

JONAT STEFANI JUSTA MARQUES

**Análise de Métodos de Classificação Automática de Uso do Solo Associadas
à Caracterização e Quantificação de Áreas Regadas - Caso de Estudo
Campina de Faro, Algarve**



FACULDADE DE CIÊNCIAS E TECNOLOGIA – FCT

INSTITUTO SUPERIOR DE ENGENHARIA – ISE

FARO, 2024

JONAT STEFANI JUSTA MARQUES

**Análise de Métodos de Classificação Automática de Uso do Solo Associadas
à Caracterização e Quantificação de Áreas Regadas - Caso de Estudo
Campina de Faro, Algarve**

Mestrado em Sistema de Informação Geográfica

Trabalho efetuado sob orientação de:

Prof. Dr. Fernando Miguel Granja Martins

Coorientação: Dr. Luís Ricardo Dias da Costa



FACULDADE DE CIÊNCIAS E TECNOLOGIA – FCT

INSTITUTO SUPERIOR DE ENGENHARIA – ISE

FARO, 2024

**Análise de Métodos de Classificação Automática de Uso do Solo Associadas à
Caracterização e Quantificação de Áreas Regadas - Caso de Estudo Campina de Faro,
Algarve**

Declaração de Autoria do Trabalho

Declaro ser autor deste trabalho, que é original e inédito. Autores e trabalhos consultados estão devidamente citados no texto e constam na listagem de referências incluída.

JONAT STEFANI JUSTA MARQUES

Copyright Jonat Stefani Justa Marques

A Universidade do Algarve reserva para si o direito, em conformidade com o disposto no Código do Direito de Autor e dos Direitos Conexos, de arquivar, reproduzir e publicar a obra, independentemente do meio utilizado, bem como de a divulgar por meio de repositórios científicos e de admitir a sua cópia e distribuição para fins meramente educacionais ou de investigação e não comerciais, conquanto seja dado o devido crédito ao autor e editor respetivos.

Dedicatória

Dedico esta tese de mestrado a todas as pessoas que estiveram ao meu lado durante esta desafiante jornada acadêmica, em especial à minha esposa que, nos momentos mais difíceis, esteve sempre presente para me incentivar. As suas palavras de encorajamento, o apoio incondicional e a crença no meu potencial foram fundamentais para que eu chegasse até aqui.

Gratidão.

Agradecimentos

Quero expressar minha profunda gratidão aos meus orientadores, Prof. Dr. Fernando Miguel Granja Martins e coorientador Dr. Luís Ricardo Dias da Costa, cuja orientação sábia, conhecimento especializado e paciência incansável foram essenciais para o desenvolvimento deste trabalho. Agradeço por terem acreditado em mim e por me terem proporcionado a oportunidade de expandir os meus horizontes académicos.

O projeto eGROUNDWATER tem como objetivo desenvolver sistemas de informação que aprimorem o conhecimento sobre as águas subterrâneas na região atlântica, permitindo o desenho de estratégias inovadoras de adaptação para uma gestão sustentável e eficiente (GA nº 1921). Este projeto integra o programa PRIMA, financiado pelo Programa de Investigação e Inovação Horizon 2020 da União Europeia. E à Universidade do Algarve, pela disponibilização dos dados que sustentaram este trabalho, sem os quais não teria sido possível a concretização desta dissertação.

À minha família e amigos, sou imensamente grato pelo amor, incentivo e compreensão que me concederam durante toda a minha jornada académica. Foram a minha fonte constante de inspiração e força, e sem o vosso apoio, não teria alcançado este marco significativo.

Às pessoas que partilharam os seus conhecimentos e experiências comigo ao longo desta investigação, agradeço sinceramente por sua generosidade e por terem contribuído para o enriquecimento deste estudo.

Por fim, dedico esta dissertação aos profissionais, investigadores e académicos que dedicam suas vidas à busca do conhecimento e à melhoria da sociedade. Que este trabalho possa, de alguma forma, contribuir para a construção de um futuro melhor.

A todos vocês, meu mais profundo agradecimento. Esta dissertação não seria possível sem a presença e apoio de cada um de vocês.

Resumo

A região Algarvia, com um clima temperado de características mediterrânicas, enfrenta uma crescente incidência de fenómenos de seca hidrológica prolongada, o que agrava de forma significativa os desafios relacionados com a escassez de recursos hídricos na região.

A estimativa de valores do consumo de água subterrânea em áreas de regadio na região Algarvia consiste numa variável difícil de controlar e quantificar, não só devido ao elevado número de captações particulares, mas também por causa da variação meteorológica, que afeta os regimes de rega e das áreas regadas.

Através da informação extraída pelo processamento de imagens digitais obtidas por deteção remota, juntamente com os valores das dotações de rega, pretende-se contribuir para estimativas do balanço hídrico do sistema aquífero de Campina de Faro mais precisas.

Neste trabalho, estudou-se a classificação de uso e ocupação do solo para desenvolver uma metodologia de classificação automática de áreas agrícolas e espaços verdes regados, usando imagens de satélite Sentinel-2, aplicados à Campina de Faro. O projeto permitiu caracterizar com precisão as principais culturas agrícolas e espaços verdes regados na área de estudo e estimar o volume de água utilizado na rega com base nas dotações de rega das diferentes culturas. A metodologia desenvolvida é facilmente replicável para diferentes períodos e zonas, oferecendo uma ferramenta útil para a gestão dos recursos hídricos na região do Algarve.

Os resultados obtidos permitiram a classificação das principais áreas e culturas regadas no sistema aquífero, bem como a quantificação da sua variação ao longo do tempo. Para além disso, foram aplicadas dotações de rega oficiais da DGADR, com o objetivo de estimar o volume de água utilizado na rega destas parcelas agrícolas, de forma a quantificar o volume de água extraído do aquífero para a agricultura e golfe. Os valores obtidos estão próximos dos valores oficiais reportados nos Planos de Gestão da Região Hidrográfica, o que demonstra, de certa forma, a fiabilidade dos resultados alcançados com esta metodologia.

Palavras Chave: Escassez hídrica, classificação automática, automatização, quantificação do volume de rega, Aquífero Campina de Faro.

Abstract

The Algarve region, with its temperate climate and Mediterranean characteristics, faces a growing incidence of prolonged hydrological droughts, which significantly exacerbates the challenges related to water scarcity in the region.

Estimating groundwater consumption values in irrigated areas in the Algarve region is a difficult variable to control and quantify, not only due to the high number of private water intakes, but also because of meteorological variations, which affect irrigation regimes and irrigated areas.

The main goal of the present work intends to contribute for more precise estimates of groundwater use at the Campina de Faro aquifer case study (South Portugal) through the use of remote sensing images and their digital processing together with the use of typical irrigation allocation values.

In this work, the classification of land use and occupation was studied to develop a methodology for the automatic classification of agricultural areas and irrigated green spaces, using Sentinel-2 satellite images, applied to Campina de Faro. The project made it possible to accurately characterize the main agricultural crops and irrigated green spaces in the study area and to estimate the volume of water used for irrigation based on the irrigation allocations of the different crops. The methodology developed is easily replicable for different periods and areas, offering a useful tool for water resource management in the Algarve region.

The results obtained allowed the classification of the main areas and crops irrigated in the aquifer system, as well as the quantification of their variation over time. In addition, official irrigation allocations from the DGADR were applied, with the aim of estimating the volume of water used to irrigate these agricultural plots, in order to quantify the volume of water extracted from the aquifer for agriculture and golf. The values obtained are similar to the official values reported in the River Basin Management Plans, which demonstrates, to a certain extent, the reliability of the results achieved with this methodology.

Keywords: Water scarcity, automatic classification, automation, quantification of irrigation volume, Campina de Faro Aquifer.

Índice

Dedicatória	iii
Agradecimentos.....	iv
Resumo	v
Abstract	vi
Índice	vii
Índice de Figuras.....	ix
Índice de Tabelas.....	xi
Índice de Equações.....	xii
Lista de Abreviaturas, Siglas e/ou Símbolos	xiii
1. Introdução.....	1
1.1. CONTEXTUALIZAÇÃO	1
1.2. JUSTIFICATIVAS	2
1.3. OBJETIVOS.....	3
1.4. DETEÇÃO REMOTA NA GESTÃO DE RECURSOS HÍDRICOS	3
1.5. ESTRUTURA DA DISSERTAÇÃO.....	4
2. Estado da Arte sobre Classificação Automática.....	5
2.1. FUZZY ARTMAP.....	6
2.2. MAXLIKE	7
2.3. FISHER (LDA).....	8
2.4. RAW	9
2.5. NORMALIZED	10
2.6. TRABALHOS INTERNACIONAIS SOBRE A CLASSIFICAÇÃO DE ZONAS AGRÍCOLAS E ESPAÇOS VERDES COM DIFERENTES CLASSIFICADORES	11
3. Hidrogeologia do Aquífero Campina de Faro	12
3.1. INTRODUÇÃO	12
3.2. CARACTERIZAÇÃO GEOLÓGICA	12
3.3. PARÂMETROS HIDRODINÂMICOS	13
3.4. RECARGA E DESCARGA	13
3.5. IMPACTOS AMBIENTAIS E USO DA ÁGUA	13
3.6. BALANÇO HIDROGEOLÓGICO	14
3.7. CARACTERIZAÇÃO PIEZOMÉTRICA.....	17
4. Caracterização da Área de Estudo.....	22
4.1. LOCALIZAÇÃO GEOGRÁFICA	22
4.2. GEOLOGIA E RELEVO (GEOMORFOLOGIA)	23
4.3. CARACTERIZAÇÃO CLIMÁTICA DA REGIÃO	26
4.3.1. Precipitação	27
4.3.2. Evapotranspiração Potencial.....	28
4.4. CARACTERIZAÇÃO DO USO E OCUPAÇÃO DO SOLO	30
5. Metodologia.....	41
5.1. DESCRIÇÃO GERAL DA METODOLOGIA	41
5.2. APLICAÇÕES INFORMÁTICAS UTILIZADOS	42
5.3. DADOS E INFORMAÇÃO DE BASE.....	43
5.3.1. Fonte de Dados Climáticos.....	45
5.3.2. Métodos de Análise.....	45
5.4. CLASSIFICAÇÃO MANUAL	46
5.4.1. Fase 1: Inclusão de Novas Áreas	48
5.4.2. Fase 2: Atualização dos Dados Existentes	49
5.5. PARÂMETRO DE REFERÊNCIA PARA DEFINIR VALORES LIMIARES.....	49

5.6.	CLASSIFICAÇÃO AUTOMÁTICA	50
5.6.1.	<i>Fuzzy Artmap</i>	51
5.6.2.	<i>Maxlike</i>	57
5.6.3.	<i>Fisher (LDA)</i>	58
5.6.4.	<i>Raw e Normalized</i>	60
5.6.5.	<i>Segmentação</i>	62
5.7.	ESTIMATIVA DO USO DA ÁGUA NAS ÁREAS REGADAS.....	63
6.	Resultados e Discussão	65
6.1.	CLASSIFICAÇÃO MANUAL	65
6.2.	ESCOLHA DO ÍNDICE VEGETATIVO	68
6.3.	QUANTIFICAÇÃO DE <i>PÍXELS</i> POR ÍNDICE E TIPO DE SOLO	74
6.4.	CLASSIFICAÇÃO SUPERVISIONADA (<i>FUZZY ARTMAP, MAXLIKE, FISCHER, RAW E NORMALIZED</i>).....	74
6.4.1.	<i>Fuzzy Artmap</i>	75
6.4.2.	<i>Maxlike</i>	76
6.4.3.	<i>Fisher (LDA)</i>	79
6.4.4.	<i>Raw</i>	80
6.4.5.	<i>Normalized</i>	81
6.4.6.	<i>Resultados Gerais</i>	82
6.4.7.	<i>Resultados Gerais com Segmentação</i>	85
6.5.	ESTIMATIVA DO VOLUME DE ÁGUA OBTIDO NAS ÁREAS REGADAS	87
6.6.	COMPARAÇÃO DO VOLUME DE ÁGUA OBTIDO NAS ÁREAS REGADAS COM OS VALORES OFICIAIS DO PGRH, PREH E COSTA ALMEIDA (2000).....	94
7.	Conclusão	98
	Bibliografia.....	101
	Anexos	104
	ANEXO 1 – PRECIPITAÇÃO E EVAPOTRANSPIRAÇÃO POTENCIAL DE 2016 A 2023	104
	ANEXO 2 – COS2018	106
	ANEXO 3 – ANÁLISE ESPECTRAL E ÍNDICES DE VEGETAÇÃO DO SENTINEL-2 (2017-2023)	110
	ANEXO 4 – ESTATÍSTICAS DOS ÍNDICES NDVI, NDWI E SAVI.....	163
	ANEXO 5 – DOTAÇÕES DE REGA DE REFERÊNCIA (M ³ /HA) PARA A REGIÃO AGROCLIMÁTICA DO ALGARVE	168
	ANEXO 6 – RESULTADOS DAS RECLASSIFICAÇÕES UTILIZANDO OS ÍNDICES NDVI E NDWI	173
	ANEXO 7 – RESULTADOS DA CONTAGEM DE <i>PÍXEIS</i> PARA CADA TIPO DE CULTURA	177
	ANEXO 8 – RESULTADOS DE CLASSIFICAÇÕES PARA O MÉTODO <i>FUZZY</i>	179
	ANEXO 9 – RESULTADOS COM A FERRAMENTA <i>SIGCOMP</i>	189
	ANEXO 10 – TOTAL HECTARES CLASSIFICADOS POR CULTURA X MÉTODO DE CLASSIFICAÇÃO (2017 A 2023) 195	
	ANEXO 11 – TOTAL HECTARES CLASSIFICADOS SEGMENTADOS POR CULTURA X MÉTODO DE CLASSIFICAÇÃO (2017 A 2023)	199
	ANEXO 12 – DADOS BASE PARA ESTIMAR O VOLUME DE ÁGUA OBTIDO NAS ÁREAS REGADAS	203
	ANEXO 13 – FLUXOGRAMA DA METODOLOGIA	204

