



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA SANITÁRIA E AMBIENTAL
CURSO ENGENHARIA SANITÁRIA E AMBIENTAL

Amanda Zulen Lee

**ANÁLISE DA EVAPOTRANSPIRAÇÃO REAL PARA A BACIA DA LAGOA DA
CONCEIÇÃO, EM FLORIANÓPOLIS - SC, COM PRODUTOS DE IMAGENS
LANDSAT 8 E 9**

Florianópolis
2023

Amanda Zulen Lee

**Análise da Evapotranspiração Real para a Bacia da Lagoa da Conceição, em
Florianópolis - SC, com Produtos de Imagens Landsat 8 e 9**

Trabalho de Conclusão de Curso submetido ao curso de Engenharia Sanitária e Ambiental do Centro Tecnológico da Universidade Federal de Santa Catarina como requisito parcial para a obtenção do título de Bacharela em Engenharia Sanitária e Ambiental em Engenharia Sanitária e Ambiental.

Orientadora: Prof.^a. Patrícia Kazue Uda, Dr.^a.

Florianópolis

2023

Ficha de identificação da obra elaborada pela autora,
Através do Programa de Geração Automática da Biblioteca Universitária da UFSC

Lee, Amanda Zulen

Análise da Evapotranspiração Real para a Bacia da Lagoa da
Conceição com Produtos de Imagens Landsat 8 e 9 / Amanda Zulen
Lee ; orientadora, Patrícia Kazue Uda, 2023.

123 p.

Trabalho de Conclusão de Curso (graduação) - Universidade
Federal de Santa Catarina, Centro Tecnológico, Graduação em
Engenharia Sanitária e Ambiental, Florianópolis, 2023.

Inclui referências.


1. Engenharia Sanitária e Ambiental. 2. Evapotranspiração. 3.
Lagoa da Conceição. 4. Sensoriamento Remoto. 5. Landsat 8 e 9.
I. Uda, Patrícia Kazue. II. Universidade Federal de Santa
Catarina. Graduação em Engenharia Sanitária e Ambiental. III.
Título.

Amanda Zulen Lee

**Análise da Evapotranspiração Real para a Bacia da Lagoa da Conceição, em Florianópolis - SC,
com Produtos de Imagens Landsat 8 e 9**

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do título de Engenharia Sanitária e Ambiental e aprovado em sua forma final pelo Curso de Engenharia Sanitária e Ambiental.

Florianópolis, 03 de julho de 2023.




Coordenação do Curso

Banca examinadora




Profª Patrícia Kazue Uda, Drª.

Orientadora



Priscilla Kern, Drª.

Universidade Federal de Santa Catarina



Esdras Coivo Villela, Me.

Universidade Federal de Santa Catarina

Florianópolis 2023.

Dedico este trabalho a minha família, por todo o esforço que me permitiram chegar
até aqui hoje.

AGRADECIMENTOS

Meus agradecimentos a todos aqueles que passaram pela minha vida, me trouxeram lições valiosas e contribuem ao meu aprendizado e bem-estar diário.

Gostaria de agradecer ao LAHIMAR, em especial a professora Patrícia e ao aluno José, por me oferecerem essa oportunidade de pesquisa e pelo suporte nesta fase final da graduação.

Ao pessoal da WST por tornarem minha vivência de estágio agradável e engrandecedora. Em especial ao diretor Nilson, e às gestoras Ana e Inês, por serem exemplos de liderança e competência.

A toda minha família Lee e Gonçalves, principalmente aos meus pais que sempre dedicaram suas vidas a trabalhar para que eu e meu irmão pudéssemos chegar até aqui.

Ao meu pai, por ser um exemplo de perseverança e batalha, quem me ensinou o amor pelos animais e o valor do trabalho.

A minha mãe, por me ensinar que nossa maior força vem do amor pelas pessoas, sendo ela mesma meu melhor exemplo de força e gentileza.

Ao meu irmãozinho querido, Guto, que já não habita o mesmo plano que o nosso, mas nos observa lá do céu e guia meus passos, por ser alegria e inocência

Ao meu irmão Gustavo por ser bondade, apoio e cumplicidade, não há ninguém no mundo que me conheça melhor do que ele. E à sua noiva Isadora e toda sua família, por serem incríveis e amorosos.

A minha madrinha Nayana e tia-amiga Mariany, que me provaram que para ser família não precisa ser de sangue, e sempre estiveram presentes.

As minhas amigas de infância Carolina, Gabrielle, Luanna e Tayná, que mesmo não estando presentes diariamente, me ensinaram muito, viveram comigo aventuras de infância imemoráveis e sem as quais talvez não estivesse aqui hoje.

Aos meus queridos amigos que fiz em SP, por quem tenho grande admiração e levo até hoje comigo: Alice, Gabriela, Isabel e Daniel, que infelizmente, não tenho a sorte de conviver diariamente, mas que com certeza moram em meu coração. Em especial ao meu amigo, Mateus, que tenho a sorte de ter por perto morando aqui nessa ilha incrível que é Florianópolis, e com quem sempre dou boas risadas. Agradeço a ele e aos amigos da Mentawmole, Esdras, Fernanda, Ingrid e Wallace por serem tão especiais.

Aos meus amigos da UFSC, que iluminam meu dia a dia e se tornaram minha família de coração e alma. Obrigada Camilla, Eduarda, Julia, Karen, Laura, Leticia G., Letícia V., Maria Eduarda, Nikollas e Oswaldo por passarem comigo esses anos lindos da graduação.

Ainda há muitas pessoas a quem gostaria de agradecer por terem feito parte desses meus 26 anos de vida, algumas nem moram no mesmo país, outras são colegas de profissão, contudo deixo expresso aqui os meus mais profundos sentimentos de reconhecimento e gratidão a eles e elas.

Agradeço ao universo por ter provido tudo que eu precisava para meu desenvolvimento, sejam eles oportunidades, pessoas, desafios ou situações inusitadas. Reconheço a vida como um breve instante para buscar evoluir e melhorar nossas relações conosco e com os seres vivos que aqui, também, habitam. E foi isso que procurei ao cursar Engenharia Sanitária e Ambiental.

fronteiras
são criação do homem
só nos separam fisicamente
não deixem que elas nos
coloquem uns contra os outros
- *não somos inimigos*
(KAUR, Rupi, 2018, p. 128)

RESUMO

O presente trabalho apresenta o uso de produtos de imagens Landsat 8 e 9 para o estudo da evapotranspiração da bacia da Lagoa da Conceição, localizada em Florianópolis, ao sul do Brasil. A evapotranspiração é um componente importante do ciclo hidrológico, e é resultado da transpiração de vegetais e evaporação da água de superfícies terrestres. O objetivo do estudo foi avaliar a estimativa da evapotranspiração real da bacia para os diferentes usos e cobertura do solo, e comparar o resultado calculado com os valores de evapotranspiração prontos obtidos pelas imagens Landsat. Foram utilizados dados de uma estação meteorológica local para a estimativa de Evapotranspiração Potencial através do método de Penman-Monteith (FAO-56), e o produto Landsat Collection 2 de coeficiente de evapotranspiração (ETF), para estimar a ET real, como dados de entrada. O processamento destes se deu com auxílio dos softwares REF-ET, QGIS e programação em linguagem Python para desenvolvimento de algoritmos capazes de calcular e processar as imagens para gerar valores de evapotranspiração real, em mm.dia^{-1} , para cada classe de solo. Os resultados indicaram que a evapotranspiração média mensal da bacia, entre os anos de 2017 a 2023 foi de cerca de $49,7 \text{ mm.mês}^{-1}$. Sendo a média mensal para: zonas urbanas igual a $32,8 \text{ mm.mês}^{-1}$; área de florestas igual a $68,1 \text{ mm.mês}^{-1}$; dunas igual $37,8 \text{ mm.mês}^{-1}$; gramíneas igual $35,4 \text{ mm.mês}^{-1}$; e corpo hídrico da lagoa igual $74,6 \text{ mm.mês}^{-1}$. A evapotranspiração da bacia apresenta variações sazonais, sendo maior no verão e menor no inverno, e distribuição heterogênea da evapotranspiração na bacia, com valores mais altos nas áreas próximas à lagoa e valores mais baixos nas áreas de zona urbana. Houve, também, uma boa correlação entre a evapotranspiração obtida pela NASA e a calculada com dados meteorológicos locais, podendo-se inferir que o sensoriamento remoto pode ser uma ferramenta útil para o estudo dos recursos naturais, permitindo a identificação de áreas com maior e menor demanda hídrica. Essas informações podem subsidiar futuros estudos sobre a gestão dos recursos hídricos na região da Lagoa da Conceição, contribuindo para a preservação do ecossistema local.

Palavras-chave: Evapotranspiração; Lagoa da Conceição; Sensoriamento Remoto; Landsat 8 e 9.

ABSTRACT

The present study presents the use of Landsat 8 and 9 images products for studying the evapotranspiration of Lagoa da Conceição watershed, located in Florianópolis, southern Brazil. Evapotranspiration is an important component of the hydrological cycle, and it results from the transpiration of plants and the evaporation of water from terrestrial surfaces. The objective of the study was to evaluate the estimation of actual evapotranspiration for different land uses and land cover within the watershed and compare the calculated result with ready-made evapotranspiration values obtained from Landsat images. Data from a local meteorological station were used for estimating Potential Evapotranspiration using the Penman-Monteith method (FAO-56), and Landsat Collection 2 Evapotranspiration Fraction (ETF) product was used to estimate actual evapotranspiration as input data. Processing of these data was done using REF-ET software, QGIS, and Python programming language to develop algorithms capable of calculating and processing the images to generate actual evapotranspiration values, in $\text{mm}\cdot\text{day}^{-1}$, for each land cover class. The results indicated that the average monthly evapotranspiration for the watershed, between the years 2017 and 2023, was approximately $49.7 \text{ mm}\cdot\text{month}^{-1}$. The monthly averages for different land cover classes were: urban areas $32.8 \text{ mm}\cdot\text{month}^{-1}$, forest areas $68.1 \text{ mm}\cdot\text{month}^{-1}$, dunes $37.8 \text{ mm}\cdot\text{month}^{-1}$, grasslands $35.4 \text{ mm}\cdot\text{month}^{-1}$, and the water body of the lagoon $74.6 \text{ mm}\cdot\text{month}^{-1}$. Evapotranspiration in the watershed showed seasonal variations, with higher values in summer and lower values in winter, and heterogeneous distribution of actual evapotranspiration within the watershed, with higher values near the lagoon and lower values in urban areas. There was a good correlation between evapotranspiration obtained from NASA and calculated using local meteorological data, suggesting that remote sensing can be a useful tool for studying natural resources and identifying areas with higher and lower water demand. This information can support future studies on water resource management in the Lagoa da Conceição region, contributing to the preservation of the local ecosystem.

Keywords: Evapotranspiration, Lagoa da Conceição, Remote Sensing, Landsat 8 and 9.

LISTA DE FIGURAS

Figura 1 - Representação simplificada dos componentes hidrológicos responsáveis pela evapotranspiração	19
Figura 2 - A libertação de vapor de água (gás) das folhas das plantas.....	20
Figura 3 - Representação esquemática do ciclo hidrológico	22
Figura 4 - Intervalos com os valores usuais de Kc para cada fase de crescimento de uma cultura	27
Figura 5 - Um instrumento de sensoriamento remoto coleta informação sobre um objeto ou fenômeno dentro do campo de visado instantâneo (IFOV) do sistema sensor sem estar em contato físico direto com ele.....	30
Figura 6 - Espectro eletromagnético.....	32
Figura 7 - Resoluções e Bandas características dos sensores OLI e TIRS do LANDSAT 8 ..	35
Figura 8 - Mapa de localização da bacia hidrográfica da Lagoa da Conceição	40
Figura 9 - Comparativos do uso e ocupação do solo no Distrito da Lagoa da Conceição entre os anos de 1985, 2000 e 2020.....	45
Figura 10 - Fluxograma metodológico.....	47
Figura 11 - Bandas espectrais para todos os sensores Landsat	50
Figura 12 - Seleção do conjunto de imagens Landsat 8-9 e alguns parâmetros	51
Figura 13 - Parâmetros de entrada do software REF-ET	54
Figura 14 - Saída dos dados de ETo calculados pelo REF-ET	55
Figura 15 - Criação das classes de uso do solo a partir de arquivo <i>shapefile</i>	57
Figura 16 - Mapas de distribuição da evapotranspiração real diária na bacia da Lagoa da Conceição, com números representativos de data da ET em ordem: ano, mês e dia (“aaaa/mm/dd”).	70
Figura 17 - Correlações de Pearson entre a ET real calculada e a ET real obtida (ETA) para as cinco classes de cobertura do solo.....	73

LISTA DE QUADROS

Quadro 1 - Variáveis biofísicas e respectivos sistemas de sensoriamento remoto	31
Quadro 2 - Lista com as especificações para cada banda incluída no produto Evapotranspiração real.	39
Quadro 3- Características do tipo climático Cfa de Köppen-Geiger (1948), por representação do conjunto de variáveis de letras.	41
Quadro 4 - Variação do uso e ocupação do solo no Distrito da Lagoa da Conceição entre 1985, 2000 e 2020.....	45
Quadro 5 - Valores mensais de evapotranspiração da bacia da Lagoa da Conceição	71

LISTA DE TABELAS

Tabela 1 - Características das estações meteorológicas nº1006 da EPAGRI em Florianópolis.	48
Tabela 2 - Número de imagens de ETF Landsat 8 e 9 trabalhadas por período	56
Tabela 3 - Diferença absoluta e relativa entre os valores de ET de referência gerados no REF-ET com inputs de dados diários e dados horários para os anos de 2022 e 2023.	59
Tabela 4 - Evapotranspiração real mensal (mm.mês ⁻¹) para cada tipo de uso e ocupação do solo da bacia.....	61
Tabela 5 - Valores máximos, mínimos e média calculados para a ET real em mm.dia ⁻¹ por classe.....	64
Tabela 6- Resultados da Evapotranspiração Real para a classe Dunas	66
Tabela 7 - Resultados da Evapotranspiração Real para a classe Lagoa	66
Tabela 8 - Resultados da Evapotranspiração Real para a classe Floresta.....	67
Tabela 9 - Resultados da Evapotranspiração Real para a classe Gramíneas.....	67
Tabela 10 - Resultados da Evapotranspiração Real para a classe Urbano.....	68
Tabela 11 - Comparação entre os valores de evapotranspiração mensal obtido por cada classe de estudo em comum às classes de Da Silva (2014)	72

SUMÁRIO

1	INTRODUÇÃO	16
2	OBJETIVOS.....	18
2.1	OBJETIVO GERAL	18
2.2	OBJETIVOS ESPECÍFICOS	18
3	REVISÃO BIBLIOGRÁFICA	18
3.1	EVAPOTRANSPIRAÇÃO.....	18
3.1.1	Conceito	18
3.1.2	Tipos de Evapotranspiração	22
3.1.3	Métodos para a quantificação da evapotranspiração.....	23
3.2	COEFICIENTE DE EVAPOTRANSPIRAÇÃO	25
3.2.1	Conceito e Determinação.....	25
3.2.2	Modelo dual-Kc da FAO	27
3.3	SENSORIAMENTO REMOTO	28
3.3.1	Conceito	29
3.3.2	Espectro Eletromagnético	31
3.3.3	Imagem	33
3.4	ESTIMATIVA DE EVAPOTRANSPIRAÇÃO REAL USANDO SENSORIAMENTO REMOTO	35
3.4.1	Estimativa da evapotranspiração por sensoriamento remoto.....	35
3.4.2	Landsat 8-9 Collection 2.....	38
4	ÁREA DE ESTUDO	39
4.1	LOCALIZAÇÃO.....	39
4.2	CLIMA	41
4.3	USO E OCUPAÇÃO DO SOLO	43
5	MATERIAIS E MÉTODOS	47
5.1	DADOS METEOROLÓGICOS	48
5.2	DADOS DE SENSORIAMENTO REMOTO	49
5.3	EVAPOTRANSPIRAÇÃO DE REFERÊNCIA PELO MÉTODO DE PENMAN- MONTEITH.....	52
5.4	ESTIMATIVA DA EVAPOTRANSPIRAÇÃO REAL:.....	55
5.5	RELAÇÃO ENTRE A EVAPOTRANSPIRAÇÃO REAL POR USO E OCUPAÇÃO DO SOLO	57

6	RESULTADOS E DISCUSSÃO	58
6.1	COMPARAÇÃO ENTRE DADOS METEOROLÓGICOS DIÁRIOS E HORÁRIOS PARA ET DE REFERÊNCIA.....	58
6.2	EVAPOTRANSPIRAÇÃO REAL MENSAL ESTIMADA.....	61
6.3	COMPARAÇÃO ENTRE EVAPOTRANSPIRAÇÃO REAL ESTIMADA E OBTIDA	72
7	CONCLUSÃO	74
	REFERÊNCIAS	78
	APÊNDICE A – ANÁLISES ESTATÍSTICAS DA EVAPOTRANSPIRAÇÃO REAL POR CLASSE DE COBERTURA DO SOLO DA BACIA DA LAGOA DA CONCEIÇÃO.....	85
	APÊNDICE B – ALGORITMO DE APLICAÇÃO DO CÁLCULO DE EVAPOTRANSPIRAÇÃO REAL COM IMAGENS LANDSAT 8 E 9 PARA BACIA DA LAGOA DA CONCEIÇÃO	97
	APÊNDICE C – COMPARAÇÃO ESTATÍSTICA ENTRE A ET REAL DA NASA E A ET REAL CALCULADA PARA CADA CLASSE DE SOLO DA BACIA	114

1 INTRODUÇÃO

Integrante do ciclo hidrológico, a evapotranspiração (ET) pode ser descrita como um processo físico no qual a água passa do estado líquido para o gasoso, movendo-se por superfícies terrestres, aquáticas e ou vegetais até evaporar para a atmosfera (TRAJKOVIC, 2010; WANG, 2012). Ela é essencial na regulação dos ciclos hídricos e afeta diretamente no balanço de água e nos ecossistemas (MARUYAMA, 2010; WANG, 2012). Por isso, sua estimativa é intrínseca para o planejamento e gestão dos recursos hídricos, sendo muito utilizada em estudos climatológicos, hidrológicos, no desenvolvimento de meios de cultura, entre outros (DONOHUE, 2007; WANG, 2012).

Sabe-se que a bacia da Lagoa da Conceição, localizada na cidade de Florianópolis, em Santa Catarina, no sul do Brasil, é vítima de intensa urbanização nos últimos anos, com o aumento da densidade populacional, cresce, também, a demanda por serviços básicos, como água e luz. A poluição das águas desta bacia é foco de estudos e abordagens científicas sobre a busca por medidas compensatórias e análises do aumento da mesma (ODRESKI, 2012; BIER, 2013; FINOTTI et al., 2009). Estimar a evapotranspiração real da bacia pode auxiliar na previsão do percentual de demanda hídrica atual e futura, entender o fenômeno de salinização existente e entre outros fatores cruciais para o manejo e gestão racional das águas da Lagoa da Conceição (UDA, 2012; BAI et al., 2021).

A evapotranspiração é influenciada por diversos fatores, como a umidade relativa do ar, a temperatura, a radiação solar, a velocidade do vento e a disponibilidade de água no solo. Os métodos para mensurá-la são diversos e, por vezes, complexos, incluindo o uso de sensores de fluxo de calor, medidores de umidade do solo e técnicas de sensoriamento remoto. Neste último, são utilizadas imagens de satélite para monitorar, classificar e modelizar esses processos através de sensores remotos.

Um exemplo da aplicação do sensoriamento remoto, é o uso de sensores que detectam a radiação infravermelha, capaz de medir a temperatura da superfície terrestre, que é um fator importante na evapotranspiração. A análise de imagens de satélite também pode ser usada para estimar a cobertura vegetal, que é outro fator importante na evapotranspiração.

Além disso, o sensoriamento remoto pode ser usado para monitorar a distribuição e a quantidade de água na superfície terrestre, incluindo rios, lagos, reservatórios e aquíferos. Isso pode ser feito por meio da análise de imagens de satélite que detectam a reflectância da luz nas diferentes bandas espectrais, o que permite identificar a presença de água.

Assim, este trabalho de conclusão de curso tem como objetivo principal estudar a evapotranspiração real na Bacia da Lagoa da Conceição, utilizando técnicas de geoprocessamento e modelagem matemática. Para isso, serão realizadas análises de dados de sensoriamento remoto, simulações numéricas e a aplicação de métodos empíricos, em particular, o método de Penman-Monteith para determinação da evapotranspiração de referência, com uso de dados orbitais do coeficiente de evapotranspiração real, para, por fim, obter estimativas precisas da evapotranspiração e entender como esse processo varia ao longo do tempo e do espaço na bacia.

Espera-se que os resultados obtidos neste estudo possam fornecer subsídios para uma melhor compreensão do ciclo hidrológico na Bacia da Lagoa da Conceição e aportar informações pertinentes para a gestão dos recursos hídricos na região.

2 OBJETIVOS

2.1 OBJETIVO GERAL

O objetivo principal do presente trabalho é analisar a evapotranspiração real da bacia da Lagoa da Conceição para seus diferentes usos e coberturas de solo, com auxílio de técnicas de geoprocessamento e estimativas numéricas.

2.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos do estudo são:

- Estimar a evapotranspiração de referência (ET_o) para a região de estudo com o método de Penman-Monteith (ALLEN et al., 1998);
- Analisar a evapotranspiração real da bacia (ET_r) da bacia da Lagoa da Conceição, com o uso de produtos de imagens LANDSAT 8 e 9;
- Avaliar a evapotranspiração real dos diferentes usos e coberturas do solo da bacia;
- Comparar a evapotranspiração real calculada com a evapotranspiração real fornecida pela USGS (Serviço Geológico dos Estados Unidos).

3 REVISÃO BIBLIOGRÁFICA


3.1 EVAPOTRANSPIRAÇÃO

3.1.1 Conceito

A evapotranspiração (ET) é estabelecida como a combinação do processo de evaporação da água presente na superfície terrestre e da transpiração das plantas. Enquanto a evaporação consiste numa transferência da água em um estado líquido para o gasoso pelo ganho de energia cinética molecular, a transpiração das plantas baseia-se num processo biofísico dado pelo metabolismo vegetal, em que a água em seu interior é perdida em forma de vapor para a atmosfera (ANDRADE, 2018). Simplificadamente, a ET é definida como a soma da quantidade de água perdida por meio da evaporação direta pela superfície do solo e da água perdida pelas plantas através da transpiração. Ela é um dos principais componentes do

ciclo hidrológico, ela possui papel intrínseco para o equilíbrio hídrico regional e dos ecossistemas (WANG et al., 2012, apud MARUYAMA et al., 2010). Na Figura 1 há uma ilustração simplificada dos componentes principais responsáveis pela evapotranspiração.

Figura 1 - Representação simplificada dos componentes hidrológicos responsáveis pela evapotranspiração



Fonte: elaborado pela autora.

A evaporação, apesar de ocorrer também em temperaturas ambientes, ocorre com maior rapidez em altas temperaturas e pressão de vapor. Allen *et al.* (1998), Monteith (1965) e Shuttleworth (1993) são autores que destacaram a importância da radiação solar e da temperatura do ar na evaporação, uma vez que a radiação solar fornece energia para que as moléculas de água na superfície sejam excitadas e convertidas em vapor, enquanto a temperatura do ar influencia a quantidade de energia necessária para que a água atinja o ponto de ebulição. Segundo Andrade (2018), o vento e a umidade do ar são fatores importantes que também influenciam na evaporação, uma vez que afetam a quantidade de vapor d'água presente na atmosfera e a troca de massa entre a superfície do solo e a atmosfera. O vento contribui para a remoção da camada de ar úmido que fica em contato com a superfície do solo, permitindo a entrada de ar seco e saída do vapor para a atmosfera, aumentando a taxa de evaporação (PENMAN, 1948; TAIZ & ZEIGER, 2010). Enquanto uma maior umidade do ar contribui para a saturação do mesmo, dificultando a evaporação da água.

Além da radiação solar, velocidade do vento, temperatura e umidade do ar, fatores como a quantidade de água disponível no solo e a presença de coberturas vegetais devem ser levados em consideração ao se avaliar a evaporação sobre uma superfície. Se por um lado a

presença de uma vegetação densa pode impedir que uma parte da radiação solar atinja diretamente o solo, por outro a escassez da disponibilidade hídrica no solo limita a taxa de evaporação, fazendo com que ela diminua, podendo até cessar (ANDRADE, 2018, apud ALLEN et al, 1998).

Já o segundo componente principal da ET, a transpiração é o processo no qual a água é perdida pelas plantas em forma de vapor através dos estômatos presentes nas folhas. Segundo Taiz & Zeiger (2010), o processo de transpiração é vital para a sobrevivência das plantas, uma vez que ajuda a regular a temperatura das folhas, a manter a turgescência celular e a absorver nutrientes e água. Quando as células vegetais perdem água e a pressão interna diminui, a turgência celular é reduzida, o que pode afetar negativamente a saúde vegetal. A transpiração é, assim como a evaporação, influenciada por diversos fatores como a umidade relativa do ar, temperatura, disponibilidade de água no solo e a radiação solar. Além disso, conforme Andrade (2018, apud ALLEN et al., 1998) “também são fatores determinantes da taxa de transpiração da espécie vegetal, seu estágio de desenvolvimento, a umidade, fertilidade e condutividade hidráulica do solo, além de condições adversas, como alta salinidade, pH extremo, patologias e hidromorfismo (encharcamento do solo)”. A Figura 2 ilustra o processo de liberação de vapor d’água pelas folhas da planta, no processo de transpiração.

Figura 2 - A liberação de vapor de água (gás) das folhas das plantas.



Fonte: Ming Kei College (2018)

Na natureza, os fenômenos de evaporação e transpiração ocorrem, normalmente, concomitantemente, por isso sua distinção é difícil (PENMAN, 1948; TAIZ & ZEIGER, 2010). Um exemplo para esses dois fenômenos é o de uma área de floresta tropical, em que boa parte da radiação solar é impedida de chegar ao solo, resultando em menor evaporação da água da superfície terrestre, contudo a densidade foliar presente pela vegetação contribui para


uma elevada transpiração da água pelas plantas. Nesse aspecto, o conhecimento do Índice de Área Foliar (IAF) torna-se uma ferramenta relevante para determinação da evapotranspiração de uma região. O IAF é uma medida da área total das folhas de uma vegetação em relação à área do solo ocupada por ela, muito importante para descrever algumas características estruturais do dossel vegetal (SANTOS et al., 2016).

Diante disso tudo, percebe-se que a evapotranspiração apresenta uma grande variabilidade temporal e espacial. A taxa de evapotranspiração pode variar de acordo com a época do ano, o horário do dia, a localização geográfica e as condições meteorológicas. E, dentre os fatores que influenciam o processo de evapotranspiração, a cobertura do solo é um dos mais importantes deles (MONTEITH, 1965; ALLEN et al., 1998).

A presença de vegetação exerce uma grande influência na taxa de evapotranspiração, uma vez que as plantas absorvem água do solo e a transpiram para a atmosfera. De acordo com Allen et al. (1998), áreas com maior cobertura vegetal apresentam taxas mais elevadas de evapotranspiração, enquanto áreas sem vegetação, como desertos e regiões áridas, apresentam taxas mais baixas. Assim, a cobertura vegetal do solo é significativa para evapotranspiração, uma vez que influencia a interação entre a superfície terrestre, as plantas e a atmosfera. Mudanças na vegetação podem impactar gravemente na taxa de evapotranspiração e, conseqüentemente, na disponibilidade hídrica de ecossistemas terrestres (Allen et al., 1998; Zhang et al., 2018).

Segundo Tucci et al., (1998) a evapotranspiração (ET) é responsável pela maior parte das perdas de água do solo e corpos d'água, representando aproximadamente 70% do total de precipitação. A Figura 3 ilustra de maneira simplificada o ciclo hidrológico.

Figura 3 - Representação esquemática do ciclo hidrológico



Fonte: Comini (2018)

3.1.2 Tipos de Evapotranspiração

De acordo com Fernandes (2010), apesar de existirem diversas metodologias desenvolvidas para estimar a evapotranspiração, somente algumas possuem aplicação prática que atendam todas as condições climáticas, sendo necessário o ajuste de parâmetros para cada local estudado. Existem três tipos de evapotranspiração principais que são estudadas para fins específicos acerca de cada temática de pesquisa, são elas: a Potencial, de Referência e a Real.

A evapotranspiração real ou atual (ET_r ou ET_a) é definida como a quantidade de água liberada para a atmosfera por meio da evaporação da superfície do solo e transpiração das plantas, levando em consideração as condições reais dos fatores atmosféricos e umidade do solo (FERNANDES, 2010, APUD MATZENAUER, 1992). Segundo Fernandes (2010) e Stone (1995), a evapotranspiração real possui valor menor ou igual a evapotranspiração potencial. Ela é a quantidade de água que efetivamente foi utilizada por uma superfície vegetada.

Já a evapotranspiração potencial (ET_p) pode ser descrita como a quantidade de água resultante da transpiração de uma vegetação rasteira, com altura uniforme, cobrindo totalmente o solo, em um determinado espaço de tempo, sem jamais sofrer limitações hídricas (FERNANDES, 2010, apud TANNER; PELTON, 1960; PENMAN, 1948). Ela é definida, de acordo com a FAO (1998), como sendo a taxa máxima de evapotranspiração que ocorreria sob um conjunto de condições atmosféricas padronizadas. A problemática acerca da definição da ET_p advém de que a mesma é calculada a partir de dados meteorológicos que foram

obtidos em condições não ideais, em que a umidade do solo nem sempre se encontra em condições ótimas de estado (FERNANDES, 2010).

A definição da evapotranspiração de referência (ET_o) é semelhante ao termo ET_p, contudo aplica-se a ET_o para uma espécie de cultura em particular, como a grama ou a alfafa. A vegetação rasteira, como as citadas anteriormente, é definida como a cultura de referência, e ela é considerada livre do estresse hídrico e de doenças (FERNANDES, 2010; DOORENBOS & PRUITT; 1977).

Em síntese, a condição da evapotranspiração de referência (ET_o) é a de uma superfície gramínea bem irrigada, e a de evapotranspiração potencial (ET_p) uma superfície com água ilimitada (como uma lagoa).

A comparação entre a ET real e a ET potencial numa mesma região auxilia na quantificação do déficit hídrico climático e a analisar a aridez de um determinado ambiente em maior detalhe (ALLEN et al., 1998; DOORENBOS, J & PRUITT, W.O., 1977). Por isso, uma estimativa confiável da ET é essencial para o planejamento e gestão dos recursos hídricos, permitindo avaliar o balanço hídrico em diferentes escalas de espaço-tempo e definir o reservatório de água disponível em uma determinada área para diferentes usos da água (FERNANDES, 2010).

3.1.3 Métodos para a quantificação da evapotranspiração

Os métodos para estimar a evapotranspiração potencial (ET_p) e de referência (ET_o) são inúmeros e complexos, e podem ser categorizados em métodos empíricos, semi-empíricos e baseados em física teórica (FERNANDES, 2010). Dentre os métodos empíricos existem, segundo Fernandes (2010), quatro classificações: “métodos baseados unicamente em dados de temperatura média do ar, métodos baseados em combinações de temperatura do ar e radiação incidente, métodos baseados na combinação de temperatura do ar e pressão de vapor e métodos baseados em dados de evaporação.”

Três métodos empíricos famosos para estimar a evapotranspiração potencial e a de referência são:

a) Método de Penman–Monteith:

Recomendado pela FAO (*Food and Agriculture Organization*) das Nações Unidas (1998) devido a sua precisão. É reconhecida como método de Penman-Monteith FAO-56 (FERNANDES apud. ALLEN et. al., 1998). O método usa como base uma cultura fictícia que tem características similares à evapotranspiração da grama. Isso garante que essas

características permaneçam como valores constantes utilizados nos cálculos. Como resultado, a ET_o é uma medida da quantidade de água necessária para as culturas de um local e período específicos (SILVA, S., 2017, apud CARVALHO, et al., 2011).

A equação de Penman-Monteith (Eq. 1) para obter os valores de evapotranspiração de referência é a seguinte:

$$ET_o = \frac{0,408 (Rn - G) + \gamma \frac{900T}{T+273} * u^2 (e_s - e_a)}{\Delta + \gamma (1 + 0,34 u^2)} \quad (1)$$

Em que: ET_o = Evapotranspiração de referência (mm.dia^{-1}) (ALLEN et al., 1998); Rn = Radiação líquida ($\text{MJ.m}^{-2}.\text{dia}^{-1}$); G = Densidade do fluxo de calor no solo ($\text{MJ.m}^{-2}.\text{dia}^{-1}$); T = Temperatura média do ar ($^{\circ}\text{C}$); u^2 = Velocidade média do vento à 2 m do solo (m.s^{-1}); e_s = Pressão do vapor de saturação (KPa); e_a = Pressão real de vapor (KPa); Δ = Declive da curva da pressão do vapor ($\text{KPa.}^{\circ}\text{C}^{-1}$); γ = Constante Psicrométrica ($\text{KPa.}^{\circ}\text{C}^{-1}$).

