na literatura, o que pode minimizar a influência da heterogeneidade da vegetação, e por consequente, a correlação entre o retroespalhamento do SAR e os índices de vegetação, podendo melhorar o desempenho dos modelos de regressão.

A respeito da análise e relação dos índices biofísicos, uso da terra e a evapotranspiração, recomenda-se que os estudos sejam realizados abrangendo uma faixa temporal maior, além de adicionar aos futuros estudos, um histórico climático de precipitação, temperatura e umidade para análise e comparação com os resultados, fornecendo assim maior subsídio para o entendimento da evapotranspiração ao longo dos dias, meses e anos.

REFERÊNCIAS

AGRITEMPO – Sistema de Monitoramento Agrometeorológico. Disponível em: https://www.agritempo.gov.br/agritempo/index.jsp, acesso em: 30/10/2020.

AGUIRRE-GARCÍA, S. D.; ARANDA-BARRANCO, S.; Nieto, H.; SERRANO-ORTIZ, P.; SÁNCHEZ-CAÑETE, E. P.; GUERRERO-RASCADO, J. L. Modelling actual evapotranspiration using a two source energy balance model with Sentinel imagery in herbaceous-free and herbaceous-cover Mediterranean olive orchards. **Agricultural and Forest Meteorology**, Volume 311, 2021, 108692, ISSN 0168-1923, https://doi.org/10.1016/j.agrformet.2021.108692.

ALLAM, M.; MHAWEJ, M.; MENG, Q.; FAOUR, G.; ABUNNASR, Y.; FADEL, A.; XINLI, H. Monthly 10-m evapotranspiration rates retrieved by SEBALI with Sentinel-2 and MODIS LST data. **Agricultural Water Management**, 1 de janeiro de 2021. https://doi.org/10.1016/j.agwat.2020.106432.

ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. "Evapotranspiração da cultura: Diretrizes para calcular os requisitos de água da cultura." FAO, 1998: 50.

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

ALLEN, R.G.; MORTON, C.; KAMBLE, B.; KILIC, A.; HUNTINGTON, J.; THAU, D.; GORELICK, N.; ERICKSON, T.; MOORE, R.; TREZZA, R.; RATCLIFFE, I.; ROBISON, C. EEFlux: A Landsat-based evapotranspiration mapping tool on the Google Earth Engine. 2015 ASABE / IA Irrigation symposium: emerging technologies for sustainable irrigation—a tribute to the career of terry howell, Sr Conference Proceedings. St. Joseph, MI: ASABE; 2015. p. 1-11. https://doi.org/10.13031/irrig.20152143511.

ALVARES, C.A., STAPE, J.L., SENTELHAS, P.C., GONÇALVES, J.L.M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013. https://doi.org/10.1127/0941-2948/2013/0507

ALVES, E. D. L.; BIUDES, M. S. "Padrões da Temperatura do Ar e da Umidade Relativa: Estudo de Caso no Campus de Cuiabá da Universidade Federal de Mato Grosso." 2012: 516.

ALVES, W. S.; MARTINS, A. P.; PÔSSA, É. M.; MOURA, D. M. B.; MORAIS, W. A.; FERREIRA, R. S.; SANTOS, L. N. S. Geotechnologies applied in the analysis of land use and land cover (LULC) transition in a hydrographic basin in the Brazilian Cerrado, **Remote Sensing Applications: Society and Environment**, Volume 22, 2021, 100495, ISSN 2352-9385. https://doi.org/10.1016/j.rsase.2021.100495

ALVINO, F. C. G.; ALEMAN, C. C.; FILGUEIRAS, R.; ALTHOFF, D.; CUNHA, F. F. "VegETation Indeces for irrigated corn monitoring." **Engenharia Agrícola**, 2021: 322-333. https://doi.org/10.1590/1809-4430-Eng.Agric.v40n3p322-333/2020

ANDRADE, R. G.; RODRIGUES, C. A. G.; SANCHES, I. D.; TORRESAN, F. E.; QUARTAROLI, C. F. Uso de Técnicas de Sensoriamento Remoto na Detecção de Processos de Degradação de Pastagens. **Revista Engenharia Na Agricultura - REVENG**, v. 21, n. 3, 234–243. 2013. https://doi.org/10.13083/reveng.v21i3.368

ARSLAN, A. E.; ERTEN, E.; INAN, M. A comparative study for obtaining effective Leaf Area Index from single Terrestrial Laser Scans by removal of wood material. **Measurement**, Volume 178, 2021, 109262, ISSN 0263-2241, https://doi.org/10.1016/j.measurement.2021.109262

ASUERO, A. G.; SAYAGO, A.; GONZÁLES, A. G. The correlation Coefficient: An Overview. **Critical Reviews in Analytical Chemistry**, v. 36. p. 41–59. 2006. https://doi.org/10.1080/10408340500526766

BAI, Z.; FANG, S.; GAO, J.; ZHANG, Y.; JIN G.; WANG, S.; ZHU, Y.; XU, J. 2020. Could VegETation Index be Derive from Synthetic Aperture Radar? – The Linear Relationship between Interferometric Coherence and NDVI. **Scientific Reports**, v. 10. https://doi.org/10.1038/s41598-020-63560-0

BARGIEL, D. 2017. A new method for crop classification combining time series of radar images and crop phenology information. **Remote Sensing of Environment**. v. 198, p. 369-383. https://doi.org/10.1016/j.rse.2017.06.022

BASTIAANSSEN, W.G.M.; PELGRUM, H.; WANG, J.; MA, Y.; MORENO, J.F.; ROERINK, G.J.; VAN DER WAL, T. A remote sensing surface energy balance algorithm for land (SEBAL).: Part 2: Validation, **Journal of Hydrology**, Volumes 212–213, 1998, Pages 213-229, ISSN 0022-1694, https://doi.org/10.1016/S0022-1694(98)00254-6

BERTONI, J., e F. LOMBARDI NETO. Conservação do solo. São Paulo: **Ícone**, 2014.

BEU, S. E.; SANTOS, A. C. A. dos; CASALI, S. Biodiversidade na APA Itupararanga: condições atuais e perspectivas futuras. 1. ed. São Paulo: SecrETaria do Meio Ambiente, 2011. E-book. cap. 3, p. 33-56. Disponível em: http://apaitupararanga2.blogspot.com/2011/10/biodiversidade-na-apa-itupararanga.html Acesso em 17 de agosto de 2022.

BOSSLE, R. C. QGIS do ABC ao XYZ. Curitiba: **Íthala**, 2016.

BOUMAN, B. A. Accuracy of estimating the leaf area index from vegETation indices derived from crop reflectance characteristics, a simulation study. International Journal of Remote Sensing, Taylor & Francis Ltd, London, UK. v. 13, 3069-3084. 1992. https://doi.org/10.1080/01431169208904103

BOUSBIH, S.; ZRIB, M.; LILI-CHABAANE, Z.; BAGHDADI, N.; HAJU, M. E.; GAO, Q.; MOUGENOT, B. Potential of Sentinel-1 Radar Data for the Assessment of Soil and Cereal Cover Parameters. **Sensors**, v. 17, n. 11. 2017. https://doi.org/10.3390/s17112617

BREIMAN, L. Random forests. Machine Learning. v. 45, n. 1. p. 5-32. 2001. https://doi.org/10.1023/A:1010933404324

CALLEGARI-JACQUES, S. M. Bioestatística: princípios e aplicações. Tradução. [s.l.] **Artmed Editora**, 2009.

CAMPOS, S., E. L. PIROLI, e S. M. BENINI. Geoprocessamento aplicado a análises ambientais. Tupã: **ANAP**, 2015.

CARVALHO, A. T. F. "Bacia hidrográfica como unidade de planejamento: discussão sobre os impactos da produção social na gestão de recursos hídricos no Brasil." **Caderno Prudentino de Geografia**, 1 de Janeiro de 2020: 140-161.

CASA, A.; OVANDO, G.; BRESSANINI, L.; MARTÍNEZ, J.; DÍAZ, G.; MIRANDA, C. Soybean crop coverage estimation from NDVI images with different spatial resolution to evaluate yield variability in a plot. ISPRS **Journal of Photogrammetry and Remote Sensing**, v. 146, p. 531-547. 2018. https://doi.org/10.1016/j.isprsjprs.2018.10.018

CDS - Climate Data Store, Copernicus. ERA5-Dados horários terrestres de 1950 até o presente. 12-07-2019. Acesso em 05 de agosto de 2022. Disponível em < https://cds-dev.copernicus-climate.eu/cdsapp#!/dataset/reanalysis-era5-land?tab=overview>. https://doi.org/10.24381/cds.e2161bac

CHANG, J. G.; SHOSHANY, M.; Oh, Y. Polarimetric Radar VegETation Index for Biomass Estimation in Desert Fringe Ecosystems. IEEE **Transactions on Geoscience and Remote Sensing**. v. 56, n. 12. p. 7102-7108. 2018. https://doi.org/10.1109/TGRS.2018.2848285

Chen, J. M., e J. Liu. "Evolution of evapotranspiration models using thermal and shortwave remote sensing data." **Remote Sensing of Environment,** v. 237, p. 111594, ISSN 0034-4257. 2020. https://doi.org/10.1016/j.rse.2019.111594

CHINTALA, S.; HARMYA, T. S.; KAMBHAMMETTU, B. V. N. P.; MOHARANA, S.; DUVVURI, S. Modelling high-resolution Evapotranspiration in fragmented croplands from the constellation of Sentinels, **Remote Sensing Applications: Society and Environment,** v. 26, p. 100704, ISSN 2352-9385. 2022. https://doi.org/10.1016/j.rsase.2022.100704.

CHRISTOFOLLETI, A. Modelagens de sistemas ambientais. São Paulo: **Edgard Blucher**, 1999.

