

TAIARA SOUZA COSTA

**EVAPOTRANSPIRAÇÃO REAL POR APRENDIZADO DE MÁQUINA E
SENSORIAMENTO REMOTO SEM O ESPECTRO TERMAL**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Magister Scientiae*.

Orientador: Fernando França da Cunha

Coorientador: Roberto Filgueiras

**VIÇOSA - MINAS GERAIS
2021**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

C837e
2021
Costa, Taiara Souza, 1995-
Evapotranspiração real por aprendizado de máquina e
sensoriamento remoto sem o espectro termal / Taiara Souza
Costa. – Viçosa, MG, 2021.
1 dissertação eletrônica (55 f.): il. (algumas color.).

Orientador: Fernando França da Cunha.
Dissertação (mestrado) - Universidade Federal de Viçosa.
Referências bibliográficas: f. 43-55.
DOI: <https://doi.org/10.47328/ufvbbt.2021.053>
Modo de acesso: World Wide Web.

1. Evapotranspiração. 2. Algoritmos computacionais.
3. Irrigação agrícola. 4. Soja - Irrigação. 5. Cana-de-açúcar -
Irrigação. I. Universidade Federal de Viçosa. Departamento de
Engenharia Agrícola. Programa de Pós-Graduação em
Engenharia Agrícola. II. Título.

CDD 22. ed. 631.587

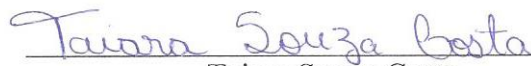
TAIARA SOUZA COSTA

**EVAPOTRANSPIRAÇÃO REAL POR APRENDIZADO DE MÁQUINA E
SENSORIAMENTO REMOTO SEM O ESPECTRO TERMAL**

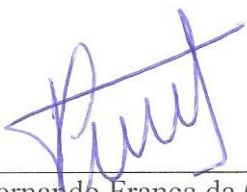
Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Magister Scientiae*.

APROVADA: 28 de julho de 2021.

Assentimento:



Taiara Souza Costa
Autora



Fernando França da Cunha
Orientador

AGRADECIMENTOS

A Deus, pelo dom da vida.

Aos meus pais, Romana Souza Carneiro e Epaminondas Costa Filho, pela educação que me deram e por terem me apoiado em todas as etapas da minha vida.

Ao meu orientador, Fernando França da Cunha, e ao meu coorientador, Roberto Filgueiras, o meu muito obrigada!!!

Ao colega Robson Argolo, pelos esclarecimentos e pelas sugestões.

À Universidade Federal de Viçosa, em especial ao Departamento de Engenharia Agrícola (DEA), pela oportunidade de realização do curso de mestrado.

Aos meus demais amigos, familiares e ao meu namorado Vitor Ramos Lucas, por terem sempre me apoiado e incentivado em todos os momentos.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pelo auxílio financeiro, através da bolsa de pesquisa durante o curso.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

RESUMO

COSTA, Taiara Souza, M.Sc., Universidade Federal de Viçosa, julho de 2021. **Evapotranspiração real por aprendizado de máquina e sensoriamento remoto sem o espectro termal.** Orientador: Fernando França da Cunha. Coorientador: Roberto Filgueiras.

A evapotranspiração (ET) é um parâmetro chave no balanço hídrico, sendo destaque nesse contexto a utilização de dados provenientes de sensoriamento remoto. Entretanto, existe um desafio significativo para a modelagem de ET com imagens frequentes sem o espectro do infravermelho termal, o que ajudaria nas decisões de gerenciamento dos recursos hídricos em nível de propriedade agrícola. Diante disso, objetivou-se neste estudo utilizar algoritmos de aprendizado de máquina para estabelecer um modelo para estimativa da fração evapotranspirativa (ET_f) utilizando dois cenários de entrada de dados a partir das informações espectrais da constelação Sentinel-2; e analisar a aplicabilidade temporal e espacial dos modelos para estimar a evapotranspiração real (ET_r) em culturas agrícolas irrigadas por pivôs centrais. O estudo foi realizado em dois cenários de entrada de variáveis independentes, sendo que, as bandas espectrais do satélite Sentinel 2A e 2B e índices de vegetação compuseram um total de 11 variáveis e formaram o primeiro cenário. Já o segundo cenário foi composto por 29 variáveis geradas a partir da realização do procedimento de razão normalizada entre as bandas (NRPB) e a junção das variáveis aplicadas no primeiro cenário. Ressalta-se que, em ambos os cenários, para seleção das variáveis, foi realizado a análise de correlação de 0,98 e a Função Recursive Feature Elimination (RFE). Os modelos gerados para prever a ET_f a partir de algoritmos de regressão e em seguida comparação com a ET_f calculada pelo algoritmo SAFER, utilizou-se diferentes algoritmos: Regressão Linear Múltipla, Linear Support Vector Machine, Cubist, Bayesian-Regularized Neural Network e eXtreme Gradient Boosting pelos métodos Linear e Tree. Depois que a ET_f foi estimada em cada cenário com as diferentes técnicas, realizou-se a análise estatística que permitiu selecionar o melhor modelo, que em ambos os cenários, foi o Cubist. Posteriormente, foi estimado a ET_f somente para os pivôs centrais presentes na área de estudo e acessou a classificação do uso e cobertura da terra desses por meio do produto MapBiomias. O uso da terra foi necessário para poder calcular a ET_r em cada cenário, nos pivôs centrais com as culturas da cana de açúcar e soja. Para estimativa da ET_r foi estimada a ET_f e multiplicada por duas abordagens de ET_o (ET_o Brazil e Hargreaves-Samani). As ET_r estimadas por essas abordagens foram comparadas com a ET_r estimada por intermédio da ET_o calculada pelo método padrão de Penman-Monteith FAO 56.

Verificou-se que a equação de Hargreaves-Samani superestimou a ET_r com maiores erros principalmente para os pivôs centrais com cana de açúcar, em que o MBE variou de 0,89-2,02 $mm\ d^{-1}$. Já o produto $ET_{o,Brazil}$ apresentou menores erros estatísticos com valores variando de 0,33-1,49 e 0,20- 1,26 para RMSE e MAE, respectivamente, para ambas as culturas agrícolas. Por meio dos resultados alcançados constata-se que a ET_r pode ser monitorada espacial e temporalmente sem a utilização da banda termal, o que faz com que a estimativa desse parâmetro seja realizada com maior frequência temporal.

Palavras-chave: Algoritmo SAFER. Fração evapotranspirativa. Manejo da irrigação. Soja. Cana de açúcar.

ABSTRACT

COSTA, Taiara Souza, M.Sc., Universidade Federal de Viçosa, July, 2021. **Actual evapotranspiration by machine learning and remote sensing without the thermal band of satellites**. Adviser: Fernando França da Cunha. Co-adviser: Roberto Filgueiras.

Evapotranspiration (ET) is a key parameter in the water balance, being highlighted in this context the use of data from remote sensing. However, there is a significant challenge to modeling ET with frequent imaging without the thermal infrared spectrum, which would help make water resources management decisions at the farm level. Therefore, this study aimed to use machine learning algorithms to establish a model for estimating the evapotranspiration fraction (ET_f) using two data entry scenarios from the spectral information of the Sentinel-2 constellation; and analyze the temporal and spatial applicability of the models to estimate the real evapotranspiration (ET_r) in agricultural crops irrigated by center pivots. The study was carried out in two independent variable input scenarios, where the spectral bands of the Sentinel 2A and 2B satellite and vegetation indices composed a total of 11 variables and formed the first scenario. The second scenario consisted of 29 variables generated from the normalized ratio procedure between the bands (NRPB) and the combination of the variables applied in the first scenario. It is noteworthy that, in both scenarios, to select the variables, the correlation analysis of 0.98 and the RFE Function was performed. The models generated to predict the ET_f from regression algorithms and then comparison with the ET_f calculated by the SAFER algorithm, used different algorithms: Multiple Linear Regression, Linear Support Vector Machine, Cubist, Bayesian-Regularized Neural Network and eXtreme Gradient Boosting by Linear and Tree methods. After the ET_f was estimated in each scenario with the different techniques, a statistical analysis was performed that allowed selecting the best model, which in both scenarios was the Cubist. Subsequently, the ET_f was estimated only for the center pivots present in the study area and accessed the classification of their land use and coverage through the MapBiomas product. The land use was necessary to be able to calculate the ET_r in each scenario, in the center pivots with the sugarcane and soybean crops. To estimate ET_r , ET_f was estimated and multiplied by two ET_o approaches (ET_o Brazil and Hargreaves-Samani). The ET_r estimated by these approaches were compared with the ET_r estimated through the ET_o calculated by the standard Penman-Monteith FAO 56 method. It was found that the Hargreaves-Samani equation overestimated the ET_r with greater errors mainly for the central centers with sugarcane, where the MBE ranged from 0.89-2.02 mm d⁻¹.

The ET_0 Brazil product, on the other hand, has smaller statistical errors with values ranging from 0.33-1.49 and 0.20-1.26 for RMSE and MAE, respectively, for both agricultural crops. Through the results achieved, it appears that the ET_r can be monitored spatially and temporally without the use of the thermal band, which makes the estimation of this parameter to be performed with a greater temporal frequency.

Keywords: SAFER algorithm. Evapotranspiration fraction. Irrigation management. Soybean. Sugarcane.

LISTA DE FIGURAS

Figura 1. Localização geográfica referente à área utilizada para modelar a fração evapotranspirativa (ET_f) utilizando informações do Sentinel-2.....	23
Figura 2. Metodologia utilizada para prever a fração evapotranspirativa (ET_f).....	25
Figura 3. Valores diários de fração evapotranspirativa (ET_f) preditos por diferentes abordagens (cenários 1 e 2) comparados com valores obtidos pelo SAFER a partir de imagens Landsat-8 no período de 2016 a 2018.....	34
Figura 4. Aplicação do modelo Cubist para predição da fração evapotranspirativa (ET_f) em áreas com pivôs centrais comparados com valores obtidos pelo SAFER com imagens Landsat-8 para os dias 06/08/2019 (DOY218) e 02/04/2020 (DOY093).....	37
Figura 5. Aplicação do modelo Cubist para a predição da evapotranspiração real (ET_r) em áreas com pivôs centrais utilizando-se a cultura da cana de açúcar e soja, obtidos por meio de duas abordagens, (ET_rET_oHS e ($ET_rET_oBrazil$), e comparados com valores obtidos pelo (ET_rSAFER) para os dias 06/08/2019 (DOY218) e 02/04/2020 (DOY093)..	39

LISTA DE TABELAS

Tabela 1. Comparação das bandas do Landsat-8 com as bandas do Sentinel 2A e 2B.....	18
Tabela 2. Combinações de variáveis de entrada para cada cenário.....	30

SUMÁRIO

1 INTRODUÇÃO.....	11
2 REVISÃO DE LITERATURA.....	13
2.1 Evapotranspiração.....	14
2.2 Irrigação.....	16
2.3 Sensoriamento remoto.....	17
2.3.1 Satélites: Landsat-8 e Sentinel-2.....	18
2.4 Aprendizado de máquina.....	19
2.4.1 Regressão linear múltipla.....	20
2.4.2 Support Vector Machine.....	20
2.4.3 Cubist.....	21
2.4.4 Bayesian-Regularized Neural Network.....	21
2.4.5 eXtreme Gradient Boosting.....	22
3 MATERIAL E MÉTODOS.....	23
3.1 Área de estudo.....	23
3.2 Variável alvo: fração evapotranspirativa (ET_f).....	25
3.3 Metodologias - recursos realizados para modelar a variável alvo.....	26
3.4 Algoritmos de regressão usados na predição da ET_f	29
3.5 Estudo de dois cenários de entrada de variáveis independentes para prever a ET_f considerando a área total.....	29
3.6 Critérios de comparação de desempenho.....	30
3.7 Estudo de caso.....	31
4 RESULTADOS E DISCUSSÃO.....	34
4.1 Validação dos modelos para estimativa da fração evapotranspirativa (ET_f).....	34
4.2 Estimativa da fração evapotranspirativa (ET_f) em áreas irrigadas por pivô central.....	37
4.3 Estimativa da evapotranspiração real (ET_r) utilizando duas abordagens no cálculo da ET_o em duas culturas agrícolas.....	39
5 CONCLUSÕES.....	42
6 REFERÊNCIAS.....	43

1 INTRODUÇÃO

Com o avanço de tecnologias e com auxílio de modelos agrometeorológicos destinados à determinação da evapotranspiração (ET), torna-se possível estimar, de forma espacializada e precisa, a demanda hídrica dos cultivos agrícolas (Silva et al., 2019). Esta informação é essencial na agricultura irrigada, uma vez que, com ela, pode-se evitar o desperdício de água, energia e insumos, além de quedas de produtividade. Desse modo, a ET é um parâmetro chave no balanço hídrico, sendo destaque nesse contexto a utilização de dados provenientes de sensoriamento remoto (Ahmadpari et al., 2019; Yamaç e Todorovic, 2020; Santos et al., 2020). Essas estimativas geralmente se baseiam nos componentes da equação do balanço de energia e têm apresentado alto grau de confiabilidade e rapidez na estimativa da ET (Senay et al., 2016).

Dentre os modelos agrometeorológicos desenvolvidos, pode ser citado o Simple Algorithm For Evapotranspiration Retrieving (SAFER), apresentado por Teixeira (2010). O SAFER é um algoritmo de balanço de energia desenvolvido com base na modelagem da fração evapotranspirativa (ET_f), de fácil aplicação e operacionalidade (Teixeira et al., 2014; Teixeira et al., 2015) e tem apresentado bons resultados em trabalhos com ênfase em manejo da irrigação (Santos et al., 2020). Para Roerink et al. (2000), a ET_f é uma razão entre a energia liberada na forma de calor latente e o calor total que sai da superfície da Terra (soma dos fluxos de calor latente e sensível).

Teixeira et al. (2013) e Teixeira et al. (2016) encontraram resultados consistentes ao utilizarem o SAFER para estimarem a evapotranspiração real (ET_r) diária e mensal em áreas com diferentes cultivos agrícolas e condições climáticas. A eficiência da ET_r estimada pelo SAFER também foi investigada por Sales et al. (2017), que compararam sua precisão em relação à evapotranspiração da cultura obtida por meio do método Penman-Monteith (FAO 56) no cultivo de tomate industrial. Esses autores encontraram um coeficiente de determinação (r^2) igual a 0,98 e um coeficiente de concordância (d) equivalente a 0,99, e, assim, recomendaram o SAFER para o gerenciamento da irrigação. No entanto, o uso com essa finalidade é restringido devido à resolução temporal do Landsat-8, que é de 16 dias.

O uso das imagens do satélite Landsat-8 para estimar a ET_r através do algoritmo SAFER é possível porque possui o espectro eletromagnético da região do infravermelho termal. Esse espectro eletromagnético possibilita estimar a temperatura da superfície, sendo considerado um dos principais parâmetros responsáveis diretamente para determinar a ET_r (Weng et al., 2014; Petchprayoon et al., 2016; Erlandsen et al., 2017; Anapalli et al., 2018).

Entretanto, a resolução temporal do Landsat-8 (16 dias) torna-se um obstáculo quando o objetivo é realizar o manejo da irrigação. Esse fator é intensificado em regiões tropicais, que tendem a ter áreas com taxas de ET maiores que os índices de precipitação (Lessa et al., 2019).

Diante do exposto, é notória a necessidade de estudar outros satélites que tenham melhor resolução temporal. Entretanto, não existem satélites gratuitos disponíveis e que combinem alta resolução espacial e temporal, além da capacidade de capturar a radiação eletromagnética emitida na região do infravermelho térmico, o que poderia tornar o manejo da irrigação acessível por imagens de satélites. Por outro lado, os satélites Sentinel 2A e Sentinel 2B possuem boa resolução espacial e temporal, embora não tenham a capacidade de capturar a radiação eletromagnética emitida na região do infravermelho termal (Filgueiras et al., 2019).

Considerando este cenário, é notório que existe um desafio significativo para a modelagem de ET com imagens frequentes sem o espectro do infravermelho termal, o que ajudaria nas decisões de gerenciamento dos recursos hídricos em nível de propriedade agrícola (Sobrino et al., 2016). Portanto, é desejável desenvolver técnicas que possibilitem preencher essa lacuna fornecendo informações detalhadas e frequentes da ET_r .

Como ferramenta alternativa e promissora, existem algoritmos de aprendizado de máquina que, cada vez mais, têm sido aplicados na modelagem de ET (Carter e Liang, 2019; Granata, 2019; Tikhamarine et al., 2019). Essas ferramentas, no geral, superam as equações convencionais para estimativa da ET_r e/ou ET_o (Antonopoulos e Antonopoulos, 2017; Mattar, 2018; Ferreira e Cunha, 2020). Estes algoritmos de aprendizado de máquina são modelos matemáticos robustos, com elevado potencial de predição (Deo et al., 2016) e, além disso, são capazes de capturar relacionamentos complexos entre entrada e saída de dados, com interessante assertividade nos valores preditos (Ferreira e Cunha, 2020; Yamaç e Todorovic, 2020).

Um trabalho com bons resultados (valores médios de coeficiente de correlação (r^2) = 0,91 e raiz do erro quadrático médio (RMSE) = 1,39 mm d^{-1}) foi realizado por Zhang et al. (2018), no qual estimou-se a ET_o a partir de modelos de aprendizado de máquina com a utilização de bandas espectrais e temperatura da superfície diurna e noturna. Esses autores também testaram somente as refletâncias de superfície para prever a ET_o e verificaram que apenas essas informações são insuficientes para atingir bons resultados. Logo, concluíram que a temperatura de superfície foi uma variável essencial para alcançarem bom desempenho no estudo devido à mesma ter relação com a temperatura do ar, a qual, por sua vez, está intimamente relacionada com a ET_o .