Contudo, como o método demanda medidas precisas de muitas variáveis meteorológicas, tais como: temperatura e umidade relativa do ar, radiação solar e velocidade do vento, ele apresenta uma maior complexidade (PEREIRA et al, 2002; POPOVA, 2006), por isso, hoje existem diversos softwares que auxiliam no cálculo da evapotranspiração potencial pelo método de Penman-Monteith. Dentre eles, o “ETM+ Tool” é um software desenvolvido pela NASA que realiza o cálculo da evapotranspiração potencial utilizando o método de Penman-Monteith a partir de imagens de satélite, disponibilizado gratuitamente no site da NASA.

b) Método de Hargreaves-Samani:

É um método mais simples que utiliza apenas dados de temperatura do ar e radiação solar extraterrestre (ALLEN et al., 1998). Hargreave e Samani (1982) partiram do princípio de que a diferença entre as temperaturas máxima e mínima do ar pode indicar a fração de radiação extraterrestre que atinge a superfície terrestre, contribuindo para a elaboração da Equação 2 para estimar a ET_o :

$$ET_o = 0,0023. (T_{m\acute{a}x} - T_{m\acute{i}n})^{0,5}. (T_{m\acute{e}d} + 17,8). Ra. 0,408 \quad (2)$$

Em que: ET_o = Evapotranspiração de referência (mm.dia^{-1}); $T_{m\acute{a}x}$ = Temperatura máxima diária do ar ($^{\circ}\text{C}$) $T_{m\acute{i}n}$ = Temperatura mínima diária do ar ($^{\circ}\text{C}$); Ra = Radiação solar no topo da atmosfera ($\text{MJ.m}^{-2}.\text{dia}^{-1}$);

No entanto, é importante ressaltar que o método de Hargreaves tende a estimar em excesso a evapotranspiração de referência em regiões úmidas e subestimá-la em áreas com alta velocidade do vento. Portanto, é necessário realizar uma calibração regional para aprimorar a precisão do modelo (ALLEN et al., 1998; MANTOVANI et al., 2006).

c) Método de Makkink:

Baseado no modelo de Penman, sua principal vantagem reside no fato de que utiliza apenas informações relativas à temperatura e irradiação solar, o que o torna indicado para áreas com clima úmido. Contudo, ele não apresenta resultados satisfatórios em locais de clima árido, conforme apontado por Fernandes et al. (2010) na Equação 3.

$$ET_o = (0,61 \cdot R_s \cdot W) - 0,12 \quad (3)$$

Em que: R_s = Radiação solar global ($\text{MJ} \cdot \text{m}^{-2} \cdot \text{dia}^{-1}$); W = fator de ponderação que representa a fração da radiação solar global, utilizada na evapotranspiração, obtido pela Equação 4:

$$W = \frac{\Delta}{\Delta + \gamma} \quad (4)$$

Em que: Δ = Declividade da curva de pressão de saturação do vapor de temperatura do ar; e γ = constante psicrométrica.

3.2 COEFICIENTE DE EVAPOTRANSPIRAÇÃO

3.2.1 Conceito e Determinação

O coeficiente de evapotranspiração, comumente chamado de coeficiente de cultura (K_c), é muito útil para reconhecimento das necessidades hídricas de diferentes culturas, para consequente manejo e aplicação de atividades, como a irrigação, de forma correta e adequada (MAIA, 2008). O K_c é utilizado para determinar, de forma simples, a evapotranspiração real (ET_a) (ANA, 2020 apud ALLEN et al., 1998), ou quando aplicado para uma cultura específica, a evapotranspiração potencial da cultura (ET_c), as quais dependem também da evapotranspiração de referência (ET_o). Esse coeficiente de ajuste é adimensional e pode ser

determinado pela seguinte relação da Equação 5 (ALBUQUERQUE, 2021; POSSE, 2008; ALLEN et al, 1998):

$$ET_a = ET_o * Kc \quad ou \quad Kc = \frac{ET_c}{ET_o} \quad (5)$$

Em que, a ET_o , em geral, pode ser calculada por meio de dados de estações climatológicas com o método de Penman-Monteith (ANA, 2020).


O coeficiente de cultura (Kc) varia para cada estágio fenológico da cultura e leva em consideração o efeito combinado da variação da área foliar, altura das plantas, grau de cobertura, resistência do dossel e albedo (ALBUQUERQUE, 2021 APUD, GOMIDE, 2021; MENDONÇA et al., 2007). Além disso, é influenciado por fatores físicos, como o tipo de solo (BERGAMASCHI, 1999), estágio de desenvolvimento da cultura, arranjo das plantas e condições climáticas predominantes (MORAIS, 2008). Por isso, deve ser determinado para as condições específicas do local em que será utilizado para resultados mais precisos.

Para a determinação do Kc de forma acurada, é recomendável considerar as diferentes fases do ciclo da cultura, já que a cobertura do solo tende a aumentar à medida que as plantas crescem (ALBUQUERQUE & COELHO, 2021; ABID, 2013; BERGAMASCHI, 1999). Albuquerque (2010) sugere a divisão do ciclo das plantas anuais em quatro fases: estágio inicial (início do crescimento da cultura, cobertura do solo <10%); estágio de desenvolvimento vegetativo (de 10% a 80% de cobertura do solo); estágio de florescimento ou reprodutivo (início da cobertura plena do solo até a maturação); e estágio de maturação (início da descoloração ou queda).

Além disso, Andrade (2018) argumenta que estimar o coeficiente de evapotranspiração exige informações sobre a espécie vegetal em questão, data de plantio e floração, além do monitoramento regular da altura média da lavoura, tipo de solo, frequência de precipitação, velocidade do vento e a umidade relativa do ar. Todos esses fatores são um desafio, por isso, em muitos casos, utiliza-se um coeficiente de cultura genérico (kc) para estimar a evapotranspiração real da área em questão (ANDRADE, 2018 apud ALLEN et al., 1998).

A Figura 4 a seguir apresenta um resumo dos fatores que influenciam o valor de Kc de acordo com Andrade (2018) e Allen et al., (1998).

Figura 4 - Intervalos com os valores usuais de K_c para cada fase de crescimento de uma cultura



Fonte: Andrade (2018) adaptado Allen et al. (1998)

De acordo com o comunicado técnico nº 251 fornecido pela Empresa Brasileira de Pesquisa Agropecuária (Embrapa) e escrito por Albuquerque e Coelho (2021), os coeficientes de cultura (K_c) são amplamente divulgados no manual da FAO nº 24 (DOORENBOS; PRUITT, 1977) e nº 56 (ALLEN et al., 1998). O K_c é tabelado e descrito por Allen et al. (1998), além disso possui diversas metodologias para sua determinação, dentre elas a de Graus-Dias Acumulados (GDAc) aplicada por Teixeira et al. (2014).

3.2.2 Modelo dual- K_c da FAO

Ademais, Kool et al. (2013) apresenta o modelo *dual- K_c* da FAO (ALLEN et al., 1998) para o cálculo da evapotranspiração de uma cultura bem irrigada usando um fator de multiplicação específico da cultura (K_c) definido empiricamente em combinação com a evapotranspiração de referência (ET_o). A abordagem do *dual- K_c* divide o fator K_c em um componente da planta K_{cb} e um componente do solo K_e , definido como (Eq. 6):

$$ET = (K_{cb} + K_e) ET_o \quad (6)$$

No qual, ET e ET_o estão em mm.d^{-1} e K_{cb} (Eq. 7) e K_e (Eq. 8) são adimensionais e são definidos como:

$$Kcb = Kcb_{(table)} + [0,04 (u_2 - 2) - 0,004(RH_{mín} - 45)](h_p)^{0,3} \quad (7)$$

$$Ke = Kr(K_{c-max} - Kcb) \leq f_{ew} * K_{c-max} \quad (8)$$

Em quem, $Kcb_{(table)}$ é um valor medido experimentalmente encontrado na literatura, u_2 é a velocidade média diária do vento a 2m de altura sobre a grama; $RH_{mín}$ é a umidade relativa mínima diária (%), h_p é a altura média da planta (m); f_{ew} é a fração do solo a partir da qual ocorre a maioria da evaporação, Kr é um fator de redução com base na disponibilidade de água do solo e K_{c-max} é o fator máximo de evaporação com base na energia disponível para ET na superfície do solo (KOOL et al.,2013).

O modelo dual-Kc da FAO é comumente usado para a partição da evapotranspiração (ET), porém por ser empírico e seus fatores de cultura pré-definidos, ele pode não ser aplicável em diferentes contextos (KOOL, 2013 apud FERREIRA et al., 2012). Não obstante, o modelo pode ser considerado uma ferramenta precisa o suficiente para a programação de irrigação e monitoramento (KOOL., 2013).

Na plataforma da *United States Geological Survey* (USGS), o Serviço Geológico dos Estados Unidos, são disponibilizados uma variedade de dados geoespaciais, fornecidos através de imagens de satélites, dentre eles a coleção de produtos relacionados à evapotranspiração, disponíveis globalmente, a Coleção Landsat 2 (C2). Nela estão incluídos *rasters* contendo informações sobre a:

- Evapotranspiração Real ou Atual (ETa): O qual fornece uma estimativa por pixel da transferência diária de água da superfície da Terra para a atmosfera em unidades de profundidade de água em milímetros (mm).
- Fração de Evapotranspiração (ETf): Representa uma fração adimensional da Evapotranspiração Real (ETr), variando nominalmente entre 0 e 1 (adimensional), estimada pelo modelo SSEBop, é semelhante ao coeficiente de cultura baseado em referência da alfafa em condições observadas. Isso pode ser usado em combinação com a ET de referência fornecida pelo usuário para criar uma ETa mais precisa, que considere as condições climáticas locais. Neste caso, o coeficiente de evapotranspiração.

3.3 SENSORIAMENTO REMOTO

3.3.1 Conceito


O Sensoriamento Remoto pode ser caracterizado como o estudo feito a partir de informações adquiridas da captura de dados de um objeto através de sensores, sem estar em contato físico com o mesmo (JENSEN, 2009; COLWELL, 1983). Ele permeia diferentes áreas da ciência, e, sobretudo, as ciências geográficas, uma vez que as informações obtidas através dele permitem um enriquecimento substancial para o estudo de outros tópicos, como a cartografia e o Sistema de Informação Geográfica. (CURRAN, 1987; CLARKE, 2001; JENSEN, 2005).

De acordo com Ponzoni (2012), definições tradicionais de técnicas de sensoriamento remoto tendem a destacar conceitos como distância, informação e contato físico, que são importantes para a base teórica dessas técnicas, mas podem obscurecer os conceitos principais que são cruciais para uma compreensão de maior complexidade e completude. Em vez disso, é fundamental compreender os processos de interação entre a radiação eletromagnética e os diferentes objetos, ou alvos, que são o foco das técnicas de sensoriamento remoto.

As aplicações da ciência do sensoriamento são inúmeras, como a análise de uso de solos, meios de culturas vegetais, medição de produtividade, demandas hídricas e fluxo da água dentro de uma bacia (CAMPBELL, 2006; JENSEN, 2009). Tudo isso utilizando imagens geradas por um sensor e registradas ao longo de um período.

Segundo Jensen (2005), os sensores responsáveis pela captura das informações de um objeto podem estar a poucos metros de distância do mesmo, como, por exemplo, uma aeronave equipada com câmeras, ou a centenas de quilômetros, como é o caso de satélites espaciais. O processo de captura desses dados é realizado, normalmente, pela leitura da energia eletromagnética emanada pelos alvos, isto é, pelo objeto em análise. Como ilustra a Figura 5:

Figura 5 - Um instrumento de sensoriamento remoto coleta informação sobre um objeto ou fenômeno dentro do campo de visado instantâneo (IFOV) do sistema sensor sem estar em contato físico direto com ele.



Fonte: Jensen (2005)

Para Jensen (2012) o sensoriamento remoto fornece informação sobre duas classes de variáveis: *biofísicas e híbridas*:

As variáveis biofísicas são informações biológicas e/ou físicas (biofísicas) que podem ser obtidas diretamente, sem a necessidade de dados auxiliares. Um exemplo disso são os sensores no infravermelho termal que podem medir a temperatura aparente de um objeto, enquanto sensores em regiões específicas do espectro podem identificar a quantidade de vapor d'água na atmosfera (JENSEN, 2012).

Já as variáveis híbridas são aquelas obtidas por meio da análise sistemática de mais de uma variável biofísica, como a detecção de estresse em vegetação por meio da absorção de

clorofila, temperatura e teor de umidade. A cobertura da terra é outra variável híbrida importante que pode ser derivada a partir da avaliação de várias variáveis biofísicas simultaneamente. Embora as variáveis híbridas de escala nominal tenham sido a principal preocupação do sensoriamento remoto, o aumento do uso de dados biofísicos escalonados por intervalo e fração agora permite a criação de modelos quantitativos que incorporam informações espaciais (JENSEN, 2012).

O Quadro 1, adaptada do livro de Jensen (2012) fornece uma lista de variáveis biofísicas para vegetação, temperatura, solos e rochas que podem ser obtidas por sensoriamento remoto usando sensores adequados para a aquisição de dados.

Quadro 1 – Variáveis biofísicas e respectivos sistemas de sensoriamento remoto

Variáveis Biofísicas	Sistemas de Sensoriamento Remoto Potenciais
Vegetação <ul style="list-style-type: none"> • Pigmentos (p.ex., clorofilas <i>a</i> e <i>b</i>) • Estrutura e altura do dossel • Biomassa derivada de índices de vegetação • Índice de área foliar (LAI ou IAF) • Radiação fotossinteticamente ativa absorvida • Evapotranspiração 	- Fotografia área colorida, ETM+ Landsat, IKONOS, QuickBird, OrbView-3, SeaWiFS da Orbimage, Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER), ENVISAT, hiperspectral aerotransportado (p.ex., AVIRIS, HyMap, CASI); - Fotografia aérea estereoscópica, LIDAR, RADARSAI, IFSAR; - Fotografia aérea infravermelha colorida (CIR), fotografia aérea, Landsat (TM, ETM+), IKONOS, QuickBird, Orb View-3, Advanced Very High Resolution Radiometer (AVHRR), CBERS (CCD, WFI), Multiangle Imaging Spectroradiometer (MISR), sistemas hiperspectrais aerotransportados (p.ex., AVIRIS, HyMap, CASI)
Temperatura Superficial (terra, água, atmosfera)	- ASTER, AVHRR, GOES, Hyperion, MISR, MODIS, SeaWiFS, infravermelho termal aerotransportado
Solos e Rochas <ul style="list-style-type: none"> • Umidade • Composição mineral • Taxonomia • Alteração hidrotermal 	- ASTER, micro-ondas passivo (SSM/1), RADARSAI, MISR, ALMAZ, Landsat (TM, ETM+), ERS-1 e 2, Intermap Star 3i; - ASTER, MODIS, sistemas hiperspectrais (p.ex., AVIRIS, HyMap, CASI); - Fotografia área colorida de alta resolução e fotografia aérea infravermelha colorida (CIR), sistemas hiperspectrais aerotransportados (p.ex., AVIRIS, HyMap, CASI); - Landsat (TM, ETM+), ASTER, MODIS, hiperspectrais aerotransportados (p.ex., AVIRIS, HyMap, CASI)

Fonte: Adaptado Jensen (2012), página 12


3.3.2 Espectro Eletromagnético

O fluxo da radiação eletromagnética permite a obtenção de uma série de dados graças aos diferentes comprimentos de ondas existentes. De acordo com Ponzoni (2012), o fluxo de radiação incidente sobre uma superfície é composto por radiação em diferentes

comprimentos de ondas. Segundo o autor, as condições geométricas da reflexão das radiações permitem caracterizar determinados comportamentos do objeto, que são os chamados de “comportamentos espectrais”.

O estudo “Introdução ao Processamento Digital de Imagens” do IBGE (2001), cita que o espectro eletromagnético pode ser ordenado em função do seu comprimento de onda e frequência. E a maior parte dos sensores de monitoramento da Terra opera nas regiões do visível, infravermelho e microondas. A seguir a Figura 6 representa o intervalo do espectro solar.

Figura 6 - Espectro eletromagnético



Fonte: DORNELLES (2008)

Em síntese, cada comprimento de onda do espectro eletromagnético interage de maneira diferente com as características físicas dos objetos e superfícies terrestres. Por exemplo, os sensores que operam na faixa do espectro visível permitem a detecção da luz refletida pela superfície da Terra e podem ser usados para distinguir diferentes tipos de vegetação e características da paisagem. Enquanto sensores da região do espectro infravermelho térmico, medem a radiação emitida pela superfície, permitindo detectar mudanças de temperatura, muito útil para o monitoramento climático de uma região (IBGE, 2001; JENSEN, 2009).

A reflectância é um termo importante para a área da teledetecção, uma vez que ela é a capacidade de um determinado objeto refletir a radiação eletromagnética incidente. Ela é uma proporção de energia refletida pelo objeto e a energia incidente sobre ele, e varia dependendo da cor do objeto (PONZONI, 2012; JENSEN, 2009; CAMPBELL, 2006).

Ponzoni (2012) explica que o fluxo de radiação refletido por uma superfície ou objeto é influenciado por suas propriedades físico-químicas e pela geometria da incidência e reflexão da radiação. Isso acontece porque a maioria das superfícies dos recursos naturais não é isotrópica, o que significa que suas propriedades variam em diferentes direções. Deste modo, as características espectrais do fluxo de radiação refletido podem fornecer informações precisas sobre as características do objeto ou superfície, bem como sobre as condições de iluminação e observação. Logo, diz-se que os fatores de reflectância são bidirecionais quando existem duas geometrias envolvidas no processo de interação: a de incidência (por exemplo, o Sol) e a de visada (por exemplo, o sensor).

3.3.3 Imagem

Outro conceito importante é o de imagem, que para o sensoriamento remoto é uma fonte de dados radiométricos. Valores de parâmetros físicos como a reflectância e a radiância podem ser obtidos a partir da conversão de números digitais (ND) das imagens (PONZONI, 2012). Uma imagem digital é composta por um agrupamento de elementos (dígitos) sob a forma de malha regular, as quais possuem unidades definidas em um sistema de coordenadas “x” e “y” de localização. (IBGE, 2001) E o menor elemento desta grade é chamado de pixel, o qual possui um valor numérico que indicará a intensidade da radiação eletromagnética da superfície em questão (PONZONI, 2012).

Em resumo, a imagem digital é a representação de uma matriz $f(x,y)$, em função da intensidade de energia EM da área imageada, com valores que dependem da intensidade (brilho) dos materiais da área relacionada ao pixel de coordenada (x,y) . (IBGE, 2001)

Além disso, a Resolução das Imagens pode ser dividida em 4 características principais, segundo o estudo do IBGE (2001) e Novo (2008):

- Resolução Espacial: pode ser caracterizada como a habilidade do sensor de diferenciar objetos que são próximos espacialmente. Nos sensores ópticos a resolução espacial depende do ângulo de visibilidade do sensor (IFOV) que influenciará no tamanho da área vista no terreno.
- Resolução Espectral: é definida como a habilidade de separar objetos espectralmente semelhantes, através da distinção de níveis de intensidade da resolução radiométrica. Sensores com melhor resolução espectral permitem uma

melhor análise das interações entre a REM e os alvos que compõem a superfície terrestre.

- **Resolução Radiométrica:** é a aptidão do sensor de diferenciar as variações no nível de energia refletida, emitida ou retroespalhada que deixa a superfície do objeto. Refere-se aos níveis digitais descritos em níveis de cinzas e é representada por números de dígitos binários (bits). Ela está diretamente relacionada ao tamanho dos arquivos de imagem.
- **Resolução Temporal:** é caracterizada pela frequência, periodicidade ou repetitividade com que o sensor monitora uma determinada área.

Estas resoluções são imprescindíveis para o campo do sensoriamento remoto, uma vez que possibilitam mensurar o número e a dimensão de comprimentos de ondas no espectro eletromagnético, chamadas de bandas ou canais (JENSEN, 2005). Com a resolução espectral é possível registrar a energia em múltiplas dimensões do espectro eletromagnético através das separações angulares ou lineares entre o objeto, ou mais, e o sensor. E assim, comparações entre diferentes materiais na superfície terrestre podem ser feitas e tiradas conclusões para um determinado estudo.

As geotecnologias, incluindo o sensoriamento remoto, são opções economicamente viáveis e tecnicamente eficazes para realizar o levantamento urbano e ajudar na tomada de decisões sobre questões socioambientais nas cidades (GARCIA; ARAÚJO, 2021; SILVA, COSTA e CASTRO, 2019). Enquanto o Sensoriamento Remoto pode ser usado para mapear a expansão urbana e a pressão antrópica sobre os recursos naturais, com o auxílio de ferramentas de geoprocessamento, como o Sistema de Informação Geográfica (SIG), é possível integrar e analisar dados de inúmeras fontes e criar bancos de dados georreferenciados (C MARA; DAVIS; MONTEIRO, 2001).

A Figura 7 apresenta uma tabela com as especificações das bandas espectrais dos sensores OLI e TIRS do satélite LANDSAT 8

Figura 7 - Resoluções e Bandas características dos sensores OLI e TIRS do LANDSAT 8

Sensor	Bandas Espectrais	Resolução Espectral	Resolução Espacial	Resolução Temporal	Área Imageada	Resolução Radiométrica
OLI (Operational Land Imager)	(B1) AZUL COSTEIRO	0.43 - 0.45 μm	30 m	16 dias	170 x 183 km	16 bits
	(B2) AZUL	0.45 - 0.51 μm				
	(B3) VERDE	0.53 - 0.59 μm				
	(B4) VERMELHO	0.64 - 0.67 μm				
	(B5) INFRAVERMELHO PRÓXIMO	0.85 - 0.88 μm				
	(B6) INFRAVERMELHO MÉDIO	1.57 - 1.65 μm				
	(B7) INFRAVERMELHO MÉDIO	2.11 - 2.29 μm	15 m			
	(B8) PANCROMÁTICA	0.50 - 0.68 μm	30 m			
	(B9) CIRRUS	1.36-1.38 μm				
TIRS (Thermal Infrared Sensor)	(B10) INFRAVERMELHO TERMAL	10.6-11.19 μm	100 m			
	(B11) INFRAVERMELHO TERMAL	11.5-12.51 μm	100 m			

Fonte: Engesat (2013)

A combinação do Sensoriamento Remoto e do SIG permite uma visão panorâmica com maior precisão das informações, o que pode garantir melhores resultados para o estudo das áreas urbanas (FELIZARDO, 2016; LEITE e ROSA, 2006).

3.4 ESTIMATIVA DE EVAPOTRANSPIRAÇÃO REAL USANDO SENSORIAMENTO REMOTO

3.4.1 Estimativa da evapotranspiração por sensoriamento remoto

O uso de sensoriamento remoto na análise da vegetação tem permitido a obtenção de informações mais detalhadas, como a biomassa e o índice de área foliar. Isso tem se mostrado útil tanto para monitorar ecossistemas quanto para se obter estimativas de safras e áreas agrícolas de forma precisa e quantitativa (PONZONI, 2012). Além disso, Comini (2018) afirma que o uso do sensoriamento remoto pode não permitir uma medida direta de evapotranspiração real (ETa), mas possibilita a estimativa da fração evaporativa que, junto a dados meteorológicos, é utilizada para derivar a ETa e sua distribuição espacial. Os métodos

de estimativa analítica baseados na tecnologia de teledetecção constituem um outro meio de estimar a evapotranspiração da vegetação urbana (FENG et al, 2021)

O sensoriamento remoto orbital oferece vantagens como a coleta de informações detalhadas para uma grande área em um curto período e a quantificação de parâmetros físicos da superfície terrestre com alta resolução temporal e espacial. O desenvolvimento atual do uso de dados de satélite para a determinação da evapotranspiração torna possível o estudo das perdas evaporativas sem a necessidade do cálculo do balanço hídrico, e o balanço de energia descreve as interações físicas na interface superfície-atmosfera (PAIVA et al., 2011).

Existem muitos modelos que podem ser usados para estimar a evapotranspiração real a partir de dados de sensoriamento remoto. Esses modelos variam desde os mais simples, que se baseiam em poucos parâmetros de entrada, até os mais complexos, que levam em consideração uma série de variáveis ambientais.

Uma abordagem popular é estimar a evapotranspiração real como sendo o produto da evapotranspiração de referência (que é a evapotranspiração que ocorreria em um campo de referência com uma cobertura vegetal padrão) multiplicada por um coeficiente de cultura que leva em consideração as características específicas da cultura em questão. Isso é conhecido como método do coeficiente de cultura.

Bastiaanssen (1995) apresentou o algoritmo Surface Energy Balance for Land (SEBAL) para estimar as componentes instantâneas do balanço de energia por meio do sensoriamento remoto. O modelo é composto de parametrizações físicas simples e bem estabelecidas, que foram confrontadas com dados de campo em diferentes partes do mundo, resultando em bons resultados. O SEBAL requer poucos dados de superfície para seu processamento, e sua utilização em bacias hidrográficas pode contribuir para o manejo dos recursos hídricos, como mencionado por Mohamed et al. (2004). O modelo tem sido aplicado com sucesso em diversas regiões do mundo, incluindo a Ásia, África, América do Norte e Europa.

Existem muitos artigos em revistas científicas que abordam a utilização de modelos para estimar a evapotranspiração real a partir de dados de sensoriamento remoto. Por exemplo, um estudo publicado na revista *Agricultural Water Management* em 2019 comparou vários modelos diferentes e descobriu que o método do coeficiente de cultura era o mais adequado para estimar a evapotranspiração real de uma plantação de batatas usando dados de satélite.

Outro estudo publicado na revista *Remote Sensing* em 2018 analisou a utilização de dados de sensoriamento remoto para estimar a evapotranspiração em áreas semiáridas na

Austrália. Os autores desenvolveram um modelo que levava em consideração a vegetação, o solo e a atmosfera e descobriram que ele era capaz de estimar com precisão a evapotranspiração em áreas com baixa disponibilidade de água.

No estudo de Parmar, Patel e Tiwari (2023) para avaliação das necessidades hídricas (ETc) da cultura de milho em várias escalas através do sensoriamento remoto e SIG, utilizou-se imagens de satélite Sentinel-2 para gerar valores médios de NDVI (Índice de Vegetação por Diferença Normalizada), muito utilizado para avaliar a saúde e a quantidade de vegetação em uma determinada área. O NDVI varia de -1 a 1, sendo que valores mais próximos de 1 indicam uma maior quantidade de vegetação saudável na área analisada, enquanto valores negativos indicam áreas com pouca ou nenhuma vegetação (PONZONI, 2012).

Para o cálculo da evapotranspiração de referência (ETo), Parmar, Patel e Tiwari (2023) utilizaram o método da FAO Penman-Monteith (FAO-PM), os coeficientes das culturas de milho foram gerados usando a sua correlação com valores NDVI baseados na detecção remota, e por fim, estimaram a evapotranspiração real da cultura (ETc) através da Equação 9:

$$ETc = Kc \times ETo \quad (9)$$

De acordo com as descobertas (PARMAR; PATEL; TIWARI, 2023), percebeu-se que os mapas de ETc criados usando índices de vegetação multiespectrais detectados remotamente foram ferramentas úteis para avaliar a utilização da água nas culturas em escalas regionais e de campo. Além disso, os resultados mostraram que as variações em Kc foram bem explicadas pelas variações em NDVI e o estudo mostra a aplicação de sensoriamento remoto e SIG para a gestão de recursos hídricos em culturas de milho.

De acordo com ANA (2020), que cita SENAY et al. (2007), os autores do SSEB argumentam que a estimativa da Evapotranspiração Real (ETa) pode ser obtida pela diferença de temperatura próxima à superfície. Essa diferença de temperatura pode ser estimada a partir das temperaturas de superfície de um pixel quente e de um pixel frio na área de estudo. Em outras palavras, enquanto se espera uma ETa próxima a zero no pixel quente, que representa uma área de solo exposto e seco, no pixel bem vegetado e úmido é esperado encontrar a ETa máxima. Nos demais pixels da área de estudo, a ETa varia proporcionalmente à diferença de temperatura entre o pixel quente e o pixel frio.

Em resumo, existem muitos modelos diferentes que podem ser utilizados para estimar a evapotranspiração real a partir de dados de sensoriamento remoto, cada um com

suas próprias vantagens e desvantagens. O método do coeficiente de cultura é um dos mais populares e pode ser uma boa opção em muitos contextos, mas é importante escolher o modelo certo para as condições específicas do seu estudo.

3.4.2 Landsat 8-9 Collection 2

Como citado anteriormente no tópico 3.2.2, a USGS oferece o produto científico Landsat 4-9 Collection 2 composto por diversas análises espectrais realizadas pelos satélites Landsat 4 a 9. Dentre eles o Level-3 (L3) Evapotranspiration Real Provisional (ETa), aporta uma estimativa da evapotranspiração real baseada nesses dados obtidos pela série Landsat. O produto fornece informações valiosas sobre os fluxos de água na superfície terrestre, auxiliando em estudos hidrológicos, gerenciamento de recursos hídricos e monitoramento de condições ambientais (EROS, 2020)

A ETa é calculada a partir de observações multiespectrais e térmicas dos satélites Landsat, combinadas com modelos e algoritmos avançados. Essa estimativa representa a quantidade real de água que é perdida para a atmosfera por evaporação e transpiração das plantas em uma determinada região. Essa informação é crucial para entender a disponibilidade e demanda de água em ecossistemas, cultivos agrícolas e áreas florestais, auxiliando no planejamento e tomada de decisões relacionadas ao uso sustentável dos recursos hídricos (EROS, 2020).

O produto L3 ETA do Landsat 4-9 Collection 2 é provisório, o que significa que ainda está sujeito a validação e refinamentos adicionais. No entanto, ele fornece uma estimativa inicialmente confiável da evapotranspiração real, sendo útil para uma ampla gama de aplicações científicas e de gestão. É importante ressaltar que esse produto é parte de uma coleção mais ampla de dados Landsat, que abrange várias coleções e níveis de processamento, cada um com suas características e finalidades específicas.

O Quadro 2 foi adaptado do Guia do Produto da Evapotranspiração Provisional da coleção citada. Ela descreve algumas características dos produtos.

Quadro 2 - Lista com as especificações para cada banda incluída no produto Evapotranspiração real.

Descrição	Nome da Banda	Intervalo Válido	Fator de Escala	Unidade	Valor de Preenchimento	Tipo de Dado
ET Real ou Atual (ETa)	ProductID_ETA	0 - 20000	0.001	mm	-9999	INT16
ET Fracionada (ETf)	ProductID_ETF	0 - 10000	0.0001	Adimensional	-9999	INT16
ET Incerta (ETUN)	ProductID_ETUN	0 - 15000	0.001	mm	-9999	INT16
Pixel QA de Nível 2	ProductID_QA_PIXEL	0 - 65535	NA	Bit Index	1 (bit 0)	UINT16
Metadados XML de Nível 3	ProductID.xml	N/A	N/A	N/A	N/A	N/A
Metadados MTL de Nível 1	.txt and .xml	N/A	N/A	N/A	N/A	N/A

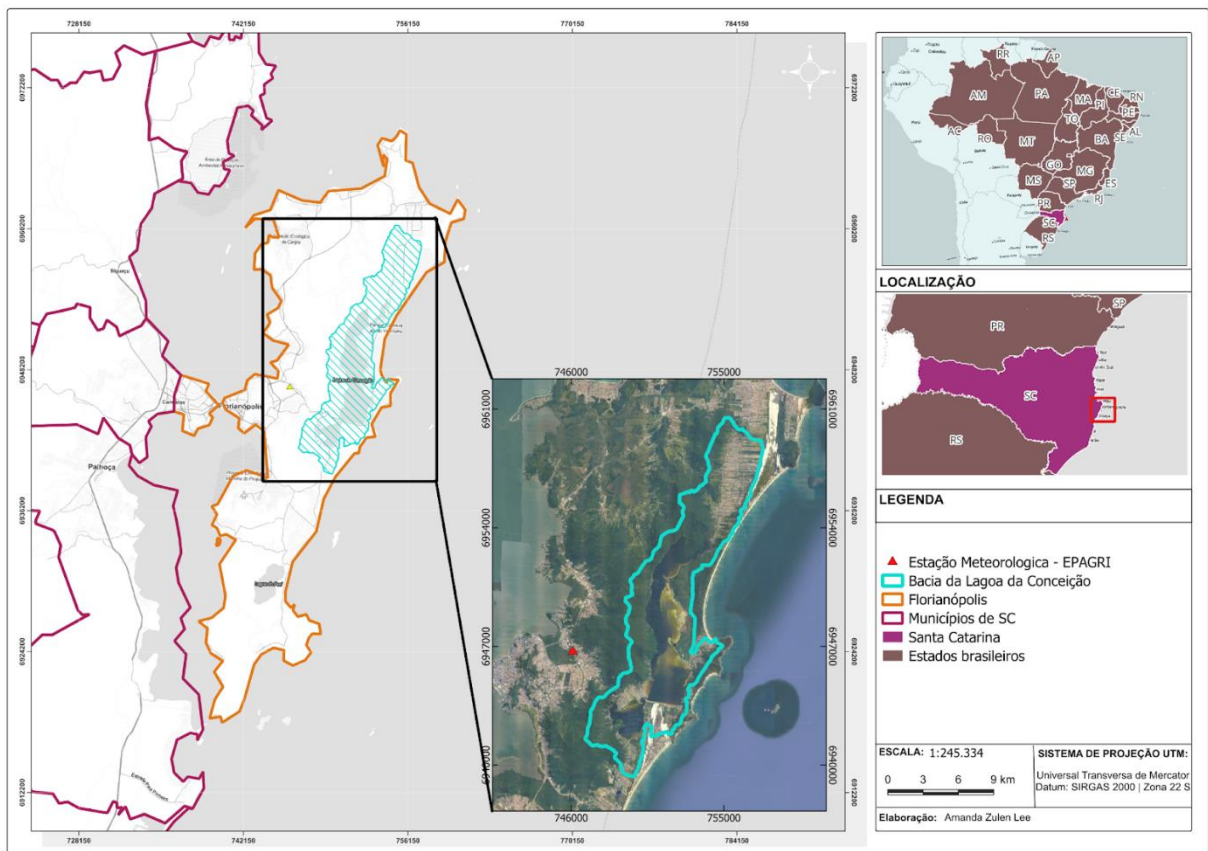
Fonte: USGS, 2022

4 ÁREA DE ESTUDO

4.1 LOCALIZAÇÃO

A bacia hidrográfica da Lagoa da Conceição (Figura 8) compreende uma área de com cerca de 75,5 km² de extensão, situada na parte centro-leste do município de Florianópolis, no estado de Santa Catarina, ao sul do Brasil. Localizada entre as latitudes 27°27'22.10'' S e 27°38'37.99'' S e longitudes 48°24'55.08'' O e 48°28'25.47'' O. O distrito da Lagoa da Conceição abrange as localidades do Canto dos Araçás, da Costa da Lagoa, Praia e Parque da Galheta, Praia Mole, Praia da Joaquina, Lagoa da Conceição, Canto da Lagoa, Porto da Lagoa e Retiro da Lagoa.