CIELO-FILHO, R.; BAITELLO, J. B.; PASTORE, J. A.; AGUIAR, O. T.; SOUZA, S. C. P. M.; TONIATO, M. T. Z.; LIMA, C. R.; RIVEIRO, A. P. Ampliando a densidade de colETas botânicas na região da bacia hidrográfica do Alto Paranapanema: Caracterização florística da Floresta Estadual e da Estação Ecológica de Paranapanema. **Biota Neotropica**, v. 9, n. 3, p. 256-276. 2009. https://doi.org/10.1590/S1676-06032009000300025

CORTES, C., VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, p. 273-297. 1995. https://doi.org/10.1007/BF00994018

COSTA, J.O.; JOSÉ, J.V.; WOLFF, W.; OLIVEIRA, N.P.R.; OLIVEIRA R.C.; RIBEIRO, N.L.; COELHO, R.D.; SILVA, T.J.A.; BONFIM-SILVA, E.M.; SCHLICHTING, A.F. Spatial variability quantification of maize water consumption based on Google EEflux tool, **Agricultural Water Management**, v. 232, p. 106037, ISSN 0378-3774. 2020. https://doi.org/10.1016/j.agwat.2020.106037.

DAEE - DEPARTAMENTO DE ÁGUAS E ENERGIA ELÉTRICA. 2020. Banco de dados hidrológicos. 2020. Disponível em: <http://www.hidrologia.daee.sp.gov.br/>. Acesso em: 23 de março de 2020.

DAEE. Dados diários mensais de precipitação nas estações pluviométricas Ibiúna (E4-047) e Mato do Gado (E4-131)]. 2019. Base de dados. Disponível em: http://www.hidrologia.daee.sp.gov.br/. Acesso em: 15 de março de 2021.

DUBREUIL, V.; FANTE, K. P.; PLANCHON, O.; SANT'ANNA NETO, J. L. Climate change evidence in Brazil from Köppen's climate annual types frequency. **International Journal of Climatology**. p. 1 - 11, 2018. https://doi.org/10.1002/joc.5893.

DUCHEMIN, B.; HADRIA, R.; ERRAKI, S.; BOULET, G.; MAISONGRANDE, P.; CHEHBOUNI, A.; ESCADAFAL, R.; EZZAHAR, J.; HOEDJES, J.C.B.; KHARROU, M.H.; KHABBA, S.; MOUGENOT, B.; OLIOSO, A.; RODRIGUEZ, J.-C.; SIMONNEAUX, V. Monitoring wheat phenology and irrigation in Central Morocco: On the use of relationships between evapotranspiration, crops coefficients, leaf area index and remotely-sensed vegetation índices Agric. **Water Manag**., v. 79, n. 1, p. 1-27. 2006. https://doi.org/10.1016/j.agwat.2005.02.013

DUTTA, D.; GUPTA, S.; CHAKRABORTY, A. Effect of different land use land cover on surface heat budget – A case study from a tropical humid region of India, Remote Sensing Applications: Society and Environment, v. 25, n. 100675, ISSN 2352-9385. 2022. https://doi.org/10.1016/j.rsase.2021.100675.

ELBEIH, S. F. Evaluation of agricultural expansion areas in the Egyptian deserts: A review using remote sensing and GIS. **The Egyptian Journal of Remote Sensing and Space** Science, v. 24, n. 3, Part 2, Pages 889-906, ISSN 1110-9823. 2021. https://doi.org/10.1016/j.ejrs.2021.10.004

EMBRAPA, Empresa Brasileira de Pesquisa Agropecuária -. Banco de Dados Climáticos do Brasil. Acesso em: 21 de Maio de 2019. Disponível em: <https://www.cnpm.embrapa.br/projetos/bdclima/>

ESA - The Copernicus Open Access Hub. Acesso em: 03/11/2020. Disponível em: https://scihub.copernicus.eu/

EVANS, J. P.; MENG, X. ; MCCABE, M. F. Land surface albedo and vegETation feedbacks enhanced the millennium drought in south-east Australia. Hydrology and Earth System Sciences, v. 21, n. 1, p. 409-422, 2017. https://doi.org/10.5194/hess-21-409-2017.

FEARNSIDE, P. M. "A água de São Paulo." **Ciência Hoje**, p. 63-65. 2004.

FERNÁNDEZ, M.; PETER, H.; ARNOLD, D.; DUAN, B.; SIMONS, W.; WERMUTH, M.; HACKEL, S.; FERNÁNDEZ, J.; JÄGGI, A.; HUGENTOBLER, U.; VISSER, P.; FÉMÉNIAS, P. Copernicus Sentinel–1 POD Reprocessing Campaign, Advances in Space Research, ISSN 0273-1177. 2022. https://doi.org/10.1016/j.asr.2022.04.036.

FERREIRA SILVA, C. O.; TEIXEIRA, A. H. C.; MANZIONE, R. L. Agriwater: An R package for spatial modelling of energy balance and actual evapotranspiration using satellite

images and agrometeorological data, **Environmental Modelling & Software**, v. 120, p. 104497, ISSN 1364-8152. 2019. https://doi.org/10.1016/j.envsoft.2019.104497

FILGUEIRA DE SÁ, T. F., J. F. COSTA FILHO, P. R. M. FRANCISCO, e J. M. BRAGA JÚNIOR. Sistema de Informações Geográficas (SIG) Para a Gestão Ambiental de Bacias Hidrográficas. Recife, Pernambuco, 27 de junho de 2010.

FILGUEIRAS, R.; MANTOVANI, E.C.; ALTHOFF, D.; FERNANDES FILHO, E. I.; CUNHA, F.F. Crop NDVI Monitoring Based on Sentinel 1. **Remote Sensing**, v. 11, n. 12. 2019. https://doi.org/10.3390/rs11121441

FITZ, P. R. Geoprocessamento sem complicação. São Paulo: **Oficina de Textos**, 2008.

FLETCHER, K. Sentinel-1: ESA's Radar Observatory Mission for GMES Operational Services. European Space Agency. SP-1322/1, March 2012. Disponível em: https://sentinel.esa.int/documents/247904/349449/S1_SP-1322_1.pdf. Acesso em: 05 de abril de 2020.

FLORENZANO, T. G. Imagens de Satélite para estudos. São Paulo: **Oficina de Textos**, 2002.

FOOLAD, F.; BLANKENAU, P.; KILIC, A.; ALLEN, R.G.; HUNTINGTON, J.L.; ERICKSON, T.A.; OZTURK, D.; MORTON, C.G.; ORTEGA, S.; RATCLIFFE, I.; FRANZ, T.E.; THAU, D.; MOORE, R.; GORELICK, N.; KAMBLE, B.; REVELLE, P.; TREZZA, R.; ZHAO, W.; ROBISON, C.W. Comparison of the Automatically Calibrated Google Evapotranspiration Application—EEFlux and the Manually Calibrated METRIC Application. **Preprints.** 2018070040. 2018. https://doi.org/10.20944/preprints201807.0040.v1.

FREITAS, B. F., G. A. BOGGIONE, E M. KAMPEL. "Fusão de bandas MODIS na condição geométrica de sunglint para estudos oceanográficos." João Pessoa: Trabalho apresentado no XVII Simpósio Brasileiro de Sensoriamento Remoto -SBSR, Abril de 2015.

FRITSCH, S.; GUENTHER, F.; WRIGHT, M. N. neuralnet: Training of Neural Networks. R package version 1.44.2. 2019. Disponível em: https://CRAN.Rproject.org/package=neuralnet

FUNDAÇÃO FLORESTAL do Estado de São Paulo. Plano de manejo da área de proteção ambiental (APA) Itupararanga. São Paulo: SecrETaria de Infraestrutura e Meio Ambiente, 2010. Acesso em: 17 de novembro de 2022. Disponível em: https://www.infraestruturameioambiente.sp.gov.br/fundacaoflorestal/planos-demanejo/planos-de-manejo-planos-concluidos/plano-de-manejo-apa-itupararanga/ .

GAGNON, L.; JOUAN, A. Speckle filtering of SAR images: a comparative study between complex-wavelet-based and standard filters", Proc. SPIE, **Wavelet Applications in Signal and Image Processing**, v. 3169. 1997. https://doi.org/10.1117/12.279681

GAMEIRO S., TEIXEIRA C.P.B., SILVA NETO T.A.; LOPES M.F.L., DUARTE C.R., SOUTO M.V.S., ZIMBACK C.R.L. Avaliação da cobertura vegetal por meio de índices de vegetação (NDVI, SAVI e IAF) na Sub-Bacia Hidrográfica do Baixo Jaguaribe, CE. **Terræ**, 13(1-2):15-22. 2016. https://www.ige.unicamp.br/terrae/V13/PDFv13/TE067-2.pdf.

GAO, B. C. NDWI - A normalized diference water index for remote sensing of vegETation liquid water from space. **Remote Sensing of Environment**. v. 58, p. 257–266. 1996. https://doi.org/10.1016/S0034-4257(96)00067-3

GASCOIN, S.; DUCHARNE, A.; RIBSTEIN, P.; PERROY, E.; WAGNON, P. Sensitivity of bare soil albedo to surface soil moisture on the moraine of the Zongo glacier (Bolivia). Geophysical Research Letters, v. 36, n 2. (2009). https://doi.org/10.1029/2008GL036377.

GERRA, J. T. Geomorfologia e Meio Ambiente. Rio de Janeiro: **Bertrand**, 2006.

GHARBIA, S. S, T SMULLEN, L GILL, P JOHNSTON, e F PILLA. "Spatially distributed potential evapotranspiration modeling and climate projections." **Science of the Total Environment**, 571–592. 2018.