Uma alternativa para estimar a ET_r poderia ser por meio da multiplicação da fração evapotranspirativa (ET_f) pela ET_o adquirida por metodologia que seja assertiva. A refletância espectral das culturas pode ser considerada uma estimativa indireta do coeficiente da cultura (K_c) que é utilizado nos modelos convencionais para calcular a evapotranspiração da cultura (Bezerra et al., 2010; Campos et al., 2016). De acordo com Santos et al. (2020), a ET_f , calculada a partir do SAFER também pode ser considerada como a combinação dos coeficientes de umidade do solo (K_s) e K_c .

Apesar de muito estudos terem sido desenvolvidos com algoritmos de regressão para estimarem a ET , não foi encontrado, após realizada uma pesquisa bibliográfica, nenhum trabalho que avaliou o impacto do uso de algoritmos de aprendizado de máquina na estimativa da ET_f utilizando apenas dados de refletância da superfície. Para El-Hendawy et al. (2019), informações espectrais têm sido usadas com grande sucesso para detectar até mesmo as pequenas variações e modificações biofísicas e bioquímicas do dossel das plantas.

Partindo dessa necessidade e da disponibilidade da constelação Sentinel-2, objetivou-se, neste estudo, estimar a ET_f por meio de algoritmos de regressão e informações espectrais dos satélites Sentinel 2A e Sentinel 2B, bem como analisar a aplicabilidade temporal e espacial dos modelos de ET_f obtidos para estimar a ET_r em culturas agrícolas irrigadas por pivôs centrais.

2 REVISÃO DE LITERATURA

2.1 Evapotranspiração

A evapotranspiração (ET) é um processo físico no qual a água líquida é transferida para a atmosfera a partir do processo físico e biofísico da vaporização. A vaporização ocorre através da água do solo, lagos e mar, enquanto o biofísico se dá pela transpiração da água pelos vegetais. Esses processos se diferenciam unicamente quanto ao tipo de superfície evaporante (Allen et al., 1998b; Gowda et al., 2008; Anjitha, 2019). Para que eles ocorram, é necessário que a radiação solar (em maior grau) e a temperatura do ar (em menor escala) atuem com o suprimento de energia (Oliveira e Lucas, 2019). Além disso, a força motriz para liberar o vapor de água da superfície de evaporação para a atmosfera é dada pelo déficit de saturação de vapor de água (Frizzone et al., 2012; Pereira et al., 2013). Logo, os principais parâmetros climáticos que afetam a ET são radiação solar, temperatura do ar, umidade e velocidade do vento (Allen et al., 2006).

A ET tem um importante papel no ciclo hidrológico, sendo considerada crucial para a gestão dos recursos hídricos (Zhang et al., 2016; Ferreira e Cunha, 2020). Assim, ela possibilita conhecer o componente do balanço hídrico do solo, o que tornam disponíveis informações que são importantes principalmente para auxiliar os agricultores nas tomadas de decisões quanto à otimização e uso sustentável da água no setor agrícola (Mariño et al., 1993; Pereira et al., 2013; Yang et al., 2016; Sales et al., 2017; Yamaç et al., 2020).

Para que a correta lâmina de água seja aplicada, é preciso estimar de forma direta ou indireta a evapotranspiração real (ET_r). Tradicionalmente, a ET_r é estimada a partir de dados medidos em estações meteorológicas locais, por meio de modelos de evapotranspiração de referência (ET_o), coeficiente de culturas (K_c) tabelados e coeficiente de umidade do solo (K_s) (Subedi, 2015; He et al., 2017).

A ET_o é definida como a taxa de evapotranspiração de cultura hipotética, bem irrigada, crescendo ativamente, com altura uniforme de 0,12 m, resistência de superfície fixa a $70 \text{ s}^{-1} \text{ m}^{-1}$ e albedo de 0,23 (Allen et al., 1998b). A ET_o pode ser estimada por métodos diretos ou métodos indiretos. Os métodos diretos incluem lisímetros de pesagem e estimativas de equilíbrio de água do solo. Já os métodos indiretos são evaporação de tanque, atmômetro, Bowen ratio-energy balance, Eddy covariance, cintilômetro, fluxo de seiva e modelos matemáticos, que são baseados na utilização de dados climáticos (Allen et al., 2011; Frizzone et al., 2012).

Os métodos diretos têm limitações de uso porque possuem instalações caras, manutenções trabalhosas, além de possuírem limitações espaciais (Dinpashoh, 2006; Anjitha, 2019). Com isso, em áreas agricultáveis, as maiores aplicabilidades são dos métodos que estimam a ET_o de forma indireta. No entanto, existem certas limitações que restringem a aplicação desses métodos porque a ET_o depende de diversas variáveis meteorológicas, as quais incluem temperatura do ar, velocidade do vento, umidade, radiação e suas interações (Tao et al., 2018; Jovanovic et al., 2018; Jing et al., 2019). Além disso, a ET_o pode ser classificada por um fenômeno não linear, que é complexo de medir e estimar com precisão (Jing et al., 2019; Yamaç et al., 2020).

Dentre os métodos matemáticos disponíveis para estimar a ET_o , existem os de base empírica e física. Os métodos empíricos foram desenvolvidos para lugares com condições climáticas específicas, com diferentes precisões e requer calibrações locais rigorosas. Entretanto, tendem a requerer menor quantidade de variáveis meteorológicas em relação ao método físico padrão de Penman-Monteith (Allen et al., 1998b), parametrizado pelo boletim da FAO 56 (Food and Agriculture Organization of the United Nations) (Abdullah et al., 2015; Feng et al., 2017; Costa et al., 2019). Por sua vez, o modelo Penman-Monteith (FAO 56), que incorpora parâmetros fisiológicos e aerodinâmicos, é considerado como o ideal na gestão do uso da água, sendo o método mais consistente em uma ampla gama de condições climáticas (Allen et al., 1998b).

A ET_r é a que de fato ocorre nas diferentes fases de desenvolvimento das plantas, independentemente de sua área e das condições de umidade do solo (Matzenauer, 1999). Para estimar a ET_r diretamente é necessário o conhecimento do albedo, das resistências aerodinâmicas superficiais do dossel, das características de crescimento da cultura específica e dos parâmetros meteorológicos (Allen et al., 2007). Porém, é preciso atentar que o albedo e as resistências variam continuamente em função do desenvolvimento e condições climáticas. Além dessas limitações na aquisição dessas variáveis, suas estimativas ainda estão sujeitas a erros devido à dificuldade de considerar adequadamente vários fatores que afetam a uniformidade e estabilidade do contínuo do solo-planta-atmosfera (Allen et al., 2011; Yamaç et al., 2020).

O K_c está relacionado com a cultura e o período de desenvolvimento, ou seja, expressa o comportamento dos cultivos e seus estádios fisiológicos no sistema solo-planta-atmosfera (Allen et al., 1998b; Warren et al., 2013). O K_c começa com um valor mínimo na emergência e aumenta de acordo com o desenvolvimento da cultura, até que o K_c máximo seja atingido,

aproximadamente, na cobertura total do dossel, que ocorre no estágio reprodutivo e, em seguida, tende a diminuir (Kamble et al., 2013).

Porém, quando se utiliza valores de K_c tabelado, pode ocorrer generalização porque admite-se que toda a área agrícola seja homogênea e, com isso, a demanda hídrica das plantas é considerada igual em toda a área manejada (He et al., 2017). Para Kamble et al. (2013), o K_c varia no tempo e no espaço devido às condições climáticas que submetem a lavoura, o manejo de solo e a irrigação. Sabendo que a área agrícola apresenta grande variabilidade quanto ao tipo de solo e vigor da cultura, não seria correto considerar o K_c único em toda área porque pode haver aplicação de água demasiada em algumas áreas e déficit em outras sob o mesmo sistema de irrigação (Allen et al., 2011; Kamble et al., 2013).

2.2 Irrigação

A produção agrícola brasileira é responsável por uma fração significativa dos alimentos consumidos globalmente, estando o país entre os maiores exportadores de commodities agrícolas, sendo os principais produtos soja, milho, açúcar e carne bovina (Zilli et al., 2020). No entanto, o Brasil é um país de grande extensão territorial e possui variabilidade quanto ao clima, vegetação, recursos hídricos, cultura e economia. Devido a essa diversidade, algumas regiões são mais afetadas com escassez hídrica, que são reforçadas pelas alterações climáticas (Nazari et al., 2018; Zilli et al., 2020), o que coloca em risco a produção das culturas agrícolas.

Nesse contexto, faz-se necessário o uso de estratégias de gestão da água e aquisição de tecnologia da irrigação para suprir a demanda hídrica pelas plantas e reduzir os riscos de baixa produtividade, além de promover a segurança alimentar (Scarpore et al., 2016; Elshaikh et al., 2018; Kadiresan e Khanal, 2018). Não obstante, tal tecnologia deve ser implantada e acompanhada de forma técnica através do manejo, o que vai permitir redução do uso de recursos hídricos sem comprometer a produção agrícola, menor impacto econômico e ambiental, bem como redução nos conflitos hídricos (Toumi et al., 2016). Para Marin et al. (2016), a falta de informações básicas para o manejo da irrigação favorece o uso inadequado da água.

Logo, o conhecimento de parâmetros relacionados à cultura, ao solo e ao clima é necessário para o manejo da água (Allen et al., 1998b). Dentre esses parâmetros, a estimativa precisa da evapotranspiração (ET) no espaço e no tempo em nível de campo é pertinente, visto que ela se configura um componente dominante do uso da água e proporciona

informações que dão subsídios a tomadas de decisões no manejo da irrigação, além de otimizar o planejamento das atividades agrícolas (He et al., 2017; Shi et al., 2017; Jing et al., 2019).

Com o avanço da tecnologia no campo, uma alternativa que permite estimar de modo espacial a ET, reduzindo assim os níveis de incerteza deste parâmetro, é a utilização de dados provenientes de sensoriamento remoto (Tang et al., 2013; Tang e Li, 2015; Campos et al., 2016; Dias et al., 2021). Os dados adquiridos por meio do sensoriamento remoto, principalmente o orbital, têm impulsionado os estudos sobre o tema em questão devido à disponibilidade de satélites gratuitos (Bezerra et al., 2018).

2.3 Sensoriamento remoto

O sensoriamento remoto é uma ferramenta bastante difundida em estudos que constituem a superfície terrestre, o qual utiliza de sensores orbitais, sub orbitais ou terrestres. Os sensores possuem a função de quantificar a energia eletromagnética emitida ou refletida pelos alvos de interesse, utilizando o sol como fonte de energia, exceto para os sensores ativos (radares e laser) que possuem suas próprias fontes de radiação (Schott, 2007; Moreira, 2011). A energia eletromagnética refletida se dá em função das características físico-químicas e biológicas dos objetos terrestres, permitindo a identificação por meio da porcentagem de energia refletida em cada comprimento de onda (Rodríguez, 2006; Moreira, 2011).

Com o rápido desenvolvimento das tecnologias de sensoriamento remoto, muitos estudos foram conduzidos para desenvolver satélites com sensores multiespectrais passivos de acesso gratuito, como o Landsat, Sentinel-2, entre outros (Rawat e Kumar, 2015; Guzinski e Nieto, 2019). Nesse âmbito, cada constelação tem suas especificidades e limitações ao trabalhar com aplicações na agricultura, em especial com modelos que requerem informações desses sensores para estimar a evapotranspiração (ET) (Guzinski e Nieto, 2019).

Ao estimar a ET, a principal limitação do uso do Landsat está na baixa resolução temporal, enquanto que para o Sentinel-2 é a ausência da capacidade de adquirir informação referente à radiação eletromagnética emitida na região do infravermelho térmico, uma vez que estudos demonstram a importância dessa informação para a estimativa da ET (Sobrino et al., 2016; Fisher et al., 2017; Xue e Su, 2017). Além desses obstáculos, também há a limitação na aquisição de imagens com a existência de nuvens em sensores passivos (Leng et al., 2017; Xue e Su, 2017). A presença de nuvens pode reduzir significativamente a insolação da

superfície e, como consequência, leva a ocorrer aumento da radiação de onda longa descendente, podendo induzir a grandes incertezas nas informações (Leng et al., 2017).

Aliado ao sensoriamento remoto, as técnicas de análise de dados baseadas em aprendizado de máquina têm contribuído com resultados com excelentes precisões (Ke et al., 2016; Althoff et al., 2018; Dou e Yang, 2018; Ferreira et al., 2019; Dias et al., 2021). Esses modelos possuem uma elevada capacidade em encontrar padrões em variáveis com comportamentos não lineares (Dou e Yang, 2018; Filgueiras et al., 2019; Granata, 2019).

2.3.1 Satélites: Landsat-8 e Sentinel-2

O satélite Landsat-8 possui os sensores Operational Land Imager (OLI) e o Thermal Infrared Sensor (TIRS), que operam com resolução temporal de 16 dias, resolução radiométrica de 16 bits, assim como capturam radiação eletromagnética (REM) em 11 bandas espectrais ao longo dos comprimentos de onda de 0,43 a 12,51 μm e possuem resoluções espaciais de 15, 30 e 100 m, conforme Tabela 1 (NASA, 2013; Roy et al., 2014). O sensor TIRS possui as bandas 10 e 11, ambas com resolução espacial de 100 m, as quais já estão disponíveis, atualmente, para downloads com pixels reamostrados para 30 m.

Tabela 1. Comparação das bandas do Landsat-8 com as bandas do Sentinel 2A e 2B

Landsat-8			Sentinel-2		
Banda	Resolução espacial (m)	Comp. onda (μm)	Banda	Resolução espacial (m)	Comp. onda central (μm)
ρ_1 - Costeira/Aerossol	30	0,43-0,45	ρ_1 - Aerossol	60	0,44
ρ_2 - Azul	30	0,45-0,51	ρ_2 -Azul	10	0,49
ρ_3 - Vermelho	30	0,53-0,59	ρ_3 - Verde	10	0,59
ρ_4 - Vermelho	30	0,64-0,67	ρ_4 - Vermelho	10	0,66
ρ_5 - IV Próximo	30	0,85-0,88	ρ_8 - IV Próximo	10	0,84
ρ_6 - IV Curto	30	1,57-1,65	ρ_5 - Red Edge1	20	0,70
ρ_7 - IV Curto	30	2,11-2,29	ρ_6 - Red Edge2	20	0,74
ρ_8 -Pancromática	15	0,50-0,68	ρ_7 - Red Edge3	20	0,78
ρ_9 - Cirrus	30	1,36-1,38	ρ_{8A} - Red Edge4	20	0,86
ρ_{10} - Termal	100	10,60-11,19	ρ_9 - Water vapor	60	0,94
ρ_{11} - Termal	100	11,50-12,51	ρ_{10} - Currus	60	1,37
-	-	-	ρ_{11} - Swir1	20	1,61
-	-	-	ρ_{12} - Swir2	20	2,19

Fonte: Roy et al. (2014); ESA (2018).

A constelação Sentinel-2 é formada por duas plataformas orbitais (Sentinel 2A e Sentinel 2B). Embarcado em cada um desses satélites está o sensor Multi Spectral Instrument (MSI), que capta a radiação refletida em 13 bandas espectrais. Esse sensor possui uma resolução radiométrica de 12 bits e temporal de 10 dias quando utilizado apenas um satélite e

uma frequência de imagens de cinco dias com as duas plataformas orbitais. A resolução espacial do sensor varia de acordo com as bandas, possuindo bandas de 10, 20 e 60 m, com o comprimento de onda entre 0,44-2,19 μm , como apresentado na Tabela 1 (ESA, 2018; Fernández-Manso et al., 2016).

2.4 Aprendizado de máquina

O aprendizado de máquina (AM) é uma área da inteligência artificial (Panch et al., 2018; Galbusera et al., 2019) que utiliza o conhecimento da probabilidade e estatística, da teoria da complexidade computacional, da teoria da informação, da filosofia, da psicologia e da neurobiologia, entre outros (Cerri e Carvalho, 2017; Panch et al., 2018). As técnicas do AM são consideradas ferramentas poderosas para encontrar padrões de dados com vistas à extração de informações a partir do desenvolvimento de algoritmos matemáticos que permitam ao computador a capacidade de aprender, generalizar ou ainda extrair padrões ou características das classes das coleções baseado na entrada de um banco de dados (Mitchell, 1997; Alpaydin, 2010; Faceli et al., 2011).

Os métodos de aprendizado de máquina podem ser divididos quanto ao nível de supervisão do conjunto de dados de treinamento, sendo eles classificados em: aprendizado supervisionado e aprendizado não supervisionado (Haykin et al., 2009). Nesse ínterim, Chapelle et al. (2006) também incluem o aprendizado semi-supervisionado.

Os métodos de aprendizado supervisionado usam um conjunto de dados conhecido para fazer inferências, sendo que cada dado possui um rótulo associado, a partir do qual deduzem uma função matemática que consiste em pares de exemplos de entradas e saídas (Haykin et al., 2009). Esse rótulo define a classe de predição à qual o conjunto de dados pertence e, de acordo com os valores atribuídos à classe, o problema é conhecido como classificação ou regressão (Mohri et al., 2012).

Os métodos não supervisionados extraem inferências de conjuntos de dados contendo dados sem saídas rotuladas. Dessa forma, o sistema aprende com base em tentativa e erro, cujo objetivo é o de agrupar informações semelhantes no mesmo cluster (Haykin et al., 2009; Jaspers et al., 2018).

O aprendizado semi-supervisionado é a combinação entre o aprendizado não supervisionado e o supervisionado. Este considera dados rotulados e não rotulados para induzir um modelo de classificação (Chapelle et al., 2006).