Figura 8 - Mapa de localização da bacia hidrográfica da Lagoa da Conceição



Fonte: elaborado pela autora.

Em sua área há uma conexão com o mar, o Canal da Barra, por meio do qual ocorre uma troca de água doce com a salina, sendo esta a razão pela qual pode-se classificar o corpo d'água da Lagoa da Conceição como uma laguna semifechada (VAZ, 2008). Ela possui uma extensão de cerca de 13,5 km, com largura variável entre 0,15 e 2,5 km, profundidade média de 1,7 m e máxima de 8,9 m, e possui uma área de cerca de 20,65 km² (GODOY, 2007).

A geomorfologia da Ilha de Florianópolis é descrita por CARUSO JUNIOR (1993) como “uma série de maciços rochosos interligados por áreas planas”, em que os maciços na ilha estão relacionados com a elevação da Serra do Mar, que se estende do sul de Santa Catarina até o norte do Rio de Janeiro. Na ilha eles têm altitudes que variam entre 180 m a 519 m, enquanto que as áreas planas na ilha consistem em sistemas de dunas, cordões arenosos, lagoas costeiras e zonas de mangue.

A região da Lagoa da Conceição conta com uma grande diversidade de elementos naturais, como remanescentes da Mata Atlântica, dunas, restingas, flora e fauna exuberantes, sendo um dos motivos pelo qual a região tem se tornado um atrativo para muitos migrantes,

além da qualidade de vida elevada (VAZ, 2008). Ela tem sido cada vez mais cobiçada por seu valor natural, arqueológico e econômico, principalmente para o turismo e a pesca. No entanto, a atividade pesqueira assim como características socioambientais locais têm diminuído nos últimos anos, e a expansão urbana tem provocado crescimento acelerado e desordenado, ocasionando o aumento de impactos ambientais na área (SILVA, 2002; VAZ, 2008).

4.2 CLIMA

Caracterizar o clima e as condições meteorológicas é importante para a compreensão das características climatológicas da região de estudo, permitindo, a partir de uma análise integrada de vários elementos climáticos, entender como os mesmos interagem entre si e prever eventuais impactos decorrentes das características de temperatura, regime de precipitação, ventos, dentre outros.

Segundo a classificação de Köppen-Geiger (1948), reconhecida internacionalmente e usualmente utilizada em estudos ambientais, a Ilha de Florianópolis é do tipo Cfa, que corresponde a um clima subtropical úmido com verões quentes e invernos amenos. A letra "C" indica que é um clima temperado, a letra "f" significa que há chuvas frequentes ao longo do ano e a letra "a" indica que as temperaturas médias do mês mais quente são superiores a 22 °C, sendo que o mês mais frio apresenta média inferior a 18 °C, mas acima de 3 °C.

O Quadro 3 apresenta as características do Clima Subtropical Cfa de Köppen-Geiger por variável de letras.

Quadro 3- Características do tipo climático Cfa de Köppen-Geiger (1948), por representação do conjunto de variáveis de letras.

CARACTERÍSTICAS CATEGORIA "C"	CARACTERÍSTICAS SUBDIVISÃO "f"	CARACTERÍSTICAS SUBDIVISÃO "a"
<ul style="list-style-type: none"> - Clima das regiões oceânicas; - Climas mesotérmicos; - Temperatura média do ar no mês mais frio fica compreendida entre 3°C e 18°C; - Verão e inverno bem definidos 	<ul style="list-style-type: none"> - Presença de chuva em todos os meses; - Inexistência de estação seca; - Clima úmido 	<ul style="list-style-type: none"> - Verão quente; - Temperatura média do ar no mês, mais quente maior que 22 °C.


Fonte: Mendonça e Dani-Oliveira, 2007.

O Clima Subtropical Cfa possui como características verão e inverno bem definidos, regime de chuvas bem distribuídas ao longo do ano e sem estação seca. O Clima tipo subtropical Cfa está presente em regiões de menor altitude do planalto.

Além disso, pode-se dizer também, que a região sul do Brasil em comparação às outras, destaca-se por seu regime de chuvas bem distribuídas ao longo do ano. Os maiores índices pluviométricos são condicionados pela atuação de massas marítimas (sistemas atmosféricos oceânicos), através das ondas de calor do leste e nordeste. Segundo MONTEIRO (2001), as frentes frias, os vórtices ciclônicos, os cavados de níveis médios, a convecção tropical, a ZCAS (Zona de Convergência do Atlântico Sul) e a circulação marítima são os principais agentes meteorológicos responsáveis pela pluviosidade no estado.

O clima em Florianópolis caracteriza-se por ser agradável, há fortes influências da maritimidade, controlada pelas Massa Tropical Marítima e Massa Polar Atlântica. Analisou-se os dados fornecidos pela estação meteorológica nº 1006 da Cetegre/EPAGRI (Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina - Centro de Treinamento), localizado no bairro Itacorubi (Figura 8), entre os períodos de 2001 a 2023. As médias das temperaturas médias do ar mensal é de cerca de 21,01°C, a máxima de 25,60°C e a mínima de 17,48°C, as variações podem ser vistas no Gráfico 1

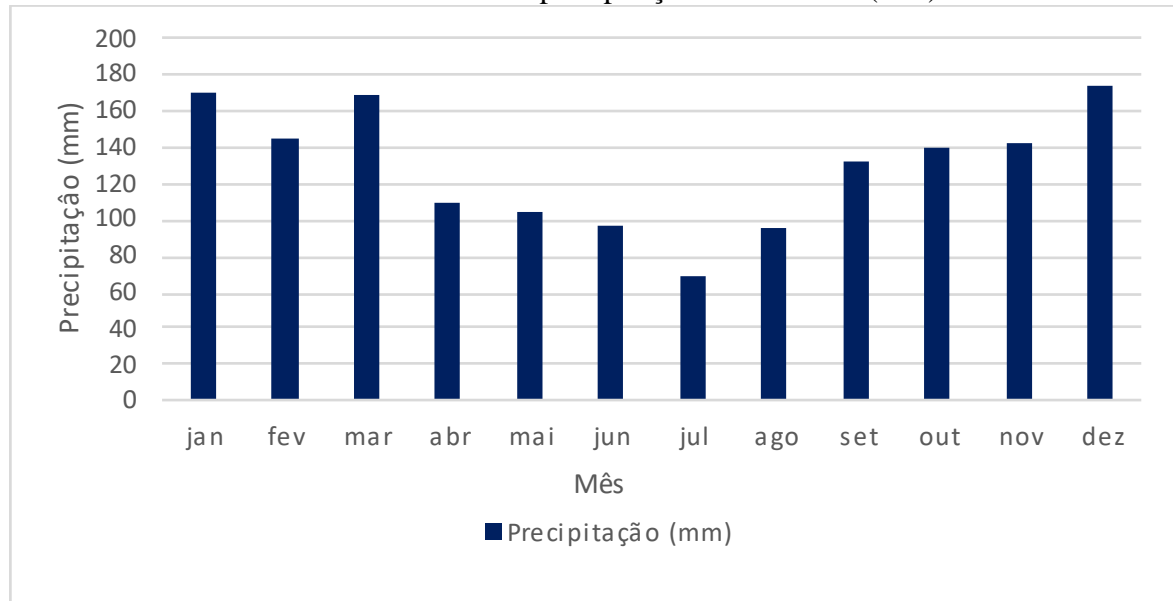
Gráfico 1 - Dados meteorológicos da estação nº1006 da Cetegre/EPAGRI.



Fonte: A autora.

Ainda, com base nos 23 anos de dados registrados pela mesma estação meteorológica, chove, em média, 1.427,55 mm por ano. O período com maior pluviosidade é durante o verão, entre os meses de dezembro a março, com média de 165 mm de chuva por mês, em contrapartida, é durante o inverno o período de menor pluviosidade, entre junho a agosto, com média de 87 mm por mês (Gráfico 2).

Gráfico 2 - Média da precipitação total mensal (mm)



Fonte: A autora.

4.3 USO E OCUPAÇÃO DO SOLO

É crucial o monitoramento da expansão do solo urbano a fim de entender sua condição atual e prever futuras situações (HIGASHI, 2006). Nesse sentido, a cartografia do uso e ocupação do solo antigamente e no presente são essenciais para interpretar os componentes do espaço urbano e sua interação com o meio natural (GARCIA; ARAUJO, 2021).

De acordo com Hauff (1996; apud Carneiro, 1987), os primeiros povos pré-históricos que habitavam o litoral do Estado de Santa Catarina eram grupos pescadores e coletores de moluscos, na ilha de Santa Catarina seus vestígios datam de 5.000 anos, eram assim intitulados como os ‘sambaquis’ ou ‘concheiros’. Ainda de acordo com a autora (1996; apud Carneiro, 1987), foi no início dos anos de 1748 que começaram a chegar os primeiros açorianos à Ilha.

Segundo Hauff (1996, apud LUPI, 1987), as atividades básicas dos colonizadores açorianos consistiam na pesca de subsistência e na pequena agricultura (cultivo de mandioca, arroz, cana-de-açúcar, milho, algodão, café, trigo e algumas frutas como banana e laranja). Segundo as bibliografias de Carneiro e Lupi (1987), os colonizadores açorianos e madeirenses, ao chegarem na ilha de Florianópolis enfrentaram algumas dificuldades como: a metragem de terra era menor do que o governo lhes havia prometido, o solo era impróprio

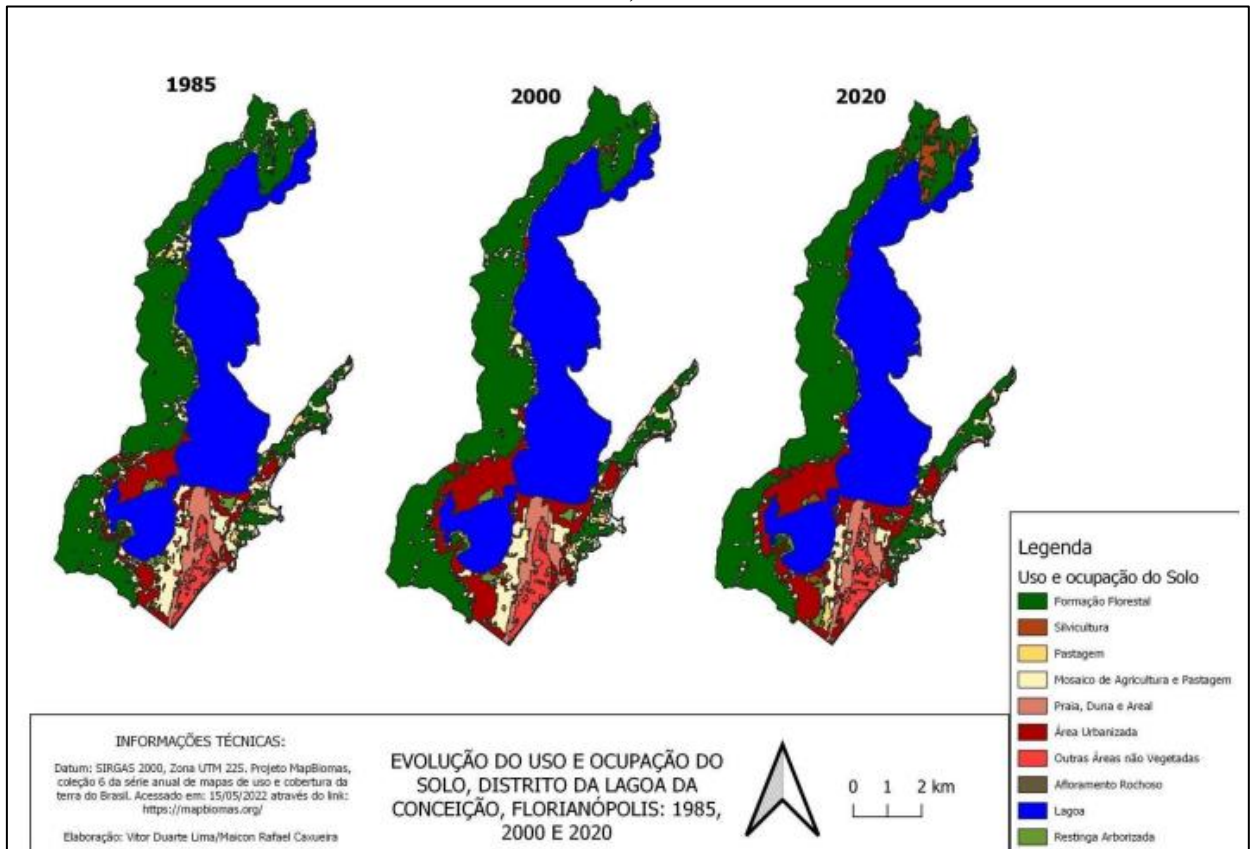
para o plantio de produtos tradicionalmente cultivados nos Açores e na Ilha da Madeira e seus produtos - tanto pesqueiros como agrícolas - eram pouco competitivos em relação aos da cidade.

Além disso, na metade do século XVIII até o século XX, cerca de 76% da cobertura vegetal da Ilha foi desmatada para a prática da agricultura (HAUFF, 1996; apud CARUSO,1983). Depois, por volta de 1820, começa uma decadência na prática da agricultura em virtude do crescimento dos centros urbanos e das terras exauridas, notando-se modificações no habitat rural açoriano.

Através de interpretações de fotografias aéreas e de imagens orbitais dos anos de 1956 a 1978 os autores HAUFF e LOCH (1991) relatam que a ocupação da Lagoa da Conceição deu-se, principalmente, ao longo das vias, assim como o desaparecimento das zonas agrícolas concomitantemente ao adensamento urbano nas localidades da Lagoa e Barra da Lagoa. Além disso, houve regeneração da cobertura vegetal em alguns pontos antes agrícolas, contudo o contrário ocorreu com as vegetações de restingas, que sofreram grande redução, com exceção das áreas internas dos campos dunares.

Lima (2022) traz uma análise quali quantitativa do uso e ocupação do solo no Distrito da Lagoa da Conceição para os anos de 1985, 2000 e 2020. Através do mapa temático (Figura 9 e do Quadro 4 de dados quantitativos, é possível observar as alterações no território ao longo desses anos.

Figura 9 - Comparativos do uso e ocupação do solo no Distrito da Lagoa da Conceição entre os anos de 1985, 2000 e 2020.



Fonte: LIMA (2022)

Quadro 4 - Variação do uso e ocupação do solo no Distrito da Lagoa da Conceição entre 1985, 2000 e 2020.

Uso	Área (km ²)			Variação 1985/2020 (%)
	1985	2000	2020	
Floresta	17,500	18,353	18,243	4,24%
Restinga	1,565	1,293	1,353	-13,57%
Silvicultura	0,015	0,113	1,229	7871,95%
Agricultura e Pastagem	6,410	4,629	3,621	-43,51%
Praia e Duna	1,920	1,698	1,611	-16,10%
Urbanização	3,709	5,146	5,395	45,47%
Corpo d'água	20,805	20,534	20,422	-1,84%

Fonte: LIMA (2022)

As análises de Lima (2022) mostram a grande diversidade de elementos naturais presentes na região, com destaque para o corpo d'água, formação florestal, restingas, praias e dunas, que a torna uma das maiores biodiversidades da Ilha de Santa Catarina. A região passou por transformações históricas, onde antes era uma comunidade rural agrícola e se transformou em uma sociedade urbana. Observa-se que a expansão urbana se intensificou nas

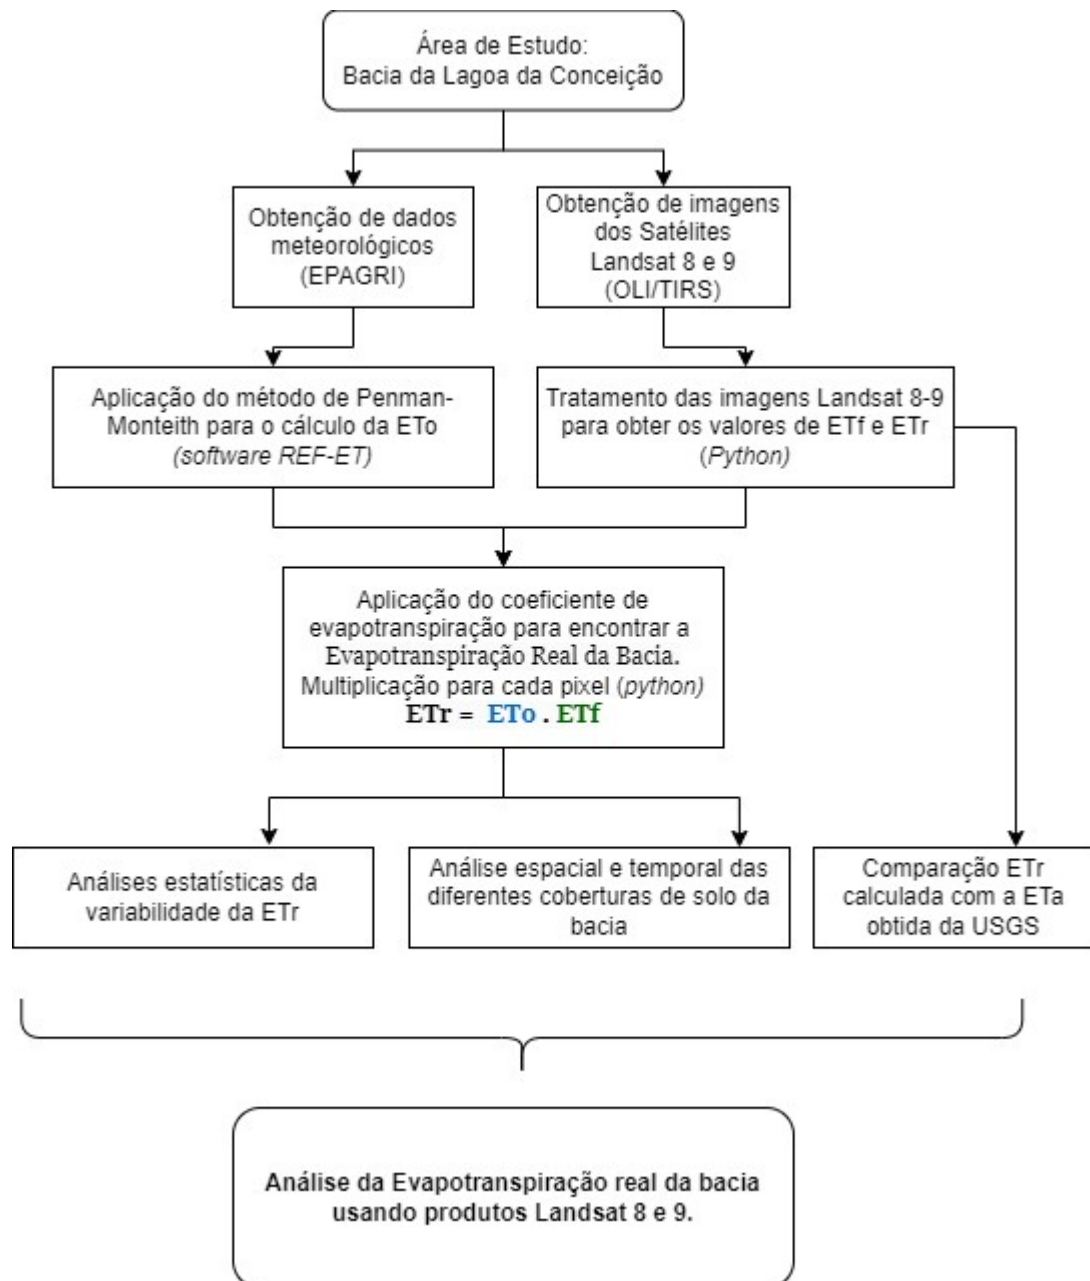
regiões costeiras da ilha a partir dos anos 1980, levando à transformação de regiões antes consideradas agrícolas e rurais. A ocupação urbana teve um aumento de 45,47% entre os anos de 1985 e 2020, com uma predominância de áreas urbanizadas sobre áreas de agricultura e pastagem nos anos 2000 (LIMA, 2022).

Ademais, Lima (2022) constata que o processo de urbanização de Florianópolis entre os anos 2000 e 2020, houve um aumento do gabarito das residências, que passaram a abrigar uma maior densidade populacional, e a criação e efetivação de novas Unidades de Conservação, assim como o aumento da fiscalização legislativa em áreas de preservação. A formação florestal foi o único ecossistema que apresentou um aumento de 4,24%, graças às Unidades de Conservação criadas. As áreas de restingas, praias e dunas apresentaram a maior redução, de 16,10%, devido ao aumento da ocupação urbana. Houve, também, uma expansão significativa da silvicultura, com um aumento percentual de 7871,95%, principalmente com o plantio de espécies exóticas, como o pinus e o eucalipto.

5 MATERIAIS E MÉTODOS

O fluxograma da metodologia aplicada para o desenvolvimento do presente Trabalho de Conclusão de Curso encontra-se na Figura 10.

Figura 10 - Fluxograma metodológico



Fonte: A autora.

O cálculo da evapotranspiração real de uma bacia através do uso de imagens de satélite pode ser um processo complexo e que requer várias etapas. No atual estudo, escolheu-

se imagens do satélite Landsat 8 e 9 devido a sua ampla gama de bandas espectrais, que permitem a detecção e análise de diferentes tipos de cobertura do solo e vegetação, resolução espacial adequada para a zona de estudo, disponibilidade de série histórica de dados compatível ao desejado e acesso gratuito. Para o cálculo da evapotranspiração de referência (ET_o) utilizou-se os dados fornecidos pela estação da Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina (EPAGRI), localizada no Itacorubi (-27,580°; -48,507°) em escala horária.

Nos tópicos a seguir, serão descritos em maiores detalhes a respeito dos dados meteorológicos e espaciais obtidos. Bem como a metodologia adotada para os cálculos da evapotranspiração potencial e real para a bacia e suas respectivas análises.

5.1 DADOS METEOROLÓGICOS

Foram utilizados dados climatológicos da estação meteorológica da Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina (EPAGRI): Florianópolis - Cetre/Epagri (1006), localizada a cerca de 3,15 km de distância da bacia hidrográfica da Lagoa da Conceição. Os dados históricos das estações foram solicitados diretamente à EPAGRI. Para as análises de evapotranspiração foram utilizados dados de 01/01/2017 00:00 a 20/03/2023 23:00. Na Tabela 1 é possível observar as especificações da estação.

Tabela 1 - Características das estações meteorológicas nº1006 da EPAGRI em Florianópolis.

Estação	Latitude	Longitude	Altitude (m)	Período de dados	Tipo	Dados
1006 - Florianópolis - Cetre/EPAGRI	-27.5814	-48.5072	5	07/05/2001 - 20/03/2023	Telemétrica	Diários e Horários

Fonte: A autora.

As estações meteorológicas da EPAGRI levam em consideração as normas da OMM (Organização Meteorológica Mundial) e INMET (Instituto Nacional de Meteorologia). A medição da temperatura é feita de maneira instantânea a cada hora civil, para o valor médio da hora são feitas leituras a cada 16 segundos e depois é calculada a média. Já a velocidade do vento é tomada a cada segundo, e então, efetuado os valores derivados. A média da hora é feita com a soma dos valores da hora e divididos pelo número de “observações”. Além do valor médio da hora, é gravado, também, a velocidade máxima da hora. Para a radiação solar,

é feita uma leitura da radiação solar global incidente (W/m^2) a cada 16 segundos, e no final do dia civil, é feita a soma de todos os valores médios das horas e divididos por 24. Salienta-se que os intervalos de tempo são relativos ao tempo de resposta de cada um dos sensores.

No processo de formatação dos dados climatológicos para a inserção no software REF-ET, nos casos de medições inválidas da estação meteorológica, utilizou-se a média mensal horária para cada hora anterior para o preenchimento dos dados faltantes. Por exemplo, no caso da radiação solar, calculou-se a média para cada hora específica com os dados disponíveis do mesmo mês. Já para os valores faltantes de umidade relativa, utilizou-se as temperaturas médias, mínimas e máximas e a pressão atmosférica para cálculo da mesma.


5.2 DADOS DE SENSORIAMENTO REMOTO

Realizou-se a aquisição dos dados para o sensoriamento remoto a partir da plataforma do *Earth Explorer*, dos satélites Landsat 8 e 9, que são duas das mais recentes adições à série Landsat, operados pela NASA. O Landsat 8, lançado em 2013, e o Landsat 9, lançado em 2021, são equipados com dois sensores principais:

- O sensor óptico OLI (*Operational Land Imager*), o qual é composto por nove bandas espectrais, permitindo uma visão detalhada da superfície terrestre;
- O sensor térmico TIRS (*Thermal Infrared Sensor*), projetado para capturar dados de radiação térmica emitida pela superfície terrestre, é composto por duas bandas espectrais.

Em conjunto, os sensores OLI/TIRS fornecem uma ampla gama de informações que permitem a análise de recursos naturais, mudanças ambientais entre outras funcionalidades. Na Figura 11, fornecida pela NASA, é possível ver a evolução da passagem de bandas espectrais que cada satélite Landsat (1 a 9) consegue capturar e seus respectivos sensores. As bandas são expressas em termos de Transmissão Atmosférica (%) por comprimento de onda (m).

Figura 11 - Bandas espectrais para todos os sensores Landsat



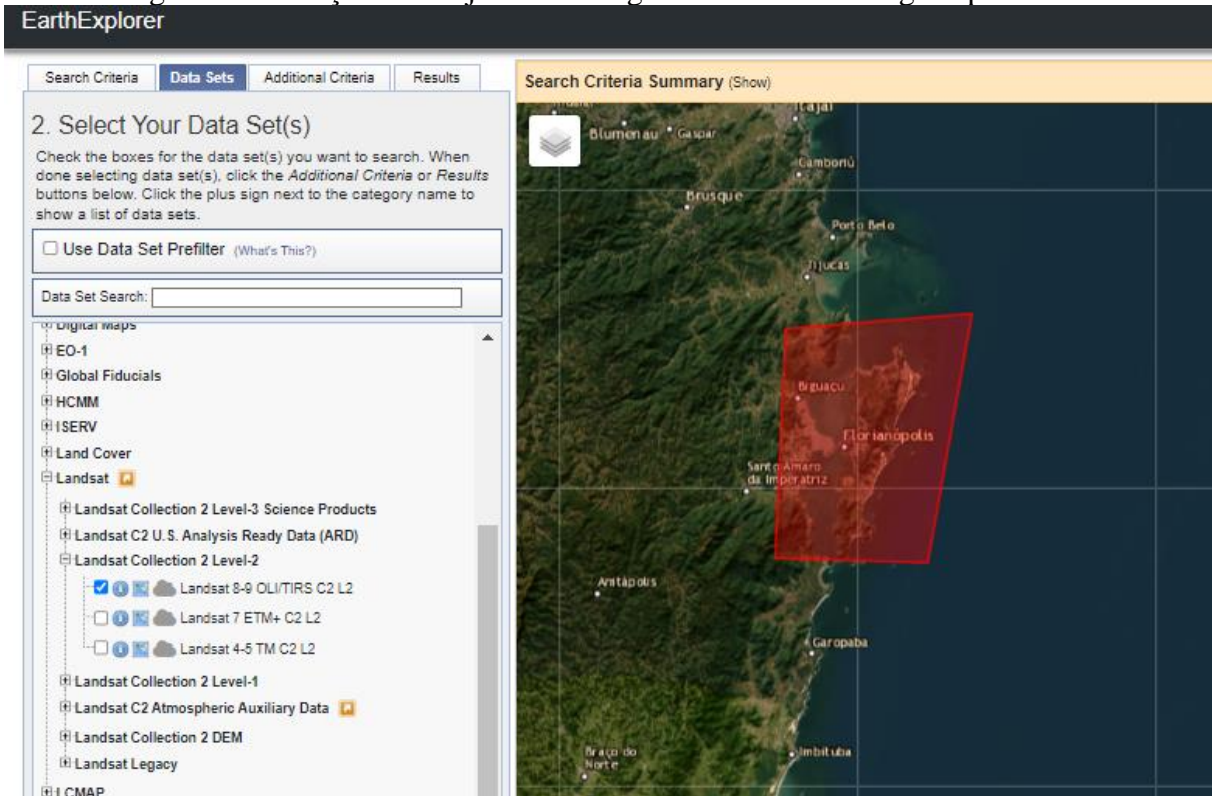
Fonte:USGS, Landsat Missions (2017)

A partir do *Earth Explorer*, selecionou-se uma área de polígono que englobava toda a bacia da Lagoa da Conceição, para um período entre novembro de 2016 a março de 2023 com cobertura de nuvens de até 45% a fim de obter-se um número de imagens significativo mas com menor obstrução nuvear. Devido a disponibilidade de imagens para a área de estudo escolhida e por conter itens com valores de evapotranspiração, optou-se pela Coleção 2, nível 2, da categoria Landsat 8-9 OLI/TIRS C2 L2, geradas com resolução espacial de 30 metros em uma grade de mapeamento Universal Transverse Mercator (UTM).

Dentre as 277 imagens capturadas pelo satélite Landsat-8 e Landsat-9 nesse período, baixadas em formato *raster*, apenas 157 imagens foram passíveis de serem utilizadas, em função da presença de nuvens sobre a bacia ou falhas nas imagens. Com elas, através de uma rotina em Python, selecionou-se aquelas com menor cobertura de nuvem, uma vez que nem todas as imagens estavam passíveis de serem utilizadas devido à qualidade das mesmas. Realizou-se uma série de refinamentos, em ambiente QGIS, através de composições de bandas espectrais RGB (Vermelho, Verde e Azul) e NIR (Infravermelho próximo), a fim de verificar o conteúdo baixado e, assim, obter imagens que pudessem quantificar a Evapotranspiração Real de forma mais precisa.

A Figura 12 apresenta a área de polígono e os parâmetros selecionados na plataforma do Earth Explorer para a aquisição das imagens.

Figura 12 - Seleção do conjunto de imagens Landsat 8-9 e alguns parâmetros



Fonte: USGS

Através do download do produto “*Landsat Collection 2 Provisional Actual Evapotranspiration Science Product*”, obteve-se as imagens de ETF (Fração da Evapotranspiração) com valores do coeficiente de evapotranspiração, e de Evapotranspiração Real (ETA) estimada pela própria NASA:

A Fração da Evapotranspiração (ETF) representa a fração adimensional do potencial de Evapotranspiração de referência de alfafa, variando nominalmente entre 0 e 1 (sendo 1 o valor máximo no modelo “*Surface Energy Balance with Optimization for Land*”- SSEBop). As imagens de ETF foram utilizadas em combinação com a ET de referência (ET_o) estimada através do método de Penman-Monteith para calcular uma ET real, levando em consideração as condições climáticas locais da bacia (USGS,2023).

As imagens de Evapotranspiração Real (ETA) fornecem uma estimativa, por pixel, da transferência diária de água da superfície da Terra para a atmosfera, medida em unidades de profundidade de água em milímetros (mm). Para a computação da ETA, de acordo com o guia da USGS (2023) é realizado através de uma parametrização melhorada do modelo de balanço de energia na superfície, chamado de SSEBop (USGS,2023).

5.3 EVAPOTRANSPIRAÇÃO DE REFERÊNCIA PELO MÉTODO DE PENMAN-MONTEITH

A evapotranspiração de referência (ET_o) da bacia da Lagoa da Conceição, para os períodos de janeiro de 2017 a março de 2023 foi calculada a partir dos dados da Estação meteorológica “1006-Florianópolis - Cetre/Epagri”, através do método de Penman-Monteith (Equação 10) e com uso do software de licença livre, REF-ET (ALLEN, 2016).

O programa REF-ET possui como objetivo principal fornecer cálculos padronizados para fins de comparação e detecção de erros e outros parâmetros micrometeorológicos e leitura de dados meteorológicos para uma vasta quantidade de arquivos, tipos de unidades de medidas e intervalos de tempo diferentes (UIDAHO, 2023). Assim, a ET_o foi estimada pelo método de Penman-Monteith da FAO, em escala diária e horária.

O cálculo foi feito baseado na seguinte fórmula:

$$ET_o = \frac{0,408 (Rn - G) + \gamma \frac{900T}{T+273} * u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0,34 u^2)} \quad (10)$$

Em que: ET_o é a Evapotranspiração de referência (mm.dia⁻¹) (ALLEN *et al.*, 1998); Rn é a Radiação líquida (MJ.m⁻².dia⁻¹); G é a Densidade do fluxo de calor no solo (MJ.m⁻².dia⁻¹); T a Temperatura média do ar (°C); u² é a Velocidade média do vento à 2 m do solo (m.s⁻¹); e_s é a Pressão do vapor de saturação (KPa); e_a é Pressão real de vapor (KPa); Δ é o Declive da curva da pressão do vapor (KPa.°C⁻¹); γ é a Constante Psicrométrica (KPa.°C⁻¹).

A equação de Penman-Monteith da FAO-56 (1998) incorpora uma altura fixa de grama igual a 0,12 m, utiliza o valor fixo para o calor latente de vaporização λ = 2,45 MJ/kg, o que implica em uma altura de rugosidade específica e uma resistência superficial de 70 s.m⁻¹. Quando as alturas de medição do vento, temperatura e umidade são presumidas como estando a 2 m acima de uma relva de 0,12 m de altura, a resistência aerodinâmica, r_a, é calculada como r_a = 208/u₂, onde u₂ é a velocidade do vento em m/s. Para manter a consistência, o valor fixo de λ = 2,45 MJ/kg é usado para calcular a constante psicrométrica, γ. Devido à altura e resistências fixas, a equação FAO-PM é limitada ao cálculo da ET_o de referência para grama. Seguindo a FAO-56, o valor de r_s é fixado em 70 s.m⁻¹ para intervalos de tempo de 24 horas e horários (ALLEN *et al.*, 1998).

O método Penman-Monteith da FAO-56 e os parâmetros intermediários associados são calculados como apresentados na FAO-56 (exceto para uma menor resistência superficial de Allen et al. (2005) utilizados para cálculos horários). Como parâmetros de entrada no software considerou-se: Sensor de vento à 10 metros de altura; Sensores de radiação solar e temperatura à 2 metros de altura; Elevação da estação meteorológica à 5 metros, Latitude da estação igual a -27,59 graus decimais; altura de referência da alfafa igual a 0,5m e da grama igual a 0,12m.