Índice de Figuras

Figura 1 - Mapa da rede piezométrica e da rede hidrográfica do Aquífero Campina de Faro.....	19
Figura 2 - Mapa piezométrico do aquífero Campina de Faro	19
Figura 3 - Evolução piezométrica nos dois sectores do Campina de Faro	21
Figura 4 - Níveis piezométricos x Concentrações de cloretos	22
Figura 5 - Localização geográfica da área de estudo.....	23
Figura 6 - Localização do sistema aquífero da Campina de Faro (M12) na Orla Meridional Algarvia.....	24
Figura 7 - Mapa de Declives (%) - Aquífero Campina de Faro	25
Figura 8 - Mapa de Hipsometria - Aquífero Campina de Faro	26
Figura 9 - Valores de precipitação acumulada (mm) para o ano hidrogeológico 2016/2023 da Estação Patacão, Faro	28
Figura 10 - Média mensal da evapotranspiração potencial (ET0) em mm na estação Patacão, Faro	29
Figura 11 - Cartografia Parcial do Uso e Ocupação do Solo no Aquífero Campina de Faro – 2007.....	31
Figura 12 - Mapa de Uso e Ocupação do Solo do Aquífero Campina de Faro para 2021.....	31
Figura 13 - Comparativo entre 2007 (azul) x 2021 (vermelho) do Uso e Ocupação do Solo em hectares	32
Figura 14 - Áreas de Campos de Golfes situados dentro do Aquífero Campina de Faro.....	34
Figura 15 - Ausência de dados sobre as áreas de golfe em 2007	35
Figura 16 - Classificação do uso e ocupação do solo em 2007 (esquerda) e 2021 (direita), destacando abacateiros (verde-escuro) e citrinos (laranja)	35
Figura 17 - Uso e ocupação do solo em 2007 (esquerda) e 2021 (direita): estufas (verde) e estufas abandonadas (verde-claro). Imagem final destaca estufas abandonadas	36
Figura 18 - Mapa de Uso e Ocupação do Solo do Aquífero Campina de Faro para 2018.....	37
Figura 19 - Uso e Ocupação do Solo COS2018 Agricultura	38
Figura 20 - Uso e Ocupação do Solo COS2018 Territórios Artificializados.....	39
Figura 21 - Uso e Ocupação do Solo COS2018 SAF e Florestas	40
Figura 22 - Uso e Ocupação do Solo COS2018 Pastagens	40
Figura 23 - Uso e Ocupação do Solo COS2018 Demais Usos (Matos, Espaços descobertos ou com pouca vegetação, Zonas húmidas e Massas de água superficiais).....	41
Figura 24 - Fluxograma da Metodologia	42
Figura 25 - Delimitação em azul do Aquífero Campina de Faro no Bing Maps Aerial através do software QGIS	47
Figura 26 - Imagem a esquerda Bing Maps 2021 x Imagem a direita Sentinel 2 NVDI 2021	47
Figura 27 - Imagem de um campo de futebol regado - a esquerda Bing Maps 2021 x Imagem a direita Sentinel-2 NVDI 2021 com um valor médio de 0,85 de NDVI.....	48
Figura 28 - Imagem NDVI com valor limiar de 0.20 e as bandas 3, 4 e 8 sobrepostas após a operação Overlay	52
Figura 29 - Imagem raster das 12 classes classificadas como áreas regadas no IDRISI	52
Figura 30 - Mapas das zonas agroclimáticas a considerar na Intervenção	63
Figura 31 - Cenários climáticos a considerar em 2023 para cada zona agroclimática	64
Figura 32 - Imagens do campo de golfe: NDWI (0.15-0.49) à esquerda, Sentinel-2 em RGB ao centro e Bing Maps (2021) com falhas visíveis à direita.....	72
Figura 33 - Campo de golfe: NDVI (0.61-1) à esquerda, Sentinel-2 em RGB ao centro e Bing Maps (2021) com	

falhas visíveis à direita	73
Figura 34 - A esquerda imagem correspondente ao NDVI e a direita imagem correspondente ao NDWI.....	73
Figura 35 - Classificação Fuzzy NDVI 0.20 com 12 classes Aquífero Campina de Faro.....	75
Figura 36 - Classificação Fuzzy dos citrinos para 2021 no período seco, com áreas de treino reduzidas	76
Figura 37 - Classificação Maxlike com 9 classes.....	77
Figura 38 - Classificação Maxlike com as classes de Campos de Golfes e Citrinos.....	77
Figura 39 - Classificação Maxlike dos citrinos (cor laranja) para 2021 período seco.....	78
Figura 40 - Classificação Fisher dos citrinos para 2021 no período seco, com áreas de treino reduzidas	79
Figura 41 - Classificação Fisher dos citrinos para 2021 período seco.....	79
Figura 42 - Classificação Fisher dos citrinos para 2021 no período seco, com áreas de treino simplificadas	80
Figura 43 - Classificação Raw dos citrinos para 2021 período seco	81
Figura 44 - Classificação Raw dos citrinos para 2021 período seco com áreas de treino com menos polígonos	81
Figura 45 - Classificação Normalized dos citrinos (cor laranja) para 2021 período seco	82
Figura 46 - Classificação Normalized dos citrinos para 2021 no período seco, com áreas de treino reduzidas... ..	82
Figura 47 - Classificação Fuzzy de 2021 no Período Seco: sem segmentação (esquerda) e segmentada (direita) com tolerância de similaridade de 10.....	85
Figura 48 - Estimativa de volumes de água: classificação automática vs. manual (2021)	90
Figura 49 - Estimativa de hectares: classificação automática vs. manual (2021)	91

Índice de Tabelas

Tabela 1 - Balanço Hidrogeológico	16
Tabela 2 - Metodologia aplicada para realizar a classificação automática utilizando o método Fuzzy Artmap no Aquífero Campina de Faro	53
Tabela 3 - Tipo de ocupação do solo x Quantidade de áreas classificadas em 2007 x 2021	66
Tabela 4 - Tipo de ocupação x Grau de confiabilidade da classificação manual	67
Tabela 5 - Resumo das alterações de cada tipo de solo	68
Tabela 6 Resultados da reclassificação do uso do solo no aquífero Campina de Faro, comparando NDVI e NDWI com diferentes limiares.....	70
Tabela 7 - Total hectares classificados por cultura x método de classificação - Período Seco 2021	83
Tabela 8 - Total hectares classificados segmentados por cultura x método de classificação - Período Seco 2021	85
Tabela 9 - Valores de rega de referência em m ³ /ha para o método de rega Gota a Gota considerando o ano médio e seco para os anos hidrogeológicos de 2017 a 2023.....	88
Tabela 10 - Estimativa do volume de água obtido em hm ³ nas áreas regadas através da classificação automática para os anos hidrogeológicos de 2017 a 2023	89
Tabela 11 - Estimativa do volume de água obtido em hm ³ nas áreas regadas através da classificação manual para o ano hidrogeológicos de 2021	89
Tabela 12 - Variação percentual do volume de água entre a classificação automática x classificação manual de 2021	89
Tabela 13 - Comparativo volume captado estimados a partir do modelo x valor de extração de acordo com as estimativas oficiais.....	95
Tabela 14 - Recarga média anual do volume de água segundo as estimativas dos principais autores: Almeida et al., (2000), APA (2020) e APA (2022)	95

Índice de Equações

Equação 1 - NDVI	44
Equação 2 - SAVI	44
Equação 3 - NDWI	44

Lista de Abreviaturas, Siglas e/ou Símbolos

SIG – Sistemas de Informação Geográfica

DR – Detecção Remota

PGRH – Plano de Gestão da Região Hidrográfica

PREH – Plano Regional de Eficiência Hídrica

ART – *Adaptive Resonance Theory*

Maxlike – *Maximum Likelihood*

Fischer – Análise Discriminante Linear (LDA, do inglês *Linear Discriminant Analysis*)

IGeoE – Instituto Geográfico do Exército

LNEG – Laboratório Nacional de Energia e Geologia

RH8 – Região Hidrográfica das Ribeiras do Algarve

APA – Agência Portuguesa do Ambiente

M7 – Quarteira

M10 – São João da Venda–Quelfes

M11 – Chão de Cevada – Quinta João d’Ourém

M12 – Massa de Água Subterrânea da Campina de Faro

M18 – Campina de Faro – Subsistema Vale do Lobo

M19 – Campina de Faro – Subsistema Faro

IPMA – Instituto Português do Mar e da Atmosfera

SNIRH - Sistema Nacional de Informação de Recursos Hídricos

REMA - Rede de Estações Meteorológicas Automáticas

DRAPALG - Direção Regional de Agricultura e Pescas do Algarve

DRAP-Algarve - Sistema Agrometeorológico para Gestão da Rega no Algarve

UEA - Intervenção Uso Eficiente da Água

DGADR - Direção-Geral de Agricultura e Desenvolvimento Rural

ETP - Evapotranspiração Potencial

FAO - Organização das Nações Unidas para a Alimentação e Agricultura

COS - Carta de Uso e Ocupação do Solo

DGT – Direção-Geral do Território

m³ - Metros cúbicos

hm³ - Hectómetros cúbicos

EUREF - *European Reference Frame*

PT-TM06/ETRS89 - Sistema de referência oficial para Portugal Continental (EPSG:3763)

NIR - Infravermelho Próximo

ART a: *Adaptive Resonance Theory a* – rede neural no módulo de entrada do *Fuzzy ARTMAP*

ART b: *Adaptive Resonance Theory b* – rede neural no módulo de saída do *Fuzzy ARTMAP*

1. Introdução

1.1. Contextualização

A gestão eficiente dos recursos hídricos é um desafio crucial em regiões com escassez de água, como o Algarve, onde a crescente pressão sobre os recursos naturais exige soluções sustentáveis. O uso de Sistemas de Informação Geográfica (SIG) tem se destacado como uma ferramenta essencial na análise espacial e na estimativa do consumo de água, especialmente em áreas agrícolas irrigadas. Esta tese de mestrado visa explorar a aplicação de SIG na análise do uso da água nas áreas regadas do Aquífero da Campina de Faro, com foco na classificação das principais culturas agrícolas e na estimativa do volume de água consumido nessas áreas.

Os recursos hídricos subterrâneos, em particular os aquíferos da região, representam uma importante fonte de abastecimento para diversos usos, como áreas urbanas, industriais e, principalmente, para a agricultura. Contudo, a exploração excessiva desses recursos, aliada ao agravamento da qualidade da água subterrânea captada, tem se tornado uma preocupação crescente. A exploração excessiva de aquíferos ocorre quando o volume de água extraído supera a capacidade de recarga natural do sistema, resultando em um rebaixamento da pressão a nível local e regional. Esse fenômeno pode comprometer a disponibilidade de água e, em casos mais graves, levar à salinização ou contaminação dos recursos hídricos.

Além disso, a qualidade da água está frequentemente em risco devido a fontes de poluição, especialmente as de caráter difuso, originadas pela atividade agrícola, que afetam os sistemas aquíferos e podem prejudicar vastas áreas de abastecimento. Durante os períodos de escassez, conhecidos como "períodos secos", a situação torna-se ainda mais crítica. Estes períodos, que ocorrem principalmente entre julho e setembro, são caracterizados pela diminuição das precipitações e pelo aumento da evapotranspiração, o que reduz a disponibilidade de água. No Algarve, essa escassez é agravada pela combinação de fatores climáticos, como as altas temperaturas e a baixa pluviosidade, e pela crescente demanda provocada por atividades como o turismo e a agricultura intensiva.

O aquífero da Campina de Faro inclui áreas agrícolas intensivas que utilizam predominantemente águas subterrâneas para a rega, sendo este sector o maior consumidor de água. No entanto, é difícil obter estimativas precisas do consumo de água na agricultura, uma vez que as extrações são complicadas de calcular devido à falta de controlo individual sobre os volumes extraídos das captações de água subterrânea utilizadas para a rega. Essas dificuldades são refletidas nas discrepâncias encontradas na bibliografia sobre as estimativas de consumo de

água para rega ao longo do tempo para o sistema aquífero em estudo.

Neste contexto, este trabalho visa analisar a aplicação de SIG para monitorizar o uso da água nas áreas irrigadas da região, utilizando imagens de satélite e algoritmos de aprendizagem automática para classificar as culturas e estimar os volumes de água aplicados. Com isso, espera-se contribuir para o desenvolvimento de estratégias de gestão mais eficientes e sustentáveis dos recursos hídricos, de forma a garantir a cobertura das necessidades da população e das atividades produtivas, especialmente durante os períodos de escassez.

1.2. Justificativas

Este trabalho surgiu da necessidade de atuar na fotointerpretação de imagens de satélite na área do aquífero Campina de Faro, no âmbito do projeto eGROUNDWATER. Essa experiência permitiu-me aplicar e aprofundar meus conhecimentos na análise e classificação dos diferentes tipos de uso e ocupação do solo. Utilizando técnicas de detecção remota, contribuí para a identificação de áreas específicas e a interpretação de dados geoespaciais, o que foi essencial tanto para o sucesso do projeto eGROUNDWATER quanto para o desenvolvimento deste estudo.

O principal objetivo do projeto eGROUNDWATER é desenvolver sistemas de informação que aprofundem o conhecimento sobre as águas subterrâneas na região atlântica, permitindo a elaboração de estratégias inovadoras para sua gestão sustentável e eficiente (eGROUNDWATER, 2023). Para alcançar este objetivo, são utilizados métodos tradicionais de recolha de dados em combinação com técnicas inovadoras, como sistemas de observação da Terra (*drones* e satélites), sensores automáticos para medir a humidade do solo, Tecnologias de Informação e Comunicação (TIC) (como aplicações móveis), e a participação de cidadãos e partes interessadas na recolha de dados (ciência cidadã) (eGROUNDWATER, 2023).

A delimitação geográfica das áreas agrícolas é essencial para caracterizar a distribuição espacial das extrações do sistema do aquífero Campina de Faro. Compreender esta distribuição é crucial para o projeto eGROUNDWATER, que visa melhorar a gestão dos recursos hídricos. Esta informação é essencial para analisar o impacto do uso de água para rega e para realizar uma modelação hidrogeológica precisa no aquífero Campina de Faro. Enquanto as técnicas tradicionais para elaborar mapas das áreas agrícolas e da distribuição das extrações exigem uma recolha de dados exaustiva, geralmente através de levantamentos de campo, os avanços das tecnologias de deteção remota e das técnicas de análise de imagens digitais permitem a criação de mapas temáticos quase em tempo real. A disponibilização frequente de imagens de satélite

em curtos intervalos de tempo facilita a atualização rápida desses mapas, proporcionando informações atualizadas e precisas sobre a distribuição espacial das extrações e das áreas agrícolas num sistema do aquífero como o de campina de Faro. Com base na informação das áreas regadas, é possível estimar o volume de água consumida utilizando os parâmetros de dotação de rega para cada tipo de solo. Os resultados dessas estimativas são comparados com as diretrizes do Plano de Gestão da Região Hidrográfica.

1.3. Objetivos

O objetivo geral deste trabalho é identificar e caracterizar as principais culturas agrícolas e espaços verdes regados na área de estudo (Aquífero da Campina de Faro), utilizando imagens Sentinel-2 para o período de 2017 a 2023, aplicando metodologias de detecção remota, nomeadamente, índices de vegetação normalizada e classificação automática supervisionada. Posteriormente, esta informação é utilizada para estimar o volume de água necessário para a rega, com base nas dotações de água aplicadas às diferentes culturas. Por fim, os resultados são analisados e validados para garantir a integridade e a fiabilidade dos dados.

1.4. Detecção Remota na Gestão de Recursos Hídricos

A detecção remota permite identificar e caracterizar de forma replicável e rápida as áreas agrícolas e os espaços verdes regados, através da utilização de imagens de satélite, como as do Sentinel-2. Foram analisados três índices (NDVI, NDWI e SAVI) para determinar qual deles representa melhor essas áreas. Com base nessas análises, foram aplicados métodos indiretos para estimar o volume de água utilizado na rega.

De acordo com o plano de atividades da DRAP (DRAP, 2020) a eficiência hídrica deve estar presente nos sistemas de rega existentes. Assim, o governo irá:

1. Implementar práticas de regadio que promovam o uso eficiente da água, designadamente recorrendo a tecnologias de precisão e de monitorização das necessidades efetivas de água pelas culturas ao longo dos ciclos de crescimento, e ainda fomentar o recurso a água reciclada tratada.
2. Promover a requalificação dos perímetros de rega existentes, tornando-os mais eficientes, designadamente por via da redução das perdas de água por percolação e infiltração;
3. Assegurar a realização e implementação de um plano de ação para o uso

eficiente da água na agricultura;

4. Rever o sistema de cálculo do tarifário da água para rega, visando potenciar a utilização das infraestruturas de regadio;
5. Monitorizar e avaliar a utilização dos regadios à luz da eficiência hídrica, identificando e promovendo as culturas que garantam um uso sustentável dos solos nos perímetros de rega;

Assim, ao comparar as estimativas de água utilizadas com as diretrizes do plano, é possível avaliar a conformidade com as políticas de eficiência hídrica e identificar áreas para melhorias na gestão dos recursos hídricos na região.