A seguir, são apresentados, de forma breve, alguns algoritmos de regressão pertencentes ao aprendizado supervisionado.

2.4.1 Regressão linear múltipla

A regressão linear múltipla (LM) é uma técnica estatística desenvolvida para representar a relação da distribuição espacial em uma variável resposta (variável dependente) por meio de uma combinação linear de variáveis explicativas (variáveis independentes). A intenção com esse modelo é ajustar uma equação linear que minimiza a soma dos quadrados dos erros (SQE) entre os dados observados e previstos (Maulud e Abdulazeez, 2020; Dias et al., 2021). A Equação 1 é um modelo de regressão linear múltipla com k variáveis preditoras, x_1, \dots, x_k .

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_i x_i + \dots + \beta_k x_k + \varepsilon \quad (1)$$

em que: y é a variável dependente; β_0 é o intercepto; x_i é a i -ésima variável independente; β_i são os coeficientes polinomiais de x_i ; k é o número de variáveis independente; ε é o erro aleatório que representa a diferença no modelo linear e um determinado valor observado para y .

2.4.2 Support Vector Machine

O Support Vector Machine (SVM) proposto por Vapnik (1995) é uma técnica de aprendizagem de máquina que foi originalmente desenvolvido no contexto de modelos de classificação de padrões a partir da teoria de aprendizado estatístico. O SVM tem o objetivo de encontrar um classificador linear capaz de separar classes de acordo com as semelhanças de características determinadas previamente (Tian et al., 2012). O classificador linear é conhecido como hiperplano que representa a separação de maneira ótima entre duas classes de pontos usando conjuntos de dados de treinamento (Chau et al., 2014).

As funções usadas para projetar o reconhecimento dos padrões dos dados do espaço de entrada para o espaço de alta dimensão são chamadas de núcleos e sua correta determinação é importante, pois possui forte influência nos resultados obtidos por uma SVM (Libralão et al., 2005). Os núcleos mais utilizados são: Linear, Polinomial, Gaussiano e Sigmoidal (Libralão et al., 2005).

2.4.3 Cubist

O Cubist é um algoritmo de regressão desenvolvido por Quinlan (1997), criado a partir de ajustes do método denominado de árvore do modelo (M5), descrito por Quinlan (1992), que tinha problemas de classificação. O Cubist é baseado em árvore de decisão e tem alta capacidade de gerar modelos preditivos a partir da análise de dados de entrada, uma vez que utiliza regras que equilibram a necessidade de previsão precisa com os requisitos de inteligibilidade (Rulequest, 2016). Os valores preditos pelo algoritmo Cubist são superiores aos modelos de regressão linear e mais simples do que o sistema de redes neurais (Rulequest, 2016).

A metodologia do Cubist difere da M5 principalmente pela criação de regras e podas usadas para suavização da criação do modelo linear (Kuhn e Johnson, 2013). A suavização permite previsões fora da amostra, em que os valores preditos gerados pelas regras do modelo podem ser ajustados usando-se os pontos próximos dos dados do conjunto de treinamento (Kuhn e Johnson, 2013). A metodologia também utiliza um procedimento chamado committees, que é similar a boosting (Kuhn e Johnson, 2013).

Nos committees, os pesos nos modelos não são alterados e o resultado do conjunto de treinamento é ajustado com base no modelo anterior. Em seguida, cria-se um conjunto de regras usando essa pseudo-resposta (Kuhn e Johnson, 2016). Para gerar o modelo final com os valores preditos, são realizadas combinações de predições resultantes de árvores de regressão simples em um conjunto de regras de produção, tendo como estimador de resposta em cada árvore um modelo de regressão linear conhecido como piecewise (Kuhn e Johnson, 2016). Se uma regra satisfaz todas as condições, a função linear correspondente é apropriada para prever os valores de saída, de forma que o produto final seja a média de todos os modelos de regressão linear (Nguyen et al., 2019; Nguyen et al., 2020; Dias et al., 2021).

2.4.4 Bayesian-Regularized Neural Network

A Bayesian-Regularized Neural Network (BRNN) é um algoritmo que foi desenvolvido com o conhecimento de artificial neural networks (ANN) a partir da inclusão de uma etapa de regularização Bayesianas (Mackay et al., 1992). Com o objetivo de minimizar os erros, a ANN determina o peso nodal e os parâmetros de polarização usando uma estimativa de máxima verossimilhança. Em consequência a essa metodologia, o modelo de treinamento está sujeito a overfitting (Piotrowski e Napiorkowski, 2011; Piotrowski e

Napiorkowski, 2013). Já o BRNN, por sua vez, treina a rede usando a regularização Bayesiana com retropropagação, sendo capaz de reduzir o overfitting. Isso é possível devido à regularização Bayesiana ser obtida por meio do tratamento dos pesos como variáveis aleatórias seguindo distribuições anteriores específicas (Mackay et al., 1992; Glória et al., 2016).

2.4.5 eXtreme Gradient Boosting

O eXtreme Gradient Boosting (Xgb) é uma implementação mais rápida e aprimorada de aumento de gradiente para aprendizagem supervisionada, considerado uma versão melhorada do modelo Gradient Boosting Machine (Friedman, 2001). Com capacidade de prevenir o sobreajuste, otimiza os recursos de computação e também incorpora a técnica de regularização e validação cruzada a fim de prevenir o overfitting (Chen e He, 2018; Fan et al., 2018; Climent et al., 2019).

O modelo Gradient Boosting Machine adiciona um dado após o outro, o que torna esse modelo de fraco aprendizado (Friedman, 2001). Enquanto o Xgb trabalha de forma semelhante ao algoritmo Random Forest, o qual gera várias árvores de decisão paralelamente entre si e usa amostras de dados seguindo o método de ensacamento ou boosting (Breiman, 2001; Ye et al., 2021), o boosting no Xgb usa um modelo de árvores de classificação ou árvores de regressão, o qual permite um melhor desempenho dos valores preditos em comparação aos modelos individuais usados isoladamente (Breiman et al., 1984).

Logo, o processamento básico do Xgb para gerar um modelo predito ocorre a partir da técnica de conjunto de árvores, considerado uma combinação de regressão linear de centenas ou milhares de árvores (Elith et al., 2008). Com isso, forma um conjunto de preditores que são ponderados de acordo com seu desempenho e cujos resultados são combinados usando votação para problemas de classificação ou a média para problema de regressão, criando, assim, o modelo final (Breiman et al., 1984; Chen e Guestrin, 2016).

3 MATERIAL E MÉTODOS

3.1 Área de estudo

A pesquisa foi realizada em uma área pertencente à região hidrográfica do rio Tocantins-Araguaia (Figura 1), estando localizada mais especificamente no Vale do São Patrício, estado de Goiás, delimitada pelos pares de coordenadas X1: 660185,23; Y1: 8356189,30 (canto superior esquerdo) e X2: 693932,13; Y2: 8332533,58 (canto inferior direito), Sistema de referência DATUM WGS84 - Sistema de coordenadas planas UTM - Zona 22S. A bacia hidrográfica do rio Tocantins-Araguaia apresenta vazão média de $13.799 \text{ m}^3 \text{ s}^{-1}$, equivalente a 9,6% de todo o recurso hídrico nacional. Em termos de disponibilidade hídrica, essa bacia é considerada a segunda maior, ficando atrás apenas da região Amazônica (MMA, 2006).

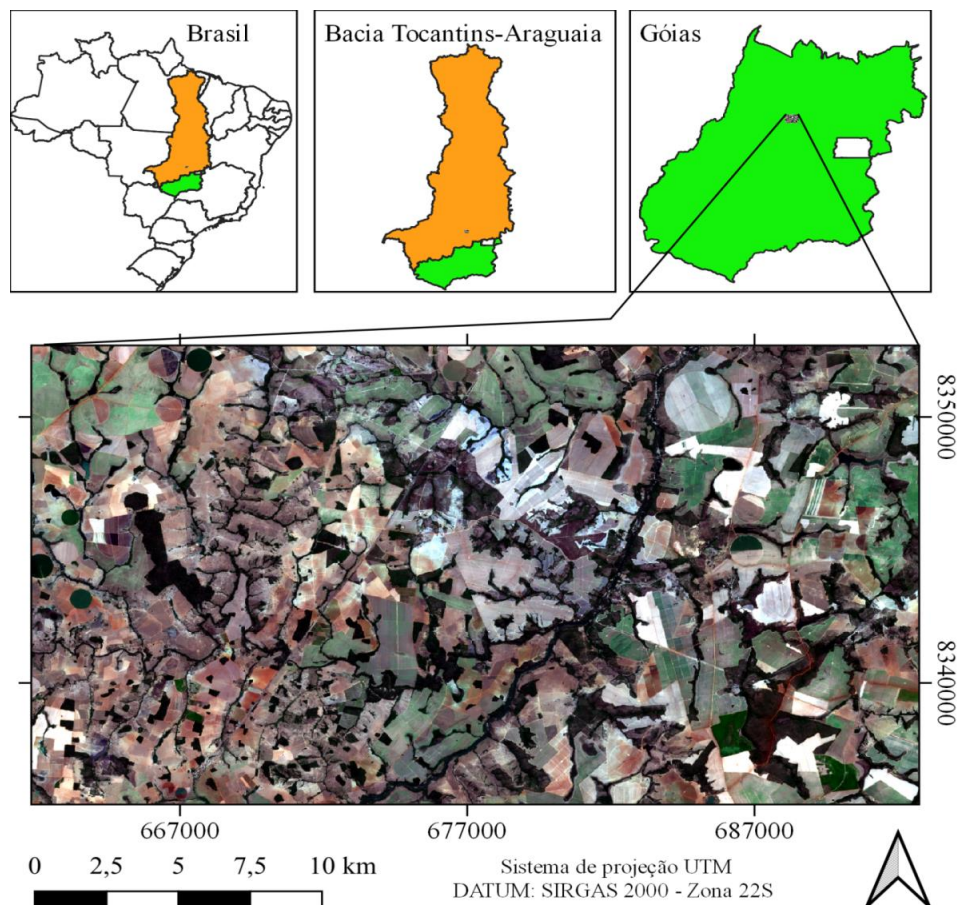


Figura 1. Localização geográfica referente à área utilizada para modelar a fração evapotranspirativa (ET_f) utilizando informações do Sentinel-2

Fonte: Elaborada pela autora.

A área de estudo, incluindo o solo exposto, possui os seguintes usos da terra: mata nativa, agricultura irrigada, agricultura de sequeiro, pastagem e rios. O clima da região hidrográfica do rio Tocantins-Araguaia é classificado, segundo a metodologia de Köppen, como Af - clima tropical sem estação seca definida, Am - clima tropical de monção, Aw - clima tropical com inverno seco e Cwa - clima úmido subtropical com inverno seco e verão quente (Alvares et al., 2013).

A área em estudo foi selecionada devido à elevada densidade de equipamentos de irrigação do tipo pivô central. Aliado a isso, existem grandes preocupações no âmbito mundial quanto ao uso dos recursos hídricos, pois a disponibilidade de fonte de água que possa ser utilizada na irrigação está diminuindo em função das mudanças climáticas (Kadiresan e Khanal, 2018). Logo, para garantir a segurança hídrica, o manejo da irrigação é necessário. Por outro lado, o manejo da irrigação também contribui com a segurança alimentar, uma vez que a água é fundamental para alcançar produtos agrícolas em maior quantidade e qualidade (Elshaikh et al., 2018; Kadiresan e Khanal, 2018).

Na Figura 2 é apresentado o fluxograma com as etapas que foram realizadas para a modelagem da variável alvo, as quais são posteriormente explicadas nos tópicos.

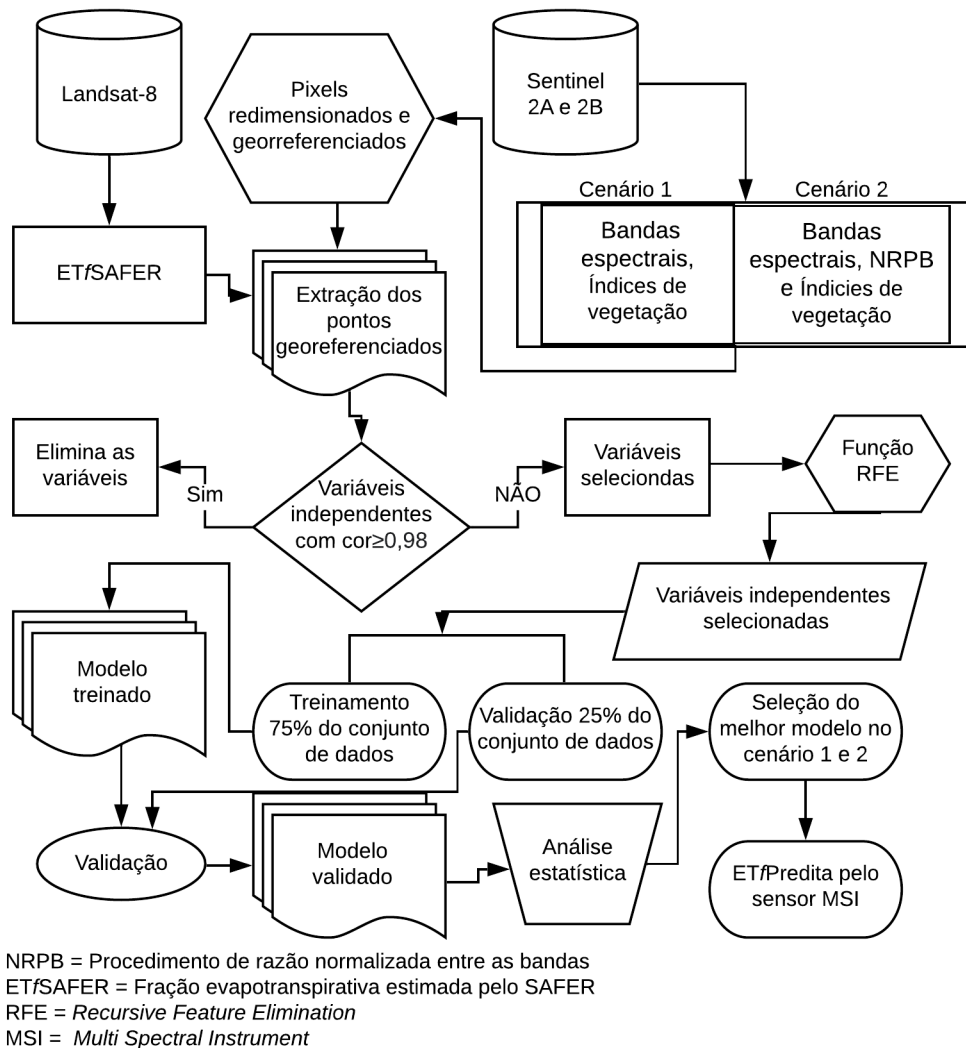


Figura 2. Metodologia utilizada para prever a fração evapotranspirativa (ET_f)

Fonte: Elaborado pela autora.

3.2 Variável alvo: fração evapotranspirativa (ET_f)

Para modelar a fração evapotranspirativa (ET_f) a partir de modelos de regressão e informações prontamente disponíveis, foram utilizadas imagens dos satélites Sentinel 2A e 2B como variáveis de entrada nos modelos. Entretanto, as informações provenientes do Landsat-8 foram usadas como referência para o cálculo da ET_f pelo Simple Algorithm For Evapotranspiration Retrieving (Teixeira, 2010), aqui denominado de ET_f SAFER.

Os recursos escolhidos para modelar a ET_f são todos constituídos de variáveis contínuas e dinâmicas no espaço e no tempo. Os satélites utilizados na pesquisa foram alvo de

estudo devido ao potencial em termos de resolução espacial e temporal, além da existência da banda referente ao espectro termal presente somente no Landsat-8.

As imagens de satélite foram adquiridas na plataforma Earth Explorer (<http://earthexplorer.usgs.gov>) pertencente ao United States Geological Survey (USGS). Posterior ao download, foi feita uma análise visual para a seleção das imagens livres de nuvens e ruídos com vistas ao não comprometimento das análises dos modelos. Após essa análise foram selecionados seis pares de imagens (Landsat-8 e Sentinel-2) com as mesmas datas, sendo eles registrados nos dias 03/02/2016, 09/03/2017, 16/08/2017 e 23/01/2018, 06/08/2019 e 02/04/2020.

Em seguida, foi realizado um pré-processamento com intuito de deixar as imagens aptas para serem utilizadas na estimativa da ET_f . Nessa etapa foram realizados procedimentos operacionais no software QGis® 2.18 (QGIS Development Team, 2015). O Semi-Automatic Classification Plugin (Congedo, 2016) foi usado para a conversão de números digitais para valores físicos (imagens Landsat-8) e para correção atmosférica (imagens Landsat-8). A metodologia de correção atmosférica Dark Object Subtraction (DOS1) (Chavez, 1996) foi adotada para conter os efeitos aditivos causados pela dispersão de partículas presentes na atmosfera. Em seguida, realizou-se a reprojeção do sistema de coordenadas para UTM, zona 22 Sul.