GIBELIN, A-L.; CALVET, J-C.; ROUJEAN, J-L.; JARLAN, L.; LOS, S. O. Ability of the land surface model ISBA-A-gs to simulate leaf area index at the global scale: Comparison with satellites products. **Journal of Geophysical Research: Atmospheres**, v. 111, n. D18, 2006. https://doi.org/10.1029/2005JD006691

GU, Y.; BROWN, J. F.; VERDIN, J. P.; WARDLOW. B. A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. **Geophysical Research Letters**, v. 34, n. 6, p. 1-6. 2007. https://doi.org/10.1029/2006GL029127

GUERSCHMAN, J. P.; MCVICAR, T. R.; VLEESHOWER, J.; VAN NIEL, T. G.; PEÑA-ARANCIBIA, J. L.; CHEN, Yun. Estimating actual evapotranspiration at field-to-continent scales by calibrating the CMRSET algorithm with MODIS, VIIRS, Landsat and Sentinel-2 data. **Journal of Hydrology**, v. 605, p. 127318, ISSN 0022-1694. 2022. https://doi.org/10.1016/j.jhydrol.2021.127318

WICKHAM, H. ggplot2: Elegant Graphics for Data Analysis. Springer-Verlag New York, 2016. https://ggplot2.tidyverse.org.

HAN, D.; LIU, S.; DU, Y.; XIE, X.; FAN, L.; LEI, L.; LI, Z.; YANG, H.; YANG, G. Crop Water Content ofWinter Wheat Revealed with Sentinel-1 and Sentinel-2 Imagery. **Sensors**. v. 19. 2019. https://doi.org/10.3390/s19184013

HAYASHI, CARMINO, DIEGO SOUZA SARDINHA, e PAULO AUGUSTO ZAITUNE PAMPLIN. Ciências Ambientais: recursos hídricos. Ribeirão Preto - SP: HAYASHI, 2020.

Haykin, S. Neural Networks: A comprehensive Foundation. Macmillan, New York, 842p. 1994.

HOLANDA, A.S.S.; GUERRA, C.E. Monitoramento da vegetação da região do eixo-forte no município de Santarém-PA utilizando imagens dos índices de vegetação NDVI e NDWI. III Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação. pp. 1-5. 2010.

HUETE, A. R. "A Soil-Ajusted VegETation Index (SAVI)." **Remote Sensing of Environment** v. 25, p. 295-309. 1988.

HUETE, A.; DIDAN, K.; LEEUWEN, W. V.; MIURA, T.; GLENN; T. M. MODIS Vegetation Indices. **Land Remote Sensing and Global Environmental Change**, v. 1, p. 579-602. 2010. https://doi.org/10.1007/978-1-4419-6749-7_26

IBGE – Instituto Brasileiro de Geografia e Estatística. Manual Técnico de Uso da Terra. 3° Edição. Rio de Janeiro. 2013. 171p. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/livros/liv81615.pdf>. Acesso em: 12 de janeiro de 2021.

IGC - INSTITUTO GEOGRÁFICO E CARTOGRÁFICO. Ortofoto Leste de SP. 2010. Disponível em: https://datageo.ambiente.sp.gov.br/, Acesso em: 22/04/2022.

JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. An Introduction to Statistical Learning. **Springer**. p. 436. 2013. https://doi.org/10.1007/978-1-4614-7138-7

JEREZ, G. O., D. B. M. ALVES, e V. M. TACHIBANA. "Multivariate analysis of combined GPS/GLONASS point positioning performance in Brazilian regions under different ionospheric conditions." **Journal of Atmospheric and Solar-Terrestrial Physics.** v. 187, p. 1-9. 2019.

JIANG, Z., A. R. HUETE, K. DIDAN, e T. MIURA. "Development of a two-band enhanced vegETation index without a blue band." **Remote Sensing of Environment**. v. 112, p. 3833–3845. (2008):

JOHNSON, R. A., e D. V. WICHERN. Applied Multivariate Statistical Analysis. 6ª. New Jersey: **Pearson**, 2007.

JURGIEL, B. Plug-in Point sampling tool. Samples polygon attributes and raster values from multiple layers at specified sampling points. Versão estável 0.5.3 atualizado em 5 de janeiro de 2020.

KAPLAN, G.; AVDAN, U. Monthly Analysis of Wetlands Dynamics Using Remote Sensing Data. **International Journal of Geo-Information**. v. 7, n. 10. 2018. https://doi.org/10.3390/ijgi7100411

KARATZOGLOU, A., MEYER, D., & HORNIK, K. Support Vector Machines em R. **Journal of Statistical Software**, v. 15, n. 9, p. 1–28. 2006. https://doi.org/10.18637/jss.v015.i09

KOBIYAMA, M. "Curso de capacitação em hidrologia e hidrometria para conservação de mananciais." Florianópolis: UFSC/CTC/ENS/LabHidro, 2009.

LEE, Y.; LEE, S.; JUNG, H-S. Mapping Forest Vertical Structure in Gong-ju, Korea Using Sentinel-2 Satellite Images and Artificial Neural Networks. **Applied sciences**. v. 10, n. 5. 2020. https://doi.org/10.3390/app10051666

LIAW, A.; WIENER, M. Classification and Regression by randomForest. R News, v. 2, n. 3, p. 18-22. 2002. Disponível em: <https://www.researchgate.net/publication/228451484_Classification_and_Regression_by_RandomForest>. Acesso em 17 de março de 2021.

Lira Filho, M. A. S., M. C. B. Sousa, e B. F. Iwata. “DETERMINAÇÃO DE ÍNDICES BIOFISICOS NA BARRAGEMDO BEZERRO, MUNICÍPIO DE JOSÉ DE FREITAS –PI, PARA OS ANOS DE 1991 E 2008.” Revista da Academia de Ciências do Piauí. P. 63–73. 2021.

LIU, W. T. H. Aplicações de sensoriamento remoto. Campo Grande: Ed. **UNIDERP**, 2006.

LOPES, E. R. N.; SALES, J. C. A.; SOUSA, J. A. P.; AMORIM, A. T.; ALBUQUERQUE FILHO, J. L.; LOURENÇO, R.W. Losses on the Atlantic Mata VegETation Induced by Land Use Changes. **Cerne**, v.24 n.2, p. 121 – 132, 2018. https://doi.org/10.1590/01047760201824022512

LOPES, E. R. N.; SOUSA, J. A. P.; SOUZA, J. C.; LOURENÇO, R. W. Spatial Dynamics Of Atlantic Forest Fragments In A River Basin. **Floresta** (online) (Curitiba), v. 50, p. 1053-1062, 2020. http://dx.doi.org/10.5380/rf.v50i1.61076

LUZ, V. G.; SIQUEIRA, C. E. G.; LA-ROTTA, E. I. G.; MIQUILIN, I. O. C.; CORREA FILHO, H. R. (In) Segurança alimentar e nutricional, autopercepção da saúde e uso de Agrotóxicos: o caso dos agricultores familiares de Ibiúna, São Paulo. **Segurança Alimentar e Nutricional**, Campinas, v. 22, n. 2, p. 729-741, 2015. https://doi.org/10.20396/san.v22i2.8642503

MAIA JÚNIOR, L. P.; e LOURENÇO, R. W. Impactos das mudanças no uso e cobertura da terra sobre a variabilidade do albedo na bacia hidrográfica do rio Sorocabuçu (Ibiúna - SP). **Revista Brasileira de Climatologia**, Ano 16 – Vol. 27 – JUL/DEZ 2020. http://dx.doi.org/10.5380/abclima.v27i0.72761

MANDAL, D.; KUMAR, V.; RATHA, D.; DEY, S.; BHATTACHARYA, A.; LOPEZ-SANCHEZ, J. M.; MCNAIRN, H.; RAO, Y. S. Dual polarimetric radar vegETation index for crop growth monitoring using sentinel-1 SAR data. **Remote Sensing of Environment**, v. 247. 2020. https://doi.org/10.1016/j.rse.2020.111954

MARENGO, J. A.; SOUZA Jr., C. M.; THONICKE, K.; BURTON, C.; HALLADAY, K.; BETTS, R. A.; ALVES, L. M.; SOARES, W. R. Changes in Climate and Land Use Over the Amazon Region: Current and Future Variability and Trends. Frente. Front. Earth Sci., 21 December 2018 Sec. **Interdisciplinary Climate Studies**. Volume 6 – 2018. https://doi.org/10.3389/feart.2018.00228

MARTINUZZI, S. et al. Mapping tropical dry forest habitats integrating Landsat NDVI, Ikonos imagery, and topographic information in the Caribbean Island of Mona. Rev. Biol. Trop, v. 56, n. 2, p. 625-639, 2008. https://www.scielo.sa.cr/scielo.php?script=sci_arttext&pid=S0034-77442008000200018

MARZIALETTI, F.; GIULIO, S.; MALAVASI, M.; SPERANDII, M. G.; ACOSTA, A. T. R.; CARRANZA, M. L. Capturing Coastal Dune Natural VegETation Types Using a Phenology-Based Mapping Approach: The Potential of Sentinel-2. **Remote Sensing**, v. 11, n. 12. 2019. https://doi.org/10.3390/rs11121506

MEYER, D.; DIMITRIADOU, E.; HORNIK, K.; WEINGESSEL, A.; LEISCH, F. 2020. e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly:

E1071), TU Wien. R package version 1.7-4. Disponível em: <https://CRAN.Rproject.org/package=e1071>. Acesso em 16 de março de 2021.

MEYER, F. Spaceborne Synthetic Aperture Radar – Principles, Data Access, and Basic Processing Techniques. **SAR Handbook**: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation. Eds. Flores, A., Herndon, K., Thapa, R., Cherrington, E. NASA. 2019. https://doi.org/10.25966/ez4f-mg98.