1.5. Estrutura da Dissertação

A tese encontra-se dividida em sete capítulos. O primeiro capítulo é a introdução, que apresenta o trabalho realizado. Este capítulo inclui a motivação para a pesquisa, os objetivos do estudo e uma breve descrição dos temas que serão abordados nos capítulos seguintes.

No segundo capítulo, são descritas as principais técnicas utilizadas na classificação automática em Sistemas de Informação Geográfica (SIG), com base numa revisão da literatura especializada. Serão explorados métodos como o *Fuzzy Artmap*, reconhecido por sua robustez frente a incertezas e dados ruidosos, e o *Maxlike*, que aplica o princípio da máxima verossimilhança para a classificação de dados de acordo com distribuições normais. Também será abordado o método de *Fisher*, que utiliza a análise discriminante linear para maximizar a separação entre classes, assim como os métodos *Normalized* e *Raw*, que respetivamente normalizam os dados para melhorar a eficácia dos classificadores ou utilizam dados brutos para fins comparativos. Ao explorar as características, vantagens, limitações e contextos de aplicação de cada um desses métodos, procura-se oferecer uma visão abrangente e crítica sobre a utilização de classificadores automáticos em SIG, orientando futuras aplicações e investigações na área.

No terceiro capítulo, são explorados diversos aspetos relacionados com a Hidrogeologia da área de estudo, incluindo a caracterização geológica, os parâmetros hidrodinâmicos, os processos de recarga e descarga, os impactos ambientais e o uso da água. Este capítulo aborda também o Balanço Hidrogeológico, a Caracterização Piezométrica, a análise da Série Piezométrica e conclui com uma síntese dos temas discutidos.

No quarto capítulo descrevem-se diferentes características da área em estudo, no qual é proposto a abordagem dos seguintes temas: a Localização geográfica, Geologia e Relevo,

Hipsometria, Declividade, Hidrografia, Climatologia, Precipitação, Evapotranspiração Potencial e Caracterização do Uso e Ocupação do Solo.

São apresentados mapas, tabelas e gráficos com informações fisiográficas da área em estudo, bem como o tratamento de dados meteorológicos e climáticos necessários para o cálculo do balanço hídrico. Este tratamento inclui estimativas da precipitação anual média, precipitações plurianuais mensais, e a análise dos períodos secos e húmidos para a série climática 2017 a 2023.

Foram analisados dados de evapotranspiração potencial, provenientes da estação de Patação situada em Faro, da rede das estações meteorológicas automáticas da DRAP Algarve. Foi também realizada uma análise de uso e ocupação do solo.

No quinto capítulo, é descrita a metodologia utilizada, incluindo o detalhamento técnico dos dados e ferramentas empregados para alcançar os resultados obtidos. Este capítulo expõe o processo completo aplicado para a determinação do volume de água utilizado na área de rega.

No sexto capítulo, são apresentados os resultados e a discussão dos dados obtidos. Serão abordados os seguintes aspetos: a classificação manual realizada para 2021, a escolha do índice vegetativo, a quantificação de pixels por índice e tipos de solo, a classificação supervisionada (*Fuzzy Artmap*, *Maxlike*, *Fisher (LDA)*, *Raw* e *Normalized*), os resultados gerais, resultados gerais com segmentação, a estimativa do volume de água obtido utilizado na rega, a comparação entre o volume de água obtido com os valores oficiais do Plano de Gestão da Região Hidrográfica (PGRH), Plano Regional de Eficiência Hídrica (PREH) e o autor Costa Almeida (2000) com o objetivo de verificar a precisão dos métodos aplicados.

E para finalizar, no sétimo capítulo oferece uma recapitulação de todos os capítulos, apresentando as considerações finais e a descrição das conclusões que foram possíveis extrair do trabalho realizado.

2. Estado da Arte sobre Classificação Automática

A classificação de imagens de satélite é uma técnica essencial na análise de dados espaciais, permitindo a extração de informações sobre a cobertura e o uso do solo a partir de imagens multiespectrais.

Este capítulo analisará os principais classificadores usados na classificação automática em Sistemas de Informação Geográfica (SIG), como o *Fuzzy Artmap*, *Maxlike*, *Fisher*, *Normalized* e *Raw* no software IDRISI Selva 17.0 (Eastman, 2012c) com base na literatura especializada. Serão discutidas as características de cada método, desde a robustez do *Fuzzy Artmap* para lidar com dados incertos, até à eficiência do *Maxlike* com distribuições normais.

Serão igualmente abordados o método de *Fisher*, cuja ideia principal é encontrar uma combinação linear de variáveis que melhore a distinção entre diferentes classes, e os métodos de distâncias mínimas à média, *Normalized* e *Raw*, que, respetivamente, normalizam ou utilizam os dados brutos. Estes métodos baseiam-se na ideia de que cada classe de dados pode ser representada por um ponto central, denominado medóide, sendo os novos padrões classificados com base na proximidade ao medóide da classe mais próxima. A análise permitirá compreender as vantagens, limitações e aplicações dos diferentes métodos em contextos de SIG.

2.1. *Fuzzy Artmap*

O classificador *Fuzzy Artmap*, é uma poderosa ferramenta de classificação baseada em redes neurais, especialmente eficaz em situações onde se trabalha com grandes volumes de dados espaciais ou classes complexas. Este método foi desenvolvido como uma extensão das redes neurais ART (*Adaptive Resonance Theory*), introduzidas por Carpenter & Grossberg (1987), com a capacidade de lidar com dados ruidosos e classes sobrepostas, características comuns em aplicações de Detecção Remota (DR) e Sistemas de Informação Geográfica (SIG).

O *Fuzzy Artmap* é uma rede neural que combina a teoria *Fuzzy* com a arquitetura *ARTMAP*. A rede *ARTMAP* de acordo com Carpenter et al., (1991) é um modelo de aprendizagem supervisionada no qual o sistema aprende a mapear padrões de entrada para categorias de saída específicas. Quando um novo padrão é apresentado, o modelo tenta associá-lo a uma categoria aprendida previamente, utilizando um processo de ressonância adaptativa que ajusta as representações internas da rede. O componente *Fuzzy* permite que o classificador lide com a imprecisão inerente aos dados, uma característica valiosa em SIG, onde os limites das classes podem ser difusos e os dados podem conter incertezas.

O funcionamento do *Fuzzy Artmap* envolve dois principais subsistemas: a rede *ART* que gerência a aprendizagem das categorias e o módulo *map*, que associa as categorias aprendidas aos rótulos de classe desejados. Durante o treinamento, a rede ajusta as suas categorias até que se alcance uma correspondência suficiente entre os padrões de entrada e os rótulos, respeitando um critério de vigilância que controla a granularidade das categorias formadas.

No contexto do *IDRISI*, o *Fuzzy Artmap* é implementado como uma ferramenta de classificação robusta para dados de imagens de satélite e outros tipos de dados espaciais. O software permite a aplicação deste classificador em diferentes etapas do processamento de imagens, como na classificação supervisionada de uso e cobertura do solo. A flexibilidade do

Fuzzy Artmap para lidar com classes sobrepostas e dados ruidosos torna-o particularmente adequado para áreas com elevada heterogeneidade espacial e espectral (Eastman, 2012a).

Além disso, o *IDRISI* fornece uma interface amigável e opções de parametrização que facilitam o ajuste fino do classificador, permitindo ao utilizador definir parâmetros como o critério de vigilância e as funções de pertinência *Fuzzy*, adaptando o processo de classificação às especificidades do projeto em questão (Eastman, 2012b).

O *Fuzzy Artmap* oferece diversas vantagens em aplicações de SIG, como a capacidade de lidar com incertezas nos dados e a adaptabilidade a diferentes tipos de entradas. Contudo, sua implementação no *IDRISI* também apresenta desafios. Entre as limitações, destacam-se a complexidade na configuração dos parâmetros, que pode exigir um conhecimento avançado do utilizador, e o potencial custo computacional elevado, especialmente em projetos com grandes volumes de dados.

Segundo Richards (2013), a combinação de métodos de aprendizagem supervisionado, como o *Fuzzy Artmap*, com técnicas de integração de dados, pode melhorar significativamente a precisão das classificações em SIG. Além disso, estudos como o de Shan et al., (2008) demonstram que o *Fuzzy Artmap* supera outros métodos de classificação tradicionais, especialmente em cenários com classes complexas ou sobrepostas.

2.2. Maxlike

O classificador *Maxlike* (*Maximum Likelihood*) é um dos mais comumente utilizados, especialmente em estudos de DR e SIG, é baseado no método da Máxima Verossimilhança, uma técnica estatística que estima a probabilidade de que um dado *pixel* pertença a uma determinada classe temática. Essa probabilidade é calculada considerando a distribuição multivariada dos valores de refletância dos *pixels* em cada banda espectral (Richards, 2013). A premissa fundamental do *Maxlike* é que os dados espectrais de cada classe sigam uma distribuição normal multivariada (*Gaussian*), permitindo que a classificação seja realizada com base na densidade de probabilidade associada a cada classe.

O processo de classificação pelo *Maxlike* envolve a utilização de amostras previamente identificadas, conhecidas como assinaturas espectrais, que servem de referência para determinar a classe à qual cada *pixel* pertence. Essas assinaturas espectrais são obtidas a partir de áreas de treino, que são regiões da imagem onde a classe temática é conhecida. O algoritmo calcula a verossimilhança de cada *pixel* em relação a todas as classes temáticas e o atribui à classe com a maior probabilidade (Conese & Maselli, 1992).

No *IDRISI*, o *Maxlike* é implementado como uma ferramenta de classificação supervisionada. O processo começa com a definição das áreas de treino para cada classe temática de interesse. A partir dessas áreas, o *IDRISI* calcula as assinaturas espectrais que servem de base para a classificação (Eastman, 2012c). O usuário tem a possibilidade de ajustar parâmetros importantes do classificador, como o limiar de probabilidade mínima para atribuição de classes, que pode influenciar a exatidão da classificação final.

O *software* também oferece a opção de realizar uma análise de confiança para cada *pixel* classificado, permitindo ao analista avaliar a confiabilidade dos resultados obtidos. Esta característica é particularmente útil em estudos onde a precisão da classificação é crítica, como na delimitação de áreas de uso e cobertura da terra em projetos ambientais e de planejamento urbano (Jensen, 2015).

Uma das principais vantagens do classificador *Maxlike* é a sua base teórica sólida de ampla aceitação na comunidade científica, sendo considerado um dos métodos mais confiáveis para a classificação de imagens de DR (Foody et al., 1992). Além disso, a sua implementação no *IDRISI* é facilitada por uma interface intuitiva e por ferramentas que auxiliam na validação e análise dos resultados.

Contudo, a eficácia do *Maxlike* depende fortemente da qualidade das áreas de treino e da premissa de que as classes temáticas sigam uma distribuição normal multivariada. Em cenários onde essa premissa não é atendida, o desempenho do classificador pode ser comprometido, resultando em classificações imprecisas (Foody, 2002). Adicionalmente, a presença de classes com assinaturas espectrais muito semelhantes pode levar a confusões na atribuição dos *pixels*, uma limitação que requer a consideração de métodos complementares ou a utilização de técnicas avançadas de pré-processamento de imagens.

O *Maxlike* tem sido amplamente aplicado em diversos estudos de classificação temática, variando desde a análise de mudanças de uso do solo até a identificação de diferentes tipos de vegetação (Lillesand et al., 2014). No contexto do *IDRISI*, o *Maxlike* tem demonstrado eficácia em projetos que exigem alta precisão, especialmente quando combinado com técnicas de validação cruzada e pós-processamento para aumentar a precisão dos resultados finais.

2.3. Fisher (LDA)

O classificador *Fischer*, também conhecido como Análise Discriminante Linear (LDA, do inglês *Linear Discriminant Analysis*), é uma técnica estatística fundamental na classificação de padrões. Introduzida por Ronald A. Fisher em 1936, o LDA é amplamente utilizado em

diversas áreas, incluindo a ciência da computação, biologia e, especialmente, em SIG para a classificação de dados geoespaciais (Fisher, 1936; McLachlan, 2004). No *software IDRISI*, o LDA é implementado como uma das ferramentas de classificação supervisionada, facilitando a discriminação de diferentes classes com base nas suas assinaturas espectrais.

O principal objetivo do LDA é maximizar a separação entre duas ou mais classes, projetando os dados em um espaço de menor dimensão, onde as classes são mais facilmente distinguíveis (Fukunaga, 1990). Ao contrário de classificadores como o *Maximum Likelihood (Maxlike)*, que considera distribuições multivariadas completas, o LDA busca uma combinação linear das variáveis que melhor separa as classes, minimizando a variabilidade dentro de cada uma.

No *IDRISI*, esta técnica é aplicada ao conjunto de dados espectrais, permitindo que o software crie funções discriminantes lineares. Essas funções são baseadas em médias e covariâncias estimadas a partir de amostras de treino fornecidas pelo utilizador, permitindo uma classificação eficaz dos dados geoespaciais (Eastman, 2012b).

O classificador *Fischer (LDA)* no *IDRISI* é particularmente útil em cenários onde as classes possuem distribuições aproximadamente normais e onde a separação linear é adequada para distinguir as classes (McLachlan, 2004). No entanto, o LDA apresenta limitações, especialmente em situações em que as classes não são linearmente separáveis ou onde a presença de *outliers* pode comprometer a precisão da classificação (Fukunaga, 1990).

Apesar dessas limitações, o LDA continua sendo uma ferramenta valiosa no SIG, proporcionando uma base sólida para a classificação de dados geoespaciais, especialmente em estudos de uso e cobertura do solo (Bishop, 2006).

2.4. Raw

O classificador *Raw* no *IDRISI* é uma técnica de classificação supervisionada que utiliza os valores espectrais originais das bandas de uma imagem para realizar a atribuição de classes. Este método baseia-se na premissa de que as assinaturas espectrais de diferentes classes podem ser comparadas diretamente, sem a necessidade de qualquer transformação ou normalização dos dados. O classificador *Raw* é especialmente útil quando as bandas espectrais possuem escalas semelhantes e contribuem de forma equivalente para a distinção entre classes de uso e cobertura do solo.

No classificador *Raw*, a distância euclidiana é utilizada como a métrica principal para determinar a proximidade entre as assinaturas espectrais de um *pixel* e as médias espectrais das

classes de treino. Para cada *pixel*, o software calcula a distância euclidiana até as médias das classes (denominado medóide), e o *pixel* é atribuído à classe cujo medóide estiver mais próximo.

Este método é relativamente simples e eficiente em termos computacionais, tornando-o uma opção atrativa para grandes conjuntos de dados onde a velocidade de processamento é uma consideração importante (Eastman, 2012b). No entanto, o uso dos valores espectrais *Raw* pode introduzir limitações, especialmente em casos em que as bandas espectrais apresentam variabilidades significativas, o que pode levar a classificações enviesadas.

O classificador *Raw* é amplamente utilizado em estudos de DR onde as bandas espectrais têm variações mínimas ou onde os dados são relativamente homogêneos (Jensen, 2015). No entanto, em cenários onde as bandas espectrais diferem significativamente em termos de amplitude ou onde certas bandas são mais sensíveis a características específicas do terreno, o classificador *Raw* pode resultar em atribuições de classe menos precisas.