3.3 Metodologias - recursos realizados para modelar a variável alvo

Foram utilizadas as quatro primeiras imagens (03/02/2016, 09/03/2017, 16/08/2017 e 23/01/2018) das seis selecionadas dos satélites Sentinel-2 (A ou B) e Landsat-8. As informações contidas nas imagens foram utilizadas para treinamento e validação dos algoritmos. Foi utilizada como variável dependente a ET_f SAFER, calculada com informações do Landsat-8 a partir das refletâncias das bandas (ρ_2 , ρ_3 , ρ_4 , ρ_5 , ρ_6 e ρ_7) e radiância ρ_{10} necessária para estimar os parâmetros biofísicos presentes na metodologia de Teixeira (2010). O primeiro parâmetro estimado no algoritmo SAFER foi o albedo no topo da atmosfera (α_{TOA}), para que, em seguida, fossem estimados os demais parâmetros. A partir do albedo no topo da atmosfera (α_{TOA}), obtido pela Equação 2, calculou-se o albedo de superfície (α_s) por meio da Equação 3.

$$\alpha_{TOA} = 0,300\rho_2 + 0,277\rho_3 + 0,233\rho_4 + 0,143\rho_5 + 0,036\rho_6 + 0,012\rho_7 \quad (2)$$

$$\alpha_s = \alpha \times \alpha_{TOA} + b \quad (3)$$

em que: $\rho_2, \rho_3, \rho_4, \rho_5, \rho_6$ e ρ_7 são as refletâncias da superfície das bandas 2, 3, 4, 5, 6 e 7, respectivamente; a (0,7) e b (0,06) são os coeficientes de regressão (Vanhellemont e Ruddick, 2014).

Os pesos adotados para encontrar o α_{TOA} foram determinados pela metodologia de Silva et al. (2016).

As temperaturas de brilho do sensor (T_{bri}) e de superfície (T_s) foram obtidas pelas Equações 4 e 5, respectivamente. Para calcular a T_{bri} , foi utilizada a banda termal 10.

$$T_{bri} = \rho_{10} + 273,16 \quad (4)$$

$$T_s = 1,11 \times T_{bri} - 31,89 \quad (5)$$

em que: ρ_{10} é a banda do infravermelho termal do sensor TIRS do satélite Landsat-8.

O índice de vegetação por diferença normalizada (NDVI) é um indicador relacionado com as condições hídricas e de vegetação, calculado pela Equação 6 (Rouse et al., 1974).

$$NDVI = \frac{\rho_8 - \rho_4}{\rho_8 + \rho_4} \quad (6)$$

em que: ρ_8 é a refletância da banda do infravermelho próximo (banda 8); e ρ_4 é a refletância na banda do vermelho (banda 4).

Com os dados do α_s , T_s e $NDVI$ obteve-se a fração evapotranspirométrica (ET_f) por meio da Equação 7.

$$ET_f SAFER = \exp \left[a + b \left(\frac{T_s}{\alpha_s \times NDVI} \right) \right] \quad (7)$$

em que: a e b são os coeficientes de regressão obtidos pelo modelo de Teixeira (2010), que apresentam, respectivamente, os valores de 1,8 e -0,008, ajustados para as condições semiáridas do Brasil.

As variáveis independentes foram as refletâncias das bandas multiespectrais provenientes da constelação Sentinel-2 ($\rho_2, \rho_3, \rho_4, \rho_8, \rho_5, \rho_6, \rho_7, \rho_{8A}, \rho_{11}$ e ρ_{12}) e três diferentes

índices de vegetação. Foram utilizados o NDVI - índice de vegetação da diferença normalizada (Rouse et al., 1974), o EVI - índice de vegetação melhorado (Huete et al., 1997) e o NDWI - índice de umidade por diferença normalizada (Gao, 2000), os quais foram calculados conforme as Equações 6, 8 e 9, respectivamente. O NDVI e o EVI estão associados com estado de crescimento da vegetação, enquanto o NDWI é um índice de umidade.

$$NDWI = \frac{\rho_8 - \rho_{12}}{\rho_8 + \rho_{12}} \quad (8)$$

$$EVI = G \frac{\rho_8 - \rho_4}{(\rho_8 + (C_1 \times \rho_4) - (C_2 \times \rho_2)) + L} \quad (9)$$

em que: ρ_8 , ρ_4 , ρ_{12} , ρ_2 são as refletâncias da banda do infravermelho próximo (banda 8), vermelho (banda 4), infravermelho de onda curta (banda 12) e azul (banda 2) do sensor MSI, respectivamente; G é o fator de ganho ajustado; L é o fator de ajuste do solo; e C_1 e C_2 são coeficientes para correção de aerossóis (fumaça, partículas de poluição do ar e poeira). Para os coeficientes G , C_1 , C_2 e L foram assumidos os valores de 2,5; 6,0; 7,5 e 1,0 respectivamente.

As bandas multiespectrais do Sentinel-2 deram origem a outras covariáveis, as quais, por meio da Função `band_ratio` do pacote `Labgeo` (Fernandes Filho, 2019) no software estatístico R, foram calculadas todas as possibilidades de razão entre as bandas. Filgueiras et al. (2019) denominaram esse procedimento de razão normalizada entre as bandas (NRPB) (Equação 10). Por meio desse procedimento, foram originadas 45 novas covariáveis, totalizando 58 variáveis independentes.

$$NRPB = \frac{\rho_n - \rho_{n+1}}{\rho_n + \rho_{n+1}} \quad (10)$$

em que: ρ_n são as refletâncias de superfície em relação às bandas do sensor MSI/Sentinel 2A e 2B.

Depois que as 58 covariáveis foram adquiridas, preditores com alta colinearidade foram excluídos usando-se um limite de correlação de 0,98. Posteriormente, foi feita novamente a filtragem do conjunto de dados para eliminar os preditores que apresentaram

baixa importância para os modelos usando a Função Recursive Feature Elimination (RFE) do pacote Caret (Kuhn, 2008) no software R (R Team, 2017).

Como apresentado, as variáveis em estudo possuem resolução espacial distinta (Tabela 1), logo, foi necessário converter todas as variáveis independentes para 30 m. Para isso, aplicou-se a Função resample do pacote Raster (Hijmans e Etten, 2012) no software R (R Team C., 2017).

O banco de dados das variáveis, para cada par de imagens, foi obtido a partir da coleta aleatória em pontos georreferenciados. Para esse procedimento foi utilizada a Função sampleRandom do pacote Raster, presente no software R (R Team C., 2017). Para avaliar o desempenho dos modelos, o conjunto de dados foi separado em treinamento e validação. Assim, os conjuntos de dados foram divididos aleatoriamente na proporção de 75% (110.442 pares de pontos) para o treinamento com validação cruzada k-fold ($k = 10$) e 25% (36.814 pares de pontos) para a validação da estimativa da ET_f . Essa proporção foi realizada com base em Althoff et al. (2020), que afirmaram que a proporção 75/25% é adequada para separar em conjunto de treinamento e validação, respectivamente.

3.4 Algoritmos de regressão usados na predição da ET_f

Na tentativa de modelar a ET_f foram utilizados seis algoritmos de regressão: Regressão Linear Múltipla (LM), Linear Support Vector Machine (SVM Linear), Cubist, Bayesian-Regularized Neural Network (BRNN) e eXtreme Gradient Boosting (Xgb) pelos métodos Linear e Tree. Todos os algoritmos foram implementados usando-se o pacote Caret (Kuhn, 2008) no software R (R Team C., 2017).

Esses modelos apresentam uma abordagem de regressão variada. Entretanto, o desempenho pode variar de acordo com a característica da variável a ser modelada, do qual decorre a importância das suas escolhas. A esse respeito, maiores informações sobre os modelos utilizados podem ser obtidas em Kuhn e Johnson (2013). Todos esses modelos de regressão foram testados e validados por meio de métricas estatísticas e, a partir dessas informações, foi selecionado o melhor modelo que ajustou-se à variável-alvo.

3.5 Estudo de dois cenários de entrada de variáveis independentes para prever a ET_f considerando a área total

As bandas espectrais do satélite Sentinel 2A e 2B e índices de vegetação compuseram um total de 11 variáveis e formaram o primeiro cenário (Tabela 2). A seleção dessas variáveis foi realizada após a análise de correlação de 0,98 e a Função RFE. No segundo cenário foi feita a combinação das variáveis derivadas somente das bandas espectrais do satélite Sentinel 2A e 2B por meio da NRPB. Após a realização do NRPB, procedeu-se à junção das variáveis aplicadas no primeiro cenário, sendo submetidas a essas variáveis a análise de correlação de 0,98 e a Função RFE, o que permitiu obter 29 variáveis (Tabela 2).

Tabela 2. Combinações de variáveis de entrada para cada cenário

Primeiro Cenário		Segundo Cenário	
ρ_2	NRPB ρ_2 e $\rho_3 = (\rho_2 - \rho_3)/(\rho_2 + \rho_3)$		ρ_2
ρ_3	NRPB ρ_2 e $\rho_4 = (\rho_2 - \rho_4)/(\rho_2 + \rho_4)$		ρ_3
ρ_4	NRPB ρ_2 e $\rho_5 = (\rho_2 - \rho_5)/(\rho_2 + \rho_5)$		ρ_4
ρ_5	NRPB ρ_2 e $\rho_6 = (\rho_2 - \rho_6)/(\rho_2 + \rho_6)$		ρ_5
ρ_6	NRPB ρ_3 e $\rho_4 = (\rho_3 - \rho_4)/(\rho_3 + \rho_4)$		ρ_6
ρ_{8A}	NRPB ρ_3 e $\rho_5 = (\rho_3 - \rho_5)/(\rho_3 + \rho_5)$		ρ_7
ρ_{11}	NRPB ρ_3 e $\rho_6 = (\rho_3 - \rho_6)/(\rho_3 + \rho_6)$		ρ_{11}
ρ_{12}	NRPB ρ_4 e $\rho_{8A} = (\rho_4 - \rho_{8A})/(\rho_4 + \rho_{8A})$		ρ_{12}
NDVI	NRPB ρ_4 e $\rho_5 = (\rho_4 - \rho_5)/(\rho_4 + \rho_5)$		NDVI
NDWI	NRPB ρ_4 e $\rho_{11} = (\rho_4 - \rho_{11})/(\rho_4 + \rho_{11})$		EVI
EVI	NRPB ρ_4 e $\rho_{12} = (\rho_4 - \rho_{12})/(\rho_4 + \rho_{12})$	NRPB ρ_8 e $\rho_6 = (\rho_8 - \rho_6)/(\rho_8 + \rho_6)$	
-	NRPB ρ_5 e $\rho_{11} = (\rho_5 - \rho_{11})/(\rho_5 + \rho_{11})$	NRPB ρ_8 e $\rho_7 = (\rho_8 - \rho_7)/(\rho_8 + \rho_7)$	
-	NRPB ρ_5 e $\rho_{12} = (\rho_5 - \rho_{12})/(\rho_5 + \rho_{12})$	NRPB ρ_8 e $\rho_{8A} = (\rho_8 - \rho_{8A})/(\rho_8 + \rho_{8A})$	
-	NRPB ρ_6 e $\rho_{8A} = (\rho_6 - \rho_{8A})/(\rho_6 + \rho_{8A})$	NRPB ρ_{11} e $\rho_{12} = (\rho_{11} - \rho_{12})/(\rho_{11} + \rho_{12})$	
-	NRPB ρ_7 e $\rho_{8A} = (\rho_7 - \rho_{8A})/(\rho_7 + \rho_{8A})$		-

Fonte: Elaborada pela autora.

As variáveis do segundo cenário foram criadas na expectativa de que pudessem aumentar o poder explicativo dos métodos de aprendizado de máquina. Esses métodos também apresentam boa capacidade de encontrar padrões em conjunto de dados com significativa quantidade de parâmetros, qualidade e quantidade dos dados de entrada (Althoff et al., 2018; Dou e Yang, 2018; Yamaç e Todorovic, 2020).

Filgueiras et al. (2019) realizaram o procedimento de NRPB para aquisição de combinações entre as informações espectrais. Os autores obtiveram 69,69% das covariáveis independentes para entrada nos modelos de algoritmos de aprendizado de máquina ao estimarem a temperatura de superfície a partir dos satélites Sentinel 2A e 2B. O uso desse recurso pode ter contribuído para alcançar bons resultados ao estimar a variável alvo em estudo.

3.6 Critérios de comparação de desempenho

Os valores de ET_f obtidos pelos modelos foram considerados como os valores previstos, enquanto que os valores do SAFER (ET_f SAFER) foram tidos como dados observados. Nesse sentido, os valores preditos foram comparados aos observados usando-se as seguintes métricas estatísticas: raiz do erro quadrático médio (RMSE, Equação 11), erro absoluto médio (MAE, Equação 12), erro sistemático (MBE, Equação 13) e coeficiente de determinação (r^2 , Equação 14).

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

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (12)$$

$$MBE = \frac{1}{n} \sum_{i=1}^n (P_i - O_i) \quad (13)$$

$$r^2 = \left[\frac{\sum_{i=1}^n (P_i - P)(O_i - \bar{O})}{\sqrt{(\sum_{i=1}^n (P_i - P)^2)(\sum_{i=1}^n (O_i - \bar{O})^2)}} \right]^2 \quad (14)$$

em que: P_i é o valor predito pelo modelo; P é o valor médio previsto pelo modelo; O_i é o valor observado; \bar{O} é o valor médio observado; n é o número de pares de dados.

3.7 Estudo de caso

Para avaliar se o Sentinel-2 é eficaz para a obtenção da fração evapotranspirativa (ET_f), o melhor modelo, em cada cenário, foi selecionado baseando-se nas métricas estatísticas obtidas no processo de validação. Esses modelos foram aplicados para estimativa da ET_f em cultivos de cana de açúcar e soja irrigados por pivôs centrais presentes na delimitação da área de estudo nos dias 06/08/2019 (DOY218) e 02/04/2020 (DOY093). Para conhecimento do uso da terra dos pivôs centrais, foram utilizadas as imagens do produto MapBiomas (Coleção 5), respectivas ao ano de 2019, disponíveis no endereço eletrônico <https://mapbiomas.org>.

No segundo momento desta pesquisa, foi utilizada a ET_r calculada a partir da evapotranspiração de referência (ET_o) pelo método de Penman-Monteith FAO 56 (Equação 15). Esse método é considerado padrão para cálculo da ET_o (Allen et al., 1998b; Djaman et al., 2015). Assim, a ET_r foi utilizada nesta pesquisa visando a obter a ET_r SAFER ao ser multiplicada pela ET_f SAFER para ser comparada pela ET_r estimada com a ET_f proveniente dos modelos selecionados. O modelo empírico de Hargreaves-Samani (1985) (Equação 16) e

o produto ET_o Brazil (Althoff et al., 2020) foram usados em cada abordagem a partir da multiplicação da ET_f Predita, formando, assim, os produtos ET_r HS e ET_r ET_o Brazil, respectivamente.

$$ET_oFAO = \frac{0,408 \Delta (R_G - G) + \gamma \left(\frac{900}{T_{med} + 273} \right) U_2 (e_s - e_a)}{\Delta + \gamma (1 + 0,34 \times U_2)} \quad (15)$$

$$ET_oHS = \alpha (T_{max} - T_{min})^\beta (T_{med} + 17,8) R_o \times 0,408 \quad (16)$$

em que: ET_o é a evapotranspiração de referência (mm d^{-1}); Δ é a declividade da curva de pressão do vapor d'água de saturação ($\text{kPa } ^\circ\text{C}^{-1}$); R_G é o saldo de radiação na superfície ($\text{MJ m}^{-2} \text{ d}^{-1}$); G é a densidade do fluxo de calor no solo ($\text{MJ m}^{-2} \text{ d}^{-1}$); γ é o coeficiente psicrométrico ($\text{kPa } ^\circ\text{C}$); T_{max} é a temperatura máxima do ar ($^\circ\text{C}$); T_{min} é a temperatura mínima do ar ($^\circ\text{C}$); T_{med} é a temperatura média do ar ($^\circ\text{C}$); U_2 é a velocidade do vento (média diária) a 2 m acima da superfície do solo; e_s é a pressão de saturação do vapor (kPa); e_a é a pressão real do vapor (kPa); α é um parâmetro empírico, sendo utilizado o seu valor original de 0,0023; β é um parâmetro empírico exponencial, sendo seu valor original de 0,5; R_o é a radiação solar extraterrestre ($\text{MJ m}^{-2} \text{ d}^{-1}$).

A ET_o pelo método de Penman-Monteith FAO 56 foi calculada a partir do pacote BrazilMet (Filgueiras et al., 2021) no software estatístico R. O pacote BrazilMet utilizou dados diários provenientes da estação automática do Instituto Nacional de Meteorologia (INMET), instalada no município de Itapaci/GO (A015), localizada a 20,5 km de distância em relação ao centro da área de estudo. A ET_o HS foi calculada utilizando-se os dados da estação supracitada, com exceção da radiação extraterrestre, que foi calculada de forma especializada no software estatístico R (Equação 17).

$$R_o = \frac{24 \times (60)}{\pi} \times S_c \times D_r \times (\hat{H} \times \text{sen} \varnothing \times \text{sen} \delta + \text{cos} \varnothing \times \text{cos} \delta \times \text{sen} \hat{H}) \quad (17)$$

em que: R_o é a radiação solar extraterrestre ($\text{MJ m}^{-2} \text{ d}^{-1}$); S_c é a constante solar que equivale a 0,0820 ($\text{MJ m}^{-2} \text{ min}^{-1}$); D_r é a distância relativa entre a terra e o sol em unidades astronômicas; \hat{H} é o ângulo horário ao nascer do sol; \varnothing é a latitude; δ é a declinação solar.

Segundo Iqbal (1983), distância relativa entre a terra e o sol em unidades astronômicas pode ser calculada pela Equação 18.

$$D_r = 1 + 0,033 \cos\left(J \times \frac{2 \times \pi}{365}\right) \quad (18)$$

em que: J é o dia no calendário juliano.

O uso do modelo de Hargreaves-Samani (1985) foi motivado pela simplicidade, por ser um método empírico que requer poucas informações climáticas para calcular a ET_o . Quando comparado ao método padrão de Penman-Monteith da FAO 56, o método de Hargreaves-Samani tem apresentado os melhores resultados em relação a outros modelos baseados em temperatura do ar (Almorox et al., 2015; Costa et al., 2019).