MKHABELA, M. S.; BULLOCK, P.; RAJ, S.; WANG, S.; YANG, Y. Crop yield forecasting on the Canadian Prairies using MODIS NDVI data. **Agricultural and Forest Meteorology**, v. 151, n. 3, p. 385-393. 2011. https://doi.org/10.1016/j.agrformet.2010.11.012

MOON, M.; LI, D.; LIAO, W.; RIGDEN, A.J.; FRIEDL, M.A. Modification of surface energy balance during springtime: The relative importance of biophysical and meteorological changes, Agricultural and Forest Meteorology, Volume 284, 2020, 107905, ISSN 0168-1923, https://doi.org/10.1016/j.agrformet.2020.107905.

MOREIRA, M. A. Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação. Viçosa: Editora UFV, 2011.

MYNENI, R.B.; HOFFMAN, S.; KNYAZIKHIN, Y.; PRIVETTE, J.L.; GLASSY, J.; TIAN, Y.; WANG, Y.; SONG, X.; ZHANG, Y.; SMITH, G.R.; LOTSCH, A.; FRIEDL, M.; MORISETTE, J.T.; VOTAVA, P.; NEMANI, R.R.; RUNNING, S.W. Global products of vegETation leaf area and fraction absorbed PAR from year one of MODIS data. Remote Sensing of Environment. v. 83, p. 214 – 231. 2002. https://doi.org/10.1016/S0034-4257(02)00074-3

NAGLER, P. L., J. CLEVERLY, E. GLENN, D. LAMPKIN, A, HUETE, e Z. WAN. "Predicting riparian evapotranspiration from MODIS vegETation indices and meteorological data." Remote Sensing of Environment, Volume 94, n. 1, p. 17-30, ISSN 0034-4257. 2005. https://doi.org/10.1016/j.rse.2004.08.009

NASCIMENTO, F. R. do; CUNHA, S. B. da; DE SOUZA, M. J.; DA CRUZ, M. L. B. Diagnóstico Geoambiental da Bacia Hidrográfica Semi-Árida do Rio Acaraú: Subsídios aos Estudos sobre Desertificação. Boletim Goiano de Geografia, Goiânia, v. 28, n. 1, p. 41–62, 2008. https://doi.org/10.5216/bgg.v28i1.4900

NASIRZADEHDIZAJI, R.; SANLI, F. B.; ABDIKAN, S.; CAKIR, Z.; SEJERTEKIN, A.; USTUNER, M. Sensitivity Analysis of Multi-Temporal Sentinel-1 SAR Parameters to Crop Height and Canopy Coverage. **Applied Sciences**. v. 9, n. 4. 2019. https://doi.org/10.3390/app9040655

NICODEMOS, F. E.; RICHMOND, J.C.; HSIA, J.J.; GINSBERG, I.W.; LIMPERIS, T.; 1977. Considerações geométricas e nomenclatura para reflexão. NBS Monografia 160, National Bureau of Standards. Disponível em: <http://graphics.stanford.edu/courses/cs448-05-winter/papers/nicodemus-brdf-nist.pdf> Acesso em: dez de 2021.

OLIVEIRA, T. H.; MACHADO, C. C. C.; SILVA, J. S.; GALVÍNCIO, J. D.; REJANE, P. M. M.; SILVA, B. B. Índice de umidade (NDWI) e análise espaço-temporal do albedo da superfície da bacia hidrográfica do rio Moxotó-PE. **Revista Brasileira de Geografia Física**,

[S.l.], v. 3, n. 2, p. 55-69, nov. ISSN 1984-2295. 2010. https://doi.org/10.26848/rbgf.v3i2.232669

OLIVEIRA, T. H.; MACHADO, C. C. C.; SILVA, J. S.; GALVÍNCIO, J. D.; PIMENTEL, R. M. M.; e SILVA, B. B. "Índice de Umidade (NDWI) e Análise Espaço-Temporal do Albedo da Superfície da Bacia Hidrográfica do Rio Moxotó-PE." Outubro de 2010. https://doi.org/10.26848/rbgf.v3i2.232669

ORSINI, R.; FIORENTINI, M.; ZENOBI, S. Evaluation of Soil Management Effect on Crop Productivity and VegETation Indices Accuracy in Mediterranean Cereal-Based Cropping Systems. **Sensors**. v. 20, n. 12. 2020. https://doi.org/10.3390/s20123383

PANG, G.; CHEN, D.; WANG, X., LAI, H. Spatiotemporal variations of land surface albedo and associated influencing factors on the TibETan Plateau, Science of The Total Environment, v. 804, n. 150100, ISSN 0048-9697. 2022. https://doi.org/10.1016/j.scitotenv.2021.150100.

PAUL, M.; RAJIB, A.; NEGAHBAN-AZAR, M.; SHIRMOHAMMADI, A.; SRIVASTAVA, P. Improved agricultural Water management in data-scarce semi-arid watersheds: Value of integrating remotely sensed leaf area index in hydrological modeling, **Science of The Total Environment**, Volume 791, 148177, ISSN 0048-9697. 2021. https://doi.org/10.1016/j.scitotenv.2021.148177

PEREIRA, A. R., L.R. ANGELOCCI, e P.C. SENTELHAS. Agrometeorologia – Fundamentos e Aplicações Práticas. Guaíba: **Editora Agropecuária Ltda**, 2002.

PEREIRA, A. R., N. A. V. NOVA, e G. C. SEDIYAMA. Evapo(transpi)ração. Piracicaba-SP: **Editora FAELQ**, 1997.

PERIASAMY, S. Significance of dual polarimetric synthetic aperture radar in biomass retrieval: An attempt on Sentinel-1. **Remote Sensing of Environment**, v. 217, p. 537–549. 2018. https://doi.org/10.1016/j.rse.2018.09.003

POLETO, C. Bacias Hidrográficas: Estudos Aplicados. Toledo-PR: **GFM Gráfica & Editora**, 2019.

PONZONI, F. J., e Y. E. SHIMABUKURO. Sensoriamento Remoto. São José dos Campos-SP: **Editora Parêntese**, 2007.

PUTRI, A. F. S.; WIDYATMANTI, W.; UMARHADI, D. A. Sentinel-1 and Sentinel-2 data fusion to distinguish building damage level of the 2018 Lombok Earthquake, Remote Sensing Applications: Society and Environment, v. 26, 100724, ISSN 2352-9385. 2022. https://doi.org/10.1016/j.rsase.2022.100724.

QGIS.org, 2022. QGIS Geographic Information System. QGIS Association. http://www.qgis.org

QUEIROZ, A.T., G.R. BARBOSA, R.M. ZANZARINI, K.A. ALBINO, e P.C. MENDES. "Caracterização da distribuição pluviométrica do Rio Tijuco." Caracterização da distribuição

pluviométrica do Rio Tijuco. Viçosa-MG: ANAIS DO SIMPÓSIO BRASILEIRO DE GEOGRAFIA FÍSICA APLICADA, 2009.

R Core Team (2021). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL: https://www.R-project.org/.

Rafique R, Zhao F, De Jong R, Zeng N, Asrar GR. Global and Regional Variability and Change in Terrestrial Ecosystems Net Primary Production and NDVI: A Model-Data Comparison. *Remote Sensing*. v.8, n. 3, p. 177. 2016; https://doi.org/10.3390/rs8030177

RANZINI, M.; ARCOVA, F. C. S.; CICCO, V. Estação Ecológica de Paranapanema. Caracterização do Meio Físico e Biótico - Hidrologia Superficial. São Paulo: IF, 2014. 26p. Disponível em: < https://www.paranapanema.sp.gov.br/turismo/estacao-ecologica/>. Accesso em 16 de julho de 2021.

REN, H.; ZHOU, G.; ZHANG, F. "Using negative soil adjustment factor in soil-adjusted vegETation index (SAVI) for aboveground living biomass estimation in arid grasslands." **Remote Sensing of Environment** 209 (2018): 439-445.

REN, H.; ZHOU, G.; ZHANG, F. Using negative soil adjustment factor in soil-adjusted vegETation index (SAVI) for aboveground living biomass estimation in arid grasslands, Remote Sensing of Environment, v. 209, p. 439-445, ISSN 0034-4257. 2018. https://doi.org/10.1016/j.rse.2018.02.068.

RODRÍGUEZ-BENITO, C. V.; NAVARRO, G.; CABALLERO, I. Using Copernicus Sentinel-2 and Sentinel-3 data to monitor harmful algal blooms in Southern Chile during the COVID-19 lockdown, Marine Pollution Bulletin, v. 161, Part A, 111722, ISSN 0025-326X. 2020. https://doi.org/10.1016/j.marpolbul.2020.111722

ROSSI, M. Mapa pedológico do Estado de São Paulo: revisado e ampliado. Escala: 1:250.000. São Paulo: Instituto Florestal, 2017. Disponível em: <http://datageo.ambiente.sp.gov.br/>. Acesso em 22 de março de 2021.

ROUSE, J. JR.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. 1973. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegETation. **Remote Sensing Center Texas A&M University College Station**, Texas. 93p. Disponível em: < https://core.ac.uk/download/pdf/42887948.pdf>; acesso em 20/01/2021.

ROUSE, J. JR.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. 1973. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegETation. Remote Sensing Center Texas A&M University College Station, Texas. 93p. Disponível em: < https://core.ac.uk/download/pdf/42887948.pdf>; acesso em 23/02/2021.

RStudio Team (2022). RStudio: Integrated Development Environment for R. RStudio, PBC, Boston, MA URL http://www.rstudio.com/.

SABESP. Relatório anual de qualidade da água 2018: município de Ibiúna. São Paulo: SABESP, 2018. Disponível em: http://www.sabesp.com.br/calandraweb/toq/2018/IBIUNA.pdf. Acesso em 19 de novembro de 2022.