O classificador *Raw* no *IDRISI* oferece uma abordagem direta e eficiente para a classificação de dados espectrais. Embora tenha vantagens em termos de simplicidade e velocidade, é essencial considerar as características específicas das bandas espectrais ao optar por este método, especialmente em estudos que requerem alta precisão na distinção entre classes.

2.5. Normalized

O classificador *Normalized* no *IDRISI* é uma variante avançada do método de classificação por distância mínima, que incorpora a normalização dos valores espectrais antes de realizar a classificação. Esta técnica visa corrigir potenciais distorções causadas por diferenças na variabilidade das bandas espectrais, assegurando que cada banda contribua de forma equilibrada para o processo de classificação. A normalização é particularmente útil em estudos onde as bandas espectrais apresentam diferentes escalas ou são afetadas por variações ambientais distintas.

O classificador *Normalized* utiliza a mesma abordagem básica de distância euclidiana empregada pelo classificador *Raw*, mas com uma etapa adicional de normalização. Antes de calcular as distâncias, o *IDRISI* ajusta os valores espectrais para compensar a variabilidade inter banda, garantindo que nenhuma banda domine a classificação devido à sua amplitude ou sensibilidade.

Esta normalização pode ser realizada de diferentes maneiras, dependendo do algoritmo

específico implementado. O objetivo principal é assegurar que a distância calculada seja representativa da verdadeira similaridade entre as assinaturas espectrais, levando a uma classificação mais precisa e confiável (Richards & Jia, 2006).

O classificador *Normalized* é ideal para cenários onde as bandas espectrais têm diferentes escalas de valores ou onde algumas bandas são particularmente sensíveis a certos atributos da superfície, como a vegetação ou a umidade (Jensen, 2015). A normalização permite uma classificação mais equilibrada e precisa, especialmente em ambientes heterogêneos ou em estudos que envolvem múltiplas fontes de dados espectrais.

Por outro lado, o processo de normalização pode aumentar a complexidade computacional e o tempo de processamento, tornando este método menos adequado para grandes volumes de dados ou para situações em que a simplicidade e a rapidez são prioritárias (Jensen, 2015).

O classificador *Normalized* no *IDRISI* oferece uma solução robusta para a classificação de dados espectrais, especialmente em situações onde a variabilidade entre bandas pode afetar a precisão. Ao normalizar os valores espectrais, este método proporciona uma análise mais equilibrada e precisa, sendo preferido em estudos de DR com dados complexos ou heterogêneos (Eastman, 2012b).

2.6. Trabalhos Internacionais sobre a Classificação de Zonas Agrícolas e Espaços Verdes com Diferentes Classificadores

Diversos estudos em todo o mundo têm utilizado classificadores de dados, como *Fuzzy*, *Fisher*, *Maxlike*, *Raw* e *Normalized*, para a classificação de zonas agrícolas e espaços verdes, particularmente em contextos de Sistemas de Informação Geográfica (SIG).

Por exemplo, Smith et al., (2018) aplicaram o classificador *Fuzzy* para mapear zonas agrícolas no sul da França. O estudo demonstrou que o uso de técnicas *Fuzzy* permite capturar melhor as transições graduais entre diferentes classes de vegetação, resultando numa maior precisão em comparação com métodos tradicionais de classificação. Da mesma forma, Chen & Wu (2020) usaram classificadores *Fuzzy* para identificar zonas regadas na China, destacando a capacidade da técnica de lidar com incertezas associadas a dados de sensores remotos.

Já o classificador de *Fisher* foi utilizado por Oliveira & al. (2019) em Portugal para a distinção de culturas agrícolas, mostrando-se eficaz na separação de classes de uso do solo com base em medidas estatísticas de discriminação. Por outro lado, *Maxlike* foi aplicado com sucesso por Gómez & Martínez, (2021) na Espanha, para a classificação de espaços verdes

áreas urbanas, evidenciando uma elevada precisão na identificação de áreas regadas, particularmente quando combinado com dados multiespectrais.

Os métodos *Raw* e *Normalized* também têm sido amplamente utilizados. Por exemplo, Patel & al. (2022) implementaram o classificador *Raw* na Índia para categorizar tipos de cultivos, observando que o método é mais adequado para regiões com dados espectrais homogêneos. Em contraste, Al-Rashed & Youssef (2023) utilizaram o método *Normalized* no Egito para analisar espaços verdes em áreas urbanas, demonstrando que a normalização dos dados melhora a robustez do modelo perante variações sazonais e atmosféricas.

Estes estudos demonstram a versatilidade e aplicabilidade dos diferentes classificadores para a classificação de zonas agrícolas e espaços verdes, contribuindo para a gestão eficiente dos recursos hídricos e a sustentabilidade ambiental.

3. Hidrogeologia do Aquífero Campina de Faro

3.1. Introdução

A hidrogeologia do aquífero Campina de Faro M12, localizado no sul de Portugal, é fundamental para o entendimento da dinâmica dos recursos hídricos subterrâneos da região. Este capítulo examina as características hidrogeológicas deste aquífero com base nos estudos de Almeida et al., (2000) e em outras fontes relevantes da literatura. A análise foca na composição geológica, nos parâmetros hidrodinâmicos, na recarga e descarga, além das interações com os ecossistemas locais e as atividades humanas.

3.2. Caracterização Geológica

O aquífero Campina de Faro M12 é constituído predominantemente por depósitos aluvionares e calcários do período Quaternário, com camadas de arenito e conglomerado em áreas específicas (Almeida et al., 2000). A estratigrafia apresenta uma alternância de camadas permeáveis e semipermeáveis, resultando em uma complexa rede de fluxo subterrâneo. A presença de dolomitos e calcários favorece a dissolução de carbonatos, aumentando a porosidade secundária e a condutividade hidráulica do aquífero.

Ainda segundo Almeida et al., (2000), as características litológicas variam significativamente ao longo da extensão do aquífero, influenciando diretamente sua capacidade de armazenamento e o comportamento do fluxo de água subterrânea. A presença de fraturas e

falhas geológicas contribui para a heterogeneidade do aquífero, criando zonas de maior permeabilidade que facilitam o fluxo de água subterrânea em certas direções preferenciais.

3.3. Parâmetros Hidrodinâmicos

Os parâmetros hidrodinâmicos do aquífero, tais como condutividade hidráulica, transmissividade e coeficiente de armazenamento, são altamente variáveis devido à complexidade litológica e estrutural. Estudos realizados por Almeida et al., (2000) indicam que a condutividade hidráulica varia de 10^{-4} a 10^{-2} m/s nas zonas mais permeáveis, como os calcários e dolomitos fraturados, enquanto nas zonas mais argilosas ou menos fraturadas, os valores de condutividade são significativamente menores, próximos de 10^{-6} m/s.

A transmissividade do aquífero também exibe variações consideráveis, com valores que podem alcançar até 5000 m²/dia nas áreas mais permeáveis. Estes parâmetros são essenciais para modelar o fluxo de água subterrânea e prever a disponibilidade de água para usos diversos, como o abastecimento público e a agricultura.

3.4. Recarga e Descarga

A recarga do aquífero Campina de Faro M12 é predominantemente alimentada pela infiltração de precipitação direta e pela contribuição de fluxos superficiais provenientes das áreas adjacentes. O clima mediterrâneo da região, caracterizado por verões quentes e secos e invernos moderadamente chuvosos, influencia diretamente o regime de recarga. Almeida et al., (2000), destacam que cerca de 30% da precipitação anual contribui para a recarga do aquífero, enquanto o restante é perdido por evapotranspiração ou escoamento superficial.

A descarga ocorre principalmente através de fontes naturais, rios, evapotranspiração direta e extração por poços. O estudo de Almeida et al., (2000), indica que as zonas de descarga estão concentradas em áreas de menor elevação topográfica, onde o nível freático está próximo da superfície, facilitando a troca de água entre o aquífero e os corpos de água superficiais.

3.5. Impactos Ambientais e Uso da Água

O uso intensivo dos recursos hídricos subterrâneos no aquífero Campina de Faro M12, especialmente para fins agrícolas e turísticos, tem gerado impactos ambientais significativos. A sobreexploração dos recursos hídricos subterrâneos tem levado a uma diminuição do nível piezométrico e ao risco de intrusão salina em áreas próximas ao litoral (Almeida et al., 2000).

A intrusão salina é particularmente preocupante em aquíferos costeiros, devido ao contacto com o Oceano Atlântico, o que coloca em risco a qualidade da água e a sustentabilidade dos usos atuais.

Além disso, as atividades humanas, como a urbanização e o desenvolvimento agrícola intensivo, têm contribuído para a contaminação por nutrientes, como nitratos provenientes de fertilizantes, e pesticidas utilizados em culturas comerciais. Esse processo compromete não apenas a qualidade da água subterrânea, mas também os ecossistemas associados, como zonas húmidas alimentadas pelo aquífero. Almeida et al., (2000) destacam a importância de estratégias como o monitoramento contínuo da qualidade da água, a aplicação controlada de fertilizantes e defensivos agrícolas, além da implementação de zonas-tampão vegetadas ao longo de áreas agrícolas e urbanas. Essas práticas são essenciais para mitigar os impactos, proteger os recursos hídricos subterrâneos e assegurar sua sustentabilidade a longo prazo.

3.6. Balanço Hidrogeológico

De acordo com Almeida et al., (2000), as entradas no sistema hídrico são constituídas pela recarga direta, perdas nos cursos de água e eventuais transferências a partir de outros sistemas. A recarga direta provavelmente não excede, em média, 10 hm³/ano, considerando a área do sistema de aproximadamente 86 km², uma precipitação média de cerca de 550 mm e a taxa de recarga das Areias e Cascalheiras de Faro-Quarteira, que se estima situar entre 15% e 20% da precipitação. As outras contribuições são de quantificação mais complexa, mas devem se aproximar do valor necessário para equilibrar o balanço hídrico. Supõe-se que o sistema esteja em equilíbrio, uma vez que os níveis médios tendem a ser mantidos, excetuando o caso mencionado anteriormente.

Conforme Almeida et al., (2000), as extrações para rega, de acordo com os inventários da DRAOT Algarve, são estimadas em aproximadamente 12 hm³/ano.

As Bases do Plano Regional de Eficiência Hídrica da APA & DGADR (2020), apresenta as 19 massas de água para a região do Algarve, incluindo o valor da recarga média anual e dos recursos hídricos subterrâneos disponíveis (RHSD). Este estudo foca-se especificamente na análise da recarga média anual, em hm³/ano, das massas de água subterrânea M18 – Campina de Faro – Subsistema Vale de Lobo e M19 – Campina de Faro – Subsistema Faro.

A recarga média anual estimada para as massas de água subterrâneas "M18 - Campina de Faro - Subsistema Vale de Lobo" e "M19 - Campina de Faro - Subsistema Faro" é de cerca de 9,16 hm³/ano, sendo 3,46 hm³/ano para M18 e 5,70 hm³/ano para M19. Os recursos hídricos

subterrâneos disponíveis para essas massas totalizam aproximadamente 8,24 hm³/ano, distribuídos em 3,11 hm³/ano para M18 e 5,13 hm³/ano para M19. Esses valores representam as disponibilidades naturais, ajustadas para considerar as necessidades ambientais e ecológicas, para as quais se considera 10% da recarga natural, uma prática comum em avaliações de recursos hídricos que visa garantir a manutenção dos ecossistemas e o suporte às funções ambientais dos aquíferos. É importante destacar que esses cálculos não incluem os usos já existentes, que devem ser avaliados separadamente.

A disponibilidade de água foi calculada subtraindo-se os recursos hídricos subterrâneos disponíveis (RHSD) pelas saídas (extrações do volume total de água captada – PGRH2 + 10%). O objetivo deste parágrafo é analisar as saídas e a disponibilidade de água ao final do ano hidrológico de 2019/2020, especificamente para as massas de água subterrânea M18 – Campina de Faro – Sistema Vale de Lobo e M19 – Campina de Faro – Sistema Faro.

Verifica-se que, as saídas (extrações do volume total de água captada – PGRH2 + 10%, em hm³/ano) para as massas de água "M18 - Campina de Faro - Sistema Vale de Lobo" e "M19 - Campina de Faro - Sistema Faro", correspondem cerca de 11,77 hm³/ano (6,45 hm³/ano para M18 e 5,32 hm³/ano para M19). A disponibilidade de água ao final do ano hidrológico de 2019/2020, também em hm³/ano para essas massas, são de aproximadamente - 3,53 hm³/ano (-3,34 hm³/ano para M18 e 0,19 hm³/ano para M19). Ressalta-se que esses quantitativos se referem ao total do aquífero e não apenas a algumas classes, conforme proposto neste estudo.

Já de acordo com o Plano de Gestão de Região Hidrográfica da APA (2022), conforme as Fichas de Massa de Água Subterrânea, verifica-se que, para as massas de água "PTM18 - Campina de Faro - Sistema Vale de Lobo" e "M19 - Campina de Faro - Sistema Faro", a recarga média anual corresponde a cerca de 7.9 hm³/ano (2,94 hm³/ano para PTM18 e 4,96 hm³/ano para PTM19). Os recursos hídricos subterrâneos disponíveis para essas massas somam aproximadamente 6.33 hm³/ano (2,36 hm³/ano para M18 e 3,97 hm³/ano para M19).

Os valores das saídas por volume (hm³/ano) divididos por Setor e Subsetor, sendo que os subsetores de interesse para este estudo são a Agricultura e o Golfe. Em contraste, as entradas obtidas referem-se à área total do Aquífero Campina de Faro. Portanto, propõe-se a quantificação da área total do aquífero e das áreas específicas de interesse (Agricultura e Golfe).

Verifica-se que, as saídas (Pressões quantitativas, em hm³/ano) para a área total do aquífero correspondem cerca de 13,17 hm³/ano (5,34 hm³/ano para M18 e 7,83 hm³/ano para M19). Já as saídas (Pressões quantitativas, em hm³/ano) para as classes de interesse (Agricultura e Golfes) deste estudo, correspondem cerca de 12,99 hm³/ano (5,25 hm³/ano para M18 –

Agricultura 2 hm³/ano e Golfe 3,25 hm³/ano) e (7,74 hm³/ano para M19 – Agricultura 7,74 hm³/ano). Ou seja, os Subsetores de interesse do presente estudo resultam em 98,6% da área total do Aquífero Campina de Faro.

A disponibilidade de água, considerando o ciclo de planeamento de 2022-2027, é de aproximadamente -5,27 hm³/ano (-2,4 hm³/ano para M18 e -2,87 hm³/ano para M19). Ressalta-se que esses quantitativos se referem ao total do aquífero e não apenas a algumas classes específicas, conforme proposto neste estudo. Se a disponibilidade de água para o ciclo de planeamento de 2022-2027 for calculada utilizando os recursos hídricos subterrâneos disponíveis, em vez da recarga média anual, os valores seriam de cerca de -6,84 hm³/ano (-2,98 hm³/ano para M18 e -3,86 hm³/ano para M19).

Com base nos valores de recarga e saídas do Aquífero Campina de Faro apresentados pelos diferentes autores (Tabela 1), observa-se uma discrepância significativa entre as estimativas de recarga, que variam de 7,9 hm³/ano a 10 hm³/ano, e as estimativas de saídas, que variam de 11,77 hm³/ano a 13,17 hm³/ano. Independentemente da fonte, todas as estimativas indicam um balanço hídrico insustentável, onde as saídas superam as recargas, evidenciando um défice hídrico no aquífero. Este défice é compensado, em parte, pela intrusão salina, que atua como um fluxo de entrada ao sistema, embora comprometa a qualidade da água e represente um risco significativo para o uso sustentável do aquífero. Este cenário reforça a necessidade de estratégias de gestão e eficiência hídrica para garantir a sustentabilidade dos recursos hídricos subterrâneos na região.