Foram utilizados os seguintes dados da estação meteorológica:

- Tempo: dia, mês, ano e horas;
- Média da temperatura do ar (°C) - automática;
- Média da umidade relativa (%) - automática;
- Pressão atmosférica (kPa);
- Radiação Média (W/m²);
- Temperatura do ar máxima (°C) - automática;
- Temperatura do ar mínima (°C) - automática;
- Velocidade média do vento - automática (km/h).

A Figura 13 ilustra a etapa inicial da configuração do software para o cálculo da evapotranspiração de referência através do método da FAO-56.

Figura 13 - Parâmetros de entrada do software REF-ET

DataFile: dados_horarios_2017-2023.txt
DefinitionFile: def_30_4_23_horario.def

The anemometer height is: 2 meters (6.5) ft
The temperature/RH height is: 10 meters (32.8) ft
The weather station elevation is: 5 meters (16.4) ft
The weather station latitude is: -27.59 degrees (- for Southern)

(Parameters in the next two lines are Required only for Hourly or shorter time period data)

The weather station longitude is: 48.51 degrees** W (E or W**)
Center of time zone longitude is: degrees** W (E or W**) (Hint: 45 W)
- Eastern Time Zone = 75 deg.; Central = 90; Mountain = 105; Pacific = 120 deg.
(The time zone longitude must be in multiples of 15 degrees for North America) **Req. only for ~hourly data.

The weather site vegetation height : .12 m (0 if same as ref. or as ht. specified in the data file)
Initial Lines of the Data file to be skipped: 0 Code for missing data (e.g. -999) -999

Description of the station and data (No more than 1000 characters)

1006 Florianopolis

How "hourly" time stamps are defined**

Time represents time at the end of the period (most common and the default)
 Time represents time at the start of the period (uncommon)
 Time represents time at the center of the period (uncommon)

For "hourly" data in U.S.A., Daylight Savings Time is Observed in Data Set (check if true)**

Note: For daily time steps, REF-ET presumes that the data represent the period from midnight to midnight.
The "Hourly" data term applies to any timestep shorter than 24 hours.

The following Data are required only for FAO-24 Eqns.

The default Day/Night wind ratio is : 2 (2 if unknown*)
The green fetch on the Class A Pan : 1000 m (1000 if unknown*)

Back Cancel Exit Continue

Fonte: Adaptado de ALLEN (2016)

Os resultados do REF-ET, semelhantes aos exibidos na Figura 14, foram armazenados em um arquivo "OUT" em formato de planilha Excel. A tela de Saída segue um formato padrão, em que o "mês", "dia" e "ano" são impressos nas três primeiras colunas (e "Hora e Minuto" para horas ou intervalos de tempo mais curtos). As próximas cinco colunas são os parâmetros de dados meteorológicos padrão de temperatura máxima e mínima do ar, radiação solar, velocidade do vento e temperatura do ponto de orvalho.

Figura 14 - Saída dos dados de ETo calculados pelo REF-ET

Mo	Day	Yr	DoY	HrMn	Tmax C	Tmin C	Rs W/m2	Wind m/s	DewP C	ASCE StPM ETr mm/h	ASCE StPM ETo mm/h	FAO 56PM ETo mm/h	
1	1	2017	1	0	.38	23.47	101	27.43	1.21	.86	.50	.38	
1	1	2017	1	1	.39	23.27	101	27.64	.91	.86	.50	.38	
1	1	2017	1	2	.40	22.94	101	27.51	.58	.85	.49	.37	
1	1	2017	1	3	.40	23.16	101	26.91	.83	.85	.49	.37	
1	1	2017	1	4	.40	23.70	101	26.96	1.42	.86	.50	.38	
1	1	2017	1	5	.46	23.74	101	26.98	1.71	.86	.50	.38	
1	1	2017	1	6	14.18	23.91	101	26.98	1.77	1.25	.73	.55	
1	1	2017	1	7	160.1	26.7	101	26.88	4.39	44.5	43.1	109.4	
1	1	2017	1	8	336.9	28.2	101	24.09	7.16	1057.0	1019.6	2542.2	
1	1	2017	1	9	348.6	29.4	101	22.71	8.94	1214.6	1168.7	2887.7	
1	1	2017	1	10	643.9	31.0	101	21.77	11.03	12595.4	12077.4	29485.6	
1	1	2017	1	11	881.0	32.0	101	19.22	12.60	33426.6	31829.8	75874.9	
1	1	2017	1	12	938.5	32.8	101	18.79	13.66	39906.1	37947.7	90041.3	
1	1	2017	1	13	955.8	33.7	101	18.30	15.05	41904.2	39801.3	94072.1	

Fonte: Elaboração da autora.

A temperatura máxima e mínima do ar representa o intervalo de tempo específico, seja um mês, dia ou hora. No caso de dados horários em que apenas a temperatura horária média do ar é inserida, a T_{máx} e as variáveis T_{mín} serão definidas para o valor médio por hora. As unidades variam de acordo com o inglês ou SI unidades e o passo de tempo. O restante das colunas na tela de saída e no arquivo são os métodos ETo de referência selecionados, neste caso FAO-56 PM. As unidades foram expressas em milímetros (mm): por dia, para os intervalos de tempo diários; e por hora; para intervalos de tempo de hora em hora.

5.4 ESTIMATIVA DA EVAPOTRANSPIRAÇÃO REAL:

Para o cálculo da evapotranspiração real da bacia realizou-se o processamento e a análise de imagens através de algoritmos criados em ambiente *Spyder* com linguagem Python. Ao todo, foram utilizadas 66 imagens de ETF para o cálculo da Evapotranspiração Real da bacia e 66 de ETA para a comparação com ET Real calculada, todas em formato *raster*. Do total das 132 imagens de ETF e ETA utilizadas, cerca de 88% foram capturadas pelo Landsat 8 e apenas 12% pelo Landsat 9. A Tabela 2 expõe a quantidade de imagens utilizadas para cada o mês de janeiro de 2017 a março de 2023.

Tabela 2 - Número de imagens de ETF Landsat 8 e 9 trabalhadas por período
ANO jan fev mar abr mai jun jul ago set out nov dez

ANO	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
2017			1	2	1		2	1				
2018				2			1	1	2			2
2019	1			2	2		2			1		1
2020			2	3	1	1		2				1
2021		2	2		3		2			1		
2022	2	2	1	1	3	2	1	2	1	1	1	2
2023	1	1	1									
Nº total de imagens Landsat 8 e 9 utilizadas												66

Fonte: A autora.

O objetivo de utilizar a rotina em Python neste estudo foi para melhorar a distribuição espacial de dados meteorológicos utilizados como inputs para o modelo, aumentar a capacidade e quantidade de análises feitas para cada intervalo de tempo.

Realizou-se o tratamento das informações, com uso de bibliotecas virtuais Python adequadas para trabalhar as imagens raster (“*rasterio*”), manipular os dados geoespaciais (“*geopandas*”), realizar operações numéricas (“*numpy*”), visualizar dados (“*matplotlib*”) e trabalhar arquivos e diretórios (“*os, glob*”).

Listou-se as imagens ETF do Landsat 8 e 9 e realizou-se a contagem de pixels de cada, a fim de extrair os valores discrepantes (*outliers*) e obter resultados mais precisos. Realizou-se uma interpolação com os valores do Coeficiente de Evapotranspiração para multiplicá-los por cada valor de ET de Referência para cada dia entre 2017 a 2023, calculados pelo REF-ET. O seguinte cálculo foi realizado (Equação 11):

$$ETR (mm. dia^{-1}) = (ETF \div 10.000) * ETo (mm. dia^{-1}) \quad (11)$$

Nota-se que os valores dos pixels nas imagens do Landsat 8 e 9 são representados como números inteiros de 16 bits, variando de 0 a 65,535. No entanto, esses valores não correspondem diretamente às grandezas físicas da fração de evapotranspiração, por isso que para converter os valores dos pixels em unidades adequadas, foi necessário ajustar as escalas dos dados dividindo-os por 10.000, pois as imagens são fornecidas com um fator de escala de 0,0001. Após, multiplicou-se a ETF pela ET de Referência, calculada anteriormente pelo

método da FAO-56 (ALLEN, 2016), em mm.dia^{-1} , para obter o valor da Evapotranspiração Real (ETR) em mm.dia^{-1} para cada pixel.

Após, somou-se os valores de ETr diária, obtendo-se valores de evapotranspiração real em escala mensal. Com os valores calculados de ET Real para cada pixel das imagens de satélite, pôde-se obter a média, mediana, desvio padrão e outras estatísticas.

5.5 RELAÇÃO ENTRE A EVAPOTRANSPIRAÇÃO REAL POR USO E OCUPAÇÃO DO SOLO

Uma vez que a ET Real foi estimada para cada pixel (mm.mês^{-1}), comparou-se os valores com as variáveis biofísicas do mapa de uso do solo. Com uso de um *shapefile*, criado em ambiente QGIS, com polígonos de classificações amostrais para representar os principais usos e coberturas do solo da bacia da Lagoa da Conceição, computou-se os valores de ETr para cada classe, são elas:

- DUN: Dunas;
- FOR: Floresta, vegetação mais densa;
- HER: Vegetação rasteira, como campos, restinga e herbáceas;
- AGU: Região das lagoas da bacia da Lagoa da Conceição;
- URB: Área Urbana.

A variação da ET Real de acordo com cada uma das 5 classes de uso e cobertura do solo foi analisada a partir de gráficos e tabelas. A Figura 15 apresenta um trecho do código utilizado para criação das classes de solo a partir de cada coluna da camada vetorial de amostras de solo para poder classificar os pixels das imagens Landsat.

Figura 15 - Criação das classes de uso do solo a partir de arquivo *shapefile*

```
gdf2 = gpd.read_file('C:/tcc/GIS\Collection2/IC_4/shapefiles/samples_classes2.shp')
gdf_dun = gdf2[gdf2['classes'].isin(['DUN'])]
gdf_urb = gdf2[gdf2['classes'].isin(['URB'])]
gdf_for = gdf2[gdf2['classes'].isin(['FOR'])]
gdf_her = gdf2[gdf2['classes'].isin(['HER'])]
gdf_agu = gdf2[gdf2['classes'].isin(['REN', 'LBA', 'LCD', 'LCS'])]

df_medias = pd.DataFrame(columns=['DIA', 'MES', 'ANO', 'DUN', 'URB', 'FOR', 'HER', 'AGU'])
```

Fonte: A autora.

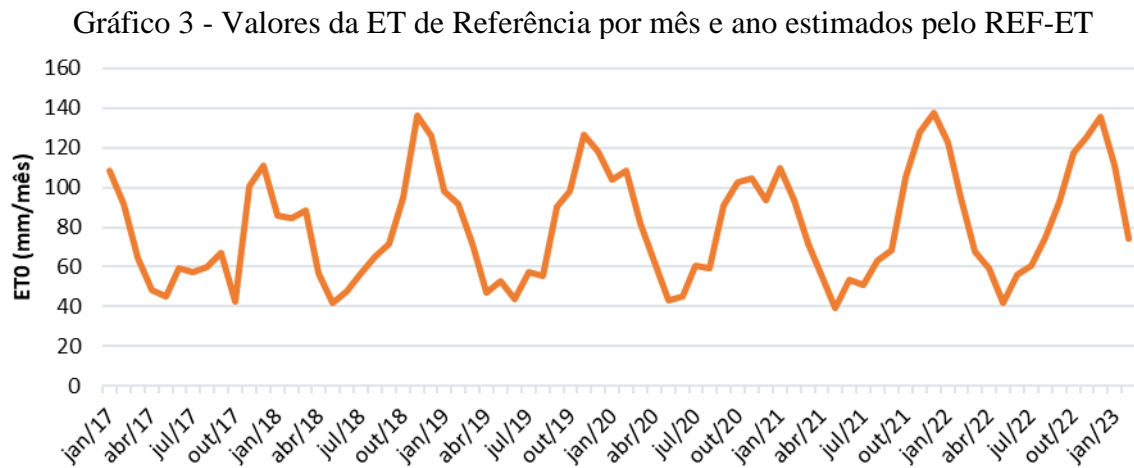
De forma semelhante, processou-se também o produto de Evapotranspiração real (ETA) dos satélites Landsat 8 e 9, para fins de comparação com a ETr calculada ao final do

estudo. Para estes produtos da NASA foi também efetuado a normalização das imagens dividindo-as por 10000, e calculados suas medidas estatísticas.

6 RESULTADOS E DISCUSSÃO

6.1 COMPARAÇÃO ENTRE DADOS METEOROLÓGICOS DIÁRIOS E HORÁRIOS PARA ET DE REFERÊNCIA

Com auxílio do software REF-ET foi possível calcular a evapotranspiração de referência (ET_o) para a bacia da Lagoa da Conceição. A partir dos dados meteorológicos horários da estação da EPAGRI obteve-se ET_o horárias, em que pela soma dessas a cada 24h pôde-se obter a ET_o diária para os períodos de 2017 a 2023. Calculou-se também a evapotranspiração diária a partir de dados meteorológicos de entrada diários. Nota-se que houve um longo período entre agosto de 2017 a novembro de 2021 em que devido a ausência de dados, a ET_o para os dados diários não pode ser computada. No Gráfico 3 é possível observar o descrito.



A partir dos resultados da Evapotranspiração de Referência (ET_o) total mensal, comparou-se os dois tipos de dados fornecidos pela estação meteorológica (diários e horários), para os períodos com a mesma quantidade de dados, isto é, meses que possuíam dias de medições completos. Sendo assim, calculou-se a diferença absoluta e a diferença relativa entre ambos.

A diferença absoluta mede a discrepância numérica entre os dois valores de ET_o, sem considerar sua magnitude ou escala. Ela foi calculada subtraindo-se o valor de ET_o de

origem dos dados horários dos de origem diária e tomando o valor absoluto do resultado para garantir um resultado positivo, expressa em milímetros por mês (mm.mês^{-1}).

Já a diferença relativa (%) relaciona a diferença entre os valores de ETo à magnitude do valor de referência, neste caso, os dados horários. Ela foi calculada dividindo-se a diferença absoluta pelo valor de referência e multiplicando por 100 para obter a porcentagem. Assim, é possível compreender a discrepância proporcional entre os valores obtidos dos dados diários e dos dados horários da estação. A Tabela 3 apresenta as comparações feitas.

Tabela 3 - Diferença absoluta e relativa entre os valores de ET de referência gerados no REF-ET com inputs de dados diários e dados horários para os anos de 2017 e 2023.

Mês/Ano	ET de Referência (mm/mês)		Diferença	
	Dados Diários	Dados Horários	Absoluta (mm)	Relativa (%)
jan/2017	124,25	126,46	2,21	1,74%
fev/2017	98,91	108,48	9,57	8,82%
mar/2017	90,33	91,5	1,17	1,27%
abr/2017	63,6	64,51	0,91	1,41%
mai/2017	46,48	48,53	2,05	4,22%
jun/2017	40,62	45,22	4,6	10,1%
jul/2017	52	59,46	7,46	12,5%
ago/2017	40,56	57,26	16,7	29,1%
fev/2018	75,62	86,05	10,43	12,1%
mar/2018	96,98	84,62	12,36	14,6%
abr/2018	91,63	88,64	2,99	3,37%
mai/2018	44,85	56,72	11,87	20,9%
nov/2021	91,6	105,5	13,9	13,1%
dez/2021	132,7	127,84	4,86	3,80%
jan/2022	143,38	137,37	6,01	4,37%
fev/2022	125,57	122,73	2,84	2,31%
mar/2022	98,28	94,64	3,64	3,84%
abr/2022	66,95	67,71	0,76	1,12%
mai/2022	53,89	59,57	5,68	9,53%
jun/2022	37,47	41,84	4,37	10,4%
jul/2022	52	56,18	4,18	7,44%
ago/2022	58,69	60,36	1,67	2,76%

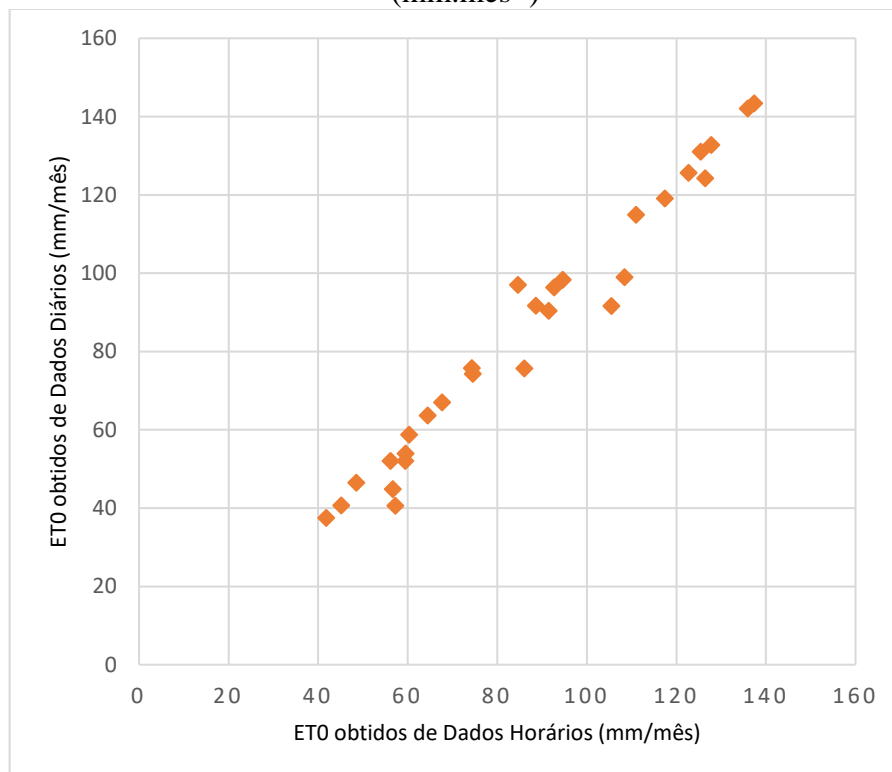
set/2022	74,27	74,57	0,3	0,40%
out/2022	96,33	92,74	3,59	3,87%
nov/2022	119,04	117,46	1,58	1,34%
dez/2022	131,03	125,45	5,58	4,44%
jan/2023	142,06	136	6,06	4,45%
fev/2023	114,85	111,04	3,81	3,43%
mar/2023	75,72	74,38	1,34	1,80%

Fonte: A autora.

Ao utilizar os dois métodos de comparação, percebe-se que não houve uma diferença maior que 29,10% entre ambas as fontes de dados. A máxima estimada foi no mês de agosto de 2017, com 16,70 mm de diferença entre as duas escalas de dados. Sendo assim, pode-se afirmar que tanto a fonte de dados diários quanto de dados horários, produzirão resultados em termos de Evapotranspiração de Referência próximos e pouco divergentes.

São apresentados no Gráfico 4 os resultados da ET de Referência gerados com base nos dados diários e horários da estação da EPAGRI. Ao observá-lo, averigua-se que os pontos tendem a uma progressão linear, indicando uma boa correlação entre si.

Gráfico 4 - ETo mensal obtida com dados diários x ETo mensal obtida com dados horários (mm.mês⁻¹)



Fonte: A autora.

Ademais, pode-se inferir que os dados horários possuem valores “mais refinados” em relação aos dados diários, tal fato pode ser explicado devido às medições dos parâmetros em menores intervalos de tempo. O que confere maior acurácia em relação ao outro tipo, uma vez que em dados diários, pode descartar semanas de informações armazenadas devido a falhas técnicas nos leitores, enquanto para armazenamentos em menores intervalos de tempo, na incompletude de alguma medição, outros parâmetros guardados poderão ser utilizados para mensurar a falta destes.

6.2 EVAPOTRANSPIRAÇÃO REAL MENSAL ESTIMADA

Computando a evapotranspiração de referência (ET_o), obtida pelo método de Penman-Monteith, multiplicada pelo coeficiente de evapotranspiração (ETF), fornecido pelas imagens Landsat 8 e 9, obteve-se o valor de Evapotranspiração Real (ETR) para cada uso e ocupação do solo da bacia, para o período de março de 2017 a março de 2023. A Tabela 4 apresenta os resultados da ET Real mensal para cada uso e cobertura do solo.

Tabela 4 - Evapotranspiração real mensal (mm.mês⁻¹) para cada tipo de uso e ocupação do solo da bacia.

Período	Evapotranspiração Real Mensal (mm/mês)				
	Dunas	Urbano	Florestas	Gramíneas	Lagoa
mar/17	27,60	22,79	64,50	26,20	70,98
abr/17	39,98	28,94	49,37	30,03	49,29
mai/17	29,14	25,60	40,92	23,67	44,23
jun/17	25,71	22,50	34,37	19,25	35,71
jul/17	35,96	31,39	41,74	27,74	52,82
ago/17	33,89	26,93	41,72	22,46	54,19
set/17	33,99	26,52	45,17	23,30	55,98
out/17	36,63	29,70	52,02	27,91	62,92
nov/17	22,34	18,81	33,79	18,74	39,98
dez/17	51,32	45,00	83,00	47,55	96,00
jan/18	54,05	49,50	93,69	55,33	105,98
fev/18	40,37	38,50	74,50	45,11	82,67

Período	Evapotranspiração Real Mensal (mm/mês)				
	Dunas	Urbano	Florestas	Gramíneas	Lagoa
mar/18	38,03	37,92	75,12	46,63	81,71
abr/18	38,17	40,24	81,67	49,59	86,26
mai/18	27,91	28,30	51,53	30,85	54,75
jun/18	25,25	22,38	36,06	22,51	39,63
jul/18	32,00	26,20	39,77	25,60	44,92
ago/18	29,86	28,98	49,96	28,98	55,96
set/18	25,66	26,98	57,10	26,70	64,19
out/18	26,10	25,56	65,12	27,32	71,58
nov/18	33,61	30,16	87,31	36,21	95,13
dez/18	54,86	45,99	125,91	58,21	134,63
jan/19	68,04	57,23	117,12	68,27	121,17
fev/19	49,40	40,22	83,88	48,03	88,02
mar/19	31,20	25,05	66,17	28,88	73,56
abr/19	28,67	26,73	56,64	25,65	63,00
mai/19	28,08	26,23	40,53	25,25	44,17
jun/19	43,77	36,81	49,19	37,69	49,86
jul/19	32,36	27,64	34,67	25,76	39,78
ago/19	26,90	21,61	39,96	18,94	57,43
set/19	26,57	19,70	44,68	18,22	55,29
out/19	46,44	31,95	80,36	32,32	90,28
nov/19	57,13	37,23	89,58	46,09	98,05
dez/19	72,49	49,60	115,90	61,24	124,83
jan/20	51,10	43,92	104,40	53,25	111,57
fev/20	29,45	36,32	88,50	43,95	93,81
mar/20	30,80	37,00	86,97	42,35	96,86
abr/20	30,77	29,89	66,62	24,16	74,01
mai/20	36,66	30,44	44,21	23,87	62,27
jun/20	28,17	24,48	28,99	17,83	40,87
jul/20	29,18	24,45	32,97	19,50	43,85
ago/20	31,10	28,50	50,21	21,54	60,38
set/20	27,39	25,70	51,09	21,54	58,72

Período	Evapotranspiração Real Mensal (mm/mês)				
	Dunas	Urbano	Florestas	Gramíneas	Lagoa
out/20	41,18	37,94	80,11	36,48	89,93
nov/20	45,72	41,32	92,67	45,14	101,70
dez/20	44,55	40,59	94,94	49,26	102,36
jan/21	36,01	36,14	82,94	45,45	89,03
fev/21	34,74	38,55	87,06	54,34	89,59
mar/21	58,78	46,37	81,15	55,62	81,10
abr/21	45,33	36,33	63,78	38,65	66,50
mai/21	34,02	28,78	47,87	30,36	50,94
jun/21	23,20	17,66	27,34	15,09	33,10
jul/21	36,74	27,57	38,81	24,65	37,61
ago/21	37,39	27,70	41,92	24,14	30,61
set/21	37,61	28,41	53,82	28,60	49,08
out/21	31,61	24,41	60,61	29,91	65,64
nov/21	52,34	36,77	94,66	48,61	102,39
dez/21	73,15	47,15	115,72	62,78	119,25
jan/22	60,44	51,65	125,12	57,99	130,02
fev/22	40,40	44,29	108,94	45,55	117,75
mar/22	39,00	38,24	78,87	44,85	93,76
abr/22	29,08	30,13	55,75	34,69	66,33
mai/22	35,94	29,82	47,10	29,51	52,37
jun/22	27,30	21,57	30,84	19,01	36,48
jul/22	39,60	31,38	45,40	27,94	41,83
ago/22	28,81	27,05	51,74	23,89	58,61
set/22	25,49	26,22	63,46	22,39	74,21
out/22	29,67	28,02	81,25	34,23	92,52
nov/22	39,50	37,59	107,41	39,93	111,21
dez/22	49,20	41,64	114,65	49,37	120,16
jan/23	59,27	53,95	125,49	67,43	135,20
fev/23	37,94	36,62	105,95	47,33	108,93
mar/23	13,75	20,26	66,65	29,00	71,03

Fonte: A autora.

Os meses de janeiro e dezembro apresentaram as maiores taxas de ETR para todas as 5 classes definidas, sendo a máxima registrada para a classe de Lagoa com 135,20 mm.mês⁻¹ em janeiro de 2022 ¹. Enquanto as menores taxas registradas foram durante o período de inverno, entre junho a julho, com exceção da classe de Dunas e Lagoa, que tiveram mínimas em março e agosto, sendo a mínima registrada em março de 2023 para a classe de Dunas, com cerca de 13,75 mm.mês⁻¹. As médias obtidas para a classe de Dunas foi de 37,8 mm.mês⁻¹; para Urbano de 32,8 mm.mês⁻¹; para Florestas de 68,1 mm.mês⁻¹; Gramíneas de 35,4mm.mês⁻¹ e para a Lagoa de 74,6 mm.mês⁻¹. A Tabela 5 sintetiza os resultados estimados.

Tabela 5 - Valores máximos, mínimos e média calculados para a ET real em mm.dia⁻¹ por classe.

Classes	ET de Referência (mm/mês)				
	Data	ETR Mín	Data	ETR Máx	ETR Méd
Dunas	mar/23	13,75	dez/21	73,2	37,8
Urbano	jun/21	17,66	jan/19	57,2	32,8
Florestas	jun/21	27,34	dez/18	125,9	68,1
Gramíneas	jun/21	15,09	jan/19	68,3	35,4
Lagoa	ago/21	30,61	jan/23	135,2	74,6


Fonte: A autora.

Ademais, observa-se algumas incoerências para os valores de ETR na classe de Dunas um pouco maiores que a classe de Gramíneas, sendo que o esperado era que a ETR fosse maior na seguinte ordem: Lagoa, Florestas, Gramíneas, Urbano e Dunas. Esperava-se que as classes de Dunas e a região Urbana apresentassem os menores valores sempre, devido à menor quantidade de cobertura vegetal e baixos reservatórios de água superficial. É possível que, mesmo após a preparação dos dados, alguns *outliers* tenham permanecido, ou que durante algumas épocas de chuva intensa houve a deposição e formação de pequenas “lagoas sazonais” na região de dunas, ou ainda, que a densidade da vegetação de restingas possam ter contribuído para a taxa de transpiração elevada nessas áreas.

As zonas das Lagoas e das Florestas são responsáveis pela maior parte da evapotranspiração da bacia, efetivamente em virtude à evaporação das águas e à transpiração das árvores. A média anual registrada para a Lagoa e Floresta foram, respectivamente, 778,1 mm.ano⁻¹ e 709,9 mm.ano⁻¹. Já a média de Gramíneas foi de 369,5 mm.ano⁻¹ em contraste à média das Dunas de 397,7 mm.ano⁻¹, o que é inesperado e pode indicar parâmetros de entrada falhos, como valores de ETF inadequados, ou por situar-se em zonas dentro do meio urbano. Já a média das manchas Urbanas foi de 342 mm.ano⁻¹, a menor dentre todas as outras classes,

uma provável causa é a impermeabilização dos solos e a menor densidade vegetal nestas regiões. O Gráfico 5 ilustra os resultados da ETR mensal para cada uso e cobertura do solo.

Gráfico 5 - Evapotranspiração real por classe de solo para os períodos de 2017 a 2023.



Fonte: A autora.

É válido salientar que as baixas taxas de evapotranspiração nas classes de dunas e urbano indicam que estes componentes podem impactar na disponibilidade de recursos hídricos na bacia.

Nota-se uma relação entre a taxa de evapotranspiração com a precipitação da região, sendo que ambas apresentam máximas durante os meses de verão e mínimas nos meses de inverno. Contudo, segundo registros meteorológicos, no primeiro semestre de 2021 houve uma baixa na média de precipitação, mas o mesmo não ocorreu para a ET, esta foi menos impactada pelo período de seca. É possível que ambas estejam relacionadas as variações de temperatura.

Estimou-se, também, dados da soma das ET diárias, resultando na ET Mensal (mm.mês⁻¹), a média diária, o desvio padrão, a máxima e a mínima diárias para cada superfície classificada da bacia, os resultados detalhados estão dispostos no APENDICE A

para posterior consulta. Nas Tabela 6, Tabela 7, Tabela 8, Tabela 9 e Tabela 10 estão listados uma parte das análises estatísticas realizadas para cada classe, tendo como período amostral o ano de 2020, em que não houve eventos extremos de precipitação, nem de secas prolongadas.

Tabela 6- Resultados da Evapotranspiração Real para a classe Dunas

Período	ETR Mensal (mm/mês)	Média diária da ETR (mm/dia)	DesvPad da ETR (mm/dia)	ETR Máxima (mm/dia)	ETR Mínima (mm/dia)
jan/20	51,10	1,65	0,58	2,55	0,38
fev/20	29,45	1,02	0,41	1,71	0,23
mar/20	30,80	0,99	0,39	1,88	0,45
abr/20	30,77	1,03	0,29	1,77	0,39
mai/20	36,66	1,18	0,35	1,69	0,32
jun/20	28,17	0,94	0,43	1,60	0,19
jul/20	29,18	0,94	0,43	1,58	0,14
ago/20	31,10	1,00	0,48	1,58	0,12
set/20	27,39	0,91	0,51	1,89	0,13
out/20	41,18	1,33	0,61	2,24	0,13
nov/20	45,72	1,52	0,52	2,34	0,40
dez/20	44,55	1,44	0,65	2,56	0,37

Fonte: A autora.

Tabela 7 - Resultados da Evapotranspiração Real para a classe Lagoa

Período	ETR Mensal (mm/mês)	Média diária da ETR (mm/dia)	DesvPad da ETR (mm/dia)	ETR Máxima (mm/dia)	ETR Mínima (mm/dia)
jan/20	111,57	3,60	1,24	5,27	0,88
fev/20	93,81	3,23	1,25	4,66	0,69
mar/20	96,86	3,12	0,85	4,26	1,10
abr/20	74,01	2,47	0,61	3,18	1,05
mai/20	62,27	2,01	0,57	2,67	0,51
jun/20	40,87	1,36	0,61	2,29	0,29
jul/20	43,85	1,41	0,64	2,40	0,21
ago/20	60,38	1,95	0,90	3,07	0,25

set/20	58,72	1,96	1,09	4,06	0,28
out/20	89,93	2,90	1,34	4,91	0,29
nov/20	101,70	3,39	1,16	5,23	0,89
dez/20	102,36	3,30	1,49	5,84	0,84

Fonte: A autora.

Tabela 8 - Resultados da Evapotranspiração Real para a classe Floresta

Período	ETR Mensal (mm/mês)	Média diária da ETR (mm/dia)	DesvPad da ETR (mm/dia)	ETR Máxima (mm/dia)	ETR Mínima (mm/dia)
jan/20	104,40	3,37	1,16	4,93	0,83
fev/20	88,50	3,05	1,18	4,39	0,65
mar/20	86,97	2,81	0,80	4,04	0,90
abr/20	66,62	2,22	0,56	3,11	1,01
mai/20	44,21	1,43	0,46	2,21	0,40
jun/20	28,99	0,97	0,44	1,66	0,20
jul/20	32,97	1,06	0,48	1,82	0,16
ago/20	50,21	1,62	0,75	2,63	0,21
set/20	51,09	1,70	0,95	3,56	0,24
out/20	80,11	2,58	1,19	4,41	0,25
nov/20	92,67	3,09	1,07	4,79	0,81
dez/20	94,94	3,06	1,38	5,42	0,78

Fonte: A autora.

Tabela 9 - Resultados da Evapotranspiração Real para a classe Gramíneas

Período	ETR Mensal (mm/mês)	Média diária da ETR (mm/dia)	DesvPad da ETR (mm/dia)	ETR Máxima (mm/dia)	ETR Mínima (mm/dia)
jan/20	53,25	1,72	0,59	2,52	0,42
fev/20	43,95	1,52	0,58	2,18	0,33
mar/20	42,35	1,37	0,41	1,96	0,49
abr/20	24,16	0,81	0,20	1,15	0,37
mai/20	23,87	0,77	0,24	1,15	0,21
jun/20	17,83	0,59	0,28	1,04	0,12

jul/20	19,50	0,63	0,28	1,07	0,09
ago/20	21,54	0,69	0,34	1,18	0,08
set/20	21,54	0,72	0,41	1,53	0,10
out/20	36,48	1,18	0,55	2,06	0,11
nov/20	45,14	1,50	0,53	2,38	0,39
dez/20	49,26	1,59	0,72	2,89	0,39

Fonte: A autora.

Tabela 10 - Resultados da Evapotranspiração Real para a classe Urbano

Período	ETR Mensal (mm/mês)	Média diária da ETR (mm/dia)	DesvPad da ETR (mm/dia)	ETR Máxima (mm/dia)	ETR Mínima (mm/dia)
jan/20	43,92	1,42	0,49	2,08	0,35
fev/20	36,32	1,25	0,48	1,80	0,27
mar/20	37,00	1,19	0,33	1,62	0,43
abr/20	29,89	1,00	0,25	1,32	0,39
mai/20	30,44	0,98	0,28	1,27	0,24
jun/20	24,48	0,82	0,37	1,38	0,18
jul/20	24,45	0,79	0,36	1,32	0,12
ago/20	28,50	0,92	0,43	1,38	0,11
set/20	25,70	0,86	0,47	1,76	0,12
out/20	37,94	1,22	0,56	2,05	0,12
nov/20	41,32	1,38	0,47	2,10	0,36
dez/20	40,59	1,31	0,59	2,34	0,33

Fonte: A autora.