SAHER, R.; STEPHEN, H.; AHMAD, S. Effect of land use change on summertime surface temperature, albedo, and evapotranspiration in Las Vegas Valley, Urban Climate, Volume 39, 100966, ISSN 2212-0955. 2021. https://doi.org/10.1016/j.uclim.2021.100966.

SALLES, M. H. et al., "Avaliação simplificada de impactos ambientais na bacia do alto Sorocaba (SP)." REA – **Revista de estudos ambientais**, p. 6-20. 2008.

SANTOS, P.; AMADO, C.; COELHO, S. T.; LEITÃO, J. P. Stochastic data mining tools for pipe blockage failure prediction. **Urban Water Journal**. V. 14, n, 4. P. 343-353. 2017. https://doi.org/10.1080/1573062X.2016.1148178

SÃO PAULO (Estado). Lei n° 10.100, de 1 de dezembro de 1998. Declara Área de Proteção Ambiental o entorno da represa de Itupararanga. São Paulo: Assembleia Legislativa do Estado de São Paulo, 1998. Alterada pela Lei n° 11.579, de 2 de dezembro de 2003. Disponível em: https://www.al.sp.gov.br/repositorio/legislacao/lei/1998/alteracao-lei-10100-01.12.1998.html . Acesso em 14 de novembro de 2022.

SÃO PAULO. Fundação Florestal. Plano de Manejo da APA Itupararanga. SecrETaria de Estado de Meio Ambiente, 2010. Disponível em: <https://www.infraestruturameioambiente.sp.gov.br/fundacaoflorestal/planos-de-manejo/planos-de-manejo-planos-concluidos/plano-de-manejo-apa-itupararanga/>, Acesso em 17 de julho de 2021.

SCHWARZ, N.; SCHLINK, U; FRANCK, U.; GROßMANN, K. Relationship of land surface and air temperatures and its implications for quantifying urban heat island indicators—An application for the city of Leipzig (Germany), Ecological Indicators, v. 18, p. 693-704, ISSN 1470-160X, 2012. https://doi.org/10.1016/j.ecolind.2012.01.001.

SEO, H.; KIM, Y. Role of remotely sensed leaf area index assimilation in eco-hydrologic processes in different ecosystems over East Asia with Community Land Model version 4.5–Biogeochemistry. **Journal of Hydrology**, v. 594, p. 125957, 2021. https://doi.org/10.1016/j.jhydrol.2021.125957

SHEN, G.; LIAO, J.; GUO, H.; LIU, J. Poyang Lake wetland vegETation biomass inversion using polarimetric RADARSAT-2 synthetic aperture radar data. **Journal of Applied Remote Sensing**, v. 9, n. 1. 2015. https://doi.org/10.1117/1.JRS.9.096077

SILVA, A. C. E. R.; MELO, J. G. S.; GALVÍNCIO, J. D.. "Identificação das Áreas Susceptíveis a Processos de Desertificação no Médio Trecho da Bacia do Rio Ipojuca - PE Através do Mapeamento do Stresse Hídrico da Vegetação e da Estimativa do Índice de Aridez." **Revista Brasileira de Geografia Física**, p. 629-649, 15 de Setembro de 2011.

SILVA, C.O.F.; MAGNONI, P.H. J.; MANZIONE, R.L. Orbital remote sensing for evapotranspiration modeling: theoretical overview and applications in cloud computing. **Revista Brasileira de Engenharia de Biossistemas**, Tupã, São Paulo, Brazil, v. 15, n. 3, p. 425–468, 2021. https://doi.org/10.18011/bioeng2021v15n3p425-468

SILVA, D. C.; ALBUQUERQUE FILHO, J. L.; OLIVEIRA, R. A.; LOURENÇO, R. W. "Aplicação do NDWI para avaliar a disponibilidade de água em bacias hidrográficas." **Revista da Universidade Vale do Rio Verde**, p. 774-783. Julho de 2017

SILVA, O. G.; e CORRÊA, A. C. B. “Progresso nos Estudos de Geomorfologia Fluvial Urbana ao Final do Século XX.” **Geo UERJ**, nº 26 (Janeiro 2015): 245-269.

SOBRINO, J. A.; JIMÉNEZ-MUÑOZ, J. C.; SÒRIA, G.; RUESCAS, A. B.; DANNE, O., BROCKMANN, C.; GÖTTSCHE, F. M.. Synergistic use of MERIS and AATSR as a proxy for estimating Land Surface Temperature from Sentinel-3 data. **Remote sensing of Environment**, v. 179, p. 149-161. 2016. https://doi.org/10.1016/j.rse.2016.03.035.

SOUSA, J. A. P. Elaboração de um índice de vulnerabilidade ambiental dos fragmentos florestais da mata atlântica / Jocy Ana Paixão de Sousa. Sorocaba, 2021. 162 p. Disponível em: <http://hdl.handle.net/11449/202686>. Acesso em 15 de dezembro de 2021.

SOUZA, J. D.; SILVA, B. B. “Correlação atmosférica para a temperatura de superfície obtida com imagem TM - Landast 5.” **Revista Brasileira de Geofísica**, 2005: 349-358.

STOY P. C.; EL-MADANY, T.S.; FISHER, J. B.; GENTINE, P.; GERKEN, T.; GOOD, S. P.; KLOSTERHALFEN, A.; LIU, S.; MIRALLES, D. G.; PEREZ-PRIEGO, O.; RIGDEN, A. J.; SKAGGS, T. H.; WOHLFAHRT, G.; ANDERSON, R. G.; COENDERS-GERRITS, A. M. J.; JUNG, M.; MAES, W. H.; MAMMARELLA, I.; MAUDER, M.; MIGLIAVACCA, M.; NELSON, J. A.; POYATOS, R.; REICHSTEIN, M.; SCOTT, R. L.; WOLF, S. “Reviews and syntheses: Turning the challenges of partitioning ecosystem evaporation and transpiration into opportunities.” **Biogeosciences**, p. 3747–3775. 2019. https://doi.org/10.5194/bg-16-3747-2019

SUN, H.; ZHAO, X.; CHEN, Y.; GONG, A.; YANG, J. A new agricultural drought monitoring index combining MODIS NDWI and day-night land surface temperatures: A case study in China. International Journal of Remote Sensing. v. 34. 2013. 10.1080/01431161.2013.860659

TAS - Thales Alenia Space; ESA - European Space Agency. Sentinel-2 Products Specification Document. 2021. Disponível em: <https://sentinel.esa.int/documents/247904/685211/sentinel-2-products-specification-document>. Acesso em: 13 de março de 2022.

TEIXEIRA, A. H. C. Determining Regional Actual Evapotranspiration of Irrigated Crops and Natural VegETation in the São Francisco River Basin (Brazil) Using Remote Sensing and Penman-Monteith Equation. **Remote Sens**. v. 2, p. 1287-1319. 2010. https://doi.org/10.3390/rs0251287

TEIXEIRA, A. H. C.; LEIVAS, J. F.; HERNANDEZ, F. B. T.; FRANCO, R. A. M. Large-scale radiation and energy balances with Landsat 8 images and agrometeorological data in the Brazilian semiarid region. **J. of Applied Remote Sensing**, v. 11, n. 1, 016030. 2017. https://doi.org/10.1117/1.JRS.11.016030

TESTA, S., K. SOUDANI, L. BOSCHETTI, e E. B. MONDINO. “MODIS-derived EVI, NDVI and WDRVI time series to estimate phenological.” Int J Appl Earth Obs **Geoinformation**, v. 64, p. 132–144. 2018.

This is ESA - European Space Agency. Disponível em: <https://esamultimedia.esa.int/docs/corporate/This_is_ESA_PT_LR.pdf > Acesso em 26 de abril de 2022.

THORNTHWAITE, C. W. “An Approach toward a Rational Classification of Climate.” **Geographical Review**, p. 55-94. 1948. https://doi.org/10.2307/210739

TUCCI, C. E. M.; e SILVEIRA, A. L. L. Hidrologia: ciência e aplicação. 4. Vol. 4. Porto Alegre: **ABRH**, 2020.

UDA, P. K. “Análise da evapotranspiração potencial distribuída por meio de imagens NDVI, na bacia do rio Negrinho - SC.” Florianópolis, Santa Catarina: UFSC, 10 de março de 2010.

UPRETI, R.; WANG, Z.H.; YANG, J. Radiative shading effect of urban trees on cooling the regional built environment, Urban Forestry & Urban Greening, v. 26, p. 18-24, ISSN 1618-8667. 2017. https://doi.org/10.1016/j.ufug.2017.05.008.

US Geological Survey, 2021, dados do National Water Information System disponíveis na World Wide Web (USGS Water Data for the Nation), acesso em 19 de outubro de 2021. Disponível em: <https://waterdata.usgs.gov/nwis/>

VAVLAS, N.; WAINE, T. W.; MEERSMANS, J.; BURGESS, P. J.; FONTANELLI, G.; RICHTER, G. M. Deriving Wheat Crop Productivity Indicators Using Sentinel-1 Time Series. **Remote Sensing**. v. 12, n. 15. 2020. https://doi.org/10.3390/rs12152385

VENANCIO, L. P.; CUNHA, F. F.; MANTOVANI, E. C.; AMARAL, C. H.; REIS, E. F. Evapotranspiração de cultura: uma abordagem dos principais métodos aplicados às pesquisas científicas e na agricultura. **Revista Irriga**, Botucatu, v. 24, n. 4, p. 719-746, outubro-dezembro, 2019. http://dx.doi.org/10.15809/irriga.2019v24n4p719-746

VENANCIO, L. P.; EUGENIO, F.C.; FILGUEIRAS, R.; FRANÇA DA CUNHA, F.; ARGOLO DOS SANTOS, R.; RIBEIRO, W.R. Mapping within-field variability of soybean evapotranspiration and crop coefficient using the Earth Engine Evaporation Flux (EEFlux) application. **PLoS ONE,** Grécia, v. 15, n. 7, julho, 2020. https://doi.org/10.1371/journal.pone.0235620

VERMA, S. B., SELLERS, P. J.; WALTHALL, C. L.; HALL, F. G.; KIM, J.; GOETZ, S. J. Photosynthesis and stomata conductance related to reflectance on the canopy scale. **Remote Sensing of Environment**, Elsevier Science Publishing Co., New York, USA. v.44, p. 103-116. 1993. https://doi.org/10.1016/0034-4257(93)90106-8

VESTENA, L. R. “Balanço Hídrico da Bacia do Rio Ribeirão da Onça, no Município de Colombo – PR.” Curitiba-PR: Setor Ciências da Terra da Universidade Federal do Paraná, 2002.