Tabela 1 - Balanço Hidrogeológico

	Sistemas Aquíferos de Portugal Continental - Almeida et al., (2000)		PREH (Plano Regional de Eficiência Hídrica) - APA (2020)		PGRH (Plano de Gestão de Recursos Hídricos) - APA (2022)	
	Área Total	Áreas de Interesse (Agricultura + Campos de Golfe)	Área Total	Áreas de Interesse (Agricultura + Campos de Golfe)	Área Total	Áreas de Interesse (Agricultura + Campos de Golfe)
Recarga Média Anual - hm³/ano	10		9,16		7,9	
Recursos Hídricos Subterrâneos Disponíveis - hm³/ano	N/D		8,24		6,33	
Extrações Média Anual - hm³/ano	12	N/D	11,77	10,87	13,17	12,99
Disponibilidade de Água - hm³/ano (Recursos Hídricos Disponíveis - Extrações)	-2*	N/D	-3,53	-2,63	-6,84	-6,66

*Calculado com base nas extrações - recarga média

3.7. Caracterização Piezométrica

A piezometria do aquífero Campina de Faro é fundamental para entender a dinâmica de fluxo e o comportamento hidrogeológico da região. Este aquífero, localizado no sul de Portugal, é caracterizado por uma intensa atividade agrícola e urbana, o que implica uma alta demanda por recursos hídricos subterrâneos. A análise piezométrica permite identificar variações na pressão da água e determinar a direção e o gradiente do fluxo subterrâneo, essencial para o gerenciamento sustentável deste recurso.

Os dados piezométricos utilizados foram obtidos do Sistema Nacional de Informação de Recursos Hídricos (SNIRH) da Agência Portuguesa do Ambiente (APA) (2023), que mantém uma rede de pontos de monitoramento de piezometria em todo o território nacional. Esses pontos são regularmente monitorados para obter medições precisas dos níveis de água subterrânea, que foram posteriormente interpolados utilizando o método de krigagem para criar superfícies piezométricas detalhadas.

De acordo com o Plano de Gestão de Região Hidrográfica da Agência Portuguesa do Ambiente (APA) (2022) ao analisar o estado quantitativo com base nos recursos hídricos subterrâneos disponíveis (hm^3/ano) conforme valores obtidos no capítulo 3.6 Balanço Hidrogeológico, os subsistemas Campina de Faro - Vale de Lobo e Faro apresentam uma situação crítica em termos de disponibilidade hídrica, devido ao desequilíbrio no balanço hídrico, refletindo-se na tendência de “descida” do nível piezométrico.

De acordo com a APA (2024), no Ano Hidrológico 2022/23, uma massa de água ser considerada em situação crítica, é colocada em situação de vigilância, quando se observa uma descida significativa dos níveis piezométricos, durante um certo período, uma vez que requer uma atenção especial de acompanhamento da sua evolução. Persistindo este decréscimo significativo, a massa de água em situação de vigilância transitará para situação crítica, requerendo medidas excepcionais a implementar.

Os resultados da análise piezométrica indicam que o aquífero Campina de Faro apresenta um gradiente hidráulico predominante no sentido nordeste-sudoeste, o que sugere uma recarga a partir das áreas elevadas do interior e um escoamento em direção ao litoral. Os mapas piezométricos gerados indicam zonas de recarga e descarga bem definidas, sendo que as áreas de maior elevação piezométrica coincidem com regiões de recarga natural.

Além disso, observou-se uma variação sazonal nos níveis piezométricos, refletindo o impacto das atividades humanas, especialmente a agricultura regada, e a influência das condições climáticas locais. Durante os meses de verão, o nível piezométrico diminui

significativamente devido ao aumento do consumo de água para rega e à menor recarga devido à precipitação reduzida.

Os dados piezométricos são cruciais para o planeamento e gerenciamento de recursos hídricos no aquífero Campina de Faro. A compreensão das dinâmicas de fluxo de água subterrânea ajuda a identificar áreas críticas de recarga e descarga, permitindo o desenvolvimento de estratégias de gestão que visem a sustentabilidade do uso do aquífero. As análises também indicam a necessidade de práticas agrícolas sustentáveis e uma melhor gestão do uso da água para mitigar os efeitos de superexploração e poluição.

Do ponto de vista da gestão dos recursos hídricos, o sistema Aquífero da Campina de Faro pertence à Região Hidrográfica das Ribeiras do Algarve (RH8), sendo administrada pela Agência Portuguesa do Ambiente (APA), através do respectivo Plano de Gestão da Região Hidrográfica (PGRH), assumindo a designação de Massa de Água Subterrânea da Campina de Faro (M12) durante o primeiro ciclo do Plano de Gestão dos Recursos Hídricos (PGRH).

No entanto, durante o 2º ciclo do PGRH, procedeu-se à re-delimitação desta massa de água, que resultou na sua divisão em dois sistemas, nomeadamente o M18 – Campina de Faro - Subsistema Vale do Lobo e o M19 - Campina de Faro - Subsistema Faro, com a fronteira delineada ao longo da Ribeira de São Lourenço (Figura 1), no entanto, esta delimitação resultou apenas na divisão do sistema M12 em 2 sistemas. De acordo com esta mesma imagem, é possível visualizar a distribuição geográfica dos pontos de coletas piezométricos.

No presente trabalho, a área de estudo considerada é o sistema aquífero na sua totalidade, pelo que será utilizada a nomenclatura antiga M12 – Campina de Faro. Adicionalmente, foi considerado, para efeitos de cálculo, o limite em vermelho com um buffer de 250 metros a norte, de forma a incluir os citrinos na sua totalidade, e 500 metros a sul, para incluir os campos de golfe.

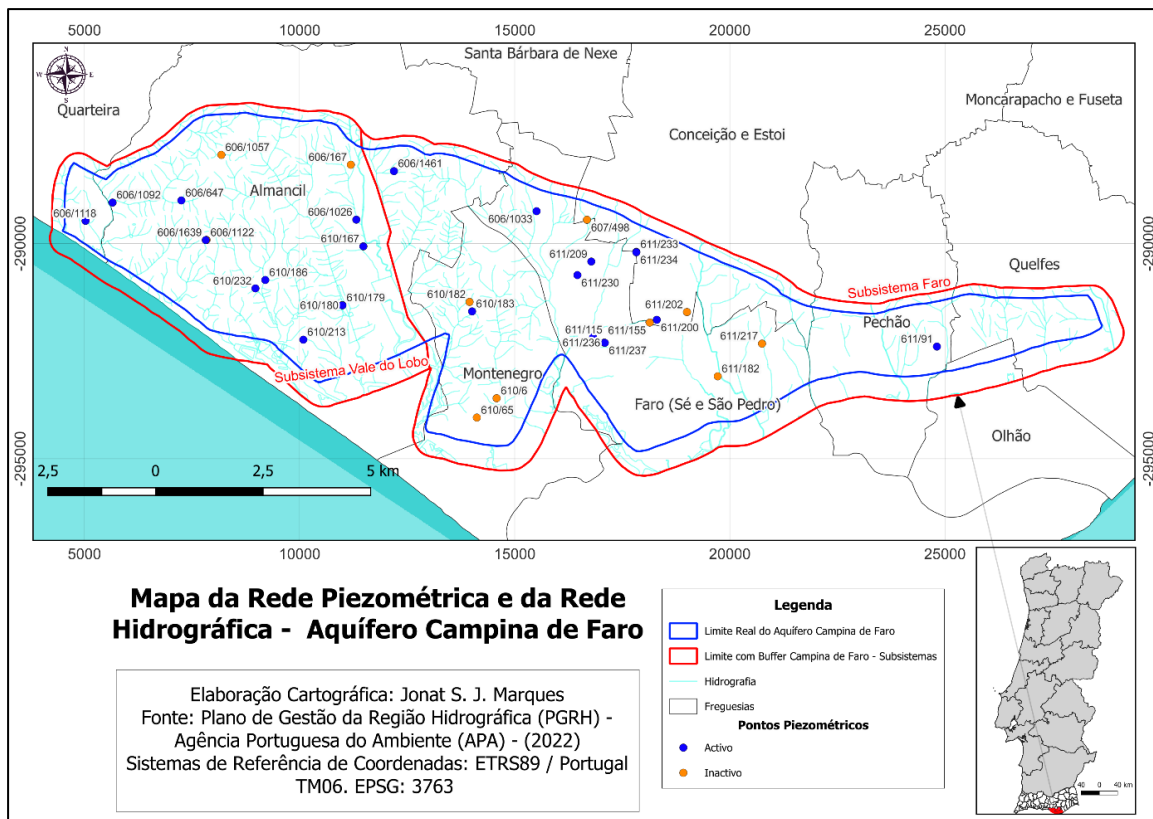


Figura 1 - Mapa da rede piezométrica e da rede hidrográfica do Aquífero Campina de Faro

A análise piezométrica deste sistema deve ser diferenciada entre o aquífero superficial freático (Plio-Quaternário) e o aquífero profundo confinado (Miocénico), dado que estes sistemas são independentes entre si (Costa et al., 2021). O aquífero profundo é atualmente o mais produtivo e explorado, enquanto o aquífero superficial é utilizado de forma residual, principalmente através de alguns poços. No aquífero profundo, a piezometria regional revela uma distribuição mais uniforme no sector leste e uma depressão acentuada no sector oeste, correspondente à massa de água PTM18 – Campina de Faro, Subsector Vale do Lobo (Figura 2 - Mapa Piezométrico).

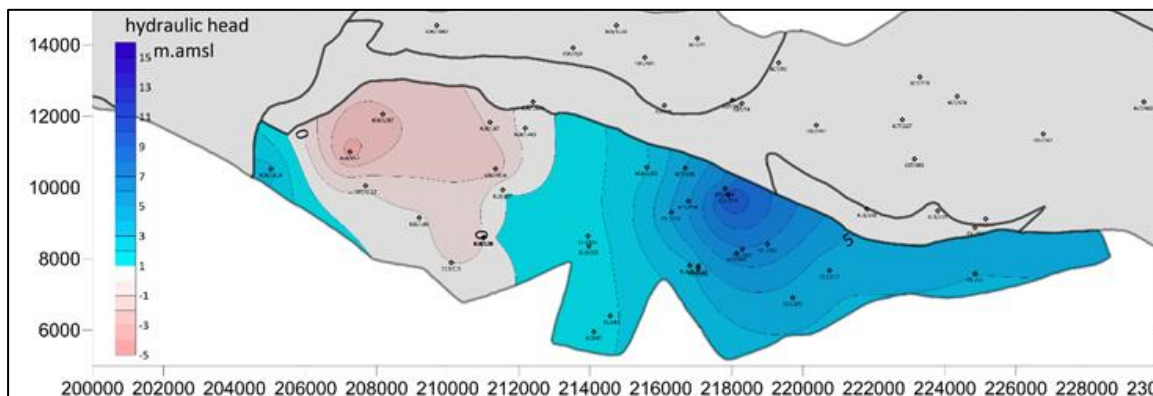


Figura 2 - Mapa piezométrico do aquífero Campina de Faro

No mapa piezométrico da Figura 2 referente ao aquífero profundo confinado

(Miocénico) da Campina de Faro, destaca-se a distribuição do nível hidráulico (*hydraulic head*) em metros acima do nível médio do mar (m.a.m.s.l.). As áreas em tons de azul representam níveis hidráulicos mais elevados, enquanto as áreas em tons de vermelho indicam níveis mais baixos. Observa-se uma distribuição mais uniforme do nível piezométrico no sector leste e uma depressão acentuada no sector oeste, associada ao Subsector Vale do Lobo (PTM18) (Costa et al., 2021)

Na Figura 3 (Evolução Piezométrica), os autores Costa et al., (2021) discutem a evolução média anual da piezometria para os diferentes sectores do aquífero Campina de Faro, apresentando um ponto de observação de referência para cada sector e para a massa de água M10 - São João da Venda - Quelfes, nomeadamente:

- M18 - Subsistema Vale do Lobo Freático (M12 West Free 610/167)
- M18 - Subsistema Vale do Lobo Confinado (M12 West Conf 606/647)
- M19 - Subsistema Faro Freático (M12 East Free 610/6)
- M19 - Subsistema Faro Confinado (M12 East Conf 611/200)
- M10 - Massa de Água São João da Venda - Quelfes (M10 608/286)

Evolução piezométrica nos dois sectores do Campina de Faro:

- M12 West -> M18 (sector vale do Lobo)
- M12 East -> M19 (Sector Campina de Faro)
- Free -> aquífero livre superficial (Plio-Quaternário)
- Conf -> Aquífero confinado profundo (miocénico)

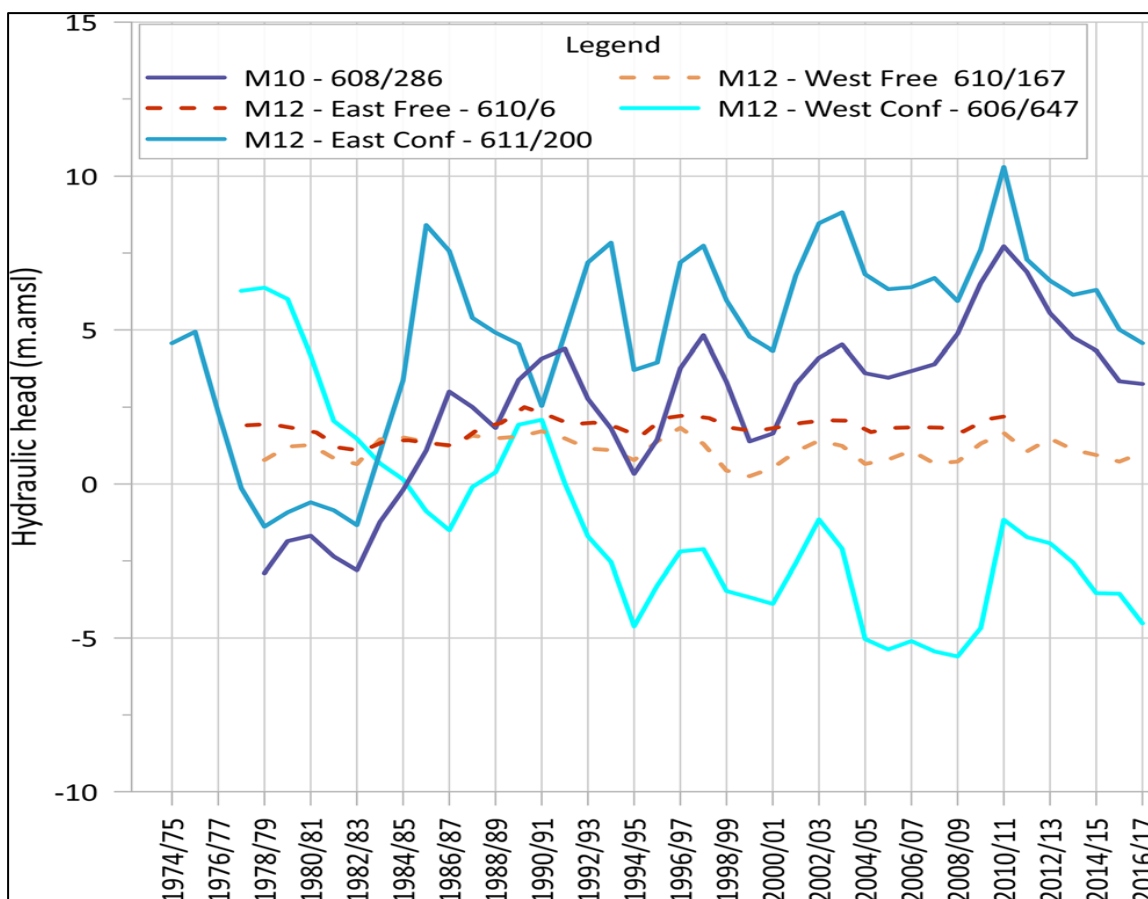


Figura 3 - Evolução piezométrica nos dois sectores do Campina de Faro

Os autores destacam que os aquíferos confinado (Miocénico) e freático (Plio-Quaternário) apresentam comportamentos hidráulicos independentes. Consequentemente, o fluxo no aquífero freático é completamente independente do fluxo no aquífero confinado, sendo que o aquífero profundo demonstra uma variação piezométrica mais acentuada, enquanto as camadas superficiais apresentam variações mais suaves.