O produto ET_o Brazil abrange todo o Brasil e fornece informações da ET_o diária que foram estimadas de forma espacializada a partir de dados de 849 estações meteorológicas (Althoff et al., 2020). Esse produto possui resolução espacial de, aproximadamente, 10 km. Ressalta-se que, para uma efetiva aplicação do produto ET_o Brazil, foi necessário usar a Função `disaggregate` do pacote `Raster` (Hijmans e Etten, 2012) presente no software `R` (R Team C., 2017). Com esse recurso, foi possível transformar os pixels para uma resolução de 1 km, sendo que os valores no novo `Raster` permaneceram iguais aos das células originais. Posteriormente, foi aplicada a Função `resample` para converter os pixels em 30m para ser compatível com as variáveis em estudo.

4 RESULTADOS E DISCUSSÃO

4.1 Validação dos modelos para estimativa da fração evapotranspirativa (ET_f)

Para avaliar a possível melhora no desempenho dos modelos de predição, optou-se pela abordagem de dois diferentes cenários. Os cenários são referentes a diferentes combinações das variáveis de entrada para estimar a ET_f por meio dos algoritmos de regressão, uma vez que a intenção é ajustar um modelo simples e preciso. Isso permitiu conhecer, em cada cenário, o algoritmo de regressão que teve maior capacidade de predição da ET_f . O desempenho dos métodos para prever a ET_f , para os diferentes cenários, está apresentado na Figura 3.

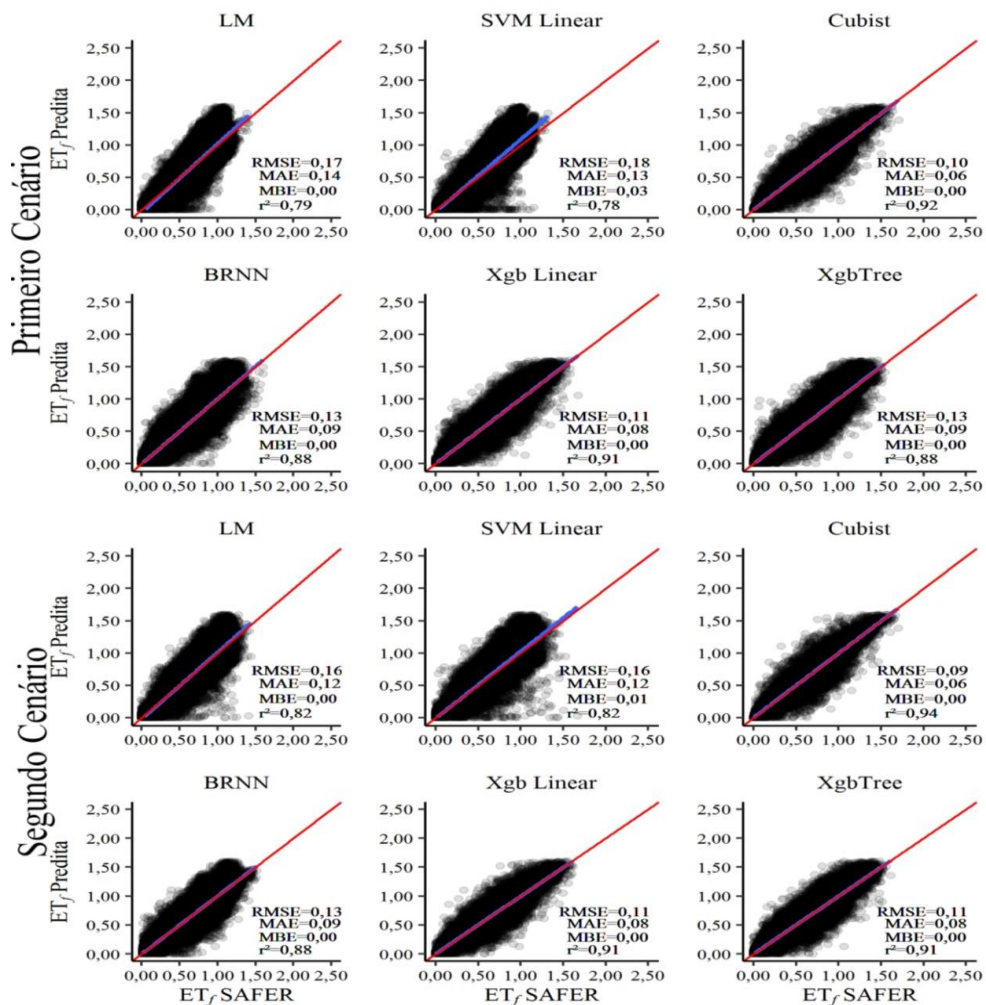


Figura 3. Valores diários de fração evapotranspirativa (ET_f) preditos por diferentes abordagens (cenários 1 e 2) comparados com valores obtidos pelo SAFER a partir de imagens Landsat-8 no período de 2016 a 2018

Analisando a Figura 3, percebe-se que ambos os cenários proporcionaram bons desempenhos, pois os modelos apresentaram exatidão (baixos valores de MAE e RMSE) e pequena presença de outliers devido à proximidade do RMSE e MAE. O modelo SVM Linear superestimou a ET_f e os demais algoritmos apresentaram valores de MBE igual a zero, demonstrando, assim, que não houve superestimação. Logo, de modo geral, todos os modelos apresentaram boa precisão (altos valores de r^2). Também é observado em cada método que a linha do modelo linear ajustado está semelhante à linha ideal (1:1).

Os valores obtidos a partir dos indicadores estatísticos demonstram que os valores de ET_f Preditos se correlacionam positivamente com os dados derivados da ET_f SAFER, ou seja, apresentaram a mesma tendência linear em ambos os cenários. Apesar de o primeiro cenário conter menos variáveis de entrada nos modelos, os resultados estatísticos obtidos indicam alta capacidade de predição dos métodos nessas condições.

Percebe-se, também, que os modelos do segundo cenário diferiram levemente do primeiro cenário, apresentando redução nos valores de RMSE e incrementos positivos nos valores de r^2 , com exceção dos modelos BRNN e Xgb Linear, que contêm as métricas iguais nas duas circunstâncias. No entanto, a nuvem de pontos é diferente, sendo mais concentrada na reta 1:1 no segundo cenário. Nesse ínterim, ressalta-se que, no momento de execução dos modelos do segundo cenário, o tempo necessário para treinamento dos modelos aumentou mais de 70 vezes em relação ao modelo com menor custo de máquina, no entanto, não promoveu grandes mudanças no desempenho dos métodos. Dessa forma, o tempo computacional, que é altamente dependente da velocidade do processador do computador, deve ser considerado como um comparativo importante para processar grandes quantidades de dados em um curto tempo (Althoff et al., 2018; Dou e Yang, 2018).

Os métodos LM e SVM Linear mostraram comportamentos estatísticos semelhantes no desempenho de predição da ET_f em ambos os cenários e possuem menor capacidade de explicação quando comparados aos demais. Entretanto, o método SVM Linear apresentou o maior custo de máquina, levando até 70 vezes mais tempo para treinar, quando comparado ao LM, que utilizou menor tempo computacional dentre todos os algoritmos. Já o Cubist, que tem melhores resultados estatísticos, apresentou um tempo para treinamento de aproximadamente 20 vezes a mais em relação ao tempo gasto pelo LM.

Diante das análises de que os dois cenários obtiveram bons resultados, é necessário verificar o desempenho dos modelos que mais se ajustam aos dados ET_f SAFER em cada ocasião. Sendo assim, os dois melhores modelos em ordem decrescente são o Cubist e o Xgb

Linear, com ligeira superioridade do Cubist. O XgbTree é o terceiro melhor modelo no segundo cenário, enquanto no primeiro cenário também proporcionou bom desempenho, com índices estatísticos iguais ao BRNN. Devido aos desempenhos dos modelos ser considerado satisfatório em ambas as estratégias, as análises e discussões posteriores foram baseadas no melhor modelo de cada cenário.

A seleção de um algoritmo com excelente acurácia é essencial para a obtenção de estimativas e posteriormente aplicação prática para a predição da ET_r , que é um parâmetro importante para o manejo da irrigação. Apesar da semelhança no desempenho dos dois melhores modelos, o Cubist foi escolhido por apresentar ligeira vantagem em todos os cenários estudados. Também nesse contexto, as variações dos valores de RMSE e r^2 na modelagem validada do Cubist no primeiro para o segundo cenário foram de 0,10 para 0,09 (-10 %) e de 0,92 para 0,94 (2,13 %), respectivamente. Além disso, a magnitude do RMSE em relação à média da ET_f SAFER foi equivalente a 18,86 e 16,67% para o primeiro e segundo cenário.

A ET_f Predita pelo método Cubist, no presente estudo, está de acordo com os resultados obtidos por Filgueiras et al. (2020), que realizaram um estudo com seis algoritmos de regressão para estimar a ET_r sem informações termiais, utilizando 40% (NDVI e SR) das variáveis independentes a partir de informações espectrais do sensor MODIS a bordo da plataforma TERRA. Os autores encontraram RMSE e r^2 com o auxílio do modelo Cubist, de 0,40 e 0,92, respectivamente, o que demonstra a robustez dessa ferramenta na estimativa da ET_r . Com isso, a indicaram como o melhor algoritmo para prever a ET_r naquela situação.

O modelo Cubist é baseado na teoria de árvores de regressão modificada e tem como princípio gerar modelos de predição a partir de sistemas baseados em regras. Essas regras são criadas com o uso dos dados de treinamento e cada uma possui um modelo linear multivariado, que são sobrepostos e organizados em ordem crescente dos valores médios preditos (Im et al., 2009). O Cubist tem sido amplamente aplicado em trabalhos acadêmicos nas mais diversas áreas a partir de imagens de satélites. Com isso, vários autores concluem que esse método fornece grande robustez e maior exatidão ao estimar a ET quando comparado com outros algoritmos tradicionais de aprendizado de máquina, como *regressão linear múltipla, análise de componente principal, artificial neural networks, support vector machine*, dentre outros (Ke et al., 2016; Noi et al., 2017; Althoff et al., 2020; Dias et al., 2021; Filgueiras et al., 2020).

Utilizando a metodologia aplicada neste trabalho, a estimativa da ET_f através do sensor MSI torna-se viável e esses resultados podem ser usados em estudos temporais que

contenham informações derivadas do Landsat-8, uma vez que o modelo foi baseado nas informações deste produto. Este fato possibilita a presença de uma maior frequência de informações e, com isso, é possível realizar o monitoramento da evapotranspiração de uma cultura com uma periodicidade de imagem substancialmente menor, conforme mencionado por Filgueiras et al. (2019).

4.2 Estimativa da fração evapotranspirativa (ET_f) em áreas irrigadas por pivô central

Devido ao objetivo da modelagem de ET_f proposta ser a aplicação do modelo treinado e validado para estimar a ET_f em áreas agricultáveis a posteriori, é conveniente analisar os gráficos de dispersão da aplicabilidade do modelo somente em áreas irrigadas por pivôs centrais. Essa análise é importante para conhecer a sensibilidade dos valores de ET_f Predita versus ET_f SAFER, bem como para conhecer também a capacidade de generalização dos modelos em previsões para datas não utilizadas no treinamento (Figura 4) - fato que simula a aplicabilidade do modelo na prática. Ao analisar o MBE, observa-se que o modelo Cubist, nessa aplicação, superestimou nos dois cenários e nos dois dias 06/08/2019 (DOY218) e 02/04/2020 (DOY093), com valores variando de 0,11 a 0,20. Para Stone (1993), quanto mais próximo de zero for o valor de MBE, melhor é o desempenho do modelo em estudo.

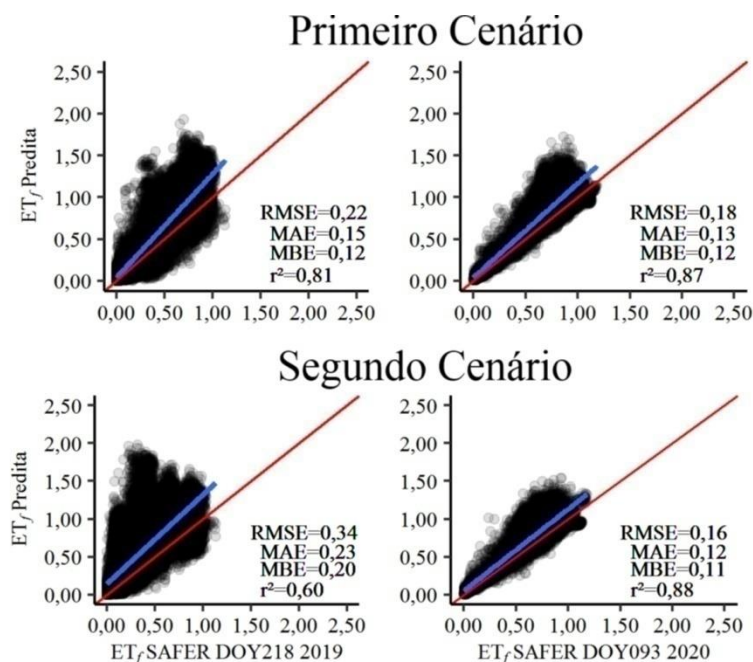


Figura 4. Aplicação do modelo Cubist para predição da fração evapotranspirativa (ET_f) em áreas com pivôs centrais comparados com valores obtidos pelo SAFER com imagens Landsat-8 para os dias 06/08/2019 (DOY218) e 02/04/2020 (DOY093)

Os dados na data correspondente ao DOY218 apresentaram um comportamento inferior em relação ao DOY093 em ambos os cenários. Isso está extremamente ligado ao uso da terra neste dia, apresentando valor médio de NDVI baixo, variando de 0,1 a 0,8, com média de 0,4. Para o DOY093, os valores de NDVI estão no intervalo de 0,1 a 0,9, com média de 0,7. O NDVI tem relação direta com os componentes fotossintéticos da planta, sendo que a presença de baixos valores de NDVI indica que as plantas, na maioria dos pivôs centrais, se encontram com pequena área foliar ou porque estão no estágio de maturidade fisiológica (Huete et al., 1997; Fontana et al., 2015).

É importante ressaltar que o NDVI é uma das variáveis utilizadas para o cálculo da ET_{γ} SAFER. Nesse panorama, baixos valores de NDVI refletem em valores mais próximos a zero para a ET_{γ} SAFER, e isso ocorreu em torno de 45% da área em estudo para o dia referente ao DOY218, quando a ET_{γ} SAFER variou de 0 a 0,40. Já a ET_{γ} Predita, no dia DOY218, apresentou valores mais próximos a um em ambos os cenários. Logo, os erros foram relativamente maiores e a precisão menor quando comparados com a imagem referente ao DOY093, que apresentou valores de ET_{γ} SAFER em torno de 0,45 a 0,90 em mais de 70% da área.

Corroborando Carpintero et al. (2020), os resultados encontrados na aplicação do modelo em áreas irrigadas por pivôs centrais possivelmente estão ligados às oscilações que acontecem na dinâmica de uso da terra em áreas de cultivo agrícola, o que acaba por provocar diferentes respostas espectrais nos dados captados pelos sensores. Além disso, as relações observadas em condições distintas da área de estudo podem não ser capazes de generalizar adequadamente, com o mesmo desempenho, uma vez que o comportamento dos algoritmos de regressão pode ser altamente específico do local (Kiafar et al., 2017; Ferreira et al., 2019).

Dou e Yang (2018) também avaliaram o desempenho dos modelos desenvolvidos para estimar a evapotranspiração em quatro diferentes ecossistemas terrestres (floresta, pastagem, área de cultivo e área úmida). Os autores verificaram que a capacidade preditiva dos quatro algoritmos de aprendizado de máquina variou com os distintos ecossistemas. Esses resultados são justificados pelo fato da evapotranspiração ser influenciada pelo uso e cobertura da terra (Li et al., 2017).

4.3 Estimativa da evapotranspiração real (ET_r) utilizando duas abordagens no cálculo da ET_o em duas culturas agrícolas

A evapotranspiração é um fator importante para o manejo da irrigação, ao passo em que o uso e cobertura da terra atuam diretamente nessa estimativa. Com isso, foi acessado os dados de uso e cobertura da terra, provenientes do MapBiomas, para os pivôs centrais. Foi verificado que 85% dos pivôs centrais estavam ocupados com cana de açúcar, enquanto que o restante, com soja. A partir desse conhecimento foi calculada a ET_r para cada cultura e comparada utilizando-se duas abordagens: ET_r SAFER vs ET_r ET₀HS e ET_r SAFER vs ET_r ET₀Brazil para os pivôs centrais nos dias DOY218 e DOY093 em ambos os cenários (Figura 5).