VREUGDENHIL, M.; WAGNER, W.; BAUER-MARSCHALLINGER, B.; PFEIL, I.; TEUBNER, I.; RÜDIGER, C.; STRAUSS, P. Sensitivity of Sentinel-1 Backscatter to VegETation Dynamics: An Austrian Case Study. **Remote Sensing**. v. 10, n. 9. 2018. https://doi.org/10.3390/rs10091396

WAGLE, P.; GOWDA, P. H.; NEEL, J. P.S.; NORTHUP, B. K.; ZHOU, Y. Integrating eddy fluxes and remote sensing products in a rotational grazing native tallgrass prairie pasture, **Science of The Total Environment**, v. 712, 136407, ISSN 0048-9697. 2020. https://doi.org/10.1016/j.scitotenv.2019.136407

WANG, S.; ZHU, G.; XIA, D.; MA, J.; HAN, T.; MA, T.; ZHANG, K.; SHANG, S. The characteristics of evapotranspiration and crop coefficients of an irrigated vineyard in arid Northwest China, **Agricultural Water Management**, v. 212, p. 388-398, ISSN 0378-3774, 2019. https://doi.org/10.1016/j.agwat.2018.09.023.

WICKHAM, H.; BRYAN, J. (2019). readxl: Read Excel Files. R package version 1.3.1. https://CRAN.R-project.org/package=readxl.

XU, C.; QU, J. J.; HAO, X.; WU, D. Monitoring Surface Soil Moisture Content over the VegETated Area by Integrating Optical and SAR Satellite Observations in the Permafrost Region of TibETan Plateau. **Remote Sensing**. v. 12, n. 1. 2020. https://doi.org/10.3390/rs12010183

YAMAMOTO, J. K. Estatística, análise e interprETação de dados aeroespaciais. 1 ed. São Paulo: **Gráfica Paulos**, 2020.

YANG, J.; ZHOU, JI.; GÖTTSCHE, F.; LONG, Z.; MA, JIN.; LUO, R. Investigation and validation of algorithms for estimating land surface temperature from Sentinel-3 SLSTR data, International Journal of Applied Earth Observation and Geoinformation, v. 91, 102136, ISSN 0303-2434. 2020. https://doi.org/10.1016/j.jag.2020.102136.

YILDIRIM, T.; SERAFETTIN, A. Index-based Assessment of Agricultural Drought using Remote Sensing in the Semi-arid Region of Western Turkey. **Journal of Agricultural Sciences** , v. 24, n. 4, pág. 510-516, 2018. https://doi.org/10.15832/ankutbd.337136

ZHANG, S.; DUAN, S.-B.; LI, Z.-L.; HUANG, C.; WU, H.; HAN, X.-J.; LENG, P.; GAO, M. Improvement of Split-Window Algorithm for Land Surface Temperature Retrieval from Sentinel-3ª SLSTR Data Over Barren Surfaces Using ASTER GED Product. Sensor Remoto, v. 11 p. 3025. 2019. https://doi.org/10.3390/rs11243025.

ZHOU, H.; ZHAO, W. Modeling soil water balance and irrigation strategies in a flood-irrigated wheat-maize rotation system. A case in dry climate, China, **Agricultural Water Management**, v. 221, p. 286-302, ISSN 0378-3774. 2019. https://doi.org/10.1016/j.agwat.2019.05.011.

ZHU, Y.; CHENG, Z.; FENG, K.; CHEN, Z.; CAO, C.; HUANG, J.; YE, H.; GAO, Y. Influencing factors for transpiration rate: A numerical simulation of an individual leaf system, **Thermal Science and Engineering Progress**, v. 27, 101110, ISSN 2451-9049. 2022. https://doi.org/10.1016/j.tsep.2021.101110

APÊNDICE A - *Script* para a estimativa do NDVI E NDWI por meio de dados SAR no software R

```
# Instalar os pacotes necessários
install.packages("readxl")
install.packages("pastecs")
install.packages("e1071")
install.packages("randomForest")
install.packages("neuralnet")
install.packages("pastecs")

# Carregando pacotes
library(readxl)
library(pastecs)
library(ggplot2)
library(GGally)
library(randomForest)
library(e1071)
library(neuralnet)

#Lmpar área de trabalho e carregar dados
rm(list=ls())
PATH <- "D:/geo/dados_R/dadostese_amazonino"
setwd(PATH)
dados <- read_excel("dados_102019.xlsx", "Planilha2")

# Analise se existe "NA" no conjunto de dados e omitir
dados[is.na(dados$NDVI), ]
dados <- na.omit(dados)

# faz a amostra de 1.0000 linhas sem reposição
set.seed(321)
dados.amostra<-dados[sample(1:nrow(dados),10000,replace=F),]
```

```
dim(dados.amostra)
summary(dados.amostra)

dados.amostra=scale(dados.amostra)
dados.amostra <- as.data.frame(dados.amostra)

#Análise descritiva
#plot(density(dados$NDVI))
#plot(density(dados$B1))
#plot(density(dados$B2))
#plot(density(dados$B5))

#Analise de correlação
cor(dados.amostra)
#ggpairs(dados.amostra,lower = list(continuous="smooth")) + theme_minimal() ### Plot

#Cross-Validation
P <- 0.7
r <- 10
set.seed(100)

# Calculo do MAE, MSE e RMSE
R2.rl <- NULL
mae.rl <- NULL
mse.rl <- NULL
rmse.rl <- NULL

#Validacao Cruzada ==> r-fold
dados.amostra <- dados[sample(1:nrow(dados.amostra), nrow(dados.amostra)),] #Sorteio
aleatorio da base de dados

partes <- vector("list",r)
ns <- floor(nrow(dados.amostra)/r) #number of samples
for(i in 1:(r-1)){
```

```
  partes[[i]] <- (1+ns*(i-1)):(i*ns)
}

#Modelo de Regressão Linear
model.rl <- lm(NDVI ~ B1 + B2 + B3 + B4, data=train)
summary(model.rl)

#Fazendo a previsao
pred.rl <- predict(model.rl, x_test)

#Avaliação da previsão
df.rl <- data.frame(actual=y_test, predicted=pred.rl)

#Cálculo do MAE, MSE e RMSE
rl.R2 <- NULL
rl.mae <- NULL
rl.mse <- NULL
rl.rmse <- NULL

y = train$NDVI
y_hat_rl = model.rl$fitted.values
y_bar_rl = mean(y)
RSS_rl = sum((y-y_hat_rl)^2)
TSS_rl = sum((y-y_bar_rl)^2)
R2_rl = 1 - (RSS_rl/TSS_rl)

mae.rl <- mean(abs(df.rl$NDVI - df.rl$predicted))
mse.rl <- mean((df.rl$NDVI - df.rl$predicted)^2)
rmse.rl <- sqrt(mean((df.rl$NDVI - df.rl$predicted)^2))


#Resultados
rl.R2 <- R2_rl
rl.mae <- c(rl.mse, mae.rl)# caso de NULL atualizar $NDVI
```

```
rl.mse <- c(rl.mse, mse.rl)
rl.rmse <- c(rl.rmse, rmse.rl)

#Support Vector Machine
model.svm = svm(formula = train$NDVI ~ train$B1
        + train$B2 + train$B3 + train$B4, data = train,
        type = "eps-regression",
        kernel = "radial", cost = 2) #"linear", "polynomial", "radial", "sigmoid"

pred.svm <- predict(model.svm, x_test)


#Avaliação da previsão
df.svm <- data.frame(actual=y_test, predicted=pred.svm)


# Cálculo do MAE, MSE e RMSE
svm.R2 <- NULL
svm.mae <- NULL
svm.mse <- NULL
svm.rmse <- NULL

y = train$NDVI
y_hat_svm = pred.svm
y_bar_svm = mean(y)
RSS_svm = sum((y-y_hat_svm)^2)
TSS_svm = sum((y-y_bar_svm)^2)
R2_svm = 1 - RSS_svm/TSS_svm

mae.svm <- mean(abs(df.svm$NDVI - df.svm$predicted))
mse.svm <- mean((df.svm$NDVI - df.svm$predicted)^2)
rmse.svm <- sqrt(mean((df.svm$NDVI - df.svm$predicted)^2))
```

```
#Resultados
svm.R2 <- R2_svm
svm.mae <- c(svm.mae, mae.svm)
svm.mse <- c(svm.mse, mse.svm)
svm.rmse <- c(svm.rmse, rmse.svm)

#Randon Forest
model.rf <- randomForest(x=train[3:6], y=train$NDVI, ntree = 100)
#plot(model.rf)
pred.rf <- predict(model.rf, x_test)

#Avaliação da prevsão
df.rf <- data.frame(actual=y_test, predicted=pred.rf)

# Calculo do MAE, MSE e RMSE
rf.R2 <- NULL
rf.mae <- NULL
rf.mse <- NULL
rf.rmse <- NULL

y = test$NDVI
y_hat_rf = predict(model.rf, test)
y_bar_rf = mean(y)
RSS_rf = sum((y-y_hat_rf)^2)
TSS_rf = sum((y-y_bar_rf)^2)
R2_rf = 1 - RSS_rf/TSS_rf

mae.rf <- mean(abs(df.rf$NDVI - df.rf$predicted))
mse.rf <- mean((df.rf$NDVI - df.rf$predicted)^2)
rmse.rf <- sqrt(mean((df.rf$NDVI - df.rf$predicted)^2))

#Resultados
rf.R2 <- R2_rf
rf.mae <- c(rf.mae, mae.rf)
```

```
rf.mse <- c(rf.mse, mse.rf)
rf.rmse <- c(rf.rmse, rmse.rf)

# ANN
f <- formula(NDVI ~ B1 + B2 + B3 + B4)
model.ann <- neuralnet(f, data=train,
                       hidden=c(4,4), threshold =2, stepmax= 1e+05)

#plot(model.ann)
pred.ann <- predict(model.ann, x_test)
#plot(model.ann)
#Avalia a previsao
df <- data.frame(actual=y_test, predicted=pred.ann)

# Calculo do MAE, MSE e RMSE
ann.R2 <- NULL
ann.mae <- NULL
ann.mse <- NULL
ann.rmse <- NULL
y = test$NDVI
y_hat_ann = predict(model.ann, test)
y_bar_ann = mean(y)
RSS_ann = sum((y-y_hat_ann)^2)
TSS_ann = sum((y-y_bar_ann)^2)
R2_ann = 1 - RSS_ann/TSS_ann
mae.ann <- mean(abs(df$NDVI - df$predicted))
mse.ann <- mean((df$NDVI - df$predicted)^2)
rmse.ann <- sqrt(mean((df$NDVI - df$predicted)^2))

#Resultados
ann.R2 <- R2_ann
ann.mae <- c(ann.mae, mae.ann)
ann.mse <- c(ann.mse, mse.ann)
ann.rmse <- c(ann.rmse, rmse.ann)
```