Adicionalmente, observa-se que no aquífero confinado do subsistema M18 - Vale do Lobo, há uma tendência de redução do nível piezométrico desde o início da década de 1990 até aos dias atuais. Essa diminuição não é acompanhada pelos restantes sectores do aquífero, que, pelo contrário, apresentaram níveis estáveis ou até mesmo aumentos até cerca de 2010, começando a decrescer apenas a partir desse ano.

Por fim, apresenta-se uma comparação entre o nível piezométrico no aquífero confinado do subsistema M18 - Vale do Lobo e as concentrações de cloretos (Figura 4 - Nível vs. Cloretos). Esta figura evidencia uma correlação clara entre a diminuição dos níveis piezométricos neste sector do aquífero e o aumento das concentrações de cloretos. De acordo com os autores, este fenómeno poderá estar associado ao avanço da intrusão salina marinha, agravado pela reduzida precipitação dos últimos anos e pela intensa extração de água

subterrânea.

Evolução temporal da piezometria (e cloretos) no subistema Vale do Lobo:




Figura 4 - Níveis piezométricos x Concentrações de cloretos

4. Caracterização da Área de Estudo

A área de estudo selecionada para caracterizar e quantificar as áreas regadas foi o aquífero Campina de Faro. Neste capítulo, pretende-se fazer uma revisão do conhecimento atual sobre a localização geográfica, geomorfologia, declividade, hipsometria, hidrografia, climatologia e uso e ocupação do solo.

4.1. Localização Geográfica

A área de estudo incide sobre o aquífero da Campina de Faro, localizado no sul de Portugal, na região litoral do Algarve, mais precisamente a sudeste, próxima da cidade de Faro. De acordo Almeida et al., (2000), este aquífero ocupa uma área de 86,4 km², abrange os concelhos de Faro, Loulé e Olhão e insere-se na bacia hidrográfica Ribeiras do Sotavento

(Figura 5). As principais áreas urbanas localizadas sobre a área de estudo incluem as cidades de Faro e Olhão, bem como as zonas turísticas de Vale do Lobo e Quinta do Lago.

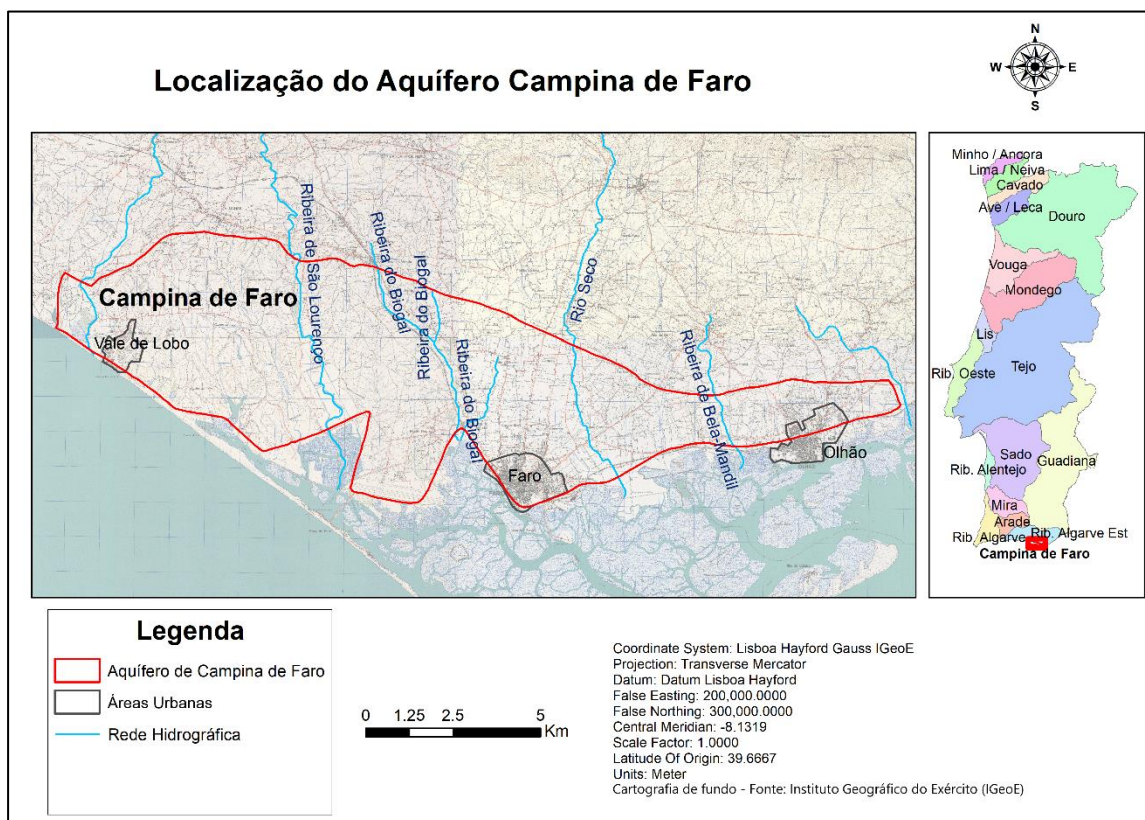


Figura 5 - Localização geográfica da área de estudo

Do ponto de vista da gestão dos recursos hídricos, o sistema Aquífero da Campina de Faro pertence à Região Hidrográfica das Ribeiras do Algarve (RH8), sendo administrada pela Agência Portuguesa do Ambiente (APA), através do respectivo Plano de Gestão da Região Hidrográfica (PGRH), assumindo a designação de Massa de Água Subterrânea da Campina de Faro (M12) durante o primeiro ciclo do Plano de Gestão dos Recursos Hídricos (PGRH).

No entanto, durante o 2º ciclo do PGRH, procedeu-se à re-delimitação desta massa de água, que resultou na sua divisão em dois sistemas, nomeadamente o M18 – Campina de Faro - Subsistema Vale do Lobo e o M19 - Campina de Faro - Subsistema Faro, com a fronteira delineada ao longo da Ribeira de São Lourenço. No Presente trabalho, a área de estudo considerada é o sistema aquífero na sua totalidade e, portanto, será usada a nomenclatura antiga M12 – Campina de Faro.

4.2. Geologia e Relevo (Geomorfologia)

Do ponto de vista hidrogeológico, o sistema aquífero M12 - Campina de Faro é limitado a Norte pelas formações menos permeáveis do Cretácico, correspondentes aos aquíferos M10 -

São João da Venda-Quelfes e M11 – Chão de Cevada – Quinta João d’Ourém; estende-se para este até Olhão e a oeste o seu limite é definido pelo contacto com o Sistema Aquífero de M7 - Quarteira, sendo provável a existência de conexão hidráulica entre eles. A sul, é limitado pelo Oceano Atlântico. A Figura 6 apresenta a identificação dos sistemas aquíferos na Orla Meridional conforme Almeida et al., (2000), assinalando-se o sistema aquífero da Campina de Faro (M12).

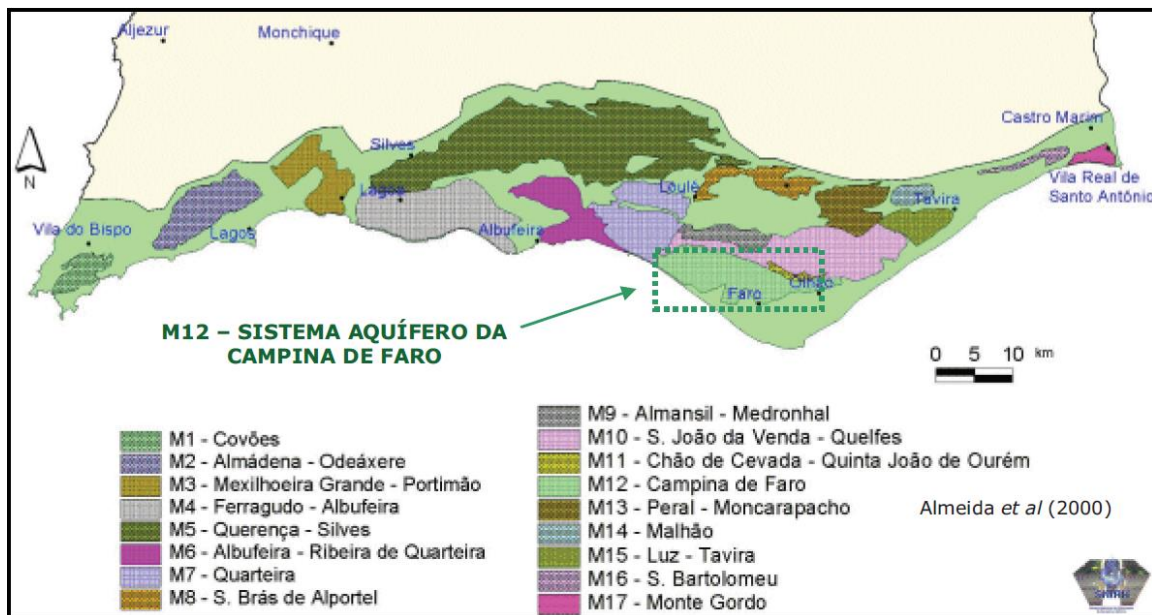


Figura 6 - Localização do sistema aquífero da Campina de Faro (M12) na Orla Meridional Alargada

Do ponto de vista geológico, Almeida et al., (2000), apresenta-se uma descrição bastante detalhada acerca das formações que compõem o aquífero M12 Campina de Faro, que aqui se resume. O relevo da Campina de Faro, caracterizado por sua planície com altitudes entre 10 e 20 metros acima do nível do mar. A topografia plana favorece a infiltração em detrimento do escoamento superficial, contribuindo para a recarga do aquífero superficial. Adicionalmente, a baixa variação altimétrica reduz o gradiente hidráulico, impactando a dinâmica de fluxo nas formações aquíferas profundas. O declive e a hipsometria também desempenham papéis importantes, controlando os padrões de escoamento e distribuição da pressão hidráulica ao longo do sistema. O sistema aquífero da Campina de Faro é um aquífero multicamada, composto por duas formações aquíferas dominantes. A primeira é a formação do Miocénico, que suporta um aquífero profundo, maioritariamente confinado, que aflora apenas em alguns locais e é constituído pelos calcários de Galvanas e pelas siltes glauconíticas da Campina de Faro. A segunda formação é a do Plio-Quaternário, que suporta um aquífero livre superficial, composto pelas areias e cascalheiras de Faro-Quarteira. Os depósitos mais permeáveis são as siltes glauconíticas, que formam o aquífero confinado, enquanto os depósitos menos

permeáveis, como as argilas e os calcários, atuam como uma barreira hidrogeológica, separando as duas camadas. A região é atravessada por uma rede de drenagem superficial, que contribui para a recarga do sistema aquífero.

O declive e a hipsometria do aquífero Campina de Faro são características geomorfológicas que influenciam o seu comportamento hidrogeológico. O declive é a medida da inclinação do terreno, que pode afetar o escoamento superficial, a infiltração e a recarga do aquífero. A hipsometria é a distribuição das altitudes do terreno, que pode afetar o gradiente hidráulico, a pressão e o potencial do aquífero.

O aquífero Campina de Faro é composto por dois subsistemas separados pela ribeira de São Lourenço: o subsistema de Vale do Lobo, a oeste, e o subsistema de Faro, a este. O subsistema de Vale do Lobo apresenta uma declividade média de 0,5%, sendo mais elevado na zona norte (cerca de 40 m de altitude) e mais baixo na zona sul (cerca de 10 m de altitude). O subsistema de Faro apresenta uma declividade média de 0,3%, sendo mais elevado na zona nordeste (cerca de 50 m de altitude) e mais baixo na zona sudoeste (cerca de 5 m de altitude), (Almeida et al., 2000).

As Figuras 7 e 8, apresentadas abaixo, mostram o declive e a hipsometria do aquífero da Campina de Faro.