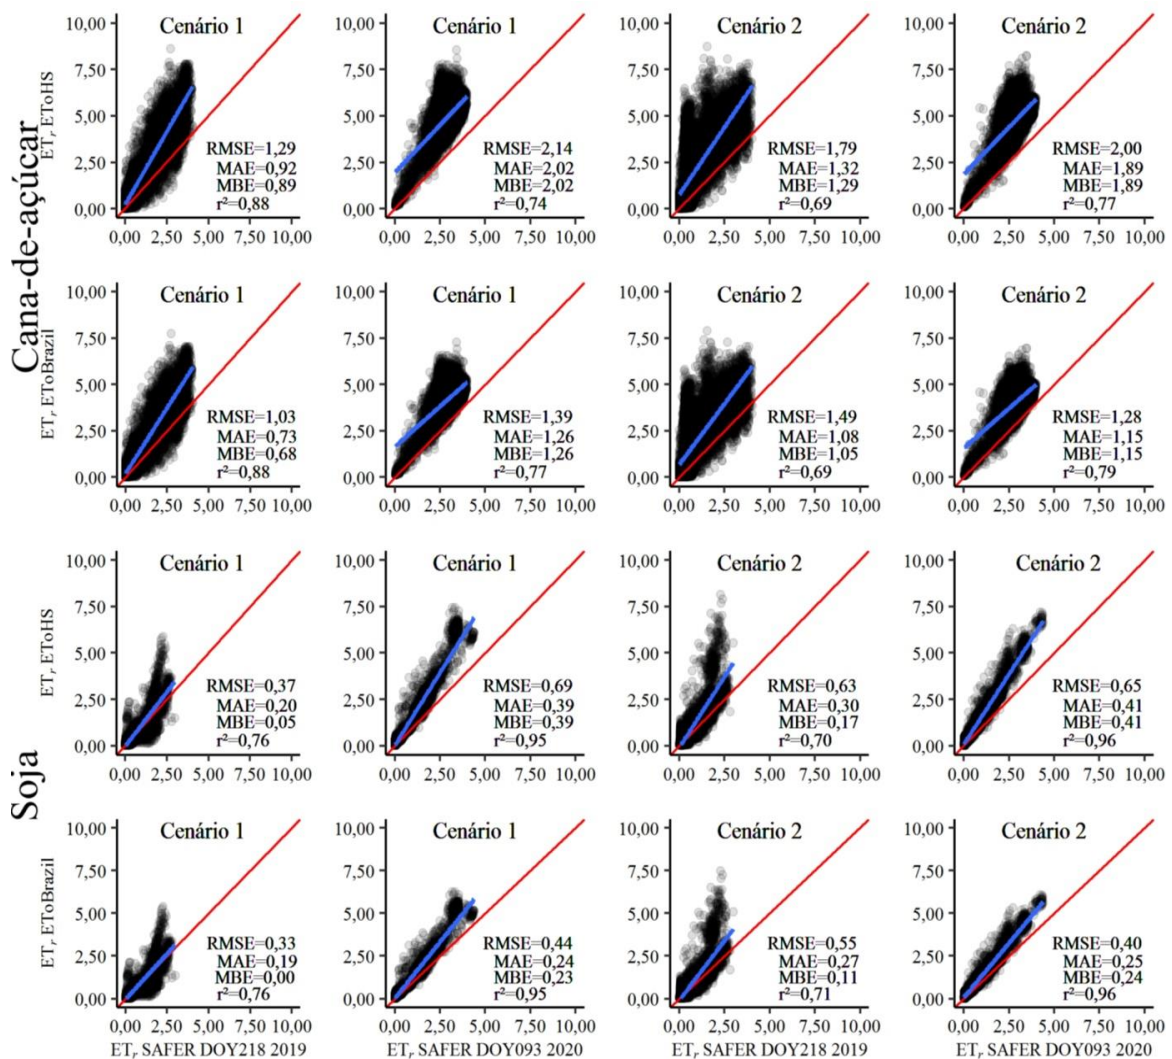


Figura 5. Aplicação do modelo Cubist para a predição da evapotranspiração real (ET_r) em áreas com pivôs centrais utilizando-se a cultura da cana de açúcar e soja, obtidos por meio de duas abordagens, (ET_r ET₀HS e (ET_r ET₀Brazil), e comparados com valores obtidos pelo (ET_r SAFER) para os dias 06/08/2019 (DOY218) e 02/04/2020 (DOY093)

O estudo com as duas abordagens possibilita conhecer qual o melhor método de ET_0 para calcular a ET_r nas condições e metodologias aplicadas neste estudo, o que pode permitir realizar o monitoramento da cultura com uma frequência de imagem substancialmente maior, bem como tornar prática a observação da dinâmica espaço-temporal da evapotranspiração. Ao comparar a diferença média das métricas estatísticas da segunda estratégia com a primeira nos dois dias em estudo, nas abordagens em qualquer uso da terra, verifica-se que o primeiro cenário possui maior precisão na estimativa da ET_r , com algumas exceções. As exceções foram para as comparações ET_r SAFER vs ET_r ET_0 Brazil para a cana de açúcar e para as comparações ET_r SAFER vs ET_r ET_0 HS e ET_r SAFER vs ET_r ET_0 Brazil no dia DOY093 na áreas com a cultura da soja.

Nesse sentido, observa-se que os valores estimados da ET_r para a cana de açúcar têm erros maiores e r^2 menores quando comparados com a soja. Isso aconteceu principalmente para ET_r SAFER vs ET_r ET_0 HS, ao passo que, se for comparado com a ET_r SAFER vs ET_r ET_0 Brazil, os indicadores de erros são relativamente melhores em ambas as culturas. Todavia, a cultura da cana de açúcar ainda continua apresentando métricas inferiores. Possivelmente, tal comportamento pode ser explicado pelo fato de essa cultura agrícola não ter a mesma dinâmica de janela que a da soja, que é mais rígida. Isso ocorre pelo motivo de a cana de açúcar ser uma cultura semi-perene, com o ciclo produtivo de seis a sete anos.

A partir das refletâncias espectrais nas áreas irrigadas pelos pivôs centrais, observa-se que existe um comportamento mais heterogêneo das plantas de cana de açúcar e isso reflete na previsão da ET_r , visto que as variáveis independentes influenciam diretamente na ET_f . Isso permite destacar que as plantas apresentam maior variação espectral ao se analisar os pivôs centrais com esse cultivo, diferente do que é visto com os pivôs centrais com a cultura da soja (em que o comportamento espectral está mais homogêneo). Vale salientar que os fatores dominantes que controlam a refletância das folhas são os pigmentos, a estrutura celular e o conteúdo de água (Novo, 2010; Jones e Vaughan, 2010; Moghadam et al., 2017). Esses fatores dependem da cultura, estágio fisiológico e manejo da área cultivável.

Ainda na Figura 5, todas as abordagens e uso da terra nas áreas irrigadas pelos pivôs centrais apresentaram superestimativa, com exceção para a comparação ET_r SAFER vs ET_r ET_0 Brazil para a soja no primeiro cenário, no dia correspondente ao DOY218. Nesse ínterim, ressaltam-se, também, as áreas cultivadas com cana de açúcar, as quais se destacam com maiores valores de MBE (0,68 a 2,02 mm d⁻¹), enquanto que, para a soja, os valores estão entre 0,00 a 0,41 mm d⁻¹. Santos et al. (2020), ao trabalharem com o algoritmo SAFER e

testarem vários métodos de ET_o para prever a ET_r , verificaram que o MBE está diretamente relacionado aos valores estimados pela ET_o .

Neste estudo, ao analisar os gráficos de dispersão para a cultura da cana de açúcar, verifica-se que, independente da abordagem utilizada para estimar a ET_r , ela está apresentando maior demanda de água em relação à ET_r SAFER, com destaque para a ET_r ET_o HS, o que causaria impacto direto no manejo da irrigação. Isso indica que obter a ET_o pelo método de HS não é uma estratégia adequada para mapear a ET_r para cana de açúcar nas condições em estudo; por isso, esta não é uma metodologia recomendada.

Entretanto, caso o produtor opte pela aplicação da lâmina média, o ideal é utilizar a abordagem ET_r ET_o Brazil. Todavia, algumas áreas vão ser super ou sub irrigadas, o que vai impactar na produtividade ou acarretará em desperdício do recurso hídrico, podendo até inferir em aumento da incidência de doenças agrícolas (Silva et al., 2019; Santos et al., 2020).

Santos et al. (2020) estimaram a ET_r da cultura de cana de açúcar utilizando o SAFER e os dados de ET_o calculados pelo modelo HS. Os autores verificaram uma superestimativa com essa estratégia, sugerindo maior demanda de água em relação à ET_r SAFER, a qual foi estimada por meio da ET_o calculada por Penman-Monteith FAO56. Com isso, a metodologia que utiliza o modelo de HS não foi recomendada pelos autores. Outros autores também estudaram o método de HS e verificaram superestimativas dos valores da ET_o , indicando melhorias na eficiência do método somente após a realização de calibração do modelo (Carvalho et al., 2015; Zanetti et al., 2019).

Conforme observado na Figura 5, as diferentes metodologias de estimativa de ET_o causaram impacto direto na previsão da ET_r em ambos os cenários. Diante disso, é notório que o modelo Cubist, para o primeiro cenário, e a abordagem ET_r ET_o Brazil respondem melhor ao trabalhar com cultivos de soja irrigada por pivôs centrais. Essa abordagem tem um potencial real para melhorar a estimativa de ET_r no tempo e no espaço, assim como torna possível o monitoramento da demanda hídrica com maior frequência de imagens durante o ciclo da cultura.

5 CONCLUSÕES

O estudo explorou seis algoritmos de regressão (LM, SVM Linear, Cubist, BRNN, Xgb Linear e XgbTree) em dois cenários de entrada de dados distintos. O primeiro cenário foi trabalhado com 11 variáveis independentes, enquanto que o segundo cenário, com 29. Independentemente deles, o modelo Cubist deve ser o recomendado para predição da fração evapotranspirativa, uma vez que apresentou as melhores métricas de desempenho, além de maior compensação de custo de computação necessário para validação.

A metodologia aplicada neste estudo permitiu analisar a evapotranspiração real (ET_r) utilizando as abordagens ET_r/ET_o HS e ET_r/ET_o Brazil nas áreas com pivôs centrais contendo as culturas agrícolas cana de açúcar e soja. O primeiro cenário e o produto ET_o Brazil compõem a estratégia recomendada para estimar a ET_r para ambas as culturas agrícolas, mas nos cultivos de soja foram obtidos os melhores desempenhos. Em contraste, a equação de Hargreaves-Samani superestimou a ET_r e proporcionou maiores erros, principalmente nos cultivos irrigados de cana de açúcar.

As descobertas encontradas neste trabalho são promissoras e de grande importância para o gerenciamento da água na irrigação, principalmente em pivôs centrais com a cultura da soja. Assim, este estudo comprovou o potencial do uso de abordagens de aprendizado de máquina, considerando sua eficácia e facilidade de implementação. No entanto, ressalta-se que esta pesquisa é inédita e deve ser testada em outras áreas para verificar se os comportamentos das duas culturas agrícolas se assemelham aos resultados ora encontrados.

6 REFERÊNCIAS

- Abdullah, S. S., Malek, M. A., Abdullah, N. S., Kisi, O., & Yap K. S. (2015). Extreme learning machines: A new approach for prediction of reference evapotranspiration. **Journal of Hydrology**, v.527, p.184–195. <https://doi.org/10.1016/j.jhydrol.2015.04.073>
- Ahmadpari, H., Shokoohi, E. S., Lalabadi, N. M., Gerdini, M. S., & ebrahimi, M. (2019). Assessment of potential evapotranspiration estimation methods in the fasa region. **Specialty Journal of Agricultural Sciences**, v.5, n.2, p.56-66.
- Allen, R. G., Tasumi, M., Trezza, R., & Kjaersgaard, J. (1998a). **Mapping evapotranspiration at high resolution, manual application for Landsat satellite imagery**. Kimberly: University of Idaho, v.2., p.7.
- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998b). **Crop evapotranspiration: guidelines for computing crop water requirements**. Rome: FAO, p.300. (Irrigation and Drainage Paper, 56). ISBN 92-5-104219-5
- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (2006). Evapotranspiración del cultivo. Guías para La determinación de los requerimientos de agua de los cultivos. **Technical report**, FAO, Roma, Itália. ISBN: 92-5-304219-2.
- Allen, R. G., Tasumi, M., & Trezza, R. (2007). Satellite-based energy balance for mapping evapotranspiration with internalized calibration (METRIC) - Model. **Journal of Irrigation and Drainage Engineering**, v.133, p.380-394.
- Allen, R., Irmak, A., Trezza, R., Hendrickx, J. M. H., Bastiaanssen, W., & Kjaersgaard, J. (2011). Satellite-based ET estimation in agriculture using SEBAL and METRIC. **Hydrological Processes**, v.25, n.26, p.4011–4027. <https://doi.org/10.1002/hyp.8408>
- Alpaydin, E. (2010). **Introduction to Machine Learning**. The MIT Press Cambridge. 2 ed. Massachusetts London, England. ISBN: 978-0-262-01243-0
- Almorox, J., Quej, V. H., & Martí, P. (2015). Global performance ranking of temperature-based approaches for evapotranspiration estimation considering Köppen climate classes. **Journal of Hydrology**, v.528, p.514-522. <http://dx.doi.org/10.1016/j.jhydrol.2015.06.057>
- Althoff, D., Bazame, H. C., Filgueiras, R., & Dias, S. H. B. (2018). Heuristic methods applied in reference evapotranspiration modeling. **Ciência e Agrotecnologia**, v.42, n.3, p.314-324. <https://doi.org/10.1590/1413-70542018423006818>
- Althoff, D., Dias, S., Filgueiras, R., & Neiva Rodrigues, L. (2020). ETo-Brazil: A Daily Gridded Reference Evapotranspiration Data Set for Brazil - Repository. **Mendeley Data**, v.3. <http://dx.doi.org/10.17632/sstjw74ryh.3>
- Alvares, C. A., Stape, J. L., Sentelhas, P. C., Gonçalves, M., & Sparovek, G. (2013). Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v.22, n.6, p.711–728. <https://doi.org/10.1127/0941-2948/2013/0507>

Anapalli, S. S., Green, T. R., Reddy, K. N., Gowda, P. H., Sui, R., Fisher, D. K., Moorhead, J. E., & Marek, G. W. (2018). Application of an energy balance method for estimating evapotranspiration in cropping systems. **Agricultural Water Management**, v.204, p.107-117. <https://doi.org/10.1016/j.agwat.2018.04.005>

Anjitha, K. P. (2019). Evapotranspiration and agriculture- A review. **Agricultural Reviews**, v.40, n.1, p.1–11. <https://doi.org/10.18805/ag.R-1848>

Antonopoulos, V. Z., & Antonopoulos, A. V. (2017). Daily reference evapotranspiration estimates by artificial neural networks technique and empirical equations using limited input climate. **Computers and Electronics in Agriculture**, v.132, p.86-96. <https://doi.org/10.1016/j.compag.2016.11.011>

Bezerra, B. G., Silva, B. B., Bezerra, J. R. C., & Brandão, Z. N. (2010). Evapotranspiração real obtida através da relação entre o coeficiente dual de cultura da FAO-56 e o NDVI. **Revista Brasileira de Meteorologia**, v.25, n.3, p.404-414. <https://doi.org/10.1590/S0102-77862010000300012>

Bezerra, U. A., Oliveira, L. M. M., Candeias, A. L. B., Silva, B. B., Leite, A. C. L. S., & Silva, L. T. M. S. (2018). Comparativo do Índice de Vegetação de Diferença Normalizada (NDVI) entre os Sensores OLI - Satélite Landsat-8 e MSI – Satélite Sentinel-2 em Região Semiárida. **Anuário do Instituto de Geociências**, v.41, n.3, p.167-177. https://doi.org/10.11137/2018_3_167_177

Breiman, L., Friedman, J., Stone, C. J., & Olshen, R. (1984). **Classification and Regression Trees**. Taylor & Francis, Editora CRC Press. ISBN: 9780412048418

CampoS, I., Balbontín, C., González-Piqueras, J., González-dugo, M. P., Neale, C. M. U., & Calera, A. (2016). Combining a water balance model with evapotranspiration measurements to estimate total available soil water in irrigated and rainfed vineyards. **Agricultural Water Management**, v.165, p.141-152. <https://doi.org/10.1016/j.agwat.2015.11.018>

Carpintero, E., Mateos, L., Andreu, A., & González-Dugo, M. P. (2020). Effect of the differences in spectral response of Mediterranean tree canopies on the estimation of evapotranspiration using vegetation index-based crop coefficients. **Agricultural Water Management**, v.238, p.106-201. <https://doi.org/10.1016/j.agwat.2020.106201>

Carter, C., & Liang, S. (2019). Evaluation of ten machine learning methods for estimating terrestrial evapotranspiration from remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, v.78, p.86-92. <https://doi.org/10.1016/j.jag.2019.01.020>

Carvalho, D. F., Rocha, H. S., Bonomo, R., & Souza, A. P. (2015). Estimativa da evapotranspiração de referência a partir de dados meteorológicos limitados. **Pesquisa Agropecuária Brasileira**, v.50, p.1–11. <http://dx.doi.org/10.1590/S0100-204X2015000100001>

Cerri, R., & Carvalho, A. C. P. L. F. (2017). Aprendizado de Máquina: Breve Introdução e Aplicações. **Cadernos de Ciência & Tecnologia**, v.34, n.3, p. 297-313.

Chapelle, O., Scholkopf, B., & Zien, A. (2006). **Semi-supervised learning**. 1ª Edição. Massachusetts Institute of Technology. ISBN: 978-0-262-03358-9

Chau, A. L., Li, X., & Yu, W. (2014). Support vector machine classification for large datasets using decision tree and Fisher linear discriminant. **Future Generation Computer Systems**, v.36, p.57-65. <http://dx.doi.org/10.1016/j.future.2013.06.021>

Chavez, P. S. (1996). Image-based atmospheric corrections: revisited and improved. **Photogrammetric Engineering e Remote Sensing**, v.62, n.9, p.1025-1036.

Chen, T., & Guestrin, C. (2016). **XGBoost: a scalable tree boosting system**. Proceedings of the 22^ª ACM SIGKDD international conference on knowledge discovery and data mining. p.785–794. <https://doi.org/10.1145/2939672.2939785>

Chen, T., & He, T. (2018). **Xgboost: extreme Gradient Boosting**. Disponível em: <https://cran.r-project.org/web/packages/xgboost/index.html>. Acesso em: 11 de junho de 2021.