As menores taxas de ET Real foram observadas para a classe de Dunas, com máxima estipulada de $2,56 \text{ mm.dia}^{-1}$, e a mínima de $0,12 \text{ mm.dia}^{-1}$, para Urbano com máxima de $2,34 \text{ mm.dia}^{-1}$ e mínima de $0,11 \text{ mm.dia}^{-1}$ e para Gramíneas com $2,89 \text{ mm.dia}^{-1}$ e $0,08 \text{ mm.dia}^{-1}$ para máxima e mínima, respectivamente. Já as maiores taxas encontram-se para as classes de Lagoas, com máxima de $5,84 \text{ mm.dia}^{-1}$ e mínima de $0,21 \text{ mm.dia}^{-1}$, e para Florestas, com máxima e mínima igual a $5,42 \text{ mm.dia}^{-1}$ e $0,16 \text{ mm.dia}^{-1}$.

Apesar dos valores aparentarem seguir uma função senoidal, como esperado, eles estão relativamente baixos, algumas hipóteses são consideradas para tal, como a necessidade

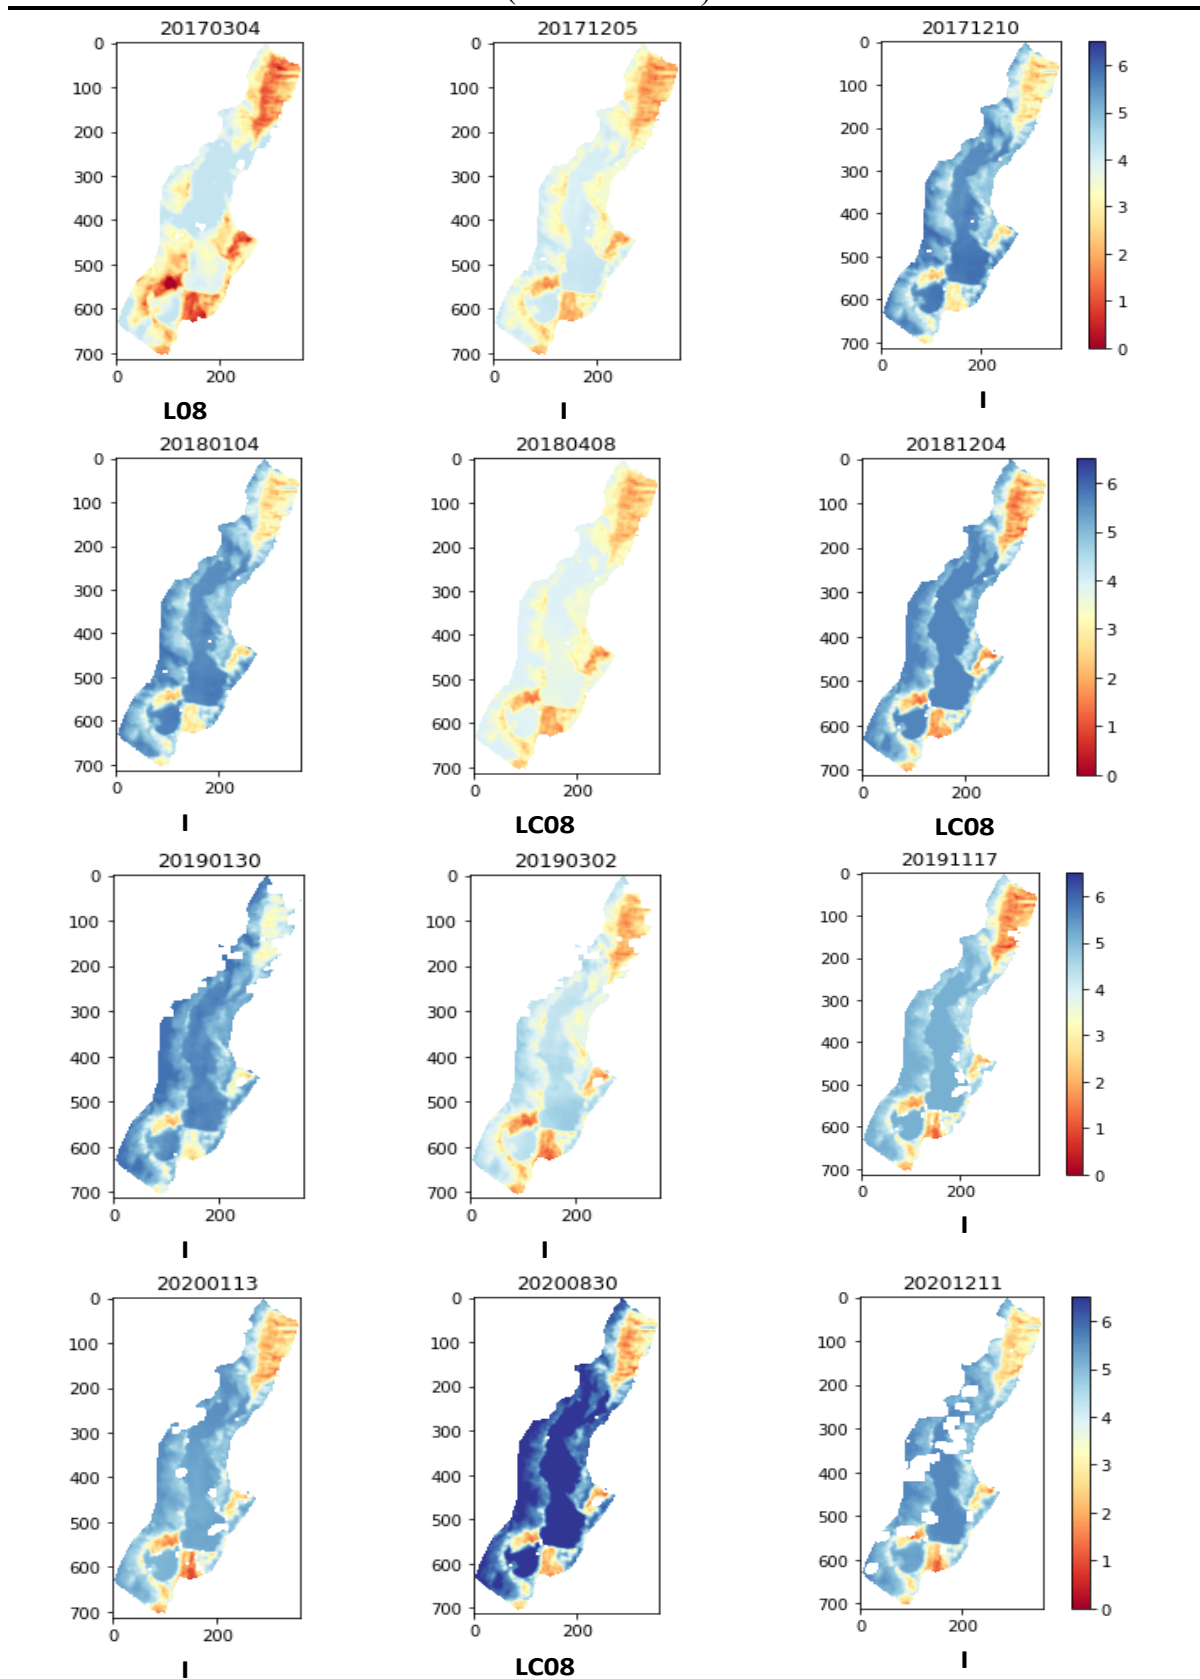
de aprimoramento dos produtos obtidos pela NASA de ET Fracional para a região de estudo ou a existência de valores extrapolados devido a falhas técnicas na medição.

Em especial, os valores da vegetação rasteira em relação às classes urbanas e de dunas foi um resultado inesperado. Uma teoria, além das já citadas anteriormente, é a de que devido a fisionomia radicular das gramíneas contribuem para maior retenção de água no solo e o protege da exposição solar direta, limitando as perdas por evaporação, enquanto solos arenosos e asfálticos possuem uma capacidade menor de retenção de calor em comparação com solos com maior teor de matéria orgânica, elevando a temperatura e ocasionando taxas de evapotranspiração mais rápidas (BERGAMASCHI, 1999). Igualmente, a superfície dos solos arenosos e asfálticos pode estar mais expostos ao vento, resultando em uma maior evaporação da água.

Por fim, através do algoritmo criado pôde-se plotar os valores de evapotranspiração real (mm.dia^{-1}) da bacia para os períodos escolhidos. Neste caso foram geradas 2.266 imagens ao total, para cada dia entre março de 2017 a março de 2023, dentre as quais muitas apresentaram valores subestimados. Ainda assim, na Figura 16 nota-se em coloração avermelhada valores menores de evapotranspiração nos locais de Dunas, localizadas ao sudeste da bacia, e de mancha urbana, como o bairro do Rio Vermelho, ao norte da bacia. Enquanto mais ao centro, está a localização do corpo hídrico da Lagoa da Conceição, apresentando as maiores taxas, seguido pelas zonas de morros que apresentam vegetações mais densas de árvores como a presença de zonas de APP e de florestas de Pinus.

Abaixo da amostra dos mapas estão indicados a origem de cada imagem, sendo: “I” para as imagens geradas por interpolação entre imagens reais, “LC08” originadas do satélite Landsat 8 e “LC09” para aquelas advindas do Landsat 9. Os números em cima de cada imagem representam a data dela, em ordem de ano, mês e dia (“aaa/mm/dd”).

Figura 16 - Mapas de distribuição da evapotranspiração real diária na bacia da Lagoa da Conceição, com números representativos de data da ET em ordem: ano, mês e dia (“aaaa/mm/dd”).



Fonte: A autora.

No estudo sobre a estimativa da evapotranspiração para a mesma bacia realizado por Da Silva (2014) através do método SEBAL (*Surface Energy Balance Algorithm for Land*) e imagens do satélite Landsat 5, os resultados obtidos pelo autor, apresentados no Quadro 5, avaliaram a evapotranspiração média mensal para cada cobertura de solo, também. O autor obteve médias mensais para classe de Floresta e Pinus igual a $106,5 \text{ mm.mês}^{-1}$; Dunas igual a $20,9 \text{ mm.mês}^{-1}$; Água igual a $109,6 \text{ mm.mês}^{-1}$ e Urbano $26,8 \text{ mm.mês}^{-1}$.

Comparando-se os valores obtidos pelo autor, em um outro período, de 2005 a 2009, percebe-se que os valores máximos de ET foram registrados, também, para os meses de verão entre dezembro e janeiro, e as mínimas durante o inverno, entre junho e julho. Pelas classes de uso e cobertura do solo do autor Da Silva (2014), seus valores em relação aos obtidos no presente aparentam certa semelhança, contudo ele obteve médias mensais maiores para as classes de Floresta e Lagoa, e menores em Dunas e Urbano, sendo a classe de Gramíneas apresentada.

Quadro 5 - Valores mensais de evapotranspiração da bacia da Lagoa da Conceição

Mês	Floresta	Dunas	Água	Urbano	Pinus	Bacia
	Evapotranspiração média mensal (mm/mês)					
Jan	164	4	180	45	152	142
Fev	133	9	148	38	124	117
Mar	144	45	154	42	135	125
Abr	109	75	113	15	98	90
Mai	82	62	87	12	69	66
Jun	64	11	70	16	53	53
Jul	68	12	73	18	58	56
Ago	77	12	85	22	64	65
Set	93	15	103	28	78	79
Out	118	2	134	25	104	99
Nov	141	1	163	27	126	120
Dez	159	3	175	34	144	134

Fonte: Da Silva (2014)

Os valores médios obtidos pelo autor em comparação as médias mensais no presente estudo apresentam-se na Tabela 11.

Tabela 11 - Comparação entre os valores de evapotranspiração mensal obtido por cada classe de estudo em comum às classes de Da Silva (2014)

Estudo	Evapotranspiração média mensal (mm/mês)				
	Floresta	Dunas	Lagoa	Urbano	Gramíneas
TCC atual	68,07	37,75	74,61	32,79	35,43
TCC de Da Silva (2014)	106,54	20,92	109,63	26,83	-

Fonte: A autora.

Para as classes que ocupam as maiores áreas da bacia, Floresta e Lagoa, os valores estimados por Da Silva (2014) tiveram valores maiores do que o do presente estudo, enquanto para as classes de Dunas e Urbano foi o contrário. Uma possível hipótese para tal ocorrência é a metodologia de classificação de solos distintas, ou devido à variação entre os períodos analisados. Ainda assim, os valores não apresentam grandes divergências entre si, ambos têm a Floresta e o corpo hídrico da lagoa como os maiores contribuintes da evapotranspiração da bacia.

6.3 COMPARAÇÃO ENTRE EVAPOTRANSPIRAÇÃO REAL ESTIMADA E OBTIDA

Com o produto de Evapotranspiração Real da NASA obtida pelos satélites Landsat 8 e 9, de maneira análoga a anterior, estimou-se valores da evapotranspiração por classe de solo. Assim, comparou-se a ET real calculada com a ET real obtida pela NASA para cada uma das 66 imagens Landsat através de suas diferenças absolutas e relativas. Os resultados para cada classe encontram-se no APENDICE C.

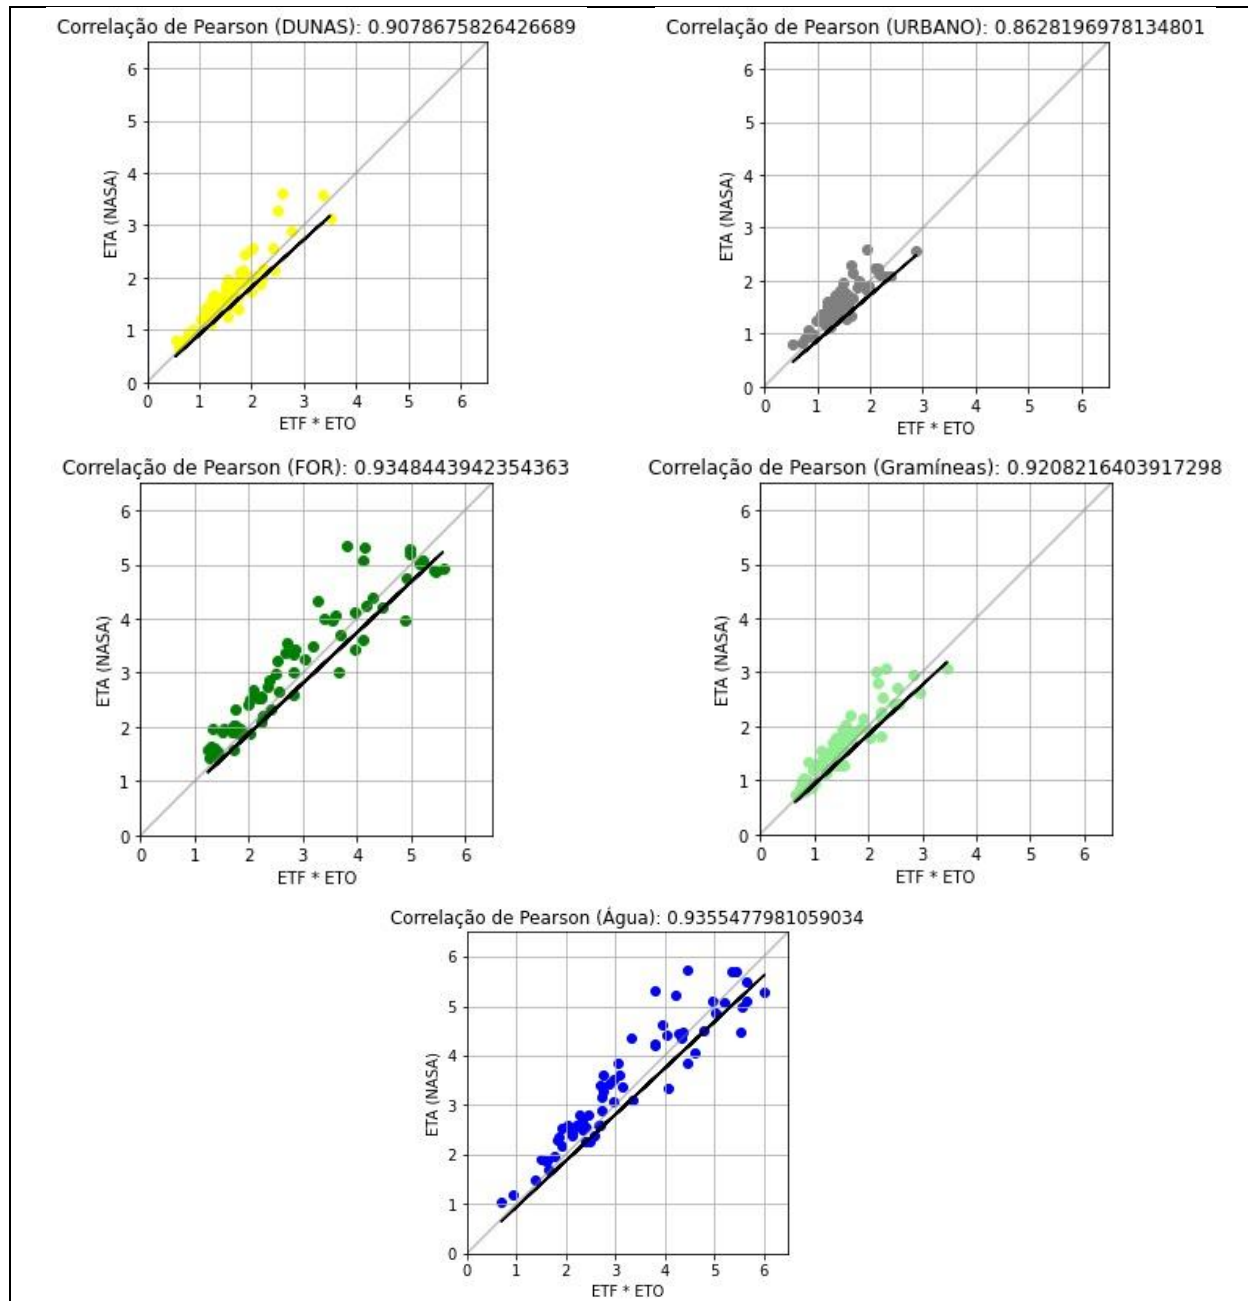
A maior diferença relativa registrada foi de 32,6% para a classe de Dunas e Lagoas, e de 32,46% para as demais classes, todas registradas para a data de 05 de janeiro de 2022.

Fez-se uma correlação de Pearson entre as duas variáveis para cada classe de ocupação do solo da bacia, buscando-se avaliar a relação linear entre as duas variáveis quantitativas. Sendo assim, o coeficiente de correlação de Pearson, “r”, varia de -1 a 1, em que quanto mais próximo de 1 maior o indicativo de uma correlação positiva forte, e 0 indica uma correlação fraca ou inexistente.

Na Figura 17 com os gráficos da correlação plotados, sendo X o eixo da ETR calculada pelos métodos anteriores e Y o eixo da ETR fornecida pelo produto da NASA. Ao

comparar-se os dois tipos de dados é possível observar que todas as cinco classes possuem uma correlação forte, em que a menor correlação apresentada (0,862) foi para o meio urbano, e a maior (0,935) para o corpo hídrico, que são também as classes de menor e maior evapotranspiração calculada, respectivamente.

Figura 17 - Correlações de Pearson entre a ET real calculada e a ET real obtida (ETA) para as cinco classes de cobertura do solo



Fonte: A autora.

Assim, pode-se inferir que os dados da evapotranspiração calculados através do método de Penman-Monteith, com uso de variáveis meteorológicas locais e coeficiente de ET

fracional Landsat (ETF) e a ET real estimada pela NASA são próximos. No entanto, em 75% dos casos, a evapotranspiração real, obtida pelo produto ETA da NASA, apresenta valores superiores aos estimados neste estudo. Uma provável explicação para o resultado é o uso do coeficiente de evapotranspiração real (ETF) durante os cálculos da ET real neste estudo, visto que se observou que as imagens de ETF, fornecidas pela NASA, parecem estar subestimadas. Este ponto, necessita de maiores investigações no futuro.

7 CONCLUSÃO

O estudo sobre a evapotranspiração da bacia da Lagoa da Conceição permitiu o melhor entendimento sobre os diferentes tipos de evapotranspiração. Foi possível testar a utilização de duas fontes de dados diferentes: uma para a determinação da evapotranspiração de referência (ET_o) através do método de Penman-Monteith (ALLEN et al., 1998) para o qual aplicou-se informações hidrometeorológicas (temperatura, velocidade do vento, umidade do ar, radiação solar e pressão atmosférica) de sensores locais, e outro para a determinação da evapotranspiração efetiva (ET_r) com uso de sensores remotos, neste caso, os produtos dos satélites Landsat 8 e 9, utilizados como coeficientes de evapotranspiração (USGS, 2022)

Dentre os resultados obtidos pode-se afirmar que ao utilizar os dados da estação meteorológica que foram fornecidos em duas escalas diferentes: diária e horária, notou-se uma baixa variação de valores entre si, sendo assim, o uso de um em detrimento do outro não acarretaria grandes discrepâncias. Todavia, os dados horários oferecem uma maior gama de informações e possibilidade de análises minuciosas em contrapartida aos dados diários.

Os resultados obtidos através das análises das imagens Landsat 8 e 9, permitiu uma análise do comportamento espectral dos alvos, neste caso, as diferentes coberturas do solo da bacia. Uma vez que, os sensores remotos permitem a análise da reflectância espectral dos recursos naturais, isto é, a capacidade dos mesmos de refletir, transmitir e absorver a REM (Radiação Eletromagnética) (PONZONI, 2001; JENSEN, 2005). A composição de bandas NIR (com Infravermelho próximo) permitiu observar como as coberturas vegetais são sensíveis a reflectância, apresentando altos valores destas, coloração avermelhada, devido à estrutura celular e composição de clorofila nas plantas. Enquanto corpos d'água, possuem baixa reflectância no NIR, coloração azulada, permitindo o diferenciar de uma cobertura vegetal densa e de áreas urbanas. Já, o meio urbano possui alta reflectância no NIR, devido às superfícies impermeáveis, podendo ser visualizados numa coloração acinzentada. Segundo Ponzoni (2001), o estudo do comportamento espectral de água difere dos estudos de outros

alvos, pois seu objetivo não é analisar a própria água, mas sim os componentes presentes nela. Uma vez que dados sobre uma superfície aquática permitem a análise de um sistema mais complexo, neste caso, os fluxos de entrada e saída da água na bacia da Lagoa em termos de evapotranspiração.

Com as médias de ET estimadas para as 5 coberturas de uso e ocupação do solo da bacia da Lagoa da Conceição, infere-se que a mesma possui uma alta taxa de perda de água da área de estudo, o que pode ter implicações para a disponibilidade de recursos hídricos na região. E, também, como o comportamento da ET está diretamente relacionado ao regime pluviométrico e clima do local, apresentando taxas maiores de ET durante os períodos de verão como janeiro e dezembro, e menores taxas durante o inverno, como o mês de junho.

Além disso, os resultados revelaram variações significativas na evapotranspiração em diferentes tipos de ocupação do solo. Por exemplo, com exceção das zonas da lagoa, as áreas florestais apresentaram a maior taxa de evapotranspiração, com uma média de 68,47 mm/mês. Isso pode ser atribuído à maior densidade de vegetação e à maior capacidade das árvores de transpirar água.

Um ponto identificado para melhoria do estudo, seria uma análise mais minuciosa dos produtos de evapotranspiração disponibilizados pela NASA. Uma vez que estes aparentam subestimar os valores de evapotranspiração para a bacia, talvez seja necessário aplicar um coeficiente de correção para as imagens ao serem utilizadas em estudos na região do hemisfério Sul.

Outra questão relevante relacionada aos produtos Landsat obtidos e que merece ser discutida é o fato das diferentes zonas orbitais e dos pontos retratados passa a área da bacia. Alguns dos quadrantes de imagens obtidos apresentavam a bacia da Lagoa da Conceição em extremidades diferentes, algumas nas bordas, o que pode acarretar uma certa distorção, e conseqüentemente, afetar os valores registrados para cada pixel.

Estudos preditivos da ET em escala de campo são importantes para entender o regime hídrico, seja para o consumo agrícola, como o comportamento da vegetação. Tornando-se imprescindível mapas históricos de ET para gerir os fluxos de água subterrânea e de superfície. Uma vez que conhecendo o passado, é possível fazer estimativas futuras. O sensoriamento remoto é a única maneira de estimar o consumo real em grandes áreas e em longas séries históricas. É sábio ressaltar a necessidade de realizar-se medições e experimentos para a melhor gestão dos recursos naturais.

7.1 LIMITAÇÕES

Algumas dificuldades identificadas durante a realização dessa pesquisa foram:

- Acesso às imagens de satélite Landsat-8 para encontrar o coeficiente de evapotranspiração ETf adequados, percebeu-se que apesar do produto da NASA ser descrito e apresentado em seu site oficial, sua aquisição não é feita de forma intuitiva pela plataforma, exigindo maior tempo para sua obtenção;
- Não haver um método simples para o preenchimento de lacunas de nuvens, que interferem imensamente na qualidade e aquisição de dados, sendo necessário realizar uma interpolação linear temporal entre cenas livres de nuvens e as contrárias.
- Escolha de períodos de dados ideais para uma boa análise e visualização de resultados, uma vez que estudos ligados a parâmetros meteorológicos necessitam de uma longa série temporal para que se possa desenvolver um padrão de comportamento para o estudo e assim realizar previsões estatísticas futuras melhores.
- A difícil importação e armazenamento das imagens Landsat 8 e 9, que exigiram o uso de dispositivos externos, a fim de se realizar as análises em maior escala, todavia, dentre todas as imagens adquiridas apenas cerca de 23% foram elegíveis para a realização dos cálculos de evapotranspiração da bacia devido a qualidade das mesmas.

7.2 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Para projetos futuros acerca dessa mesma temática recomenda-se o uso da plataforma Google Earth Engine ou outros modelos de softwares para o tratamento e armazenamento de dados que não exijam uma capacidade de memória da máquina utilizada. E que testem modelos de evapotranspiração mais complexos, podendo tomar como base de dados os resultados fornecidos no presente estudo. É, também, interessante o uso de imagens Landsat para períodos iguais períodos de tempo, a fim de obter uniformidade nos dados analisados.

Recomenda-se que estudos futuros relacionados a esta temática foquem em realizar análises mais acuradas dos parâmetros investigados, com o objetivo de obter resultados ainda mais precisos e confiáveis. Além disso, é importante considerar a criação de imagens e tabelas de melhor visualização e entendimento para o leitor, buscando formatos que facilitem a interpretação dos dados e destaquem as principais conclusões do estudo.

Outro aspecto relevante é a comparação dos resultados obtidos com outros trabalhos semelhantes realizados em regiões do mundo diferentes. Isso permitirá identificar padrões, similaridades e diferenças nas respostas da evapotranspiração em diferentes contextos

geográficos, contribuindo para o conhecimento global sobre o tema. Essa abordagem comparativa ampliará a compreensão dos processos envolvidos na evapotranspiração e fornecerá uma visão mais abrangente dos fenômenos estudados.

REFERÊNCIAS

- ABID-ASSOCIAÇÃO BRASILEIRA DE IRRIGAÇÃO E DRENAGEM (Brasil). **Kc Coeficiente de cultura:** Evapotranspiração da cultura. Disponível em: . Acesso em: 18 out. 2013.
- ALBUQUERQUE, P & COELHO, E. **Planilha para obtenção de coeficiente de cultura (Kc) para culturas de ciclo anual, segundo método FAO, para as condições climáticas brasileiras.** Embrapa. Comunicado técnico - 254, Sete Lagoas, MG, 2021.
- ALBUQUERQUE, P. E. P. de; DURÃES, F. O. M. (ed.). **Irrigação: dos fundamentos ao manejo de sistemas.** Brasília, DF: Embrapa, 2021. p. 257-280
- ALBUQUERQUE, Paulo Emílio Pereira de. **Estratégias de Manejo de Irrigação:** Exemplos de Cálculo. Sete Lagoas, MG: Embrapa Milho e Sorgo, 2010. 24 p. (Embrapa. Circular técnica, 136).
- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. **Crop evapotranspiration: guidelines for computing crop water requirements.** FAO Irrigation and Drainage Paper 56. Rome, Italy. 1998. 300 p.
- ANA Agência Nacional de Águas. **Estimativas de Evapotranspiração Real por Sensoriamento Remoto no Brasil.** Atlas Irrigação. Brasília - DF, 2020
- ANDRADE, Bruno C. C. A553e **Estimativa da evapotranspiração real via sensoriamento remoto** [recurso eletrônico] Escola de Engenharia da UFMG. Belo Horizonte, 2018
- BAI, T. et al. **Simulating on the effects of irrigation on jujube tree growth, evapotranspiration and water use based on crop growth model.** Agricultural Water Management, v. 243, p. 106517, 2021.
- BASTAANSSEN, W.G.M. **Regionalization of surface flux densites and moisture indicators in composite terrain.** 1995. 273p. Wageningen Agricultural University. Ph.D. Thesis, Wageningen, 1995.
- BERGAMASCHI, Homero et al. **Agrometeorologia aplicada à irrigação.** 2. ed. Porto Alegre: Editora da Universidade, 1999. 130 p.
- BIER, F.B. **Caracterização morfométrica e hidrológica da bacia hidrográfica da Lagoa da Conceição, Florianópolis – SC.** Trabalho de Conclusão de Curso apresentado ao curso de graduação em Engenharia Sanitária e Ambiental, Florianópolis, 2013.
- CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. V. **Introdução a ciência da geoinformação.** 2001. Disponível em: <http://www.dpi.inpe.br/gilberto/livro/introd/>. Acesso em: 03 abr. 2023.

CAMPBELL, J.B. **Introduction to remote sensing**. 4th Edition, The Guilford Press. New York. 2006

CARNEIRO, G., **Florianópolis: roteiro da ilha encantada**. Museu de Arte de São Paulo. Florianópolis: Ed. da UFSC, 1987

CARUSO JUNIOR, F. 1993. **Mapa geológico da Ilha de Santa Catarina**. Escala. 1:100000. Texto explicativo. Notas Técnicas, Porto Alegre, v. 6, p. 1-28.

CARUSO, M. M. L., **O desmatamento da Ilha de Santa Catarina de 1500 aos dias de atuais**. Florianópolis: Ed. da UFSC, 1983.

COELHO FILHO, M. A.; PEREIRA, F. A. de C.; ANGELOCCI, L. R.; COELHO, E. F.; OLIVEIRA, G. X. S. **O processo de evapotranspiração**. In: SOUSA, V. F. de;

MAROUELLI, W. A.; COELHO, E. F.; PINTO, J. M.; COELHO FILHO, M. A. (Ed.). **Irrigação e fertirrigação em fruteiras e hortaliças**. Brasília, DF: Embrapa Informação Tecnológica, 2011. Cap. 2, p. 91-113.

DA SILVA, C. F. **Estimativa Da Evapotranspiração Na Bacia Da Lagoa Da Conceição**. Trabalho de Conclusão de Curso apresentado ao curso de graduação em Engenharia Sanitária e Ambiental, Florianópolis, 2014.

DOORENBOS, J.; PRUITT, W. O. **Crop Water Requirements**. FAO Irrigation and Drainage Paper 24. Rome: FAO, 1977. 144 p.

DORNELLES, K. P. **Absortância solar de superfícies opacas: métodos de determinação e base de dados para tintas látex acrílica e PVA**. Campinas, SP: [s.n.], 2008. DOI - 10.13140/RG.2.1.4498.0967

ENGESAT. **Landsat 8**. 2013. Disponível em: <https://www.engesat.com.br/imagem-de-satelite/landsat-8/>. Acesso em: 20 fev. 2023.

EPAGRI Ciram, **Altas Climatológico do Estado de Santa Catarina**. Florianópolis, 2001. Disponível em: <https://ciram.epagri.sc.gov.br/index.php/solucoes/climatologia/>. Acesso em: 03 abr. 2023.

FAO. **Chapter 1 - Introduction to evapotranspiration**. 1998. Disponível em: <http://www.fao.org/3/X0490E/x0490e04.htm>. Acesso em: 20 fev. 2023.

FELIZARDO, L. M. **Aplicação de Sistema de Informações Geográficas (SIG) para modelagem de eventos críticos de vazão em uma microbacia urbana**. Dissertação (Mestrado em Engenharia Civil) – Universidade Estadual Paulista, Ilha Solteira, 2016. Disponível em: https://repositorio.unesp.br/bitstream/handle/11449/144450/felizardo_lm_me_ilha.pdf?sequence=3&isAllowed=y. Acesso em: 02 abr. 2023.

FENG, L. *et al.* **A UAV-derived thermal infrared remote sensing three-temperature model and estimation of various vegetation evapotranspiration in urban micro-environments**. Urban Forestry & Urban Greening, v. 69, p. 127495, 2022.

FERNANDES, D. S.; HEINEMANN, A. B.; PAZ, R. L. F.; AMORIM, A. O. **Evapotranspiração** – Uma Revisão sobre os Métodos Empíricos. Embrapa Arroz e Feijão, Santo Antônio de Goiás, GO, p. 44. 2010. Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/879913/evapotranspiracao-uma-revisao-sobre-os-metodos-empiricos>>. Acesso em: 08 fev 2023.

FERREIRA, M. I.; SILVESTRE, J.; CONCEIÇÃO, N.; MALHEIRO, A. C. **Crop and stress coefficients in rainfed and deficit irrigation vineyards using sap flow techniques**. Irrig. Sci., v. 30, p. 433-447, 2012.

FINOTTI, A. R., FINKLER, R., SILVA M. D´A., CEMIN, G. **Monitoramento de recursos hídricos em áreas urbanas**. Educus, Caxias do Sul, 2009.