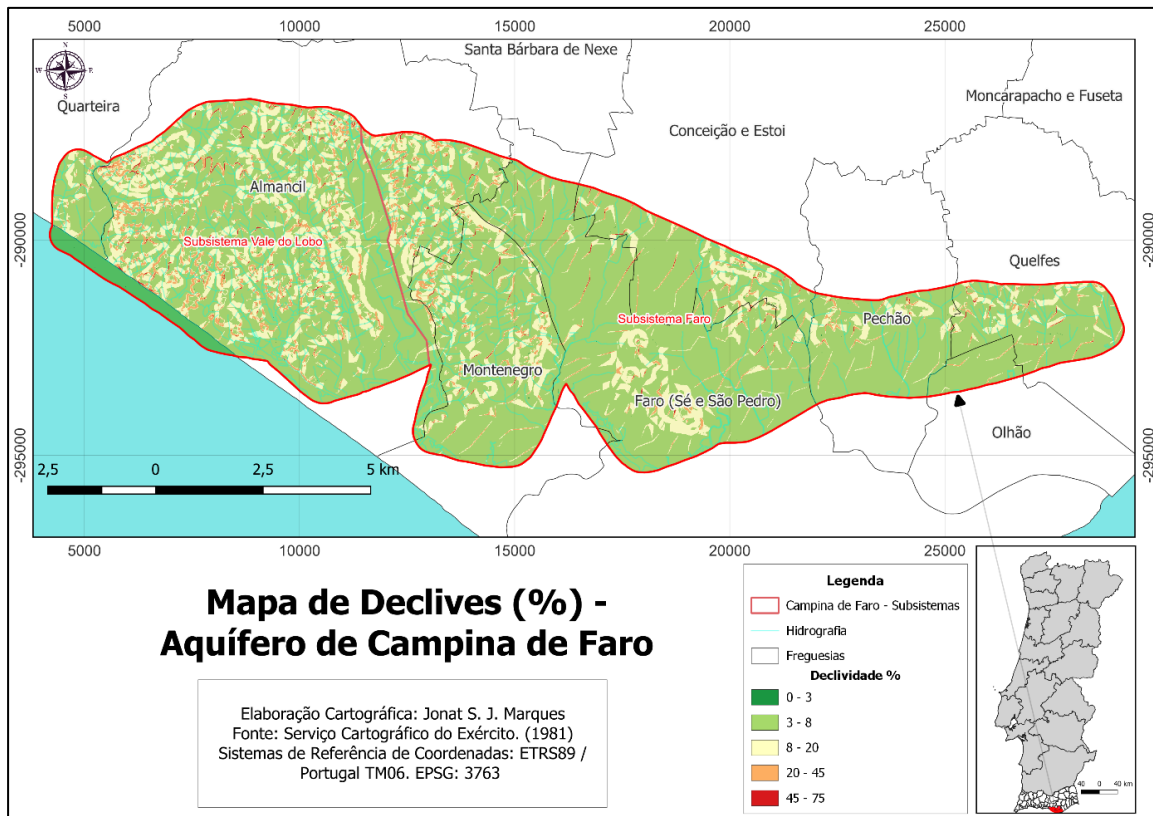


Figura 7 - Mapa de Declives (%) - Aquífero Campina de Faro

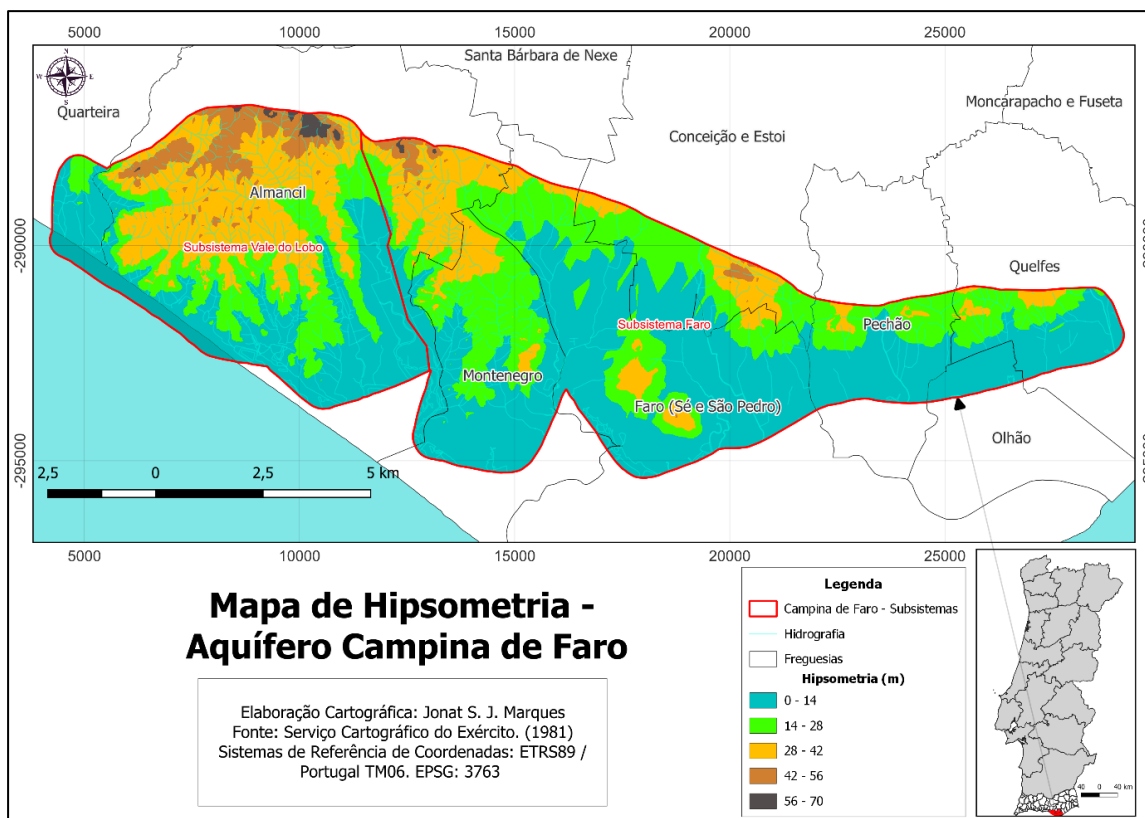


Figura 8 - Mapa de Hipsometria - Aquífero Campina de Faro

O declive e a hipsometria influenciam diretamente a gestão sustentável do aquífero, especialmente face às alterações climáticas e à exploração dos recursos hídricos. Um declive suave pode favorecer a acumulação de água no subsolo, mas também aumentar o risco de intrusão salina na zona costeira. Por outro lado, uma hipsometria baixa facilita o acesso à água subterrânea, mas pode reduzir o seu potencial hidráulico. Estes fatores devem ser tidos em conta na modelação do balanço hídrico, como demonstrado por Ferreira (2009), que analisou diferentes cenários climáticos e de exploração dos recursos.

4.3. Caracterização Climática da Região

O aquífero da Campina de Faro é essencial para o abastecimento de água em consumo humano, agricultura e turismo. Como o clima afeta a recarga do aquífero e a disponibilidade de água, é crucial incluir as características climáticas e a variabilidade sazonal na análise.

A região do Algarve, onde se localiza o Aquífero Campina de Faro, tem um clima mediterrânico (Csa segundo a classificação de Köppen), caracterizado por verões quentes e secos e invernos amenos e chuvosos. Os principais fatores climáticos que influenciam o aquífero incluem a precipitação sazonal, que ocorre maioritariamente entre dezembro e março,

e a variabilidade interanual, crucial para a recarga do aquífero. A região também apresenta temperaturas médias anuais elevadas, frequentemente acima dos 30°C no verão, e alta evapotranspiração devido à temperatura e baixa humidade, o que reduz a água disponível para a recarga.

4.3.1. Precipitação

Os dados climáticos utilizados para caracterizar a precipitação na área de estudo provêm da estação meteorológica do Patacão da rede Agrometeorológica da DRAP-Algarve (<https://www.drapalgarve.gov.pt/ema/publica.htm>), situada a 13 metros de altitude no Patacão, Faro, nas Coordenadas WGS84: Latitudet (N): 37° 02' 48,8" e Longitude g (W): 07° 56' 49,8". O clima da área de estudo, segundo dados da estação meteorológica de Patacão em Faro, segue o padrão mediterrânico, com verões secos e invernos chuvosos. A precipitação é maior de dezembro a março, atingindo o pico em novembro, e diminui de julho a setembro, quando as temperaturas sobem.

A análise da precipitação cobre o ano hidrológico de outubro a setembro, no período de 2016 a 2023. A média anual de precipitação é de cerca de 555 mm. Dezembro regista a maior média (105 mm), seguido de novembro e março, com médias de aproximadamente 95 mm e 88 mm, respetivamente. Junho, julho e agosto têm os valores mais baixos, quase nulos, sendo julho o mais seco, refletindo a estação seca típica do clima mediterrâneo. A precipitação aumenta significativamente a partir de outubro, atingindo o pico em dezembro, e diminui gradualmente após março até os mínimos valores em julho. A partir de setembro, inicia-se um novo aumento da precipitação, marcando o começo da estação chuvosa (Anexo 1, Tabela 1). Os dados obtidos (Anexo 1, Tabela 2) foram utilizados para classificar os anos em condições médias ou semi-húmidas, quando a precipitação anual é superior a 509 mm, ou em condições secas, quando é inferior. A classificação segue os critérios estabelecidos pela Intervenção Uso Eficiente da Água (UEA), da (Direção-Geral de Agricultura e Desenvolvimento Rural (DGADR), 2023).

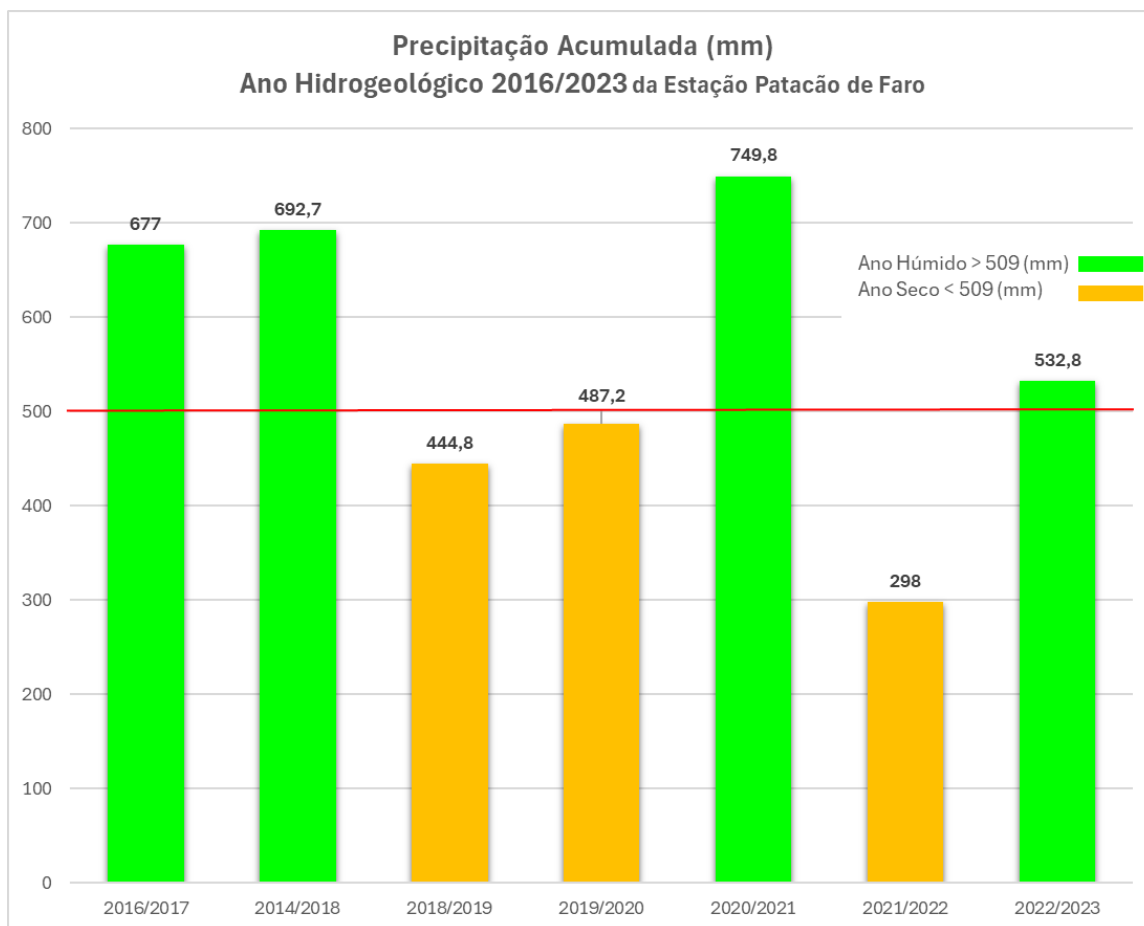


Figura 9 - Valores de precipitação acumulada (mm) para o ano hidrogeológico 2016/2023 da Estação Patação, Faro

Com base no Anexo 1, Tabela 1 e Figura 9, verifica-se que os anos hidrogeológicos de 2016/2017, 2017/2018, 2020/2021 e 2022/2023 apresentam valores acima da média, ou seja, são anos que se enquadram no cenário A (Condições Climáticas Médias ou Semi-Húmidas) no qual a precipitação no ano é maior que 509 mm (Direção-Geral de Agricultura e Desenvolvimento Rural (DGADR), 2023).

Os dados mostram períodos de baixa disponibilidade de água durante o verão, o que pode exigir estratégias de armazenamento e conservação. A variabilidade da precipitação afeta diretamente a agricultura, tornando essencial conhecer esses padrões para escolher as culturas mais adequadas e planear a rega durante os períodos de seca.

4.3.2. Evapotranspiração Potencial

A ETP representa a quantidade máxima de água que poderia ser evaporada e transpirada por uma superfície vegetal com água ilimitada, ou seja, a quantidade transferida para a atmosfera em condições ideais. Este conceito é essencial para o balanço hídrico e a gestão

sustentável dos recursos hídricos, especialmente em regiões com importância agrícola e turística, como a Campina de Faro.

O cálculo da ETP no aquífero Campina de Faro foi realizado através do método de *Penman-Monteith*, recomendado pela Organização das Nações Unidas para a Alimentação e Agricultura (FAO) pela sua precisão, ao integrar variáveis climáticas como radiação solar, temperatura do ar, humidade relativa e velocidade do vento. (Allen et al., 1998). Foram utilizados dados meteorológicos da Direção Regional de Agricultura e Pescas do Algarve (DRAP Algarve), incluindo valores diários de evapotranspiração de referência (ET₀), interpolados numa malha regular. Estes dados são fundamentais para modelar o balanço hídrico e implementar práticas agrícolas sustentáveis. Na Campina de Faro, a elevada ETP, aliada à baixa precipitação anual (cerca de 555 mm), intensifica a necessidade de rega, aumentando a pressão sobre o aquífero (eGROUNDWATER, 2023), que já sofre com a sobre-exploração e intrusão salina (Scheiffer et al., 2023), reforçando a urgência de uma gestão eficiente dos recursos hídricos.

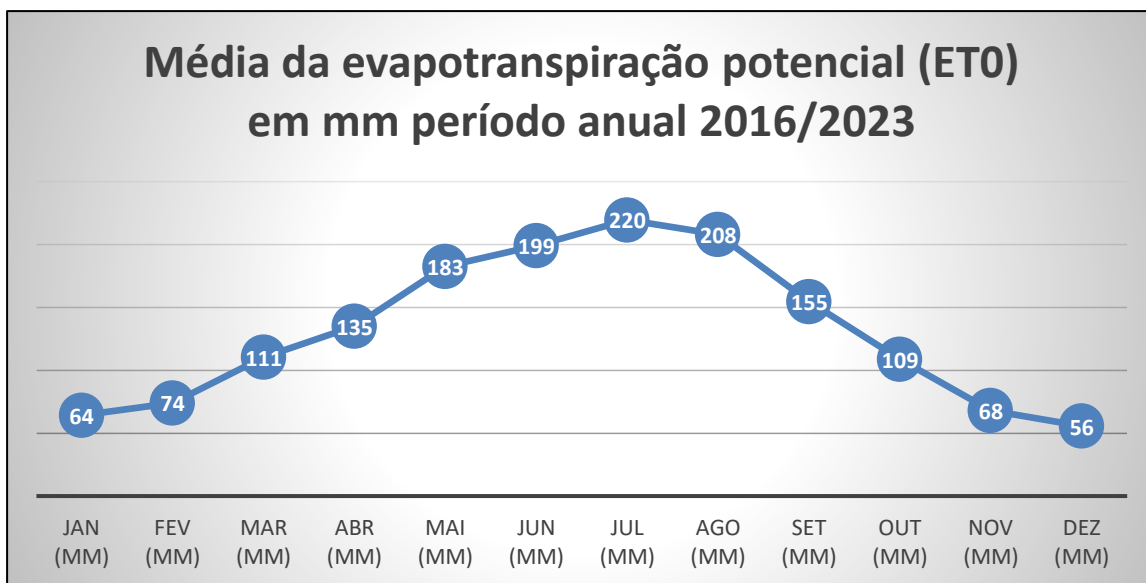


Figura 10 - Média mensal da evapotranspiração potencial (ET₀) em mm na estação Patacão, Faro

De acordo com o Anexo 1, Tabela 3 e Figura 10, a evapotranspiração aumenta a partir de abril, atingindo o pico em julho (220 mm), com junho e agosto também a registar valores elevados (199 mm e 208 mm, respetivamente), refletindo uma maior necessidade de água durante o verão, o período mais seco. A partir de setembro, os valores começam a diminuir, chegando aos níveis mais baixos em dezembro (56 mm), janeiro (64 mm) e fevereiro (74 mm), meses de inverno com menor radiação solar e temperaturas mais baixas.