Climent, F., Momparler, A., & Carmona, P. (2019). Anticipating bank distress in the Eurozone: An Extreme Gradient Boosting approach. **Journal of Business Research**, v.101, p.885-896. <https://doi.org/10.1016/j.jbusres.2018.11.015>

Congedo, L. (2016). **Semi-automatic classification plugin documentation: Release**. v.5, n.1.1, p.201. Sapienza University of Rome, Roma.

Costa, T. S., Sales, R. A., Santos, R. A., Oliveira, E. C., Bohry, D., Salles, R. A., Santos, E. P., & Santos, R. L. (2019). Calibration methods for estimation of reference evapotranspiration in Morro do Chapéu, Bahia, Brazil. **Journal of Agricultural Science**, v.11. <https://doi.org/10.5539/jas.v11n5p82>

Deo, R. C., Samui, P., & Kim, D. (2016). Estimation of monthly evaporative loss using relevance vector machine, extreme learning machine and multivariate adaptive regression spline models. **Stochastic Environmental Research and Risk Assessment**, v.30, p.1769-1784. <https://doi.org/10.1007/s00477-015-1153-y>

Dias, S. H. B., Filgueiras R., Fernandes Filho, E. I., Arcanjo, G. S., Silva, G. H., Mantovani E, C., & Cunha, F. F. (2021). Reference evapotranspiration of Brazil modeled with machine learning techniques and remote sensing. **PLoS ONE**, v.16 n.2. <https://doi.org/10.1371/journal.pone.0245834>

Dinpashoh, Y. (2006). Study of reference crop evapotranspiration in I. R. of Iran. **Agricultural Water Management**, v.84, p.123–129. <https://doi.org/10.1016/j.agwat.2006.02.011>

Doorenbos, J., & Pruitt, W. O. (1997). **Crop water requirements**. FAO Irrigation and Drainage Paper 24, FAO, Rome, p.144.

Dou, X., & Yang, Y. (2018). Evapotranspiration estimation using four different machine learning approaches in different terrestrial ecosystems. **Computers and Electronics in Agriculture**, v.148, p.95-106. <https://doi.org/10.1016/j.compag.2018.03.010>

- Djaman, K., Balde, A. B., Sow, A., Muller, B., Irmak, S., Diaye, M. K. N., Manneh, B., Moukoumbi, Y. D., Futakuchi, K., & Saito, K. (2015). Evaluation of sixteen reference evapotranspiration methods under sahelian conditions in the Senegal River Valley. **Journal of Hydrology: Regional Studies**, v.3, p.139-159. <http://dx.doi.org/10.1016/j.ejrh.2015.02.002>
- El-Hendawy, S. E., Al-Suhaibani, N. A., Elsayed, S., Hassan, W. M., Dewir, Y. H., Refay, Y., & Abdella, K. A. (2019). Potential of the existing and novel spectral reflectance indices for estimating the leaf water status and grain yield of spring wheat exposed to different irrigation rates. **Agricultural Water Management**, v.217, p.356-373. <https://doi.org/10.1016/j.agwat.2019.03.006>
- Elith, J., Leathwick, J. R., & Hastie, T. (2008). A working guide to boosted regression trees. **Journal of Animal Ecology**, v.77, p.802–813. <https://doi.org/10.1111/j.1365-2656.2008.01390.x>
- Elshaikh, A. E., Yang, S., Jiao, X., & Elbasher, M. M. (2018). Impacts of legal and institutional changes on irrigation management performance: a case of the gezira irrigation Scheme, Sudan. **Water**, v.10, n.1579. <https://doi.org/10.3390/w10111579>
- Erlandsen, H. B., Haddeland, I., Tallaksen, L. M., & Kristiansen, J. (2017). The sensitivity of the terrestrial surface energy and water balance estimates in the WRF model to lower surface boundary representations: a south Norway case study. **Journal of Hydrometeorol**, v.18, n.1, p.265-284. <https://doi.org/10.1175/JHM-D-15-0146>
- Faceli, K., Lorena, A. C., Gama, J., & Carvalho, A. C. P. L. F. (2011). **Inteligência artificial: uma abordagem de aprendizado de máquina**. Editora LTC. ISBN: 9788521618805
- Feng, Y., Cui, N., Gong, D., Zhang, Q., & Zhao, L. (2017). Evaluation of random forests and generalized regression neural networks for daily reference evapotranspiration modelling. **Agricultural Water Management**, v.193, p.163–173. <https://doi.org/10.1016/j.agwat.2017.08.003>
- Fernández-Manso, A., Fernández-Manso, O., & Quintano, C. (2016). Sentinel-2A red-edge spectral indices suitability for discriminating burn severity. **International Journal of Applied Earth Observation and Geoinformation**, v.50, p.170–175. <https://doi.org/10.1016/j.jag.2016.03.005>
- Ferreira, L. B., Cunha, F., Oliveira R. A., & Fernandes Filho, E. I. (2019). Estimation of reference evapotranspiration in Brazil with limited meteorological data using ANN and SVM – A new approach. **Journal of Hydrology**, v.572, p.556 – 570. <https://doi.org/10.1016/j.jhydrol.2019.03.028>
- Ferreira, L. B., & Cunha, F. (2020). New approach to estimate daily reference evapotranspiration based on hourly temperature and relative humidity using machine learning and deep learning. **Agricultural Water Management**, v.234, p.106-113. <https://doi.org/10.1016/j.agwat.2020.106113>
- Fernandes Filho, E. I. F. (2019). Labgeo: Collection of functions to fit models with emphasis in landuse and soil mapping. **R package**, v.0.3.8.2. Disponível em: <https://github.com/elpidiofilho/labgeo>. Acesso em: 11 de Fevereiro de 2021.

Filgueiras, R., Montovani, E. C., Dias, S. H. B., Fernandes Filho, E. I., Cunha, F. F., & Neale, C. M. U. (2019). New approach to determining the surface temperature without thermal band of satellites. **European Journal of Agronomy**, v.106, p.12-22. <https://doi.org/10.1016/j.eja.2019.03.001>

Filgueiras, R., Almeida, T. S., Mantovani, E. C., Dias, S. H. B., Fernandes-Filho, E. I., Cunha, F. F., & Venancio, L. P. (2020). Soil water content and actual evapotranspiration predictions using regression algorithms and remote sensing data. **Agricultural Water Management**, v.244. <https://doi.org/10.1016/j.agwat.2020.106346>

Filgueiras, R., Venancio, L. P., Aleman, C. C., & Cunha, F. F. (2021). BrazilMet: Download and Processing of Automatic Weather Stations (AWS) Data of INMET-Brazil. **R Package**, v.1. Disponível em: <https://CRAN.R-project.org/package=BrazilMet>. Acesso em: 10 de abril de 2021.

Fisher, J. B., Melton, F., Middleton, E., Hain, C., Anderson, M., Allen, R., McCabe, M. F., Hook, S., Baldocchi, D., Townsend, P. A., Kilic, A., Tu, K., Miralles, D. D., Perret, J., Lagouarde, J. P., Waliser, D., Purdy, A. J., French, A., Schimel, D., Famiglietti, J. S., Stephens, G., & Wood, E. F. (2017). The future of evapotranspiration: global requirements for ecosystem functioning, carbon and climate feedbacks, agricultural management, and water resources. **Water Resources Research**, v.53 n.4, p.2618–2626. <https://doi.org/10.1002/2016WR020175>

Fontana, D. C., Pinto, D. G., Junges, A. H., & Bremm, C. (2015). Inferências sobre o calendário agrícola a partir de perfis temporais de NDVI/MODIS. **Bragantia**, v.74, n.3, p.350-358. <https://doi.org/10.1590/1678-4499.0439>

Fan, J., Wang, X., Wu, L., Zhou, H., Zhang, F., Yu, X., Lu, X., & Xiang, Y. (2018). Comparison of Support Vector Machine and Extreme Gradient Boosting for predicting daily global solar radiation using temperature and precipitation in humid subtropical climates: A case study in China. **Energy Conversion and Management**, v.164, p-102-111. <https://doi.org/10.1016/j.enconman.2018.02.087>

Friedman, J. H. (2001). Greedy function approximation: A Gradient Boosting Machine. **The Annals of Statistics**, v.29, n.5, p.1189-1232.

Frizzone, J. A., Freitas, P. S. L., Rezende, R., & Faria, M. A. (2012). **Microirrigação: Gotejamento e microaspersão**. 1 ed. Editora Eduem. ISBN: 9788576284604

Galbusera, F., Casaroli, G., & Bassani, T. (2019). Artificial intelligence and machine learning in spine research. **JOR Spine**, v.2. <https://doi.org/10.1002/jsp2.1044>

Gao, X., Huete, A. R., Ni, W., & Miura, T. (2000). Optical–biophysical relationships of vegetation spectra without background contamination. **Remote Sensing of Environment**, n.74, v.3, p.609-620.

Glória, L. S., Cruz, C. D., Vieira, R. A. M., Resende, M. D. V., Lopes, P. S., Siqueira, O. H. G. B. D., & Silva, F. F. (2016). Accessing marker effects and heritability estimates from

genome prediction by Bayesian regularized neural networks. **Livestock Science**, v.191, p.91-96. <http://dx.doi.org/10.1016/j.livsci.2016.07.015>

Gowda, P. H., Chavez, J. L., Colaizzi, P. D., Evett, S. R., Howell, T. A., & Tolk, J. A. (2008). ET mapping for agricultural water management: present status and challenges. **Irrigation Science**, v.26, n.3, p.223–237. <https://doi.org/10.1007/s00271-007-0088-6>

Granata, F. (2019). Evapotranspiration evaluation models based on machine learning algorithms-A comparative study. **Agricultural Water Management**, v.217, p.303-315. <https://doi.org/10.1016/j.agwat.2019.03.015>

Guzinski, R., & Nieto, H. (2019). Evaluating the feasibility of using Sentinel-2 and Sentinel-3 satellites for high-resolution evapotranspiration estimations. **Remote Sensing of Environment**, v.221, p.157-172. <https://doi.org/10.1016/j.rse.2018.11.019>

Hargreaves, G. H., & Samani, Z. A. (1985). Reference crop evapotranspiration from temperature. **Applied Engineering in Agriculture**, v.01, n.02, p.96-99. <https://doi.org/10.13031/2013.26773>

Haykin, S. S. (2009). **Neural networks and learning machines**. Editora Pearson education Upper Saddle River, 3ª Edição. ISBN: 978-0-13-147139-9

He, R., Jin, Y., Kandelous, M. M., Zaccaria, D., Sanden, B. L., Snyder, R. L., Jiang, J., & Hopmans, J. W. (2017). Evapotranspiration estimate over an almond orchard using Landsat satellite observations. **Remote Sensing**, v.9, p.1-21. <https://doi.org/10.3390/rs9050436>

Hijmans, R. J., & Etten, J.V. (2012). Raster: Geographic Analysis and Modeling with Raster Data. **R Package**, v.2.0.12. Disponível em: <http://CRAN.Rproject.org/package=raster>. Acesso em: 15 de Fevereiro de 2021.

Huete, A. R. A., Liu, H. Q., Batchily, K., & Van Leeuwen, W. J. (1997). A comparison of vegetation indice over a global set of TM images for EOS- MODIS. **Remote Sensing of Environment**, n.59, p.440-451. [https://doi.org/10.1016/S0034-4257\(96\)00112](https://doi.org/10.1016/S0034-4257(96)00112)

Im, J., Jensen, J. R., Coleman, M., & Nelson, M. (2009). Hyperspectral remote sensing analysis of short rotation woody crops grown with controlled nutrient and irrigation treatments. **Geocarto International**, v.24, n.4, p.293-312. <https://doi.org/10.1080/10106040802556207>

Instituto Nacional De Meteorologia (INMET). **Clima**. Disponível em: <http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>. Acesso em: 11 de janeiro de 2021.

Iqbal, M. (1983). **An introduction to solar radiation**. Editora Academic Press, p.390. ISBN: 9780323151818

Jaspers, S., Troyer, E. D., & Aerts, M. (2018). Machine learning techniques for the automation of literature reviews and systematic reviews in EFSA. **External Scientific Report**, v.15, n.6. <https://doi.org/10.2903/sp.efsa.2018.EN-1427>

Jing, W., Yaseen, Z. M., Shahid, S., Saggi, M. K., Tao, H., Kisi, O., Salih, S. Q., Al-Ansari, N., & Chau, K. W. (2019). Implementation of evolutionary computing models for reference evapotranspiration modeling: short review, assessment and possible future research directions. **Engineering Applications of Computational Fluid Mechanics**, v.13, n.1, p.811–823. <https://doi.org/10.1080/19942060.2019.1645045>

Jones, H. G., & Vaughan, R. A. (2010). **Remote sensing of vegetation: principles, techniques, and applications**. Editora Oxford University Press. ISBN: 978-0-19-9207779-4

Jovanovic, N., Dzikiti, S., & Gush, M. (2018). An integrated approach for the estimation of crop water requirements based on soil, plant and atmospheric measurements. **Water Management for Sustainable Agriculture**, p.121-158. <https://doi.org/10.19103/AS.2017.0037.18>

Leng, P., Li, Z. L., Duan, S. B., Tang, R., & Gao, M. F. A. (2017). Method for Deriving All-Sky Evapotranspiration from the synergistic use of remotely sensed images and meteorological data. **Journal of Geophysical Research: Atmospheres**, v.122, p.13.263–13.277. <https://doi.org/10.1002/2017JD027880>

Lessa, C. I. N., Oliveira, A. C. N., Magalhães, C. L., Sousa, J. T. M., & Sousa, G. G. (2019). Estresse salino, cobertura morta e turno de rega na cultura do sorgo. **Revista Brasileira de Agricultura Irrigada**, v.13, n.9, p.3637-3645. <http://dx.doi.org/10.7127/rbai.v13n5001122>

Li, G., Zhang, F., Jing, Y., Liu, Y., & Sun, G. (2017). Response of evapotranspiration to changes in land use and land cover and climate in China during 2001–2013. **Science of the Total Environment**, v.596, p.256–265. <http://dx.doi.org/10.1016/j.scitotenv.2017.04.080>

Libralão, G. L., Netto, A. V., Carvalho, A. P. L. F., & Oliveira, M. C. F. (2005). Determinação de vícios refrativos oculares utilizando Support Vector Machines. **Revista Controle & Automação**, v.16, n.2. <https://doi.org/10.1590/S0103-17592005000200004>

Kadiresan, K., & Khanal, P. R. (2018). Rethinking irrigation for global food security. **Irrigation and Drainage**, v.67, p.8-11. <http://dx.doi.org/10.1002/ird.2219>

Kamble, B., Kilic, A., & Hubbard, K. (2013). Estimating crop coefficients using remote sensing-based vegetation index. **Remote Sensing**, v.5, p.1588-1602. <http://dx.doi.org/10.3390/rs5041588>

Ke, Y., Im, J., Park, S., & Gong, H. (2016). Downscaling of MODIS one kilometer evapotranspiration using Landsat-8 data and machine learning approaches. **Remote Sensing**, v.8, p.1-26. <http://dx.doi.org/10.3390/rs8030215>

Kiafar, H., Babazadeh, H., Marti, P., Kisi, O., Landeras, G., Karimi, S., & ShirI, J. (2017). Evaluating the generalizability of GEP models for estimating reference evapotranspiration in distant humid and arid locations. **Theor Appl Climatol**, v.130, p.377–389. <https://doi.org/10.1007/s00704-016-1888-5>

Kuhn, M. (2008). Building predictive models in r using the caret package. **Journal of Statistical Software**, v.28. <https://doi.org/10.18637/jss.v028.i05>

- Kuhn, M., & Johnson, K. (2013). **Applied predictive modeling**. Editora Springer, New York. <https://doi.org/10.1007/978-1-4614-6849-3>
- Kuhn, M., & Johnson, K. (2016). **Applied predictive modeling**. Editora Springer, New York. <https://doi.org/10.1007/978-1-4614-6849-3>
- Mackay, D. J. C. (1992). Interpolação bayesiana. **Comput neural**, v.4, n.3, p.415-447. <https://doi.org/10.1162/neco.1992.4.3.415>
- Marin, F. R., Angelocci, L. R., Nassif, D. S. P., Costa, L. G., Vianna, M. S., & Carvalho, K. S. (2016). Crop coefficient changes with reference evapotranspiration for highly canopy-atmosphere coupled crops. **Agricultural Water Management**, v.163, p.139-145. <http://dx.doi.org/10.1016/j.agwat.2015.09.010>
- Mariño, M. A., Tracy, J. C., & Taghavi, S. (1993). Forecasting of reference crop evapotranspiration. **Agricultural Water Management**, v.24, n.3, p.163–187. [https://doi.org/10.1016/0378-3774\(93\)90022-3](https://doi.org/10.1016/0378-3774(93)90022-3)
- Mattar, M. A. (2018). Using gene expression programming in monthly reference evapotranspiration modeling: a case study in Egypt. **Agricultural Water Management**, v.198, p.28-38. <https://doi.org/10.1016/j.agwat.2017.12.017>
- Matzenauer, R. (1999). Evapotranspiração de plantas cultivadas e coeficientes de cultura. In: Bergamaschi, H. (org): **Agrometeorologia aplicada à irrigação**. Porto Alegre, Editora Universidade Federal do Rio Grande do Sul.
- Maulud, D. H., & Abdulazeez, A. M. (2020). A Review on Linear Regression Comprehensive in Machine Learning. **Journal of Applied Science and Technology**, v.1, n.4, p.140–147. <https://doi.org/10.38094/jastt1457>
- Mitchell, T. M. (1997). **Machine Learning**. Editora McGraw-Hill, New York. ISBN 0070428077.
- Ministério Do Meio Ambiente (MMA). (2006). **Caderno da região Hidrográfica do Tocantins-Araguaia**. Secretaria de Recursos Hídricos. Brasília: MMA, p.132.
- Moghadam, P., Ward, D., Goan, E., Jayawardena, S., Sikka, P., & Hernandez, E. (2017). Plant disease detection using hyperspectral imaging. **International Conference on Digital Image Computing: Techniques and Applications (DICTA)**. <https://doi.org/10.1109/DICTA.2017.8227476>
- Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2012). **Foundations of machine learning**. Editora MIT Press, 2ª Edição. ISBN: 978-0-262-01825-8
- Moreira, M. A. (2011). **Fundamentos do sensoriamento remoto e metodologias de aplicação**. Editora UFV, 4ª Edição. ISBN 978-85-7269-381-3.
- National Aeronautics And Space Administration (NASA). (2013). **Landsat Data Continuity Mission: Continuously Observing Your World**. Disponível em: <https://www.nasa.gov/astronauts/2013astroclass.html>. Acesso em: 15 de agosto de 2020.