FRANCO, B. M., ZIANI, F. A., KONRAD, J., & ANDRES, C. M. **Comparação entre métodos de estimativa de evapotranspiração potencial e de referência**. Revista Brasileira De Ciência, Tecnologia E Inovação, 4(2), 180–189, 2019.
<https://doi.org/10.18554/rbcti.v4i2.3715>

GARCIA, R. C.; ARAUJO, R. C. **Uso de Sensoriamento Remoto e Geoprocessamento para estimativa de áreas vegetadas e não vegetadas nos bairros de maior crescimento em São Luís-MA, durante os anos de 2000 e 2010**. *Research, Society and Development*, v. 10, n. 5, p. e27110515013- e27110515013, 2021. DOI: <http://dx.doi.org/10.33448/rsd-v10i5.15013>. Disponível em: <https://rsdjournal.org/index.php/rsd/article/download/15013/13382/194362>. Acesso em: 03 abr. 2023.

GODOY, F. B. **Modelagem Hidrológico-Hidrodinâmica da Lagoa da Conceição – SC**. Dissertação (Mestrado em Engenharia Ambiental), UFSC, Florianópolis, Santa Catarina, 2009.

HARGREAVES, G. H.; SAMANI, Z. A. **Estimating potential evapotranspiration**. Journal of the Irrigation and Drainage Division, v. 108, n. IR2, p. 225-230, 1982.

HAUFF, S. N., **Diagnóstico Ambiental Integrado da Bacia Hidrográfica da Lagoa da Conceição - Florianópolis, SC**. Dissertação (Mestrado em Geografia, concentração em Utilização e Conservação de Recursos Naturais). UFSC, Florianópolis, 1996.

HAUFF, S.N., LOCH, C., **Evolução da ocupação do solo na bacia hidrográfica da Lagoa da Conceição** (Ilha de Santa Catarina, SC. Florianópolis: Curso de Pós-Graduação em Geografia da UFSC, 1991.

HIGASHI, R. R. **Metodologia de uso e ocupação dos solos de cidades costeiras brasileiras através de SIG com base no comportamento geotécnico e ambiental**. 2006. Tese (Doutorado) – Universidade Federal de Santa Catarina, 2006. Disponível em: <http://repositorio.ufsc.br/xmlui/handle/123456789/89358>. Acesso em: 05 abr. 2023.

JENSEN, J. R., **Sensoriamento Remoto do Ambiente: Uma perspectiva em recursos terrestres**. Sao Jose dos Campos, SP: Parêntese, 2009

LACERDA, Zilda C. **Métodos de estimativa da evapotranspiração de referência para a mesoregião do Triângulo Mineiro e Alto Paranaíba-MG**. Jaboticabal, 2012 vii, 69 f. : il.; 29 cm

LEITE, M. E.; ROSA, R. **Geografia e geotecnologias no estudo urbano**. Caminhos de Geografia, v. 7, n. 17, 2006. Disponível em: <https://seer.ufu.br/index.php/caminhosdegeografia/article/view/15396>. Acesso em: 03 abr. 2023.

LIMA, Victor D. **Lagoa da Conceição: Análise integrativa da expansão urbana e seus impactos socioambientais**. Trabalho de Conclusão de Curso - Universidade Federal de Santa Catarina, Centro Tecnológico, Graduação de Engenharia Civil, Florianópolis, 2022.

LUPI, J.E.P.B., LUPI, S.M., **São João do Rio Vermelho. Memória dos Açores em Santa Catarina**. Porto Alegre: Escola Superior de Teologia e Espiritualidade Franciscana, 1987.

MAIA, C.;MORAIS, E.; COSTA DE, R. E. **Coefficiente de cultura do meloeiro irrigado com água salina estimado por modelo matemático**. Ciências Rurais, Santa Maria, v. 38, n. 5, p.1273-1278, ago. 2008.

MANTOVANI, E. C.; BERNARDO, S.; PALARETTI, L. F. **Irrigação: princípios e métodos**. 3. Ed. Viçosa-MG: UFV, 2006. 355p.

MARUYAMA, A. KUWAGATA, T. **Coupling land surface and crop growth models to estimate the effects of changes in the growth season on energy balance and water use of rice paddies**. Agr Forest Meteorol, 150 (2010), pp. 919-930

MENDONÇA, F.; DANNI-OLIVEIRA, I. M. **Climatologia: noções básicas e climas do Brasil**. São Paulo: Oficina de Texto, 2007. 206 p.

MOHAMED, Y. A.; BASTIAANSEN, W. G. M.; SAVENIJE, H. H. G. **Spatial variability of evaporation and moisture storage in the swamps of the upper Nile studied by remote sensing techniques**. Journal of Hydrology, v. 289, p. 145-164, 2004.

MONTEIRO, M. A. **Caracterização climática do estado de Santa Catarina: uma abordagem dos principais sistemas atmosféricos que atuam durante o ano**. Geosul, Florianópolis, v. 16, n. 31, p. 69-78, jan.-jun. 2001.

MONTEITH, J. L. **Evaporation and environment**. In: Symposia of the Society for Experimental Biology, Vol. 19, Cambridge University Press, 1965, p. 205-234.

NETO, D. D; LIVER, Q. J. V.; METSELAAR, K.; REICHARDT, K.; NIELSEN, D. R. **General procedure to initialize the cyclic soil water balance by the Thornthwaite and Mather method**. Scientia Agricola, v. 67, n. 1, 2010. Disponível em: <<http://www.scielo.br/pdf/sa/v67n1/v67n01a13.pdf>>. Acesso em: 01 fev 2023.

ODRESKI, L. F. R. **Influência hidrológica nos processos hidrodinâmicos da Lagoa da Conceição** - Florianópolis - SC. [s.l.] Universidade Federal de Santa Catarina, 2012.

PAIVA, C.M. et al. **Estimativa da evapotranspiração via sensoriamento remoto para fins de manejo de irrigação**. Revista Brasileira de Engenharia Agrícola e Ambiental, v. 23, n. 7, p. 518-524, 2019.

PARMAR, S. H.; PATEL, G. R.; TIWARI, M. K. **Assessment of crop water requirement of maize using remote sensing and GIS**. Smart Agricultural Technology, v. 4, p. 100186, 2023.

PENMAN, H. L. **Natural evaporation from open water, bare soil and grass, Bare Soil and Grass**. Proceedings of the Royal Society of London, 193, 120-145.1948
<https://doi.org/10.1098/rspa.1948.0037>

PEREIRA, A. R.; VILLA NOVA, N. A.; SEDIYAMA, G. C. **Evapo(transpi)ração**. Piracicaba: FEALQ, 1997. 183 p.

PONZONI, F. J. *et al*, **Sensoriamento remoto da vegetação** - 2 ed. atualizada e ampliada. Oficina de Textos. ISBN 978-85-7975-053-3 São Paulo, 2012.

POPOVA, Z.; KERCHEVA, M.; PEREIRA, L. S. **Validation of the FAO methodology for computing ETo with limited data: application to South Bulgaria**. Irrigation and Drainage, v. 55, n. 2, p. 201–215, Apr. 2006. Disponível em:
 <<http://onlinelibrary.wiley.com/doi/10.1002/ird.228/pdf>>. Acesso em: 30 fev. 2023.

POSSE, Robson Prucoli. **Determinação dos coeficientes da cultura (kc), de produtividade (ky), da área foliar e efeito da lâmina de irrigação, do turno de rega e da adubação potássica na produtividade do mamoeiro nas regiões Norte e Noroeste Fluminense**. 2008. 197 f. Disponível em: <https://uenf.br/posgraduacao/producao-vegetal/wp-content/uploads/sites/10/2015/05/Robson-Prucoli.pdf>. Acesso em: 02 mar. 2023.

PYTHON SOFTWARE FOUNDATION. **Python Language Site**: Documentation, 2020. Página de documentação. Disponível em: <<https://www.python.org/doc/>>. Acesso em: 06 de abr. de 2023.

QGIS Development Team, 2023. **QGIS Geographic Information System**. Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>

REF-ET: REFERENCE EVAPOTRANSPIRATION CALCULATION SOFTWARE for FAO and ASCE Standardized Equations Version 2.0 for Windows for Windows 95, 98 and NT Copyright 1999, 2000 University of Idaho and Dr. Richard G. Allen

SANTOS, M. L., et al., **Métodos para determinação de índice de área foliar em forrageiras**, Embrapa Agrossilvipastoril. In: SIMPÓSIO DE PECUÁRIA INTEGRADA, 2., 2016, Sinop. Recuperação de pastagens: anais. Cuiabá: Fundação Uniselva, 2016. p. 272-273.

SHUTTLEWORTH, W. J. **Evaporation**. In: MICHAEL, A. S. (Ed.). Handbook of Hydrology. New York: McGraw-Hill, 1993. p. 4.1-4.53.

SILVA, L. S.; COSTA, I. S.; CASTRO, A. A. B. C. **Geotecnologias como auxílio no planejamento urbano** – O uso do Google Earth como ferramenta de visualização espacial para o planejamento urbano. XVII Encontro da Associação Nacional de Pós-Graduação e

Pesquisa em Planejamento Urbano e Regional, Natal, 2019. Disponível em: <http://anpur.org.br/xviiiinanpur/anaisadmin/capapdf.php?reqid=550>. Acesso em: 03 abr. 2023.

SILVA, M. L. G. **Análise da qualidade ambiental urbana da bacia hidrográfica da Lagoa da Conceição**. 2002. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Catarina, Florianópolis, 2002. Disponível em: <https://repositorio.ufsc.br/xmlui/handle/123456789/84084>. Acesso em: 05 abr. 2023.

SILVA, Sérgio S., **Comparação de métodos empírico-teóricos de estimativa de evapotranspiração de referência ao modelo de Penman-Monteith** [manuscrito] / Goiania, 2017. 74 f.

STONE, Luis. F; SILVEIRA, Pedro. **Determinação da evapotranspiração para fins de irrigação**. Goiânia: EMBRAPA-CNPAP, 1995. 49p.

TAIZ, L.; ZEIGER, E **Fisiologia Vegetal**. (5ª ed.). Sunderland, MA: Sinauer Associates, 2010.

TRAJKOVIC. S. **Testing hourly reference evapotranspiration approaches using lysimeter measurements in a semiarid climate**. Hydrology Research, 41 (1) (2010), pp. 38-49

U.S. Geological Survey. (2023). **Landsat 8-9 Collection 2 (C2) Level 2 Science Product (L2SP)** Guide. Document Owner: Kristi Sayler, LSRD Project Manager.

UDA, Patricia. **Avaliação da evapotranspiração real da bacia do alto Rio Negro, região sul brasileira, por meio do modelo SEBAL**. Florianópolis, 2012. 163 p. Dissertação (Mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de PósGraduação em Engenharia Ambiental.

UIDAHO - University of Idaho All Rights Reserved. Kimberly Research and Extension Center. **Ref-ET Software**. Disponível em: <https://www.uidaho.edu/cals/kimberly-research-and-extension-center/research/water-resources/ref-et-software>. Acesso em: 28 maio 2023

UNITED STATES GEOLOGICAL SURVEY (USGS). **Landsat Collection 2 Provisional Actual Evapotranspiration Science Product**. Disponível em: <https://www.usgs.gov/landsat-missions/landsat-collection-2-provisional-actual-evapotranspiration-science-product>. Acesso em: 05 abr. 2023.

VAZ, M. C. **Lagoa da Conceição: a metamorfose de uma paisagem**. 2008. Dissertação (Mestrado em Urbanismo, História e Arquitetura da Cidade) – Universidade Federal de Santa Catarina, Florianópolis, 2008. Disponível em: <https://repositorio.ufsc.br/handle/123456789/91058>. Acesso em: 29 mar. 2023.

WANG, Y.L. et al. **A Comparative Study on Hourly Real Evapotranspiration and Potential Evapotranspiration during Different Vegetation Growth Stages in the Zoige Wetland**, Procedia Environmental Sciences, Volume 13, 2012, Pages 1585-1594, ISSN 1878-0296, <https://doi.org/10.1016/j.proenv.2012.01.150>.

WANG, Y.L. et al. **Procedia Environmental Sciences** 13 (2012) 1585 – 1594

ZHANG, Y., SIVAPALAN, M., & BLÖSCHL, G. **Scale dependence of the evapotranspiration**—Vegetation cover feedback and its implications for hydrological predictions. *Journal of Hydrology*, 2018. 556, 665-678.

**APÊNDICE A – Análises Estatísticas Da Evapotranspiração Real Por Classe De
Cobertura Do Solo Da Bacia Da Lagoa Da Conceição**

LAGOA

Período	ETR Mensal (mm/mês)	Média diária da ETR (mm/dia)	DesvPad da ETR (mm/dia)	ETR Máxima (mm/dia)	ETR Mínima (mm/dia)
mar/17	70,98	2,53	0,80	3,96	0,85
abr/17	49,29	1,64	0,64	2,72	0,70
mai/17	44,23	1,43	0,73	2,47	0,18
jun/17	35,71	1,19	0,49	2,09	0,26
jul/17	52,82	1,70	0,54	2,48	0,48
ago/17	54,19	1,75	0,56	2,85	0,47
set/17	55,98	1,87	0,17	2,29	1,44
out/17	62,92	2,03	0,36	3,38	1,53
nov/17	39,98	1,43	0,62	2,48	0,07
dez/17	96,00	3,10	1,43	5,67	1,02
jan/18	105,98	3,42	1,30	5,59	0,67
fev/18	82,67	3,06	1,23	4,79	0,01
mar/18	81,71	2,64	1,12	4,56	0,61
abr/18	86,26	2,88	0,59	3,80	1,44
mai/18	54,75	1,77	0,48	2,49	0,63
jun/18	39,63	1,32	0,53	2,05	0,38
jul/18	44,92	1,45	0,61	2,29	0,18
ago/18	55,96	1,81	0,80	2,85	0,28
set/18	64,19	2,14	1,12	4,07	0,24
out/18	71,58	2,31	1,18	4,41	0,81
nov/18	95,13	3,17	1,29	5,51	0,89
dez/18	134,63	4,34	1,19	5,89	1,39
jan/19	121,17	3,91	1,19	5,60	0,95
fev/19	88,02	3,14	1,37	5,27	0,45
mar/19	73,56	2,37	0,98	4,38	0,65
abr/19	63,00	2,10	0,94	3,24	0,47

mai/19	44,17	1,42	0,72	2,82	0,14
jun/19	49,86	1,66	0,45	2,13	0,21
jul/19	39,78	1,28	0,59	2,33	0,11
ago/19	57,43	1,85	0,69	3,08	0,44
set/19	55,29	1,84	0,97	3,56	0,32
out/19	90,28	2,91	1,35	4,95	0,58
nov/19	98,05	3,27	1,57	5,35	0,99
dez/19	124,83	4,03	1,40	5,62	1,07
jan/20	111,57	3,60	1,24	5,27	0,88
fev/20	93,81	3,23	1,25	4,66	0,69
mar/20	96,86	3,12	0,85	4,26	1,10
abr/20	74,01	2,47	0,61	3,18	1,05
mai/20	62,27	2,01	0,57	2,67	0,51
jun/20	40,87	1,36	0,61	2,29	0,29
jul/20	43,85	1,41	0,64	2,40	0,21
ago/20	60,38	1,95	0,90	3,07	0,25
set/20	58,72	1,96	1,09	4,06	0,28
out/20	89,93	2,90	1,34	4,91	0,29
nov/20	101,70	3,39	1,16	5,23	0,89
dez/20	102,36	3,30	1,49	5,84	0,84
jan/21	89,03	2,87	1,46	5,03	0,45
fev/21	89,59	3,20	1,55	5,00	0,28
mar/21	81,10	2,62	0,86	4,12	0,47
abr/21	66,50	2,22	0,63	3,34	0,66
mai/21	50,94	1,64	0,68	2,71	0,23
jun/21	33,10	1,10	0,51	1,86	0,12
jul/21	37,61	1,21	0,37	1,76	0,10
ago/21	30,61	0,99	0,42	1,78	0,22
set/21	49,08	1,64	0,86	3,28	0,15
out/21	65,64	2,12	1,35	5,02	0,61
nov/21	102,39	3,41	1,35	5,94	0,30
dez/21	119,25	3,85	1,17	5,41	1,80
jan/22	130,02	4,19	1,43	5,99	1,16

fev/22	117,75	4,21	1,06	5,53	1,99
mar/22	93,76	3,02	1,30	5,16	0,72
abr/22	66,33	2,21	0,80	3,53	0,78
mai/22	52,37	1,69	0,66	2,64	0,18
jun/22	36,48	1,22	0,50	1,85	0,34
jul/22	41,83	1,35	0,39	1,78	0,15
ago/22	58,61	1,89	0,87	3,16	0,37
set/22	74,21	2,47	1,07	4,41	0,40
out/22	92,52	2,98	1,36	5,54	0,27
nov/22	111,21	3,71	1,41	5,92	0,93
dez/22	120,16	3,88	1,46	6,13	0,84
jan/23	135,20	4,36	1,34	6,03	1,67
fev/23	108,93	3,89	1,40	5,92	0,77
mar/23	71,03	3,55	0,78	4,93	2,08

DUNA

Período	ETR Mensal (mm/mês)	Média diária da ETR (mm/dia)	DesvPad da ETR (mm/dia)	ETR Máxima (mm/dia)	ETR Mínima (mm/dia)
mar/17	27,60	0,99	0,37	1,65	0,42
abr/17	39,98	1,33	0,54	2,41	0,60
mai/17	29,14	0,94	0,47	1,57	0,12
jun/17	25,71	0,86	0,35	1,39	0,17
jul/17	35,96	1,16	0,33	1,62	0,33
ago/17	33,89	1,09	0,35	1,79	0,29
set/17	33,99	1,13	0,11	1,37	0,86
out/17	36,63	1,18	0,20	1,93	0,90
nov/17	22,34	0,80	0,35	1,41	0,04
dez/17	51,32	1,66	0,77	3,06	0,53
jan/18	54,05	1,74	0,67	2,90	0,34
fev/18	40,37	1,50	0,61	2,38	0,00
mar/18	38,03	1,23	0,53	2,13	0,28
abr/18	38,17	1,27	0,26	1,71	0,64

mai/18	27,91	0,90	0,26	1,22	0,28
jun/18	25,25	0,84	0,33	1,35	0,26
jul/18	32,00	1,03	0,45	1,63	0,12
ago/18	29,86	0,96	0,42	1,47	0,14
set/18	25,66	0,86	0,44	1,53	0,11
out/18	26,10	0,84	0,43	1,63	0,29
nov/18	33,61	1,12	0,46	1,95	0,32
dez/18	54,86	1,77	0,53	2,83	0,62
jan/19	68,04	2,19	0,69	3,51	0,57
fev/19	49,40	1,76	0,80	3,23	0,25
mar/19	31,20	1,01	0,50	2,14	0,25
abr/19	28,67	0,96	0,45	1,64	0,18
mai/19	28,08	0,91	0,44	1,61	0,11
jun/19	43,77	1,46	0,41	1,95	0,20
jul/19	32,36	1,04	0,58	1,92	0,11
ago/19	26,90	0,87	0,32	1,46	0,20
set/19	26,57	0,89	0,47	1,72	0,15
out/19	46,44	1,50	0,70	2,70	0,29
nov/19	57,13	1,90	0,94	3,25	0,55
dez/19	72,49	2,34	0,79	3,36	0,62
jan/20	51,10	1,65	0,58	2,55	0,38
fev/20	29,45	1,02	0,41	1,71	0,23
mar/20	30,80	0,99	0,39	1,88	0,45
abr/20	30,77	1,03	0,29	1,77	0,39
mai/20	36,66	1,18	0,35	1,69	0,32
jun/20	28,17	0,94	0,43	1,60	0,19
jul/20	29,18	0,94	0,43	1,58	0,14
ago/20	31,10	1,00	0,48	1,58	0,12
set/20	27,39	0,91	0,51	1,89	0,13
out/20	41,18	1,33	0,61	2,24	0,13
nov/20	45,72	1,52	0,52	2,34	0,40
dez/20	44,55	1,44	0,65	2,56	0,37
jan/21	36,01	1,16	0,60	2,05	0,18

fev/21	34,74	1,24	0,53	1,89	0,21
mar/21	58,78	1,90	0,64	3,04	0,36
abr/21	45,33	1,51	0,43	2,22	0,46
mai/21	34,02	1,10	0,48	1,99	0,16
jun/21	23,20	0,77	0,35	1,27	0,08
jul/21	36,74	1,19	0,38	1,83	0,16
ago/21	37,39	1,21	0,49	2,08	0,23
set/21	37,61	1,25	0,63	2,15	0,12
out/21	31,61	1,02	0,57	2,21	0,32
nov/21	52,34	1,74	0,74	3,30	0,15
dez/21	73,15	2,36	0,76	3,48	1,01
jan/22	60,44	1,95	0,85	3,80	0,31
fev/22	40,40	1,44	0,50	2,31	0,36
mar/22	39,00	1,26	0,54	2,15	0,30
abr/22	29,08	0,97	0,35	1,60	0,32
mai/22	35,94	1,16	0,46	1,85	0,11
jun/22	27,30	0,91	0,41	1,61	0,24
jul/22	39,60	1,28	0,36	1,66	0,14
ago/22	28,81	0,93	0,41	1,72	0,22
set/22	25,49	0,85	0,36	1,49	0,14
out/22	29,67	0,96	0,43	1,75	0,09
nov/22	39,50	1,32	0,50	2,12	0,34
dez/22	49,20	1,59	0,66	2,97	0,35
jan/23	59,27	1,91	0,61	2,86	0,81
fev/23	37,94	1,36	0,58	2,21	0,24
mar/23	13,75	0,69	0,18	1,22	0,43

FLORESTAS

Período	ETR Mensal (mm/mês)	Média diária da ETR (mm/dia)	DesvPad da ETR (mm/dia)	ETR Máxima (mm/dia)	ETR Mínima (mm/dia)
mar/17	64,50	2,30	0,69	3,40	0,81
abr/17	49,37	1,65	0,64	2,81	0,71

mai/17	40,92	1,32	0,67	2,25	0,17
jun/17	34,37	1,15	0,47	1,95	0,24
jul/17	41,74	1,35	0,34	1,73	0,38
ago/17	41,72	1,35	0,43	2,25	0,36
set/17	45,17	1,51	0,14	1,86	1,17
out/17	52,02	1,68	0,30	2,82	1,26
nov/17	33,79	1,21	0,52	2,08	0,06
dez/17	83,00	2,68	1,24	4,89	0,89
jan/18	93,69	3,02	1,15	4,90	0,59
fev/18	74,50	2,76	1,11	4,28	0,01
mar/18	75,12	2,42	1,03	4,18	0,56
abr/18	81,67	2,72	0,55	3,56	1,36
mai/18	51,53	1,66	0,45	2,35	0,61
jun/18	36,06	1,20	0,48	1,88	0,34
jul/18	39,77	1,28	0,54	2,03	0,16
ago/18	49,96	1,61	0,71	2,54	0,25
set/18	57,10	1,90	1,00	3,67	0,21
out/18	65,12	2,10	1,08	4,00	0,74
nov/18	87,31	2,91	1,18	5,06	0,81
dez/18	125,91	4,06	1,12	5,59	1,31
jan/19	117,12	3,78	1,15	5,47	0,93
fev/19	83,88	3,00	1,31	5,13	0,43
mar/19	66,17	2,13	0,91	4,05	0,59
abr/19	56,64	1,89	0,84	2,98	0,41
mai/19	40,53	1,31	0,66	2,58	0,13
jun/19	49,19	1,64	0,44	2,09	0,21
jul/19	34,67	1,12	0,55	1,88	0,12
ago/19	39,96	1,29	0,48	2,29	0,29
set/19	44,68	1,49	0,80	3,00	0,25
out/19	80,36	2,59	1,21	4,47	0,51
nov/19	89,58	2,99	1,44	4,93	0,90
dez/19	115,90	3,74	1,31	5,23	0,99
jan/20	104,40	3,37	1,16	4,93	0,83

fev/20	88,50	3,05	1,18	4,39	0,65
mar/20	86,97	2,81	0,80	4,04	0,90
abr/20	66,62	2,22	0,56	3,11	1,01
mai/20	44,21	1,43	0,46	2,21	0,40
jun/20	28,99	0,97	0,44	1,66	0,20
jul/20	32,97	1,06	0,48	1,82	0,16
ago/20	50,21	1,62	0,75	2,63	0,21
set/20	51,09	1,70	0,95	3,56	0,24
out/20	80,11	2,58	1,19	4,41	0,25
nov/20	92,67	3,09	1,07	4,79	0,81
dez/20	94,94	3,06	1,38	5,42	0,78
jan/21	82,94	2,68	1,36	4,68	0,42
fev/21	87,06	3,11	1,34	4,68	0,42
mar/21	81,15	2,62	0,81	4,07	0,62
abr/21	63,78	2,13	0,61	3,23	0,62
mai/21	47,87	1,54	0,67	2,55	0,22
jun/21	27,34	0,91	0,42	1,54	0,10
jul/21	38,81	1,25	0,37	1,81	0,16
ago/21	41,92	1,35	0,56	2,38	0,27
set/21	53,82	1,79	0,91	3,38	0,18
out/21	60,61	1,96	1,19	4,48	0,59
nov/21	94,66	3,16	1,27	5,61	0,28
dez/21	115,72	3,73	1,15	5,33	1,70
jan/22	125,12	4,04	1,38	5,81	1,05
fev/22	108,94	3,89	0,98	5,36	1,83
mar/22	78,87	2,54	1,15	4,61	0,63
abr/22	55,75	1,86	0,68	2,95	0,64
mai/22	47,10	1,52	0,60	2,39	0,16
jun/22	30,84	1,03	0,45	1,80	0,28
jul/22	45,40	1,46	0,42	1,95	0,16
ago/22	51,74	1,67	0,75	2,70	0,34
set/22	63,46	2,12	0,92	3,79	0,34
out/22	81,25	2,62	1,20	4,89	0,23

nov/22	107,41	3,58	1,36	5,75	0,91
dez/22	114,65	3,70	1,38	5,61	0,80
jan/23	125,49	4,05	1,24	5,62	1,52
fev/23	105,95	3,78	1,38	5,76	0,74
mar/23	66,65	3,33	0,72	4,68	1,96

GRAMÍNEA

Período	ETR Mensal (mm/mês)	Média diária da ETR (mm/dia)	DesvPad da ETR (mm/dia)	ETR Máxima (mm/dia)	ETR Mínima (mm/dia)
mar/17	26,20	0,94	0,29	1,38	0,39
abr/17	30,03	1,00	0,40	1,84	0,45
mai/17	23,67	0,76	0,39	1,31	0,10
jun/17	19,25	0,64	0,26	1,11	0,14
jul/17	27,74	0,89	0,24	1,21	0,26
ago/17	22,46	0,72	0,24	1,12	0,20
set/17	23,30	0,78	0,07	0,98	0,61
out/17	27,91	0,90	0,16	1,53	0,67
nov/17	18,74	0,67	0,29	1,13	0,03
dez/17	47,55	1,53	0,71	2,78	0,52
jan/18	55,33	1,78	0,67	2,86	0,35
fev/18	45,11	1,67	0,67	2,57	0,01
mar/18	46,63	1,50	0,63	2,59	0,35
abr/18	49,59	1,65	0,35	2,27	0,83
mai/18	30,85	1,00	0,27	1,40	0,36
jun/18	22,51	0,75	0,30	1,17	0,21
jul/18	25,60	0,83	0,35	1,31	0,10
ago/18	28,98	0,93	0,41	1,45	0,14
set/18	26,70	0,89	0,46	1,55	0,12
out/18	27,32	0,88	0,45	1,69	0,31
nov/18	36,21	1,21	0,49	2,10	0,34
dez/18	58,21	1,88	0,55	2,91	0,65
jan/19	68,27	2,20	0,68	3,46	0,57

fev/19	48,03	1,72	0,78	3,18	0,24
mar/19	28,88	0,93	0,48	2,03	0,22
abr/19	25,65	0,86	0,40	1,48	0,16
mai/19	25,25	0,81	0,40	1,46	0,09
jun/19	37,69	1,26	0,35	1,66	0,17
jul/19	25,76	0,83	0,49	1,60	0,10
ago/19	18,94	0,61	0,23	1,02	0,15
set/19	18,22	0,61	0,32	1,17	0,11
out/19	32,32	1,04	0,49	2,00	0,19
nov/19	46,09	1,54	0,79	2,76	0,42
dez/19	61,24	1,98	0,68	2,72	0,52
jan/20	53,25	1,72	0,59	2,52	0,42
fev/20	43,95	1,52	0,58	2,18	0,33
mar/20	42,35	1,37	0,41	1,96	0,49
abr/20	24,16	0,81	0,20	1,15	0,37
mai/20	23,87	0,77	0,24	1,15	0,21
jun/20	17,83	0,59	0,28	1,04	0,12
jul/20	19,50	0,63	0,28	1,07	0,09
ago/20	21,54	0,69	0,34	1,18	0,08
set/20	21,54	0,72	0,41	1,53	0,10
out/20	36,48	1,18	0,55	2,06	0,11
nov/20	45,14	1,50	0,53	2,38	0,39
dez/20	49,26	1,59	0,72	2,89	0,39
jan/21	45,45	1,47	0,73	2,55	0,24
fev/21	54,34	1,94	0,71	2,69	0,47
mar/21	55,62	1,79	0,54	2,80	0,54
abr/21	38,65	1,29	0,37	1,96	0,38
mai/21	30,36	0,98	0,46	1,68	0,14
jun/21	15,09	0,50	0,23	0,80	0,05
jul/21	24,65	0,80	0,25	1,23	0,11
ago/21	24,14	0,78	0,32	1,36	0,15
set/21	28,60	0,95	0,48	1,75	0,10
out/21	29,91	0,96	0,58	2,20	0,29

nov/21	48,61	1,62	0,67	2,95	0,14
dez/21	62,78	2,03	0,63	2,93	0,90
jan/22	57,99	1,87	0,71	3,13	0,37
fev/22	45,55	1,63	0,43	2,35	0,61
mar/22	44,85	1,45	0,62	2,40	0,35
abr/22	34,69	1,16	0,42	1,81	0,39
mai/22	29,51	0,95	0,38	1,47	0,10
jun/22	19,01	0,63	0,32	1,30	0,15
jul/22	27,94	0,90	0,26	1,30	0,10
ago/22	23,89	0,77	0,34	1,42	0,18
set/22	22,39	0,75	0,33	1,39	0,12
out/22	34,23	1,10	0,53	2,25	0,10
nov/22	39,93	1,33	0,51	2,16	0,34
dez/22	49,37	1,59	0,68	3,07	0,35
jan/23	67,43	2,18	0,69	3,07	0,86
fev/23	47,33	1,69	0,62	2,56	0,33
mar/23	29,00	1,45	0,31	2,06	0,86

URBANO

Período	ETR Mensal (mm/mês)	Média diária da ETR (mm/dia)	DesvPad da ETR (mm/dia)	ETR Máxima (mm/dia)	ETR Mínima (mm/dia)
mar/17	22,79	0,81	0,26	1,24	0,34
abr/17	28,94	0,96	0,39	1,75	0,44
mai/17	25,60	0,83	0,42	1,42	0,11
jun/17	22,50	0,75	0,31	1,26	0,16
jul/17	31,39	1,01	0,28	1,37	0,29
ago/17	26,93	0,87	0,28	1,35	0,24
set/17	26,52	0,88	0,08	1,08	0,68
out/17	29,70	0,96	0,17	1,59	0,72
nov/17	18,81	0,67	0,29	1,17	0,03
dez/17	45,00	1,45	0,67	2,66	0,48
jan/18	49,50	1,60	0,61	2,62	0,31

fev/18	38,50	1,43	0,57	2,23	0,00
mar/18	37,92	1,22	0,52	2,11	0,28
abr/18	40,24	1,34	0,27	1,78	0,66
mai/18	28,30	0,91	0,25	1,27	0,31
jun/18	22,38	0,75	0,30	1,17	0,22
jul/18	26,20	0,85	0,36	1,32	0,10
ago/18	28,98	0,93	0,41	1,47	0,14
set/18	26,98	0,90	0,46	1,55	0,12
out/18	25,56	0,82	0,42	1,66	0,28
nov/18	30,16	1,01	0,41	1,74	0,30
dez/18	45,99	1,48	0,45	2,39	0,53
jan/19	57,23	1,85	0,57	2,87	0,49
fev/19	40,22	1,44	0,65	2,64	0,20
mar/19	25,05	0,81	0,40	1,73	0,20
abr/19	26,73	0,89	0,43	1,58	0,16
mai/19	26,23	0,85	0,41	1,55	0,09
jun/19	36,81	1,23	0,34	1,66	0,17
jul/19	27,64	0,89	0,50	1,66	0,10
ago/19	21,61	0,70	0,26	1,13	0,17
set/19	19,70	0,66	0,34	1,25	0,11
out/19	31,95	1,03	0,48	1,81	0,20
nov/19	37,23	1,24	0,61	2,08	0,37
dez/19	49,60	1,60	0,56	2,24	0,43
jan/20	43,92	1,42	0,49	2,08	0,35
fev/20	36,32	1,25	0,48	1,80	0,27
mar/20	37,00	1,19	0,33	1,62	0,43
abr/20	29,89	1,00	0,25	1,32	0,39
mai/20	30,44	0,98	0,28	1,27	0,24
jun/20	24,48	0,82	0,37	1,38	0,18
jul/20	24,45	0,79	0,36	1,32	0,12
ago/20	28,50	0,92	0,43	1,38	0,11
set/20	25,70	0,86	0,47	1,76	0,12
out/20	37,94	1,22	0,56	2,05	0,12

nov/20	41,32	1,38	0,47	2,10	0,36
dez/20	40,59	1,31	0,59	2,34	0,33
jan/21	36,14	1,17	0,59	2,04	0,18
fev/21	38,55	1,38	0,59	2,07	0,21
mar/21	46,37	1,50	0,48	2,37	0,33
abr/21	36,33	1,21	0,34	1,83	0,36
mai/21	28,78	0,93	0,39	1,48	0,13
jun/21	17,66	0,59	0,27	0,98	0,06
jul/21	27,57	0,89	0,29	1,40	0,12
ago/21	27,70	0,89	0,37	1,55	0,17
set/21	28,41	0,95	0,47	1,64	0,09
out/21	24,41	0,79	0,45	1,68	0,24
nov/21	36,77	1,23	0,50	2,23	0,11
dez/21	47,15	1,52	0,48	2,20	0,68
jan/22	51,65	1,67	0,61	2,55	0,37
fev/22	44,29	1,58	0,47	2,46	0,53
mar/22	38,24	1,23	0,53	2,14	0,29
abr/22	30,13	1,00	0,36	1,57	0,34
mai/22	29,82	0,96	0,38	1,47	0,10
jun/22	21,57	0,72	0,34	1,37	0,18
jul/22	31,38	1,01	0,29	1,39	0,12
ago/22	27,05	0,87	0,38	1,51	0,20
set/22	26,22	0,87	0,37	1,51	0,14
out/22	28,02	0,90	0,40	1,64	0,08
nov/22	37,59	1,25	0,48	2,00	0,30
dez/22	41,64	1,34	0,54	2,47	0,30
jan/23	53,95	1,74	0,54	2,41	0,67
fev/23	36,62	1,31	0,50	1,99	0,25
mar/23	20,26	1,01	0,22	1,49	0,62