APÊNDICE B - Script para a estimativa da ETA por meio do pacote Agriwater no software R

```
# Carregando pacotes necessários
library(raster)
library(rgdal)
library(gstat)
library(sp)
library(agriwater)

# Limpar memoria
rm(list=ls())
ls()
character(0)

path = "D:/GOOGLE_DRIVE_UFAM/001_DOUTORADO_UNESP/AgriwaterEvapo/"

# Definir caminho e mês a ser processados
setwd(paste(path, "Dez", sep = ""))

#Mudar os dados meteorológicos a ser utilizado de acordo com mês
mask <- readOGR(paste(path, "arearETangulo50/rETangulo50.shp", sep = ""))
data = read.table(file=paste(path, "Dados_meteoro/dados_amazonino_S2_December.csv", sep = ""), header=TRUE, sep=",")
data <- as.data.frame(data)

#Aqui prepara-se o grid a partir do shapefile mask.shp. O tamanho de pixel da interpolação deve respeitar a resolução espacial das imagens do Sentinel-2, 10 m.
B2 = raster("B2.tif")
b2_mask = crop(B2, extent(mask))
min_x = min(data$Long)
min_y = min(data$Lat)
x_length = max(data$Long) - min_x #easting amplitude
y_length = max(data$Lat) - min_y #northing amplitude
cellsize = 0.05 #pixel size
```

```
ncol = round(x_length/cellsize,0) #number of columns in grid
nrow = round(y_length/cellsize,0) #number of rows in grid
dfx = data
coordinates(dfx) = ~Long+Lat
proj4string(dfx) = crs(mask)
grid = GridTopology(cellcentre.offset = c(min_x , min_y) , cellsize=c(cellsize, cellsize)
,cells.dim=c(ncol,nrow))
#Convert GridTopolgy object to SpatialPixelsDataFrame object.
grid = SpatialPixelsDataFrame(grid,
                              data=data.frame(id=1:prod(ncol,nrow)),
                              proj4string=CRS(proj4string(mask)))
```

 # Aqui interpola-se a radiação solar global com IDW e gera-se o raster RG.tif:

```
RG = idw(formula = RG ~ 1, locations = dfx, newdata = grid)
idw_raster <- rasterFromXYZ(RG)
RG_mask_orig <- crop(idw_raster, extent(mask))
RG_mask <- resample(RG_mask_orig, b2_mask, method="bilinear")
writeRaster(RG_mask, "RG", format = "GTiff", overwrite=TRUE)
```

 # Visualizar o resultado

```
plot(RG_mask)
```

 # Aqui interpola-se a temperatura média do ar com IDW e gera-se o raster Ta.tif.

```
Ta = idw(formula = Ta ~ 1, locations = dfx, newdata = grid)
idw_raster <- rasterFromXYZ(Ta)
Ta_mask_orig <- crop(idw_raster, extent(mask))
Ta_mask <- resample(Ta_mask_orig, b2_mask, method="bilinear")
writeRaster(Ta_mask, "Ta", format = "GTiff", overwrite=TRUE)
```

 # Visualizar

```
plot(Ta_mask)
```

 # Aqui interpola-se a evapotranspiração de referência com IDW e gera-se o raster ET0.tif.

```
ET0 = idw(formula = ET0 ~ 1, locations = dfx, newdata = grid)
```

```
idw_raster <- rasterFromXYZ(ET0)
ET0_mask_orig <- crop(idw_raster, extent(mask))
ET0_mask <- resample(ET0_mask_orig, b2_mask, method="bilinear")
writeRaster(ET0_mask, "ET0", format = "GTiff", overwrite=TRUE)

# Visualizar
plot(ET0_mask)

# Executando o Agriwater - Mudar o DOY conforme o dia da imágem S2 utilizada – recomendado o uso do calendário Juliano.
DOY = 355
a = 1.8
b = -0.008

# Parâmetros para calcular a ET (Albedo, NDVI, LST, Rn)
radiation_s2_grid(DOY, a, b)

# Calcular parametros da ET (Kc)
kc_s2_grid(DOY, a, b)

# Obtendo variáveis para o cálculo da Evapotranspiração real
evapo_s2_grid(DOY, a, b)
##################################################
alb = raster("Alb_24.tif")
plot(alb)
##################################################
NDVI = raster("NDVI.tif")
plot(NDVI)
##################################################
LST = raster("LST.tif")
plot(LST)
##################################################
rn = raster("Rn_MJ.tif")
plot(rn)
```

```
##################################################
kc = raster("kc.tif")
plot(kc)
##################################################

# Evapotranspiração real
evapo = raster("evapo.tif")
plot(evapo)
##################################################
```

OBS: Link de acesso para em nuvem aos produtos gerados: Temperatura de Superfície (TS), Albedo de Superfície, Radiação Global (RG), Temperatura média do Ar (Ta), Evapotranspiração de Referência (ET_0), NDVI, Saldo de Radiação (RN), Fluxo de Calor Sensível (H) e Fluxo de Calor no Solo (G). No link encontra-se também todas as entradas necessárias para executar o algoritmo e realizar a geração dos produtos supracitados. < https://www.google.com/intl/pt-br/drive/about.html>

APÊNDICE C - Script dos parâmetros estatísticos da análise de regressão multivariada entre os índices biofísicos, uso da terra e a ETA

```
# Carregando pacotes necessários
library(readxl)
library(corrplot)

# Limpar memoria
rm(list=ls())

# Definindo o caminho e carregando os dados
PATH <-
"D:/GOOGLE_DRIVE_UFAM/001_DOUTORADO_UNESP/DADOS_PLANILHADOS_TESE"

setwd(PATH)
dados <- read_excel("dadostese.xlsx", "dados12")

#Filtros para limpar ruidos dados 0
dados[is.na(dados)] <- 0

#Omitindo as colunas x e y das coordenadas dos pontos
dados$x=NULL
dados$y=NULL

#Normalização Max e Min dos dados
maxmin <- function(x){return((x-min(x))/(max(x)-min(x)))}
dados <- maxmin(dados[,1:6])
summary(dados)

#Realizando a análise de regressão
mode1=lm(formula = ETA ~ NDVI+NDWI+SAVI+IAF+USO,data = dados)
summary(mode1)
```

#Realizando testes de Pearson, Spearman e Kendall (o melhor desempenho foi o teste de Person)

```
M=cor(dados, method="pearson")
corrplot(M,method = "square", tl.col="black", tl.cex = 2.5,
        addCoef.col = 'white', cl.cex = 2, number.cex = 2.5)
```

#Formatação do Gráfico

```
#tl.cex = 1.5->aumenta a fonte dos eixos esquerdo e superior
#cl.cex = 1.2-> aumenta a fonte do eixo direito
#number.cex = 1.5-> aumenta a fonte dos dados da correlação
#square ou circle -> mostra a força da correlação em círculo ou quadrado
```

#Referência das bibliotecas utilizadas

```
#Cita o Software R
citation()
#Cita o Software RStudio
RStudio.Version()
#Cita as bibliotecas utilizadas
citation(package = "readxl")
citation(package = "ggplot2")
```

APÊNDICE D - Resíduos, coeficientes, erro padrão e níveis de significância dos índices biofísicos para cada mês do ano de 2020 em relação a ETA

JANEIRO

Call:

lm(formula = ETA ~ NDVI + NDWI + SAVI + IAF +

USO

Residuals:

Min	1Q	Median	3Q	Max
-0.82429	-0.02832	0.00132	0.03061	0.97769

Coefficients:

	Estimate	Std. Error	t value	Pr(>|t|)	
(Intercept)	-0.671741	0.001349	-497.946	< 2e-16	***
NDVI	7.536912	0.072251	104.315	< 2e-16	***
NDWI	3.713786	0.040977	90.631	< 2e-16	***
SAVI	12.247662	0.081995	149.371	< 2e-16	***
IAF	0.072009	0.002357	30.548	< 2e-16	***
USO	-0.008393	0.001632	-5.142	2.72e-07	***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 0.07255 on 225176 degrees of

freedom

Multiple R-squared: 0.8581

F-statistic: 2.723e+05 on 5 and 225176 DF

FEVEREIRO

Call:

```
lm(formula = ETA ~ NDVI + NDWI + SAVI + IAF +
USO

Residuals:
    Min      1Q  Median      3Q     Max
-0.48617 -0.01870  0.00025  0.01955  0.64636

Coefficients:
             Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.5496882  0.0009279 -592.40   <2e-16 ***
NDVI         6.6822352  0.0277637  240.68   <2e-16 ***
NDWI         2.2094309  0.0229552   96.25   <2e-16 ***
SAVI         8.3620401  0.0375542  222.67   <2e-16 ***
IAF          0.0708771  0.0016856   42.05   <2e-16 ***
USO         -0.0133574  0.0007805  -17.11   <2e-16 ***
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 0.04313 on 225176 degrees of
freedom
Multiple R-squared:  0.8803
F-statistic: 3.312e+05 on 5 and 225176 DF
```

MARÇO

```
Call:
lm(formula = ETA ~ NDVI + NDWI + SAVI + IAF +
USO

Residuals:
    Min      1Q  Median      3Q     Max
-0.64794 -0.02306  0.02317  0.05694  0.90706

Coefficients:
             Estimate Std. Error  t value Pr(>|t|)
```

(Intercept) -0.744781 0.002580 -288.704 < 2e-16 ***
NDVI 10.779922 0.103494 104.160 < 2e-16 ***
NDWI 4.205787 0.073662 57.096 < 2e-16 ***
SAVI 6.124592 0.123371 49.644 < 2e-16 ***
IAF 0.164606 0.004493 36.632 < 2e-16 ***
USO -0.012021 0.002124 -5.661 1.51e-08 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.1115 on 225176 degrees of freedom
Multiple R-squared: 0.6567
F-statistic: 8.615e+04 on 5 and 225176 DF

ABRIL

Call:
lm(formula = ETA ~ NDVI + NDWI + SAVI + IAF + USO

Residuals:
Min 1Q Median 3Q Max
-0.72582 -0.03717 0.00300 0.04666 0.82166

Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.449646 0.003038 -148.00 <2e-16 ***
NDVI 14.143479 0.085456 165.50 <2e-16 ***
NDWI 0.962302 0.056321 17.09 <2e-16 ***
SAVI -1.430429 0.107942 -13.25 <2e-16 ***
IAF 0.089121 0.004823 18.48 <2e-16 ***
USO 0.048428 0.001999 24.23 <2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.1206 on 225176 degrees of freedom
Multiple R-squared: 0.6106
F-statistic: 7.06e+04 on 5 and 225176 DF

MAIO

Call:
lm(formula = ETA ~ NDVI + NDWI + SAVI + IAF + USO

Residuals:

Min	1Q	Median	3Q	Max
-0.78415	-0.04020	0.00172	0.04811	0.80115

Coefficients:

	Estimate	Std. Error	t value	Pr(>|t|)	
(Intercept)	-0.470563	0.002297	-204.86	<2e-16	***
NDVI	10.618277	0.051705	205.36	<2e-16	***
NDWI	3.208357	0.036400	88.14	<2e-16	***
SAVI	2.709317	0.076798	35.28	<2e-16	***
IAF	-0.097652	0.004392	-22.23	<2e-16	***
USO	0.067151	0.001635	41.06	<2e-16	***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 0.1107 on 225176 degrees of freedom
Multiple R-squared: 0.7133
F-statistic: 1.121e+05 on 5 and 225176 DF

JUNHO

Call:

lm(formula = ETA ~ NDVI + NDWI + SAVI + IAF +
USO

Residuals:

Min	1Q	Median	3Q	Max
-0.57527	-0.04798	-0.00017	0.04600	0.57843

Coefficients:

	Estimate	Std. Error	t value	Pr(>|t|)	
(Intercept)	-0.322452	0.001656	-194.71	<2e-16	***
NDVI	3.620280	0.035291	102.58	<2e-16	***
NDWI	1.972501	0.029921	65.92	<2e-16	***
SAVI	4.634794	0.039129	118.45	<2e-16	***
IAF	0.530289	0.002842	186.58	<2e-16	***
USO	0.108746	0.001451	74.95	<2e-16	***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 0.08341 on 225176 degrees of
freedom
Multiple R-squared: 0.6485
F-statistic: 8.308e+04 on 5 and 225176 DF

JULHO

Call:
lm(formula = ETA ~ NDVI + NDWI + SAVI + IAF +
USO

Residuals:

Min	1Q	Median	3Q	Max
-0.70672	-0.03691	-0.00108	0.03940	0.74440

Coefficients:

	Estimate	Std. Error	t value	Pr(>|t|)	
(Intercept)	-0.697720	0.002805	-248.72	<2e-16	***

NDVI 14.340211 0.067520 212.38 <2e-16 ***
NDWI 3.966781 0.037673 105.29 <2e-16 ***
SAVI -3.089686 0.092027 -33.57 <2e-16 ***
IAF 0.097801 0.004081 23.96 <2e-16 ***
USO 0.016614 0.001453 11.44 <2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.08975 on 225176 degrees of freedom
Multiple R-squared: 0.7927
F-statistic: 1.722e+05 on 5 and 225176 DF

AGOSTO

Call:
lm(formula = ETA ~ NDVI + NDWI + SAVI + IAF + USO

Residuals:
Min 1Q Median 3Q Max
-0.69343 -0.04006 0.00147 0.04303 0.90666

Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.636550 0.002340 -272.041 < 2e-16 ***
NDVI 18.699178 0.120886 154.685 < 2e-16 ***
NDWI 6.733748 0.056114 120.000 < 2e-16 ***
SAVI -1.432619 0.184987 -7.744 9.64e-15 ***
IAF -0.054304 0.007604 -7.142 9.23e-13 ***
USO 0.121470 0.001815 66.935 < 2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.1023 on 225176 degrees of freedom
Multiple R-squared: 0.7295
F-statistic: 1.214e+05 on 5 and 225176 DF

SETEMBRO

Call:
lm(formula = ETA ~ NDVI + NDWI + SAVI + IAF + USO

Residuals:

Min	1Q	Median	3Q	Max
-0.64363	-0.04612	0.00293	0.04622	0.97866

Coefficients:

	Estimate	Std. Error	t value	Pr(>|t|)	
(Intercept)	-0.349030	0.002748	-127.03	<2e-16	***
NDVI	16.107748	0.103105	156.23	<2e-16	***
NDWI	3.683161	0.055753	66.06	<2e-16	***
SAVI	-8.272962	0.158572	-52.17	<2e-16	***
IAF	0.343396	0.005124	67.01	<2e-16	***
USO	0.031794	0.001985	16.02	<2e-16	***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 0.1129 on 225176 degrees of freedom
Multiple R-squared: 0.6796
F-statistic: 9.551e+04 on 5 and 225176 DF

OUTUBRO

Call:

```
lm(formula = ETA ~ NDVI + NDWI + SAVI + IAF +
USO

Residuals:
    Min      1Q  Median      3Q     Max
-0.62842 -0.04311  0.00748  0.04898  0.94699

Coefficients:
             Estimate Std. Error  t value Pr(>|t|)
(Intercept) -0.573668   0.002265 -253.238  < 2e-16 ***
NDVI        11.272971   0.110127  102.363  < 2e-16 ***
NDWI         6.887792   0.064462  106.851  < 2e-16 ***
SAVI        -0.709855   0.140965   -5.036 4.77e-07 ***
IAF          0.033916   0.004726    7.176 7.19e-13 ***
USO          0.084234   0.002130   39.556  < 2e-16 ***
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 0.1154 on 225176 degrees of
freedom
Multiple R-squared:  0.694
F-statistic: 1.021e+05 on 5 and 225176 DF
```

NOVEMBRO

```
Call:
lm(formula = ETA ~ NDVI + NDWI + SAVI + IAF +
USO

Residuals:
    Min      1Q  Median      3Q     Max
-0.59053 -0.05505  0.01525  0.06290  0.95508

Coefficients:
```

```
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.375653   0.002522 -148.97   <2e-16 ***
NDVI         7.910854   0.080148   98.70   <2e-16 ***
NDWI         5.546331   0.071927   77.11   <2e-16 ***
SAVI        -1.214060   0.120940  -10.04   <2e-16 ***
IAF          0.070622   0.005370   13.15   <2e-16 ***
USO          0.182075   0.002400   75.85   <2e-16 ***
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 0.14 on 225176 degrees of
freedom
Multiple R-squared:  0.505
F-statistic: 4.594e+04 on 5 and 225176 DF
```

DEZEMBRO

```
Call:
lm(formula = ETA ~ NDVI + NDWI + SAVI + IAF +
USO

Residuals:
    Min      1Q  Median      3Q     Max
-0.71534 -0.01508  0.01666  0.04848  1.00793

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.657277   0.002188 -300.43   <2e-16 ***
NDVI        15.438463   0.109866  140.52   <2e-16 ***
NDWI         4.511841   0.077735   58.04   <2e-16 ***
SAVI         3.105881   0.131866   23.55   <2e-16 ***
IAF          0.035323   0.003978    8.88   <2e-16 ***
USO         -0.065009   0.001858  -34.98   <2e-16 ***
---
```

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 0.1088 on 225176 degrees of freedom
Multiple R-squared: 0.6936
F-statistic: 1.019e+05 on 5 and 225176 DF