Nazari, B., Liaghat, A., Akbari, M. R., & Keshavarz, M. Irrigation water management in Iran: Implications for water use efficiency improvement. **Agricultural Water Management**, v.208, p.7-18. <https://doi.org/10.1016/j.agwat.2018.06.003>

Nguyen, H., Bui, X. N., Tran, Q. H., & Mai, N. L. (2019). A new soft computing model for estimating and controlling blast-produced ground vibration based on Hierarchical K-means clustering and Cubist algorithms. **Applied Soft Computing Journal**, v.77, p.376–386. <https://doi.org/10.1016/j.asoc.2019.01.042>

Nguyen, H., Bui, X. N., Tran, Q. H., Hoa, P. V., Nguyen, D. A., Hoa, L. T. T., Le, Q. T., Do, N. H., Bao, T. D., Bui, H. B., & Moayedí, H. (2020). A comparative study of empirical and ensemble machine learning algorithms in predicting air over-pressure in open-pit coal mine. **Acta Geophysica**, v.68, p.325–336. <https://doi.org/10.1007/s11600-019-00396-x>

Noi, P., Degener, J., & Kappas, M. (2017). Comparison of multiple linear regression, cubist regression, and random forest algorithms to estimate daily air surface temperature from dynamic combinations of MODIS LST data. **Remote Sensing**, v.9, n.5, p.398. <https://doi.org/10.3390/rs9050398>

Novo, E. M. L. M. (2010). **Sensoriamento remoto: princípios e aplicações**. Editora Brochura, 4ª Edição. ISBN: 9788521205401

Oliveira e Lucas, P. (2019). **Previsão de séries temporais de evapotranspiração de referência com Redes Neurais Convolucionais**. Dissertação (mestrado em Engenharia Elétrica)- Programa de Pós-Graduação em Engenharia Elétrica. Universidade Federal de Minas Gerais, Minas Gerais.

Panch, T., Szolovits, P., & Atun, R. (2018). Artificial intelligence, machine learning and health systems. **Journal of Global Health**, v.8, n.2. <https://doi.org/10.7189/jogh.08.020303>

Pereira, A. R., Sediyaama, G. C., & Nova, N. A. V. (2013). **Evapotranspiração**. 1 ed. Editora Fundag.

Petchprayoon, P., Blanken, P. D., Hussein, K., Abdalati, W., & Lawavirotwong, S. (2016). A Decade of Changing Surface Energy Balance Components Over a Large Water Region. **Remote Sensing of the Ocean**, v.9999. <https://doi.org/10.1117/12.2241516>

Piotrowski, A. P., & Napiorkowski, J. J. (2011). Optimizing neural networks for river flow forecasting – Evolutionary computation methods versus the Levenberg–Marquardt approach. **Journal of Hydrology**, v.407, p.12-27. <http://dx.doi.org/10.1016/j.jhydrol.2011.06.019>

Piotrowski, A. P., & Napiorkowski, J. J. (2013). A comparison of methods to avoid overfitting in neural networks training in the case of catchment runoff modelling. **Journal of Hydrology**, v.476, p.97-111. <http://dx.doi.org/10.1016/j.jhydrol.2012.10.019>

QGIS Development Team (2015). **QGIS Geographic information system (3.16)**. Disponível em: <http://www.qgis.org/>. Acesso em: 23 de Janeiro de 2020.

Quinlan, J. R. (1992). **Learning with continuous classes**. Proceedings of the Australian Joint Conference on Artificial Intelligence. p.343-348.

Quinlan, J. R. (1997). **New tool for continuous classes (aka Regression), machine learning list**. Disponível em: <http://www.ics.uci.edu/mlearn/MLlist/v9/13.html>. Acesso em: 10 de Junho de 2021.

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the great plains with ERTS. **Proceedings, Third Earth Resources Technology Satellite-1**, Symposium, Greenbelt: NASA SP- 351, p.3010-3017.

Rawat, J. S., & Kumar, M. Monitoring land use/cover change using remote sensing and GIS techniques: A case study of Hawalbagh block, district Almora, Uttarakhand, India. **The Egyptian Journal of Remote Sensing and Space Sciences**, v.18, p.77-84. <http://dx.doi.org/10.1016/j.ejrs.2015.02.002>

Roerink, G. J., Su, Z., & Menenti, M. (2000). S-SEBI: A Simple Remote Sensing Algorithm to Estimate the Surface Energy Balance. **Physics and Chemistry of the Earth — Part B: Hydrology, Oceans and Atmosphere**, v.25, p.147-157. [http://dx.doi.org/10.1016/S1464-1909\(99\)00128-8](http://dx.doi.org/10.1016/S1464-1909(99)00128-8)

Roy, D. P., Wulder, M. A., Loveland, T. R., Woodcock, C.E., Allen, R. G., Anderson, M. C., Helder, D., Irons, J. R., Johnson, D. M., Kennedy, R., Scambos, T. A., Schaaf, C. B., Schott, J. R., Sheng, Y., Vermote, E. F., Belward, A. S., Bindschadler, R., Cohen, W. B., Gao, F., Hipple, J. D., Hostert, P., Huntington, J., Justice, C. O., Kilic, A., Kovalsky, V., Lee, Z. P., Lyburner, L., Masek, J. G., MccorkeL, J., Shuai, Y., Trezza, R., Vogelmann, J., Wynne, R. H., & Zhu, Z. (2014). Landsat-8: Science and product vision for terrestrial global change research. **Remote Sensing of Environment**, v.145, p.154–172. <https://doi.org/10.1016/j.rse.2014.02.001>

Rulequest. (2016). **Data Mining with Cubist**. RuleQuest Research Pty Ltd., St. Ives, NSW, Australia. Disponível em: <https://www.rulequest.com/cubist-info.html>. Acesso em: 10 de maio de 2020.

Sales, D. L. A., Alves Júnior, J., Casaroli, D., Evangelista, A. W. P., & Souza, J. M. F. (2017). Estimativa de evapotranspiração e coeficiente de cultura do tomateiro industrial utilizando o algoritmo SAFER. **Irriga**, v.22, n.3, p.629-640. <http://dx.doi.org/10.15809/irriga.2017v22n3p529-640>

Santos, J. E. O., Cunha, F. F., Filgueiras, R., Silva, G. H., Texeira, A. H. C., Silva, F. C. S., & Sedivama, G. C. (2020). Performance of SAFER evapotranspiration using missing meteorological data. **Agricultural Water Management**, v.233, n.106076. <https://doi.org/10.1016/j.agwat.2020.106076>

Scarpate, F. V., Hernandez, T. A. D., Ruiz-Correa, S. T., Kolln, O. T., Gava, G. J. C., Santos, L. N. S., & Victoria, R. L. (2016). Sugarcane water footprint under different management practices in Brazil: Tietê/Jacaré watershed assessment. **Journal of Cleaner Production**, v.112, p.4576-4584. <http://dx.doi.org/10.1016/j.jclepro.2015.05.107>

Schott, J. R. (2007). **Remote Sensing: The Image Chain Approach**. Editora Oxford University Press, 2ª Edição. ISBN: 978-0-19-517817-3

Senay, G. B., Friedrichs, M., Singh, R. K., & Velpuri, N. M. (2016). Evaluating Landsat 8 evapotranspiration for water use mapping in the Colorado River Basin. **Remote Sensing of Environment**, v.185, p.171-185. <https://doi.org/10.1016/j.rse.2015.12.043>

Sentinel-2. Agência Espacial Europeia (ESA). (2017). Disponível em: http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Sentinel1/Introducing_Sentinel-1. Acesso em: 20 de agosto de 2020.

Shi, Z., Xu, L., Yang, X., Guo, H., Dong, L., Song, A., Zhang, X., & Shan, N. (2017). Trends in reference evapotranspiration and its attribution over the past 50 years in the Loess Plateau, China: implications for ecological projects and agricultural production. **Stochastic Environmental Research and Risk Assessment**, v.31, p.257-273. <https://doi.org/10.1007/s00477-015-1203-5>

Silva, B. B., Braga, A. C., Braga, C. C., Oliveira, L. M. M., Montenegro, S. M. G., & Barbosa Junior, B. (2016). Procedures for calculation of the albedo with Oli-Landsat 8 images: Application to the Brazilian semi-arid. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.20, n.1, p.3-8. <https://doi.org/10.1590/1807-1929/agriambi.v20n1p3-8>

Silva, C. O. F., Teixeira, A. H. C., & Manzione, R. L. (2019). Agriwater: An R package for spatial modelling of energy balance and actual evapotranspiration using satellite images and agrometeorological data. **Environmental Modelling & Software**, v.120, n.104497 <https://doi.org/10.1016/j.envsoft.2019.104497>

Sobrino, J., Del Frate, F., Drusch, M.; Jimenez-Munoz, J. C., Manunta, P., & Regan, A. (2016). Review of thermal infrared applications and requirements for future high-resolution sensors. **Ieee Transactions on Geoscience and Remote Sensing**, v.54, n.5, p.2963-2972. <https://doi.org/10.1109/TGRS.2015.2509179>

Stone, R. J. (1993). Improved statistical procedure for the evaluation of solar radiation estimation models. **Solar Energy**, v.51, p.289-291. [https://doi.org/10.1016/0038-092X\(93\)90124-7](https://doi.org/10.1016/0038-092X(93)90124-7)

Subedi, A. (2015). Crop evapotranspiration (ET) estimation models: A review and discussion of the applicability and limitations of ET methods. **Journal of Agricultural Science**, v.7, n.6. <http://dx.doi.org/10.5539/jas.v7n6p50>

Tang, R., Li, Z. L., Chen, K. S., Jia, Y., Li, C., & Sun, X. (2013). Spatial-scale effect on the SEBAL model for evapotranspiration estimation using remote sensing data. **Agricultural and Forest Meteorology**, v.174, p.28–42. <https://doi.org/10.1016/j.agrformet.2013.01.00813>

Tang, R., & Li, Z. L. (2015). Evaluation of two end-member-based models for regional land surface evapotranspiration estimation from MODIS data. **Agricultural and Forest Meteorology**, v.202, p.69–82. <https://doi.org/10.1016/j.agrformet.2014.12.005>

Tao, H., Diop, L., Bodian, A., Djaman, K., Ndiaye, P. M., & Yassen, Z. M. (2018). Reference evapotranspiration prediction using hybridized fuzzy model with firefly algorithm: Regional

case study in Burkina Faso. **Agricultural Water Management**, v.208, p.140-151. <https://doi.org/10.1016/j.agwat.2018.06.018>

Teixeira, A. H. C. (2010). Determining regional actual evapotranspiration of irrigated and natural vegetation in the São Francisco river basin (Brazil) using remote sensing and Penman-Monteith equation. **Remote Sensing**, v.2, n.5, p.1287-1319. <https://doi.org/10.3390/rs0251287>

Teixeira, A. H. C., Scherer-Warren, M., Hernandez, F. B., Andrade, R. G., & Leivas, J. F. (2013). Large-scale water productivity assessments with modis images in a changing semi-arid environment: A brazilian case study. **Remote Sensing**, v.5, n.11, p.5783-5804. <https://doi.org/10.3390/rs5115783>

Teixeira, A. H. C., Hernandez, F. B. T., Andrade, R. G., Leivas, J. F., & Bolfe, E. L. (2014). Energy balance with Landsat images in irrigated central pivots with corn crop in the São Paulo State, Brazil. **Remote Sensing for Agriculture, Ecosystems, and Hydrology**, v.9239. <https://doi.org/10.1117/12.2067090>

Teixeira, A. H. C., Leivas, J. F., Andrade, R. G., & Hernandez, F. B. T. (2015). Water productivity assessments with Landsat 8 images in the Nilo Coelho irrigation scheme. **Revista Irriga**, v.1, n.2, p.1-10. <https://doi.org/10.15809/irriga.2015v1n2p01>

Teixeira, A. H. C., Leivas, J. F., Ronquim, C. C., & Victoria, D. C. (2016). Sugarcane water productivity assessments in the São Paulo state, Brazil. **International Journal of Remote Sensing Applications**, v.6, p.84-95. <https://doi.org/10.14355/ijrsa.2016.06.009>

Tian, Y., Shi, Y., & Liu, X. (2012). Recent advances on support vector machines research. **Technological and Economic Development of Economy**, v.18, n.1, p.5-33. <https://doi.org/10.3846/20294913.2012.661205>

Tikhamarine, Y., Malik, A., Kumar, A., Souag-Gamane, D., & Kisi, O. (2019). Estimation of monthly reference evapotranspiration using novel hybrid machine learning approaches. **Hydrological Sciences Journal**, v.64, p.1824-1842. <https://doi.org/10.1080/02626667.2019.1678750>

Toumi, S., Erraki, J., Khabba, S., Jarlan, L., & Chehbouni, A. (2006). Performance assessment of Aqua Crop model for estimating evapotranspiration, soil water content and grain yield of winter wheat in Tensift Al Haouz (Morocco): Application to irrigation management. **Agricultural Water Management**, v.163, p.219-235. <https://doi.org/10.1016/j.agwat.2015.09.007>

Vanhellemont, Q., & Ruddick, K. (2014). Turbid wakes associated with offshore wind turbines observed with Landsat 8. **Remote Sensing of Environment**, v.145, n.1, p.105–115. [10.1016/j.rse.2014.01.009](https://doi.org/10.1016/j.rse.2014.01.009)

Vapnik, V. N. (1998). **Statistical Learning Theory**. John Wiley and Sons.

Warren, M. S., & Rodrigues, L. N. (2013). Estimativa de evapotranspiração real por sensoriamento remoto: procedimento e aplicação em pivô central. **Embrapa Cerrados**. ISSN:1676- 918X

- Weng, Q., Fu, P., & Gao, F. (2014). Generating daily land surface temperature at Landsat resolution by fusing Landsat and MODIS data. **Remote Sensing of Environment**, v.145, p.55-67. <https://doi.org/10.1016/j.rse.2014.02.003>
- Xue, J., & Su, B. (2017). Significant Remote Sensing Vegetation Indices: A review of developments and applications. **Journal of Sensors**, v.2017, p.1-17. <https://doi.org/10.1155/2017/1353691>
- Yamaç, S. S., & Todorovic, M. (2020). Estimation of daily potato crop evapotranspiration using three different machine learning algorithms and four scenarios of available meteorological data. **Agricultural Water Management**, v.228, n.105875. <https://doi.org/10.1016/j.agwat.2019.105875>
- Yang, Y., Cui, Y., Luo, Y., Lyu, X., Traore, S., Khan, S., & Wang, W. (2016). Short-term forecasting of daily reference evapotranspiration using the Penman-Monteith model and public weather forecasts. **Agricultural Water Management**, v.177, p.329–339. <https://doi.org/10.1016/j.agwat.2016.08.020>
- Ye, L., Jabbar, S. F., Zahra, M. M. A., & Tan, M. L. (2021). Bayesian Regularized Neural Network model development for predicting daily rainfall from Sea level pressure data: Investigation on solving complex hydrology problem. **Hindawi Complexity**, v.2021, p.1-14. <https://doi.org/10.1155/2021/6631564>
- Zanetti, S. S., Dohler, R., cecílio, R. A., Pezzopane, J. E. M., & Xavier, A. C. (2019). Proposal for the use of daily thermal amplitude for the calibration of the Hargreaves-Samani equation. **Journal of Hydrology**, v.571, p.193-201. <https://doi.org/10.1016/j.jhydrol.2019.01.049>
- Zhang, Z., Gong, Y., & Wang, Z. (2018). Accessible remote sensing data based reference evapotranspiration estimation modeling. **Agricultural Water Management**, v.210, p.59-69. <https://doi.org/10.1016/j.agwat.2018.07.039>
- Zhang, .Y., Peña-Arancibia, J. L., Mcvicar, T. R., Chiew, F. H. S., Vaze, J., Liu, C., Lu, X., Zheng, H., Wang, Y., Liu, Y. Y., Miralles, D. G., & Pan, M. (2016). Multi-decadal trends in global terrestrial evapotranspiration and its components. **Scientific Reports**, v.6, n.19124. <https://doi.org/10.1038/srep19124> PMID: 26750505
- Zilli, M., Scarabello, M., Soterroni, A. C., Valin, H., Mosnier, A., Leclère, D., Havlík, P., Kraxner, F., Lopes, M. A., & Ramos, F. M. (2020). The impact of climate change on Brazil's agriculture. **Science of the Total Environment**, v.740, n.139384. <https://doi.org/10.1016/j.scitotenv.2020.139384>