**APÊNDICE B – Algoritmo De Aplicação Do Cálculo De Evapotranspiração
Real Com Imagens Landsat 8 E 9 Para Bacia Da Lagoa Da Conceição**

```

1 Created on Mon May 22 09:26:21 2023
2
3
4 import rasterio
5 from rasterio.mask import mask
6 import numpy as np
7 import pandas as pd
8 import geopandas as gpd
9 import matplotlib.pyplot as plt
10 from matplotlib.colors import Normalize
11 from datetime import datetime
12 import os
13 import glob
14 #From datetime import datetime, timedelta
15
16 ### Função para converter em número juliano
17
18 def data_para_numero_juliano(data):
19     data_formatada = datetime.strptime(data, '%Y%m%d')
20     ano = data_formatada.year
21     mes = data_formatada.month
22     dia = data_formatada.day
23
24     a = (14 - mes) // 12
25     y = ano + 4800 - a
26     m = mes + 12 * a - 3
27
28     numero_juliano = dia + ((153 * m + 2) // 5) + 365 * y + (y // 4) - (y // 100) + (y
29         // 400) - 32045
30
31     return numero_juliano
32
33 ### Função para converter Juliano em yyyymmdd
34
35 def julian_to_date(julian_date):
36     A = julian_date
37     E = int((A-1867216.25)/36524.25)
38     D = A + 1 + E - int(E/4)
39     F = D + 1524
40     G = int(((F - 122.1) / 365.25))
41     H = int((G * 365.25))
42     I = int(((F - H) / 30.6001))
43     J = F - H - int(I * 30.6001)
44
45     if I < 14:
46         K = I - 1
47     else:
48         K = I - 13
49
50     if K > 2:
51         L = G - 4716
52     else:
53         L = G - 4715
54
55     if L > 0:
56         M = L
57     else:
58         M = L*(-1) + 1
59
60     if J < 10:
61         dia = str(J)
62         dia = '0'+dia
63     else:
64         dia = str(J)
65
66     if K < 10:
67         mes = str(K)
68         mes = '0'+mes
69     else:
70         mes = str(K)
71

```

```

72
73     ano = str(M)
74
75     data = ano+mes+dia
76
77     return data
78
79     ### Função para criar uma pasta com o nome das imagens
80
81     def listar_imagens_etf(caminho_pasta):
82         lista_imagens = []
83         formato_imagem = '^ETF.tif' # Identifica as imagens terminadas em "ETF.tif"
84
85         padrao_arquivos = os.path.join(caminho_pasta, formato_imagem)
86         lista_imagens.extend(glob.glob(padrao_arquivos))
87
88         return lista_imagens
89
90     ### Criar lista de imagens com menos de 70% de NoData
91
92     pasta = 'C:/tcc/GIS/Collection2/extraidos' # Caminho para a pasta
93     lista_imagens_etf = listar_imagens_etf(pasta)
94     a = 0
95     b = 0
96
97     lista_imagens_etf = [linha for linha in lista_imagens_etf if "_219080_" not in linha]
98
99     dados = {'Endereço': [],
100             'Data': [],
101             'Data Juliana': []}
102
103     while a < len(lista_imagens_etf):
104         with rasterio.open(lista_imagens_etf[a]) as src:
105
106             # Carregar o polígono de interesse usando geopandas
107             gdf = gpd.read_file(
108                 'C:/tcc/GIS/Collection2/IC_4/shapefiles/lc_basin_with_lagoon.shp')
109             # Recortar a imagem para o polígono de interesse usando a função 'mask' do
110             Rasterio
111             out_image, out_transform = mask(src, gdf.geometry, crop=True)
112
113             # Calcular a porcentagem de pixels sem dados na imagem recortada
114             no_data_count = np.count_nonzero(out_image == src.nodata)
115             total_pixels = out_image.size
116             nodata_percent = no_data_count / total_pixels * 100
117
118             if nodata_percent < 70:
119                 dados['Endereço'].append(lista_imagens_etf[a])
120
121                 date_str = lista_imagens_etf[a].split('_')[3]
122
123                 dados['Data'].append(date_str)
124                 dados['Data Juliana'].append(data_para_numero_juliano(date_str))
125
126                 a = a + 1
127
128     ### Recortagem, Interpolação e Plotagem
129
130     a = 2457817
131
132     df_eto = pd.read_excel(r'C:\tcc\GIS\Collection2\IC_4\Evapotranspiração
133     Referencial\dados_horarios_refet_04_6.xlsx')
134     gdf2 = gpd.read_file('C:/tcc/GIS/Collection2/IC_4/shapefiles/samples_classes.shp')
135
136     gdf_dun = gdf2[gdf2['classes'].isin(['DUN'])]
137     gdf_urb = gdf2[gdf2['classes'].isin(['URB'])]
138     gdf_for = gdf2[gdf2['classes'].isin(['FOR'])]
139     gdf_her = gdf2[gdf2['classes'].isin(['HER'])]
140     gdf_agu = gdf2[gdf2['classes'].isin(['REN', 'LBA', 'LCD', 'LCS'])]
141
142     df_medias = pd.DataFrame(columns=['DIA', 'DUN', 'URB', 'FOR', 'HER', 'AGU'])

```

```

141
142 while a <= (2460001):
143
144     # Definir menor distância e valor superior e mais próximo de 'a'
145     menor_distancia = float('inf')
146     valor_mais_proximo = None
147
148     # Índice da ETO de determinado dia
149     c = (df_eto['DIA'] == a).idxmax()
150
151     if a in dados['Data Juliana']:
152
153         if a < 2460001:
154             for num in dados['Data Juliana']:
155                 if num > a and num - a < menor_distancia:
156                     menor_distancia = num - a
157                     valor_mais_proximo = num
158
159             a1 = valor_mais_proximo
160             b1 = dados['Data Juliana'].index(a1)
161
162         b = dados['Data Juliana'].index(a)
163         with rasterio.open(dados['Endereço'][b]) as src:
164
165             # Recortar a imagem para o polígono de interesse usando a função 'mask'
166             # do Rasterio
167             out_image, out_transform = mask(src, gdf.geometry, crop=True)
168             im_dun, out_transform = mask(src, gdf_dun.geometry, crop=True)
169             im_urb, out_transform = mask(src, gdf_urb.geometry, crop=True)
170             im_for, out_transform = mask(src, gdf_for.geometry, crop=True)
171             im_her, out_transform = mask(src, gdf_her.geometry, crop=True)
172             im_agu, out_transform = mask(src, gdf_agu.geometry, crop=True)
173
174             # Transformar o valor de ETF entre 0 e 1
175             out_image = out_image / 10000
176             im_dun = im_dun / 10000
177             im_urb = im_urb / 10000
178             im_for = im_for / 10000
179             im_her = im_her / 10000
180             im_agu = im_agu / 10000
181
182             # Definir ETO
183             d = df_eto['FAO 56PM ETO (mm/h)'][c]
184
185             # Multiplicar por ETO e encontrar ETR
186             out_image = out_image * d
187             im_dun = im_dun * d
188             im_urb = im_urb * d
189             im_for = im_for * d
190             im_her = im_her * d
191             im_agu = im_agu * d
192
193             # Definir valores abaixo de zero como NaN
194             out_image[out_image < 0] = np.nan
195             im_dun[im_dun < 0] = np.nan
196             im_urb[im_urb < 0] = np.nan
197             im_for[im_for < 0] = np.nan
198             im_her[im_her < 0] = np.nan
199             im_agu[im_agu < 0] = np.nan
200
201             # Média das classes
202             media_dun = np.nanmean(im_dun)
203             media_urb = np.nanmean(im_urb)
204             media_for = np.nanmean(im_for)
205             media_her = np.nanmean(im_her)
206             media_agu = np.nanmean(im_agu)
207
208             # Adicionar médias ao dataframe
209             linha_medias = pd.DataFrame([[str(a), media_dun, media_urb, media_for,
210 media_her, media_agu]], columns=['DIA', 'DUN', 'URB', 'FOR', 'HER', 'AGU'
211 ])
212             df_medias = pd.concat([df_medias, linha_medias], ignore_index=True)

```



```

210
211     # Define a escala de cores para a imagem
212     vmin, vmax = 0, np.nanmax(out_image)
213     # Define a escala de cores ignorando valores menores que zero
214     norm = Normalize(vmin=vmin, vmax=6.5, clip=True)
215
216     # Define a cor dos valores NaN como branco
217     cmap = plt.cm.RdYlBu
218     cmap.set_bad(color='w')
219
220     # Plota a imagem
221     plt.imshow(out_image[0], cmap=cmap, norm=norm)
222     plt.colorbar()
223     plt.title(dados['Data'][b])
224     plt.show()
225     a = a + 1
226
227 else:
228     if a == 2458080 or a == 2458081 or a == 2458176:
229         a = a + 1
230
231     else:
232         with rasterio.open(dados['Endereço'][b]) as src:
233             with rasterio.open(dados['Endereço'][b1]) as src2:
234
235                 # Recortar a imagem para o polígono de interesse usando a função
236                 # 'mask' do Rasterio
237                 out_image1, out_transform = mask(src, gdf.geometry, crop=True)
238                 out_image2, out_transform = mask(src2, gdf.geometry, crop=True)
239                 im_dun1, out_transform = mask(src, gdf_dun.geometry, crop=True)
240                 im_dun2, out_transform = mask(src2, gdf_dun.geometry, crop=True)
241                 im_urb1, out_transform = mask(src, gdf_urb.geometry, crop=True)
242                 im_urb2, out_transform = mask(src2, gdf_urb.geometry, crop=True)
243                 im_for1, out_transform = mask(src, gdf_for.geometry, crop=True)
244                 im_for2, out_transform = mask(src2, gdf_for.geometry, crop=True)
245                 im_her1, out_transform = mask(src, gdf_her.geometry, crop=True)
246                 im_her2, out_transform = mask(src2, gdf_her.geometry, crop=True)
247                 im_agu1, out_transform = mask(src, gdf_agu.geometry, crop=True)
248                 im_agu2, out_transform = mask(src2, gdf_agu.geometry, crop=True)
249
250                 # Pesos das imagens 1 e 2
251                 p1 = (dados['Data Juliana'][b1] - a) / (dados['Data Juliana'][b1]
252                 - dados['Data Juliana'][b])
253                 p2 = (a - dados['Data Juliana'][b]) / (dados['Data Juliana'][b1] -
254                 dados['Data Juliana'][b])
255
256                 # Encontrar a maior forma entre as duas arrays
257                 max_shape = np.max([out_image1.shape, out_image2.shape], axis=0)
258                 max_shape_dun = np.max([im_dun1.shape, im_dun2.shape], axis=0)
259                 max_shape_urb = np.max([im_urb1.shape, im_urb2.shape], axis=0)
260                 max_shape_for = np.max([im_for1.shape, im_for2.shape], axis=0)
261                 max_shape_her = np.max([im_her1.shape, im_her2.shape], axis=0)
262                 max_shape_agu = np.max([im_agu1.shape, im_agu2.shape], axis=0)
263
264                 # Calcular o valor de preenchimento
265                 fill_value = np.min([out_image1.min(), out_image2.min()])
266                 fill_value_dun = np.min([im_dun1.min(), im_dun2.min()])
267                 fill_value_urb = np.min([im_urb1.min(), im_urb2.min()])
268                 fill_value_for = np.min([im_for1.min(), im_for2.min()])
269                 fill_value_her = np.min([im_her1.min(), im_her2.min()])
270                 fill_value_agu = np.min([im_agu1.min(), im_agu2.min()])
271
272                 # Ajustar as formas das arrays mantendo os dados alinhados
273                 new_shape = (1, max_shape[1], max_shape[2])
274                 new_shape_dun = (1, max_shape_dun[1], max_shape_dun[2])
275                 new_shape_urb = (1, max_shape_urb[1], max_shape_urb[2])
276                 new_shape_for = (1, max_shape_for[1], max_shape_for[2])
277                 new_shape_her = (1, max_shape_her[1], max_shape_her[2])
278                 new_shape_agu = (1, max_shape_agu[1], max_shape_agu[2])
279
280                 if im_dun1.shape != new_shape_dun:
281                     pad_width = [(0, 0)]
282                     for i in range(1, len(new_shape_dun)):

```

```

279         pad_width.append((0, max_shape_dun[i] - im_dun1.shape[i]))
280         im_dun1 = np.pad(im_dun1, pad_width, mode='constant',
281                          constant_values=fill_value_dun)
282
283     if im_dun2.shape != new_shape_dun:
284         pad_width = [(0, 0)]
285         for i in range(1, len(new_shape_dun)):
286             pad_width.append((0, max_shape_dun[i] - im_dun2.shape[i]))
287         im_dun2 = np.pad(im_dun2, pad_width, mode='constant',
288                          constant_values=fill_value_dun)
289
290     if im_urb1.shape != new_shape_urb:
291         pad_width = [(0, 0)]
292         for i in range(1, len(new_shape_urb)):
293             pad_width.append((0, max_shape_urb[i] - im_urb1.shape[i]))
294         im_urb1 = np.pad(im_urb1, pad_width, mode='constant',
295                          constant_values=fill_value_urb)
296
297     if im_urb2.shape != new_shape_urb:
298         pad_width = [(0, 0)]
299         for i in range(1, len(new_shape_urb)):
300             pad_width.append((0, max_shape_urb[i] - im_urb2.shape[i]))
301         im_urb2 = np.pad(im_urb2, pad_width, mode='constant',
302                          constant_values=fill_value_urb)
303
304     if im_for1.shape != new_shape_for:
305         pad_width = [(0, 0)]
306         for i in range(1, len(new_shape_for)):
307             pad_width.append((0, max_shape_for[i] - im_for1.shape[i]))
308         im_for1 = np.pad(im_for1, pad_width, mode='constant',
309                          constant_values=fill_value_for)
310
311     if im_for2.shape != new_shape_for:
312         pad_width = [(0, 0)]
313         for i in range(1, len(new_shape_for)):
314             pad_width.append((0, max_shape_for[i] - im_for2.shape[i]))
315         im_for2 = np.pad(im_for2, pad_width, mode='constant',
316                          constant_values=fill_value_for)
317
318     if im_her1.shape != new_shape_her:
319         pad_width = [(0, 0)]
320         for i in range(1, len(new_shape_her)):
321             pad_width.append((0, max_shape_her[i] - im_her1.shape[i]))
322         im_her1 = np.pad(im_her1, pad_width, mode='constant',
323                          constant_values=fill_value_her)
324
325     if im_her2.shape != new_shape_her:
326         pad_width = [(0, 0)]
327         for i in range(1, len(new_shape_her)):
328             pad_width.append((0, max_shape_her[i] - im_her2.shape[i]))
329         im_her2 = np.pad(im_her2, pad_width, mode='constant',
330                          constant_values=fill_value_her)
331
332     if im_agu1.shape != new_shape_agu:
333         pad_width = [(0, 0)]
334         for i in range(1, len(new_shape_agu)):
335             pad_width.append((0, max_shape_agu[i] - im_agu1.shape[i]))
336         im_agu1 = np.pad(im_agu1, pad_width, mode='constant',
337                          constant_values=fill_value_agu)
338
339     if im_agu2.shape != new_shape_agu:
340         pad_width = [(0, 0)]
341         for i in range(1, len(new_shape_agu)):
342             pad_width.append((0, max_shape_agu[i] - im_agu2.shape[i]))
343         im_agu2 = np.pad(im_agu2, pad_width, mode='constant',
344                          constant_values=fill_value_agu)
345
346     if out_image1.shape != new_shape:
347         pad_width = [(0, 0)]
348         for i in range(1, len(new_shape)):
349             pad_width.append((0, max_shape[i] - out_image1.shape[i]))
350         out_image1 = np.pad(out_image1, pad_width, mode='constant',

```

```

341         constant_values=fill_value)
342
343     if out_image2.shape != new_shape:
344         pad_width = [(0, 0)]
345         for i in range(1, len(new_shape)):
346             pad_width.append((0, max_shape[i] - out_image2.shape[i]))
347         out_image2 = np.pad(out_image2, pad_width, mode='constant',
348                             constant_values=fill_value)
349
350     # Calcular imagem intermediária
351     out_image = out_image1 * p1 + out_image2 * p2
352     im_dun = im_dun1 * p1 + im_dun2 * p2
353     im_urb = im_urb1 * p1 + im_urb2 * p2
354     im_for = im_for1 * p1 + im_for2 * p2
355     im_her = im_her1 * p1 + im_her2 * p2
356     im_agu = im_agu1 * p1 + im_agu2 * p2
357
358     # Transformar o valor de ETF entre 0 e 1
359     out_image = out_image / 10000
360     im_dun = im_dun / 10000
361     im_urb = im_urb / 10000
362     im_for = im_for / 10000
363     im_her = im_her / 10000
364     im_agu = im_agu / 10000
365
366     # Definir ETO
367     d = df_eto['FAO 56PM ETo (mm/h)'][c]
368
369     # Multiplicar por ETO e encontrar ETR
370     out_image = out_image * d
371     im_dun = im_dun * d
372     im_urb = im_urb * d
373     im_for = im_for * d
374     im_her = im_her * d
375     im_agu = im_agu * d
376
377     # Aplicar a máscara para substituir os valores negativos por NaN
378     out_image[out_image < 0] = np.nan
379     im_dun[im_dun < 0] = np.nan
380     im_urb[im_urb < 0] = np.nan
381     im_for[im_for < 0] = np.nan
382     im_her[im_her < 0] = np.nan
383     im_agu[im_agu < 0] = np.nan
384
385     # Média das classes
386     media_dun = np.nanmean(im_dun)
387     media_urb = np.nanmean(im_urb)
388     media_for = np.nanmean(im_for)
389     media_her = np.nanmean(im_her)
390     media_agu = np.nanmean(im_agu)
391
392     # Adicionar médias ao dataframe
393     linha_medias = pd.DataFrame([[stv(a), media_dun, media_urb,
394                                 media_for, media_her, media_agu]], columns=['DIA', 'DUN', 'URB',
395                                 'FOR', 'HER', 'AGU'])
396     df_medias = pd.concat([df_medias, linha_medias], ignore_index=True)
397
398
399
400
401     # Define a escala de cores para a imagem
402     vmin, vmax = 0, np.nanmax(out_image)
403     # Define a escala de cores ignorando valores menores que zero
404     norm = Normalize(vmin=vmin, vmax=vmax, clip=True)
405
406     # Define a cor dos valores NaN como branco
407     cmap = plt.cm.RdYlBu

```



```

408         cmap.set_bad(color='w')
409
410         data = julian_to_date(a)
411
412         # Plota a imagem
413         plt.imshow(out_image[0], cmap=cmap, norm=norm)
414         plt.colorbar()
415         plt.title(data)
416         plt.show()
417         a = a + 1
418
419
420 ### Criar gráfico com DataFrame
421
422 # Obter colunas do eixo Y
423 y_columns = df_medias.columns[1:]
424
425 # Definir cores para cada linha
426 colors = ['yellow', 'gray', 'green', 'lightgreen', 'blue']
427
428 # Plotar gráficos para cada coluna do eixo Y
429 for column, color in zip(y_columns, colors):
430     fig, ax = plt.subplots()
431
432     plt.plot(df_medias['DIA'], df_medias[column], label=column, color=color)
433
434     # Definir os rótulos personalizados no eixo X
435     plt.xticks([2458120-2457961, 2458485-2457961, 2458850-2457961, 2459216-2457961,
436                2459581-2457961, 2459946-2457961], ['2018', '2019', '2020', '2021', '2022', '2023',
437                ])
438     plt.xlim(2457961-2457961, 2460001-2457961)
439
440     # Definir intervalo do eixo Y
441     plt.ylim(0, 6.5)
442
443     # Adicionar linhas horizontais em intervalos de 0.5 de altura
444     y_ticks = plt.yticks()[0]
445     for y in y_ticks:
446         plt.axhline(y, color='black', linestyle='--', alpha=0.3)
447
448     # Definir tamanho do plot
449     fig.set_size_inches(20, 5)
450
451     # Definir rótulos dos eixos e título do gráfico
452     plt.xlabel('Data')
453     plt.ylabel('Evapotranspiração da classe ' + column)
454     plt.title('Evapotranspiração diária da classe ' + column + ' de 1 de janeiro de
455             2017 a 20 de março de 2023')
456
457     # Exibir legenda
458     plt.legend()
459
460     # Exibir o gráfico
461     plt.show()
462
463 ###
464 # Plotar gráficos para cada coluna do eixo Y
465 fig, ax = plt.subplots()
466
467 plt.plot(df_eto['DIA'], df_eto['FAO 56PM ETo (mm/h)'], color='cyan')
468
469 # Definir os rótulos personalizados no eixo X
470 plt.xticks([2458120, 2458485, 2458850, 2459216, 2459581, 2459946], ['2018', '2019',
471                '2020', '2021', '2022', '2023'])
472 plt.xlim(2457961, 2460001)
473
474 # Definir intervalo do eixo Y
475 plt.ylim(0, 6.5)
476
477 # Adicionar linhas horizontais em intervalos de 0.5 de altura
478 y_ticks = plt.yticks()[0]

```



```

476 for y in y_ticks:
477     plt.axhline(y, color='black', linestyle='--', alpha=0.3)
478
479 # Definir tamanho do plot
480 fig.set_size_inches(20, 5)
481
482 # Definir rótulos dos eixos e título do gráfico
483 plt.xlabel('Data')
484 plt.ylabel('Evapotranspiração da classe ')
485 plt.title('Evapotranspiração diária da classe de 1 de janeiro de 2017 a 20 de março
de 2023')
486
487 # Exibir legenda
488 plt.legend()
489
490 # Exibir o gráfico
491 plt.show()
492
493 $$$
494
495 a=2457817
496
497 while a <= (2460024):
498     c = (df_eto['DIA'] == a).idxmax()
499     if a in dados['Data Juliana']:
500         b = dados['Data Juliana'].index(a)
501         with rasterio.open(dados['Endereço'][b]) as src:
502
503             # Recortar a imagem para o polígono de interesse usando a função 'mask'
do Rasterio
504             out_image, out_transform = mask(src, gdf.geometry, crop=True)
505
506             # Transformar o valor de ETF entre 0 e 1
507             out_image = out_image / 10000
508
509             # Definir ETO
510             d = df_eto['FAO 56PM ETo (mm/h)'][c]
511
512             # Definir valores abaixo de zero como NaN
513             out_image[out_image < 0] = np.nan
514
515             # Define a escala de cores para a imagem
516             vmin, vmax = 0, np.nanmax(out_image)
517             # Define a escala de cores ignorando valores menores que zero
518             norm = Normalize(vmin=vmin, vmax=1, clip=True)
519
520             # Define a cor dos valores NaN como branco
521             cmap = plt.cm.RdYlBu
522             cmap.set_bad(color='w')
523
524             # Plota a imagem
525             plt.imshow(out_image[0], cmap=cmap, norm=norm)
526             plt.colorbar()
527             plt.title(dados['Data'][b])
528             plt.show()
529             a = a + 1
530         else:
531             a = a + 1
532
533 $$$
534
535 dia = 31
536 mes = 12
537 ano = 2017
538
539 a = (14 - mes) // 12
540 y = ano + 4800 - a
541 m = mes + 12 * a - 3
542
543 numero_juliano = dia + ((153 * m + 2) // 5) + 365 * y + (y // 4) - (y // 100) + (y //
400) - 32045
544 print(2458119-2457755+1)

```

```

545
546 ###
547
548 A = 2457960
549
550 while A <= 2460001:
551     menor_distancia = float('inf')
552     valor_mais_proximo = None
553
554     for num in dados['Data Juliana']:
555         if num > A and num - A < menor_distancia:
556             menor_distancia = num - A
557             valor_mais_proximo = num
558
559     if valor_mais_proximo is None:
560         break
561
562     print(valor_mais_proximo)
563     A = valor_mais_proximo
564
565 ### -- coding: utf-8 --
566
567
568
569 import rasterio
570 from rasterio.mask import mask
571 import numpy as np
572 import pandas as pd
573 import geopandas as gpd
574 import matplotlib.pyplot as plt
575 from matplotlib.colors import Normalize
576 from datetime import datetime
577 import os
578 import glob
579 #from datetime import datetime, timedelta
580
581 ### Função para converter em número juliano
582
583 def data_para_numero_juliano(data):
584     data_formatada = datetime.strptime(data, '%Y%m%d')
585     ano = data_formatada.year
586     mes = data_formatada.month
587     dia = data_formatada.day
588
589     a = (14 - mes) // 12
590     y = ano + 4800 - a
591     m = mes + 12 * a - 3
592
593     numero_juliano = dia + ((153 * m + 2) // 5) + 365 * y + (y // 4) - (y // 100) + (y
594         // 400) - 32045
595
596     return numero_juliano
597
598 ### Função para converter Juliano em yyyyymmdd
599
600 def julian_to_date(julian_date):
601     A = julian_date
602     E = int((A-1867216.25)/36524.25)
603     D = A + 1 + E - int(E/4)
604     F = D + 1524
605     G = int(((F - 122.1) / 365.25))
606     H = int((G * 365.25))
607     I = int(((F - H) / 30.6001))
608     J = F - H - int(I * 30.6001)
609
610     if I <14:
611         K = I - 1
612     else:
613         K = I - 13
614
615     if K > 2:
616         L = G - 4716

```

```

616     else:
617         L = G - 4715
618
619     if L > 0:
620         M = L
621     else:
622         M = L*(-1) + 1
623
624     if J < 10:
625         dia = str(J)
626         dia = '0'+dia
627
628     else:
629         dia = str(J)
630
631     if K < 10:
632         mes = str(K)
633         mes = '0'+mes
634
635     else:
636         mes = str(K)
637
638     ano = str(M)
639
640     data = ano+mes+dia
641
642     return data
643
644     ### Função para criar uma pasta com o nome das imagens
645
646     def listar_imagens_etf(caminho_pasta):
647         lista_imagens = []
648         formato_imagem = '*.ETF.tif' # Identifica as imagens terminadas em "ETF.tif"
649
650         padrao_arquivos = os.path.join(caminho_pasta, formato_imagem)
651         lista_imagens.extend(glob.glob(padrao_arquivos))
652
653         return lista_imagens
654
655     ### Criar lista de imagens com menos de 70% de NoData
656
657     pasta = 'C:/bcc/GIS/Collection2/extracted ETF_ETA_bands' # Caminho para a pasta
658     lista_imagens_etf = listar_imagens_etf(pasta)
659     a = 0
660     b = 0
661
662
663     lista_imagens_etf = [linha for linha in lista_imagens_etf if "_219080_" not in linha]
664
665     dados = {'Endereço': [],
666             'Data': [],
667             'Data Juliana': []}
668
669     while a < len(lista_imagens_etf):
670         with rasterio.open(lista_imagens_etf[a]) as src:
671
672             # Carregar o polígono de interesse usando geopandas
673             gdf = gpd.read_file(
674                 'C:/bcc/GIS/Collection2/IC_4/shapefiles/lc_basin_with_lagoon.shp')
675             # Recortar a imagem para o polígono de interesse usando a função 'mask' do
676             Rasterio
677             out_image, out_transform = mask(src, gdf.geometry, crop=True)
678
679             # Calcular a porcentagem de pixels sem dados na imagem recortada
680             no_data_count = np.count_nonzero(out_image == src.nodata)
681             total_pixels = out_image.size
682             nodata_percent = no_data_count / total_pixels * 100
683
684             if nodata_percent < 70 and lista_imagens_etf[a].split('_')[6] != '20181211'
685                 and lista_imagens_etf[a].split('_')[6] != '20220825':
686                 dados['Endereço'].append(lista_imagens_etf[a])

```

```

685         date_str = lista_imagens_etf[a].split('_')[6]
686
687         dados['Data'].append(date_str)
688         dados['Data Juliana'].append(data_para_numero_juliano(date_str))
689
690         a = a + 1
691
692     pd.DataFrame(dados).to_csv('dados.csv')
693
694     ### Recortagem, Interpolação e Plotagem
695
696     a = 2457817
697     df_eto = pd.read_excel(r'C:\tcc\GIS\Collection2\IC_4\Evapotranspiração
Referencial\dados_horarios_refet_04_6.xlsx')
699     gdf2 = gpd.read_file('C:\tcc\GIS\Collection2\IC_4\shapefiles\samples_classes2.shp')
700
701     gdf_dun = gdf2[gdf2['classes'].isin(['DUN'])]
702     gdf_urb = gdf2[gdf2['classes'].isin(['URB'])]
703     gdf_for = gdf2[gdf2['classes'].isin(['FOR'])]
704     gdf_her = gdf2[gdf2['classes'].isin(['HER'])]
705     gdf_agu = gdf2[gdf2['classes'].isin(['REN', 'LBA', 'LCD', 'LCS'])]
706
707     df_medias = pd.DataFrame(columns=['DIA', 'MES', 'ANO', 'DUN', 'URB', 'FOR', 'HER',
'DIA', 'MES', 'ANO', 'DUN', 'URB', 'FOR', 'HER',
'AGU'])
708
709     while a <= (2460024):
710         print(a)
711
712         # Definir menor distância e valor superior e mais próximo de 'a'
713         menor_distancia = float('inf')
714         valor_mais_proximo = None
715
716         # Índice da ETO de determinado dia
717         c = (df_eto['DIA'] == a).idxmax()
718
719         if a in dados['Data Juliana']:
720
721             if a < 2460024:
722                 for num in dados['Data Juliana']:
723                     if num > a and num - a < menor_distancia:
724                         menor_distancia = num - a
725                         valor_mais_proximo = num
726
727                 a1 = valor_mais_proximo
728                 b1 = dados['Data Juliana'].index(a1)
729
730             b = dados['Data Juliana'].index(a)
731             with rasterio.open(dados['Endereço'][b]) as src:
732
733                 # Recortar a imagem para o polígono de interesse usando a função 'mask'
734                 do Rasterio
735                 out_image, out_transform = mask(src, gdf.geometry, crop=True)
736                 im_dun, out_transform = mask(src, gdf_dun.geometry, crop=True)
737                 im_urb, out_transform = mask(src, gdf_urb.geometry, crop=True)
738                 im_for, out_transform = mask(src, gdf_for.geometry, crop=True)
739                 im_her, out_transform = mask(src, gdf_her.geometry, crop=True)
740                 im_agu, out_transform = mask(src, gdf_agu.geometry, crop=True)
741
742                 # Transformar o valor de ETF entre 0 e 1
743                 out_image = out_image / 10000
744                 im_dun = im_dun / 10000
745                 im_urb = im_urb / 10000
746                 im_for = im_for / 10000
747                 im_her = im_her / 10000
748                 im_agu = im_agu / 10000
749
750                 # Definir ETO
751                 d = df_eto['FAO 56PM ETo (mm/h)'][c]
752
753                 # Multiplicar por ETO e encontrar ETR
754                 out_image = out_image * d

```



```

754         im_dun = im_dun * d
755         im_urb = im_urb * d
756         im_for = im_for * d
757         im_her = im_her * d
758         im_agu = im_agu * d
759
760         # Definir valores abaixo de zero como NaN
761         out_image[out_image < 0] = np.nan
762         im_dun[im_dun < 0] = np.nan
763         im_urb[im_urb < 0] = np.nan
764         im_for[im_for < 0] = np.nan
765         im_her[im_her < 0] = np.nan
766         im_agu[im_agu < 0] = np.nan
767
768         # Média das classes
769         media_dun = np.nanmean(im_dun)
770         media_urb = np.nanmean(im_urb)
771         media_for = np.nanmean(im_for)
772         media_her = np.nanmean(im_her)
773         media_agu = np.nanmean(im_agu)
774
775         #Adicionar data em yyyyymmdd
776         data = julian_to_date(a)
777         mes = data[4:6]
778         ano = data[:4]
779
780         # Adicionar médias ao dataframe
781         linha_medias = {'DIA':str(a), 'MES':int(mes), 'ANO':int(ano), 'DUN':
782             media_dun, 'URB':media_urb, 'FOR':media_for, 'HER':media_her, 'AGU':
783             media_agu}
784         # df_medias = df_medias.loc(linha_medias, ignore_index=True)
785         df_medias.loc[len(df_medias)] = linha_medias
786
787         # Define a escala de cores para a imagem
788         vmin, vmax = 0, np.nanmax(out_image)
789         # Define a escala de cores ignorando valores menores que zero
790         norm = Normalize(vmin=vmin, vmax=6.5, clip=True)
791
792         # Define a cor dos valores NaN como branco
793         cmap = plt.cm.RdYlBu
794         cmap.set_bad(color='w')
795
796         # Plota a imagem
797         plt.imshow(out_image[0], cmap=cmap, norm=norm)
798         plt.colorbar()
799         plt.title(dados['Data'][b])
800         plt.show()
801         a = a + 1
802     else:
803         if a == 2458080 or a == 2458081 or a == 2458176:
804             a = a + 1
805         else:
806             with rasterio.open(dados['Endereço'][b]) as src:
807                 with rasterio.open(dados['Endereço'][b1]) as src2:
808
809                     # Recortar a imagem para o polígono de interesse usando a função
810                     'mask' do Rasterio
811                     out_image1, out_transform = mask(src, gdf.geometry, crop=True)
812                     out_image2, out_transform = mask(src2, gdf.geometry, crop=True)
813                     im_dun1, out_transform = mask(src, gdf_dun.geometry, crop=True)
814                     im_dun2, out_transform = mask(src2, gdf_dun.geometry, crop=True)
815                     im_urb1, out_transform = mask(src, gdf_urb.geometry, crop=True)
816                     im_urb2, out_transform = mask(src2, gdf_urb.geometry, crop=True)
817                     im_for1, out_transform = mask(src, gdf_for.geometry, crop=True)
818                     im_for2, out_transform = mask(src2, gdf_for.geometry, crop=True)
819                     im_her1, out_transform = mask(src, gdf_her.geometry, crop=True)
820                     im_her2, out_transform = mask(src2, gdf_her.geometry, crop=True)
821                     im_agu1, out_transform = mask(src, gdf_agu.geometry, crop=True)
822                     im_agu2, out_transform = mask(src2, gdf_agu.geometry, crop=True)
823
824                     # Pesos das imagens 1 e 2
825                     p1 = (dados['Data Juliana'][b1] - a) / (dados['Data Juliana'][b1]

```

```

- dados['Data Juliana'][b])
823 p2 = (a - dados['Data Juliana'][b]) / (dados['Data Juliana'][b] -
      dados['Data Juliana'][b])
824
825 # Encontrar a maior forma entre as duas arrays
826 max_shape = np.max([out_image1.shape, out_image2.shape], axis=0)
827 max_shape_dun = np.max([im_dun1.shape, im_dun2.shape], axis=0)
828 max_shape_urb = np.max([im_urb1.shape, im_urb2.shape], axis=0)
829 max_shape_for = np.max([im_for1.shape, im_for2.shape], axis=0)
830 max_shape_her = np.max([im_her1.shape, im_her2.shape], axis=0)
831 max_shape_agu = np.max([im_agu1.shape, im_agu2.shape], axis=0)
832
833 # Calcular o valor de preenchimento
834 fill_value = np.min([out_image1.min(), out_image2.min()])
835 fill_value_dun = np.min([im_dun1.min(), im_dun2.min()])
836 fill_value_urb = np.min([im_urb1.min(), im_urb2.min()])
837 fill_value_for = np.min([im_for1.min(), im_for2.min()])
838 fill_value_her = np.min([im_her1.min(), im_her2.min()])
839 fill_value_agu = np.min([im_agu1.min(), im_agu2.min()])
840
841 # Ajustar as formas das arrays mantendo os dados alinhados
842 new_shape = (1, max_shape[1], max_shape[2])
843 new_shape_dun = (1, max_shape_dun[1], max_shape_dun[2])
844 new_shape_urb = (1, max_shape_urb[1], max_shape_urb[2])
845 new_shape_for = (1, max_shape_for[1], max_shape_for[2])
846 new_shape_her = (1, max_shape_her[1], max_shape_her[2])
847 new_shape_agu = (1, max_shape_agu[1], max_shape_agu[2])
848
849 if im_dun1.shape != new_shape_dun:
850     pad_width = [(0, 0)]
851     for i in range(1, len(new_shape_dun)):
852         pad_width.append((0, max_shape_dun[i] - im_dun1.shape[i]))
853     im_dun1 = np.pad(im_dun1, pad_width, mode='constant',
854                     constant_values=fill_value_dun)
855
856 if im_dun2.shape != new_shape_dun:
857     pad_width = [(0, 0)]
858     for i in range(1, len(new_shape_dun)):
859         pad_width.append((0, max_shape_dun[i] - im_dun2.shape[i]))
860     im_dun2 = np.pad(im_dun2, pad_width, mode='constant',
861                     constant_values=fill_value_dun)
862
863 if im_urb1.shape != new_shape_her:
864     pad_width = [(0, 0)]
865     for i in range(1, len(new_shape_urb)):
866         pad_width.append((0, max_shape_urb[i] - im_urb1.shape[i]))
867     im_urb1 = np.pad(im_urb1, pad_width, mode='constant',
868                     constant_values=fill_value_urb)
869
870 if im_urb2.shape != new_shape_her:
871     pad_width = [(0, 0)]
872     for i in range(1, len(new_shape_urb)):
873         pad_width.append((0, max_shape_urb[i] - im_urb2.shape[i]))
874     im_urb2 = np.pad(im_urb2, pad_width, mode='constant',
875                     constant_values=fill_value_urb)
876
877 if im_for1.shape != new_shape_for:
878     pad_width = [(0, 0)]
879     for i in range(1, len(new_shape_for)):
880         pad_width.append((0, max_shape_for[i] - im_for1.shape[i]))
881     im_for1 = np.pad(im_for1, pad_width, mode='constant',
882                     constant_values=fill_value_for)
883
884 if im_for2.shape != new_shape_for:
885     pad_width = [(0, 0)]
886     for i in range(1, len(new_shape_for)):
887         pad_width.append((0, max_shape_for[i] - im_for2.shape[i]))
888     im_for2 = np.pad(im_for2, pad_width, mode='constant',
889                     constant_values=fill_value_for)
890
891 if im_her1.shape != new_shape_her:
892     pad_width = [(0, 0)]
893     for i in range(1, len(new_shape_her)):
894         pad_width.append((0, max_shape_her[i] - im_her1.shape[i]))
895     im_her1 = np.pad(im_her1, pad_width, mode='constant',
896                     constant_values=fill_value_her)
897
898 if im_her2.shape != new_shape_her:
899     pad_width = [(0, 0)]
900     for i in range(1, len(new_shape_her)):
901         pad_width.append((0, max_shape_her[i] - im_her2.shape[i]))
902     im_her2 = np.pad(im_her2, pad_width, mode='constant',
903                     constant_values=fill_value_her)
904
905 if im_agu1.shape != new_shape_agu:
906     pad_width = [(0, 0)]
907     for i in range(1, len(new_shape_agu)):
908         pad_width.append((0, max_shape_agu[i] - im_agu1.shape[i]))
909     im_agu1 = np.pad(im_agu1, pad_width, mode='constant',
910                     constant_values=fill_value_agu)
911
912 if im_agu2.shape != new_shape_agu:
913     pad_width = [(0, 0)]
914     for i in range(1, len(new_shape_agu)):
915         pad_width.append((0, max_shape_agu[i] - im_agu2.shape[i]))
916     im_agu2 = np.pad(im_agu2, pad_width, mode='constant',
917                     constant_values=fill_value_agu)

```

```

887         for i in range(1, len(new_shape_dun)):
888             pad_width.append((0, max_shape_her[i] - im_her1.shape[i]))
889         im_her1 = np.pad(im_her1, pad_width, mode='constant',
890                         constant_values=fill_value_her)
891
892     if im_her2.shape != new_shape_her:
893         pad_width = [(0, 0)]
894         for i in range(1, len(new_shape_dun)):
895             pad_width.append((0, max_shape_her[i] - im_her2.shape[i]))
896         im_her2 = np.pad(im_her2, pad_width, mode='constant',
897                         constant_values=fill_value_her)
898
899     if im_agu1.shape != new_shape_agu:
900         pad_width = [(0, 0)]
901         for i in range(1, len(new_shape_dun)):
902             pad_width.append((0, max_shape_agu[i] - im_agu1.shape[i]))
903         im_agu1 = np.pad(im_agu1, pad_width, mode='constant',
904                         constant_values=fill_value_agu)
905
906     if im_agu2.shape != new_shape_agu:
907         pad_width = [(0, 0)]
908         for i in range(1, len(new_shape_dun)):
909             pad_width.append((0, max_shape_agu[i] - im_agu2.shape[i]))
910         im_agu2 = np.pad(im_agu2, pad_width, mode='constant',
911                         constant_values=fill_value_agu)
912
913     if out_image1.shape != new_shape:
914         pad_width = [(0, 0)]
915         for i in range(1, len(new_shape)):
916             pad_width.append((0, max_shape[i] - out_image1.shape[i]))
917         out_image1 = np.pad(out_image1, pad_width, mode='constant',
918                             constant_values=fill_value)
919
920     if out_image2.shape != new_shape:
921         pad_width = [(0, 0)]
922         for i in range(1, len(new_shape)):
923             pad_width.append((0, max_shape[i] - out_image2.shape[i]))
924         out_image2 = np.pad(out_image2, pad_width, mode='constant',
925                             constant_values=fill_value)
926
927     # Calcular imagem intermediária
928     out_image = out_image1 * p1 + out_image2 * p2
929     im_dun = im_dun1 * p1 + im_dun2 * p2
930     im_urb = im_urb1 * p1 + im_urb2 * p2
931     im_for = im_for1 * p1 + im_for2 * p2
932     im_her = im_her1 * p1 + im_her2 * p2
933     im_agu = im_agu1 * p1 + im_agu2 * p2
934
935     # Transformar o valor de ETF entre 0 e 1
936     out_image = out_image / 10000
937     im_dun = im_dun / 10000
938     im_urb = im_urb / 10000
939     im_for = im_for / 10000
940     im_her = im_her / 10000
941     im_agu = im_agu / 10000
942
943     # Definir ETO
944     d = df_eto['FAO 56PM ETo (mm/h)'][c]
945
946     # Multiplicar por ETO e encontrar ETR
947     out_image = out_image * d
948     im_dun = im_dun * d
949     im_urb = im_urb * d
950     im_for = im_for * d
951     im_her = im_her * d
952     im_agu = im_agu * d
953
954     # Aplicar a máscara para substituir os valores negativos por NaN
955     out_image[out_image1 < 0] = np.nan
956     out_image[out_image2 < 0] = np.nan
957     im_dun[im_dun1 < 0] = np.nan
958     im_dun[im_dun2 < 0] = np.nan

```



```

953     im_urb[im_urb1 < 0] = np.nan
954     im_urb[im_urb2 < 0] = np.nan
955     im_for[im_for1 < 0] = np.nan
956     im_for[im_for2 < 0] = np.nan
957     im_her[im_her1 < 0] = np.nan
958     im_her[im_her2 < 0] = np.nan
959     im_agu[im_agu1 < 0] = np.nan
960     im_agu[im_agu2 < 0] = np.nan
961
962     # Média das classes
963     media_dun = np.nanmean(im_dun)
964     media_urb = np.nanmean(im_urb)
965     media_for = np.nanmean(im_for)
966     media_her = np.nanmean(im_her)
967     media_agu = np.nanmean(im_agu)
968
969     #Adicionar data em yyyyymmdd
970     data = julian_to_date(a)
971     mes = data[4:6]
972     ano = data[:4]
973
974     # Adicionar médias ao dataframe
975     linha_medias = {'DIA':str(a), 'MES': int(mes), 'ANO': int(ano),
976                   'DUN':media_dun, 'URB':media_urb, 'FOR':media_for, 'HER':media_her,
977                   'AGU':media_agu}
978     #df_medias = df_medias.append(linha_medias, ignore_index=True)
979     df_medias.loc[len(df_medias)] = linha_medias
980
981     # Define a escala de cores para a imagem
982     vmin, vmax = 0, np.nanmax(out_image)
983     # Define a escala de cores ignorando valores menores que zero
984     norm = Normalize(vmin=vmin, vmax=6.5, clip=True)
985
986     # Define a cor dos valores NaN como branco
987     cmap = plt.cm.RdYlBu
988     cmap.set_bad(color='w')
989
990     # Plota a imagem
991     plt.imshow(out_image[0], cmap=cmap, norm=norm)
992     plt.colorbar()
993     plt.title(data)
994     plt.show()
995     a = a + 1
996
997     ### Criar dataframe com dados mensais
998     df_medias.to_csv('df_medias.csv')
999     ano = 2017
1000     mes = 3
1001     x = 0
1002
1003     df_medias_mes = pd.DataFrame(columns=['X', 'DUN', 'DUN_desv', 'DUN_min', 'DUN_max',
1004     'DUN_mdn',
1005     'URB', 'URB_desv', 'URB_min', 'URB_max',
1006     'URB_mdn',
1007     'FOR', 'FOR_desv', 'FOR_min', 'FOR_max',
1008     'FOR_mdn',
1009     'HER', 'HER_desv', 'HER_min', 'HER_max',
1010     'HER_mdn',
1011     'AGU', 'AGU_desv', 'AGU_min', 'AGU_max',
1012     'AGU_mdn'])
1013
1014     while ano <= 2023:
1015         while mes <= 12:
1016             mes_dun = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
1017                 'DUN'].sum()
1018             desv_dun = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
1019                 'DUN'].std()
1020             min_dun = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
1021                 'DUN'].min()
1022             max_dun = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][

```



```

'DUN'].max()
1015 mdn_dun = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'DUN'].median()
1016
1017 mes_urb = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'URB'].sum()
1018 desv_urb = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'URB'].std()
1019 min_urb = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'URB'].min()
1020 max_urb = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'URB'].max()
1021 mdn_urb = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'URB'].median()
1022
1023 mes_for = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'FOR'].sum()
1024 desv_for = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'FOR'].std()
1025 min_for = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'FOR'].min()
1026 max_for = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'FOR'].max()
1027 mdn_for = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'FOR'].median()
1028
1029 mes_her = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'HER'].sum()
1030 desv_her = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'HER'].std()
1031 min_her = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'HER'].min()
1032 max_her = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'HER'].max()
1033 mdn_her = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'HER'].median()
1034
1035 mes_agu = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'AGU'].sum()
1036 desv_agu = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'AGU'].std()
1037 min_agu = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'AGU'].min()
1038 max_agu = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'AGU'].max()
1039 mdn_agu = df_medias[(df_medias['ANO'] == ano) & (df_medias['MES'] == mes)][
'AGU'].median()
1040
1041 linha_mes = {'X': x, 'DUN': mes_dun, 'DUN_desv': desv_dun, 'DUN_min': min_dun,
'DUN_max': max_dun,
1042             'DUN_mdn': mdn_dun,
1043             'URB': mes_urb, 'URB_desv': desv_urb, 'URB_min': min_urb,
'URB_max': max_urb,
1044             'URB_mdn': mdn_urb,
1045             'FOR': mes_for, 'FOR_desv': desv_for, 'FOR_min': min_for,
'FOR_max': max_for,
1046             'FOR_mdn': mdn_for,
1047             'HER': mes_her, 'HER_desv': desv_her, 'HER_min': min_her,
'HER_max': max_her,
1048             'HER_mdn': mdn_her,
1049             'AGU': mes_agu, 'AGU_desv': desv_agu, 'AGU_min': min_agu,
'AGU_max': max_agu,
1050             'AGU_mdn': mdn_agu}
1051
1052 df_medias_mes.loc[len(df_medias_mes)] = linha_mes
1053
1054 x = x + 1
1055 mes = mes + 1
1056 if mes == 4 and ano == 2023:
1057     mes = 13
1058
1059 mes = 1

ano = ano + 1
1060
1061
1062
1063

```

**APÊNDICE C – Comparação Estatística Entre A ET Real Da Nasa E A ET
Real Calculada Para Cada Classe De Solo Da Bacia**

DATA	DUNAS			
	ETR NASA (mm/dia)	ETR calculada (mm/dia)	DIFERENÇA ABSOLUTA	DIFERENÇA RELATIVA
4/3/2017	0,94	0,81	0,14	14,38
12/4/2017	2,58	2,41	0,17	6,48
28/4/2017	2,06	1,77	0,29	14,13
14/5/2017	1,74	1,51	0,23	13,24
1/7/2017	1,16	1,09	0,07	5,96
26/7/2017	1,48	1,62	-0,14	-9,58
18/8/2017	1,47	1,58	-0,11	-7,39
8/4/2018	1,89	1,71	0,18	9,74
24/4/2018	1,44	1,34	0,10	6,89
13/7/2018	1,66	1,47	0,19	11,67
14/8/2018	1,41	1,44	-0,03	-2,30
6/9/2018	1,35	1,31	0,05	3,47
22/9/2018	1,26	1,53	-0,27	-21,49
4/12/2018	1,95	2,01	-0,06	-2,91
28/1/2019	3,14	3,51	-0,37	-11,80
2/4/2019	1,01	0,87	0,14	13,79
18/4/2019	1,81	1,54	0,27	14,74
20/5/2019	1,66	1,26	0,41	24,40
29/5/2019	1,91	1,58	0,33	17,26
16/7/2019	2,16	1,83	0,33	15,42
23/7/2019	1,15	1,07	0,08	6,57
11/10/2019	1,88	2,18	-0,30	-15,89
7/12/2019	3,58	3,36	0,22	6,13
12/3/2020	0,79	0,71	0,08	9,86
19/3/2020	2,06	1,88	0,17	8,43
4/4/2020	1,23	1,03	0,20	16,23
20/4/2020	1,31	1,09	0,21	16,12

29/4/2020	2,11	1,77	0,34	16,19
31/5/2020	1,48	1,27	0,21	13,93
7/6/2020	1,64	1,31	0,33	19,90
3/8/2020	1,68	1,57	0,11	6,58
10/8/2020	1,24	1,28	-0,05	-3,83
9/12/2020	2,58	2,01	0,57	22,07
18/2/2021	1,64	1,74	-0,10	-6,10
27/2/2021	0,80	0,54	0,26	32,59
6/3/2021	3,29	2,49	0,79	24,10
31/3/2021	2,44	1,87	0,57	23,33
2/5/2021	2,53	1,99	0,54	21,28
18/5/2021	1,61	1,27	0,35	21,57
25/5/2021	1,58	1,25	0,33	20,89
12/7/2021	1,42	1,12	0,31	21,60
28/7/2021	1,97	1,54	0,43	21,86
25/10/2021	1,74	1,98	-0,24	-13,73
5/1/2022	3,62	2,58	1,03	28,60
20/1/2022	1,99	2,20	-0,21	-10,73
5/2/2022	0,96	0,93	0,03	2,71
13/2/2022	2,02	2,10	-0,07	-3,64
18/3/2022	1,87	1,87	0,00	0,05
19/4/2022	1,59	1,26	0,32	20,43
12/5/2022	1,85	1,66	0,19	10,50
20/5/2022	1,61	1,39	0,21	13,17
21/5/2022	1,86	1,51	0,35	18,92
13/6/2022	1,26	1,13	0,13	10,12
30/6/2022	1,80	1,56	0,24	13,23
31/7/2022	1,60	1,54	0,06	3,77
1/8/2022	1,47	1,56	-0,09	-5,86
1/9/2022	1,11	1,19	-0,09	-7,99
28/10/2022	1,41	1,75	-0,34	-23,86
4/11/2022	1,55	1,51	0,04	2,37
14/12/2022	1,95	1,58	0,37	18,97

31/12/2022	2,88	2,76	0,12	4,21
24/1/2023	2,15	2,45	-0,30	-13,83
1/2/2023	2,16	2,21	-0,05	-2,34
20/3/2023	0,65	0,62	0,02	3,82

URBANO				
DATA	ETR NASA (mm/dia)	ETR calculada(mm/dia)	DIFERENÇA ABSOLUTA	DIFERENÇA RELATIVA
4/3/2017	0,93	0,78	0,14	15,46
12/4/2017	1,88	1,75	0,13	6,89
28/4/2017	1,50	1,27	0,23	15,39
14/5/2017	1,64	1,41	0,24	14,48
1/7/2017	0,99	0,92	0,06	6,29
26/7/2017	1,25	1,35	-0,11	-8,46
18/8/2017	1,12	1,20	-0,08	-7,56
8/4/2018	1,99	1,78	0,21	10,63
24/4/2018	1,62	1,50	0,12	7,51
13/7/2018	1,31	1,15	0,15	11,80
14/8/2018	1,33	1,37	-0,05	-3,40
6/9/2018	1,47	1,42	0,05	3,09
22/9/2018	1,27	1,55	-0,28	-21,66
4/12/2018	1,54	1,59	-0,05	-3,24
28/1/2019	2,55	2,87	-0,32	-12,39
2/4/2019	0,82	0,71	0,12	14,36
18/4/2019	1,77	1,49	0,28	15,93
20/5/2019	1,61	1,20	0,41	25,40
29/5/2019	1,63	1,32	0,30	18,63
16/7/2019	1,80	1,53	0,27	15,14
23/7/2019	0,99	0,91	0,07	7,54
11/10/2019	1,31	1,52	-0,21	-15,74
7/12/2019	2,23	2,10	0,14	6,07
12/3/2020	1,60	1,42	0,18	11,09

19/3/2020	1,73	1,57	0,15	8,82
4/4/2020	1,28	1,06	0,22	17,07
20/4/2020	1,43	1,19	0,24	16,87
29/4/2020	1,54	1,28	0,26	17,17
31/5/2020	1,43	1,22	0,21	14,98
7/6/2020	1,36	1,08	0,28	20,60
3/8/2020	1,34	1,25	0,09	6,69
10/8/2020	1,18	1,21	-0,04	-3,24
9/12/2020	2,15	1,68	0,47	22,02
18/2/2021	1,83	1,94	-0,11	-6,13
27/2/2021	0,80	0,54	0,26	32,46
6/3/2021	2,58	1,95	0,63	24,47
31/3/2021	1,97	1,50	0,47	23,86
2/5/2021	1,83	1,43	0,40	21,72
18/5/2021	1,61	1,25	0,36	22,53
25/5/2021	1,24	0,97	0,27	21,65
12/7/2021	1,07	0,83	0,24	22,28
28/7/2021	1,50	1,18	0,32	21,59
25/10/2021	1,40	1,59	-0,19	-13,84
5/1/2022	2,30	1,64	0,66	28,69
20/1/2022	2,09	2,31	-0,22	-10,68
5/2/2022	1,24	1,21	0,03	2,60
13/2/2022	2,12	2,19	-0,07	-3,36
18/3/2022	1,67	1,66	0,01	0,65
19/4/2022	1,71	1,35	0,36	21,04
12/5/2022	1,58	1,39	0,18	11,70
20/5/2022	1,25	1,07	0,18	14,07
21/5/2022	1,60	1,28	0,32	19,97
13/6/2022	0,96	0,85	0,11	11,45
30/6/2022	1,54	1,34	0,20	13,07
31/7/2022	1,18	1,13	0,05	3,93
1/8/2022	1,32	1,40	-0,08	-6,40
1/9/2022	1,14	1,25	-0,10	-9,17

28/10/2022	1,32	1,64	-0,31	-23,58
4/11/2022	1,53	1,50	0,03	2,09
14/12/2022	1,63	1,32	0,31	18,77
31/12/2022	2,23	2,14	0,09	3,90
24/1/2023	2,09	2,37	-0,28	-13,43
1/2/2023	1,92	1,97	-0,05	-2,58
20/3/2023	1,21	1,16	0,05	4,47

FLORESTA

DATA	ETR NASA (mm/dia)	ETR calculada(mm/dia)	DIFERENÇA ABSOLUTA	DIFERENÇA RELATIVA
4/3/2017	4,00	3,40	0,59	14,84
12/4/2017	3,01	2,81	0,20	6,59
28/4/2017	2,55	2,17	0,38	14,82
14/5/2017	2,58	2,22	0,36	13,82
1/7/2017	1,47	1,38	0,08	5,76
26/7/2017	1,58	1,72	-0,14	-8,94
18/8/2017	1,89	2,03	-0,14	-7,46
8/4/2018	3,96	3,56	0,40	10,19
24/4/2018	3,26	3,03	0,23	7,15
13/7/2018	1,92	1,70	0,22	11,42
14/8/2018	2,34	2,41	-0,08	-3,30
6/9/2018	2,65	2,57	0,08	3,00
22/9/2018	3,02	3,67	-0,66	-21,73
4/12/2018	5,07	5,23	-0,16	-3,17
28/1/2019	4,86	5,46	-0,60	-12,29
2/4/2019	2,73	2,35	0,38	13,98
18/4/2019	3,34	2,82	0,52	15,47
20/5/2019	2,32	1,74	0,58	24,89
29/5/2019	2,41	1,98	0,43	17,99
16/7/2019	2,03	1,73	0,30	14,90
23/7/2019	1,54	1,43	0,11	7,22

11/10/2019	3,42	3,96	-0,54	-15,82
7/12/2019	5,29	4,97	0,33	6,21
12/3/2020	4,05	3,61	0,43	10,73
19/3/2020	3,49	3,19	0,30	8,59
4/4/2020	3,43	2,86	0,57	16,66
20/4/2020	2,99	2,50	0,49	16,40
29/4/2020	2,85	2,37	0,48	16,75
31/5/2020	1,60	1,37	0,23	14,45
7/6/2020	1,64	1,31	0,33	20,29
3/8/2020	1,97	1,85	0,13	6,44
10/8/2020	2,20	2,27	-0,07	-3,37
9/12/2020	5,31	4,14	1,17	22,10
18/2/2021	4,20	4,46	-0,26	-6,16
27/2/2021	1,96	1,33	0,64	32,45
6/3/2021	4,34	3,28	1,06	24,34
31/3/2021	3,55	2,71	0,84	23,73
2/5/2021	3,21	2,53	0,68	21,22
18/5/2021	2,67	2,08	0,59	22,07
25/5/2021	1,95	1,54	0,41	21,15
12/7/2021	1,59	1,24	0,35	21,91
28/7/2021	1,91	1,50	0,40	21,19
25/10/2021	3,62	4,12	-0,50	-13,74
5/1/2022	5,34	3,81	1,54	28,77
20/1/2022	4,90	5,43	-0,53	-10,75
5/2/2022	4,40	4,28	0,12	2,62
13/2/2022	4,74	4,91	-0,17	-3,51
18/3/2022	3,71	3,69	0,02	0,44
19/4/2022	3,36	2,68	0,68	20,13
12/5/2022	2,52	2,24	0,28	11,20
20/5/2022	2,03	1,75	0,28	13,69
21/5/2022	2,51	2,02	0,49	19,45
13/6/2022	1,42	1,26	0,15	10,85
30/6/2022	2,00	1,74	0,25	12,66

31/7/2022	1,88	1,81	0,07	3,56
1/8/2022	2,09	2,22	-0,13	-6,43
1/9/2022	2,60	2,84	-0,23	-8,96
28/10/2022	3,96	4,89	-0,93	-23,59
4/11/2022	4,25	4,16	0,09	2,21
14/12/2022	5,09	4,12	0,96	18,94
31/12/2022	5,20	4,98	0,22	4,16
24/1/2023	4,92	5,59	-0,67	-13,56
1/2/2023	5,02	5,15	-0,13	-2,57
20/3/2023	4,13	3,96	0,17	4,08

GRAMÍNEAS

DATA	ETR NASA (mm/dia)	ETR calculada(mm/dia)	DIFERENÇA ABSOLUTA	DIFERENÇA RELATIVA
4/3/2017	1,34	1,13	0,20	15,32
12/4/2017	1,97	1,84	0,14	6,91
28/4/2017	1,49	1,26	0,23	15,59
14/5/2017	1,51	1,29	0,22	14,79
1/7/2017	0,81	0,76	0,05	6,16
26/7/2017	1,12	1,21	-0,09	-8,08
18/8/2017	0,87	0,94	-0,07	-7,60
8/4/2018	2,54	2,27	0,27	10,56
24/4/2018	1,89	1,75	0,14	7,44
13/7/2018	1,27	1,12	0,15	11,98
14/8/2018	1,40	1,45	-0,05	-3,71
6/9/2018	1,42	1,38	0,04	3,11
22/9/2018	1,28	1,55	-0,28	-21,67
4/12/2018	2,16	2,23	-0,07	-3,21
28/1/2019	3,08	3,46	-0,38	-12,46
2/4/2019	0,87	0,75	0,13	14,39
18/4/2019	1,66	1,39	0,27	16,30

20/5/2019	1,54	1,14	0,39	25,69
29/5/2019	1,70	1,38	0,32	18,87
16/7/2019	1,75	1,48	0,26	15,07
23/7/2019	0,76	0,70	0,06	7,53
11/10/2019	1,26	1,47	-0,20	-15,84
7/12/2019	2,70	2,54	0,17	6,12
12/3/2020	2,15	1,91	0,24	11,10
19/3/2020	1,90	1,74	0,17	8,75
4/4/2020	1,20	0,99	0,21	17,13
20/4/2020	0,99	0,82	0,17	16,96
29/4/2020	1,39	1,15	0,24	17,34
31/5/2020	0,98	0,83	0,15	15,78
7/6/2020	1,03	0,82	0,22	21,02
3/8/2020	1,26	1,18	0,08	6,56
10/8/2020	0,80	0,83	-0,02	-3,11
9/12/2020	2,80	2,18	0,62	22,05
18/2/2021	2,41	2,56	-0,15	-6,14
27/2/2021	1,34	0,91	0,44	32,46
6/3/2021	3,07	2,32	0,75	24,53
31/3/2021	2,20	1,68	0,53	23,91
2/5/2021	1,95	1,52	0,43	21,85
18/5/2021	1,80	1,39	0,41	22,86
25/5/2021	0,99	0,77	0,22	21,80
12/7/2021	1,00	0,77	0,22	22,41
28/7/2021	1,32	1,03	0,28	21,50
25/10/2021	1,78	2,03	-0,25	-13,83
5/1/2022	3,00	2,14	0,86	28,67
20/1/2022	1,82	2,01	-0,19	-10,67
5/2/2022	1,58	1,53	0,04	2,60
13/2/2022	1,94	2,00	-0,07	-3,38
18/3/2022	2,26	2,24	0,02	0,92
19/4/2022	2,01	1,58	0,43	21,24
12/5/2022	1,62	1,43	0,19	11,78

20/5/2022	1,02	0,87	0,15	14,38
21/5/2022	1,68	1,34	0,34	20,24
13/6/2022	0,74	0,65	0,09	11,73
30/6/2022	1,49	1,30	0,20	13,21
31/7/2022	0,96	0,92	0,04	3,93
1/8/2022	1,28	1,36	-0,08	-6,45
1/9/2022	0,94	1,03	-0,09	-9,36
28/10/2022	1,82	2,25	-0,43	-23,55
4/11/2022	1,59	1,55	0,03	2,05
14/12/2022	1,92	1,56	0,36	18,72
31/12/2022	2,95	2,83	0,11	3,83
24/1/2023	2,62	2,97	-0,35	-13,39
1/2/2023	2,43	2,49	-0,06	-2,65
20/3/2023	1,74	1,67	0,08	4,37

LAGOA

DATA	ETR NASA (mm/dia)	ETR calculada(mm/dia)	DIFERENÇA ABSOLUTA	DIFERENÇA RELATIVA
4/3/2017	4,63	3,96	0,67	14,50
12/4/2017	2,91	2,72	0,19	6,40
28/4/2017	2,60	2,23	0,37	14,22
14/5/2017	2,82	2,44	0,37	13,20
1/7/2017	1,48	1,39	0,08	5,65
26/7/2017	2,26	2,48	-0,22	-9,53
18/8/2017	2,39	2,57	-0,18	-7,39
8/4/2018	4,22	3,80	0,41	9,83
24/4/2018	3,38	3,15	0,23	6,86
13/7/2018	2,17	1,93	0,24	11,21
14/8/2018	2,60	2,67	-0,07	-2,65
6/9/2018	3,06	2,96	0,09	3,10
22/9/2018	3,35	4,07	-0,72	-21,65

4/12/2018	5,49	5,66	-0,17	-3,04
28/1/2019	4,98	5,57	-0,60	-11,96
2/4/2019	3,17	2,74	0,43	13,65
18/4/2019	3,61	3,07	0,54	14,91
20/5/2019	2,53	1,92	0,62	24,32
29/5/2019	2,54	2,10	0,44	17,29
16/7/2019	1,88	1,60	0,28	15,12
23/7/2019	2,50	2,33	0,17	6,71
11/10/2019	3,84	4,45	-0,61	-15,89
7/12/2019	5,71	5,36	0,35	6,20
12/3/2020	4,24	3,81	0,43	10,21
19/3/2020	4,41	4,04	0,37	8,37
4/4/2020	3,44	2,88	0,56	16,30
20/4/2020	3,51	2,95	0,56	15,98
29/4/2020	3,29	2,76	0,53	16,23
31/5/2020	2,73	2,35	0,38	13,82
7/6/2020	2,30	1,84	0,45	19,75
3/8/2020	2,56	2,40	0,17	6,44
10/8/2020	2,59	2,69	-0,10	-3,70
9/12/2020	5,72	4,46	1,27	22,12
18/2/2021	4,51	4,78	-0,27	-6,10
27/2/2021	1,03	0,69	0,33	32,58
6/3/2021	4,36	3,31	1,05	24,15
31/3/2021	3,60	2,76	0,85	23,47
2/5/2021	3,41	2,70	0,72	20,94
18/5/2021	2,58	2,03	0,56	21,54
25/5/2021	2,35	1,86	0,48	20,64
12/7/2021	1,91	1,50	0,41	21,32
28/7/2021	1,19	0,93	0,26	21,55
25/10/2021	4,05	4,61	-0,56	-13,83
5/1/2022	5,31	3,79	1,52	28,67
20/1/2022	5,09	5,64	-0,55	-10,81
5/2/2022	5,09	4,96	0,13	2,65

13/2/2022	4,86	5,04	-0,17	-3,58
18/3/2022	4,35	4,35	0,00	0,06
19/4/2022	3,85	3,07	0,78	20,30
12/5/2022	2,37	2,12	0,25	10,64
20/5/2022	2,44	2,12	0,32	13,10
21/5/2022	2,79	2,27	0,53	18,89
13/6/2022	1,97	1,76	0,20	10,24
30/6/2022	1,87	1,63	0,24	12,73
31/7/2022	1,71	1,65	0,06	3,52
1/8/2022	2,25	2,40	-0,14	-6,26
1/9/2022	3,09	3,36	-0,26	-8,51
28/10/2022	4,48	5,54	-1,06	-23,76
4/11/2022	4,48	4,37	0,11	2,37
14/12/2022	5,23	4,24	0,99	18,98
31/12/2022	5,70	5,46	0,24	4,28
24/1/2023	5,29	6,03	-0,73	-13,84
1/2/2023	5,08	5,20	-0,12	-2,43
20/3/2023	4,45	4,28	0,17	3,82