Comparando a evapotranspiração com a precipitação (Figura 9), verifica-se que os meses de alta evapotranspiração, geralmente no verão, coincidem com baixos níveis de

precipitação, o que indica uma grande necessidade de rega. A elevada evapotranspiração no verão sublinha a importância de um planeamento cuidadoso da rega para garantir a produtividade agrícola. No inverno, a menor evapotranspiração coincide com uma maior precipitação, o que reduz a necessidade de rega. Estes dados são cruciais para a gestão dos recursos hídricos, facilitando o planeamento do armazenamento de água e a implementação de medidas de conservação. A análise anual da evapotranspiração potencial, junto com a precipitação, oferece uma visão clara das necessidades hídricas na região de Faro, sendo fundamental para o planeamento ambiental e agrícola sustentável, a gestão dos recursos hídricos e o desenvolvimento de estratégias para enfrentar as variações climáticas sazonais.

4.4. Caracterização do Uso e Ocupação do Solo

Entender os tipos de uso e ocupação do solo e seus impactos é essencial para caracterizar e quantificar as áreas regadas. Neste estudo, foi realizada a análise do uso e ocupação do solo na área do aquífero Campina de Faro para o ano de 2021, o que resultou no mapa apresentado (Figura 12), identificando os diferentes tipos de uso do solo. Como parte desta análise, foram utilizados dados históricos da classificação parcial do uso e ocupação do solo de 2007, fornecidos pela Agência Portuguesa do Ambiente (2007). Esses dados destacam várias classes de áreas que, de alguma forma, foram submetidas à antropização na região de estudo (Figura 11) e serviram como referência para avaliar as mudanças no uso do solo ao longo do tempo. Além disso, a análise desenvolvida nesta tese está alinhada ao contexto do projeto eGROUNDWATER, que investiga a relação entre o uso do solo e os recursos hídricos subterrâneos.

Este projeto não se concentrou na atualização de todos os tipos de uso e ocupação do solo na área de estudo, mas apenas nas principais ocupações que demandam recursos hídricos e que já haviam sido mapeadas em 2007. Foram mapeados 3.052,61 ha (27,65% da área total) das culturas, de um total de 11.040,51 ha (conforme a classificação da COS 2018) da área total do aquífero Campina de Faro.

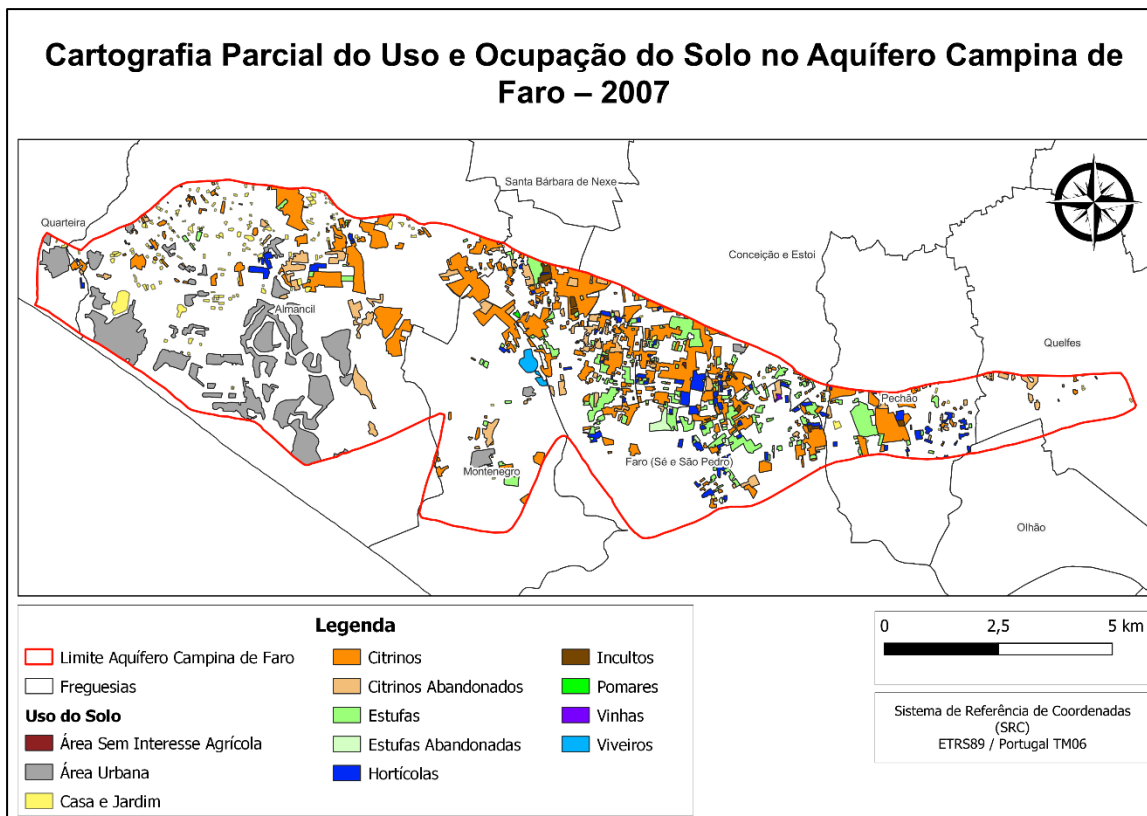


Figura 11 - Cartografia Parcial do Uso e Ocupação do Solo no Aquífero Campina de Faro – 2007

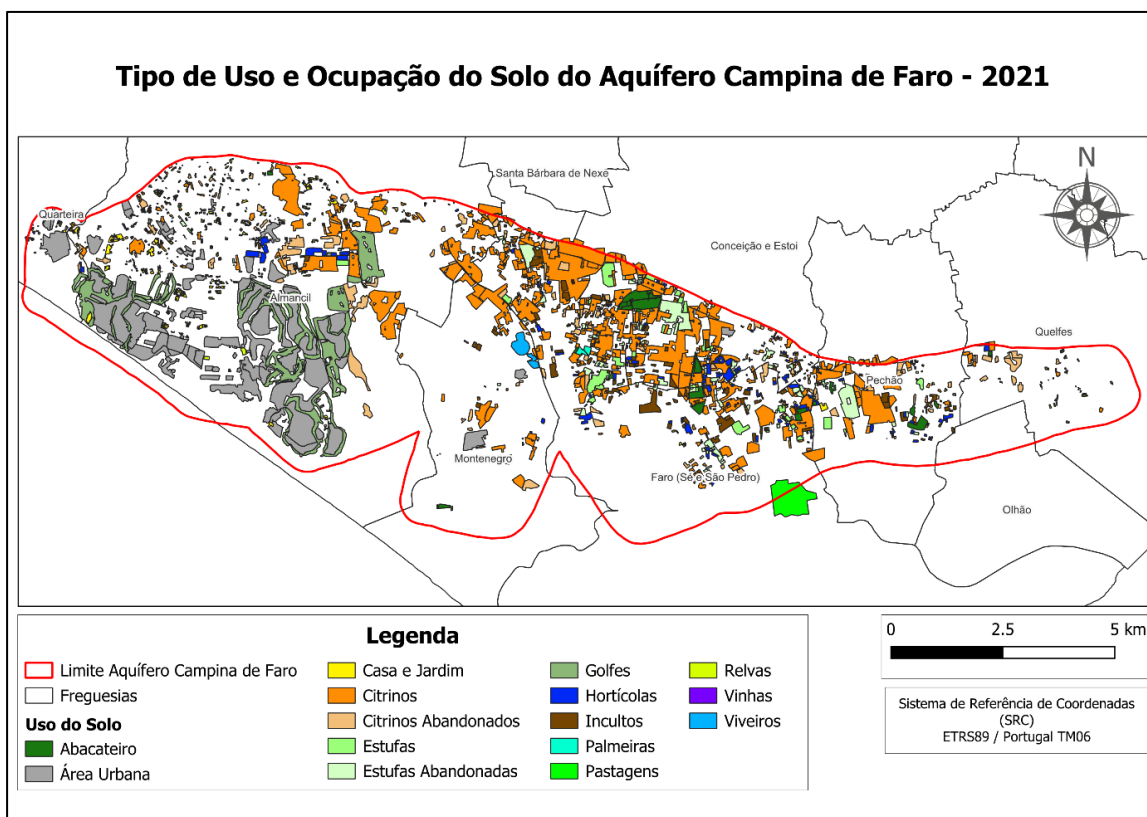


Figura 12 - Mapa de Uso e Ocupação do Solo do Aquífero Campina de Faro para 2021

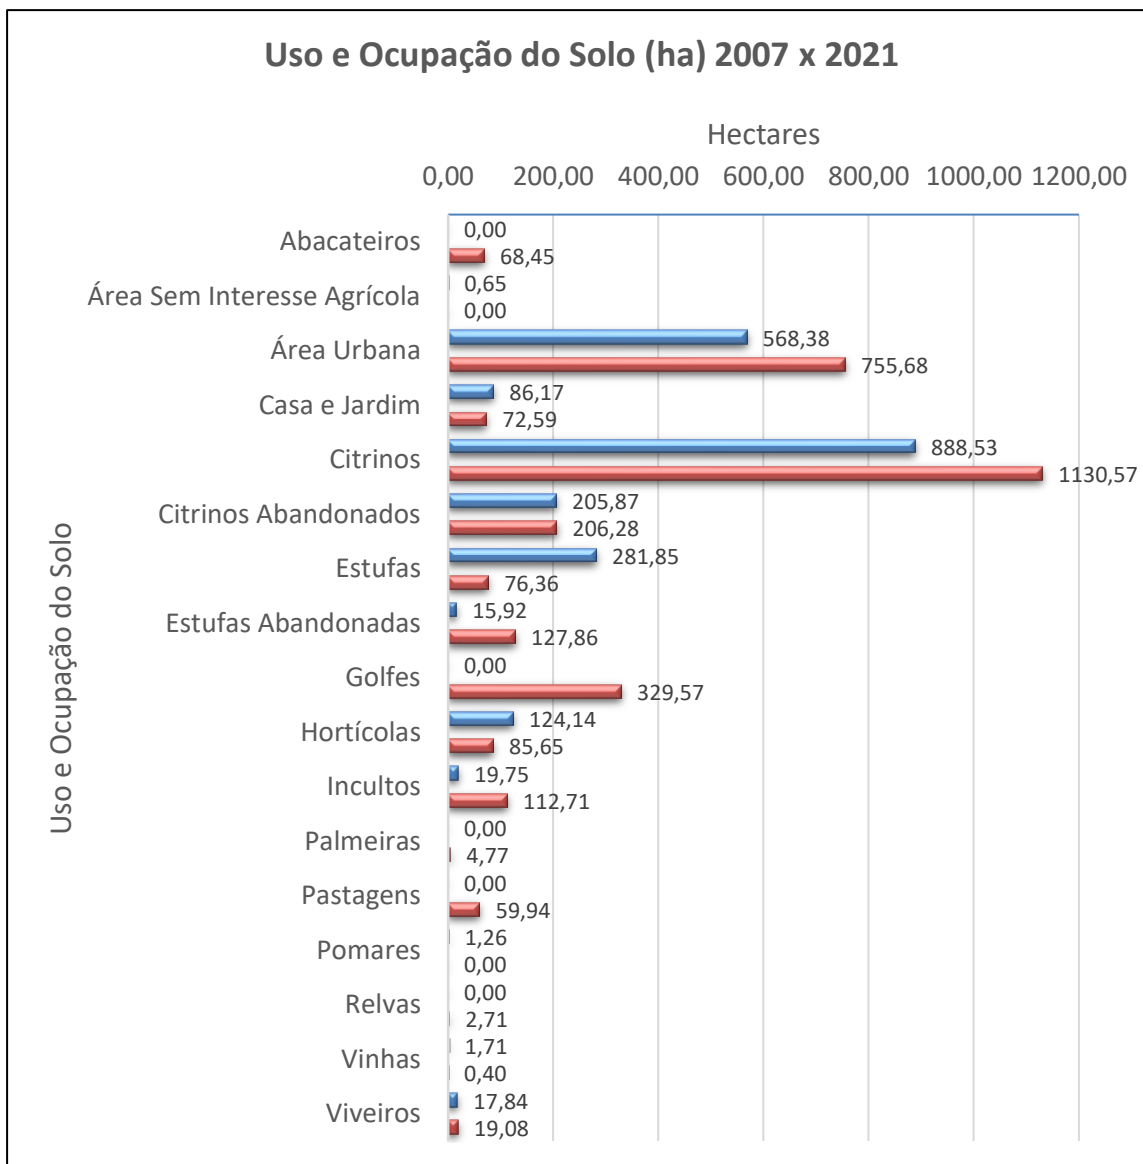


Figura 13 - Comparativo entre 2007 (azul) x 2021 (vermelho) do Uso e Ocupação do Solo em hectares

O comparativo do quantitativo em hectares entre os anos de 2007 e

2021 dos tipos de uso e ocupação do solo, determinada com base nas áreas correspondentes das figuras anteriores, podem ser observadas no gráfico da Figura 13.

A análise dos dados de uso e ocupação do solo entre 2007 e 2021 revela várias tendências significativas, dentre elas:

Crescimento Urbano: Houve um aumento de aproximadamente 33% na área urbana, indicando uma expansão significativa de áreas residenciais e comerciais. Isso pode ter impactos na recarga do aquífero devido ao aumento da impermeabilização do solo.

Expansão dos Cultivos de Citrinos: As áreas dedicadas a citrinos cresceram cerca de 27%, indicando um aumento na produção agrícola desses frutos. No entanto, também se observa um leve aumento nas áreas de citrinos abandonados, o que pode sugerir desafios na manutenção

dessas plantações.

Introdução e Expansão de Novos Usos: Novos usos do solo, como abacateiros, palmeiras, pastagens e relvas, foram introduzidos e cresceram significativamente. Estas novas práticas podem alterar a dinâmica da recarga e a qualidade da água subterrânea.

Durante a análise, foi identificado uma discrepância nos dados referentes às áreas destinadas a campos de golfe. De acordo com as imagens de satélite de junho de 2007 (Figura 14), já existiam áreas significativas dedicadas a campos de golfe na região. No entanto, essas áreas não foram contabilizadas e existe ausência nos dados de uso do solo para o ano de 2007 de acordo com os dados recebidos (Figura 15). Essa inconsistência na classificação pode ser devido à falta de critérios claros ou à variabilidade nas metodologias utilizadas na época.

Declínio em Estufas: Houve uma redução dramática (aproximadamente 73%) nas áreas de estufas ativas, enquanto as estufas abandonadas aumentaram significativamente (703%). Isso pode indicar uma transição nas práticas agrícolas ou problemas de sustentabilidade económica dessas operações.

Aumento das Áreas Incultas: As áreas incultas aumentaram em 470%, sugerindo um crescimento significativo de terras deixadas sem cultivo. Isso pode ter implicações para a gestão de recursos e a sustentabilidade ambiental. As áreas classificadas como "sem interesse agrícola" em 2007 foram reclassificadas como "incultas" em 2021.

Redução de Áreas Hortícolas e Vinhas: As áreas dedicadas a hortícolas e vinhas diminuíram consideravelmente, o que pode afetar negativamente a diversidade agrícola da região.

Estas mudanças no uso e ocupação do solo impactam a gestão do aquífero Campina de Faro. O aumento das áreas urbanas reduz a infiltração de água e compromete a recarga do aquífero. Para mitigar isso, é importante adotar práticas de urbanismo sustentável, como superfícies permeáveis e sistemas de gestão de águas pluviais.

O crescimento de estufas abandonadas pode afetar a qualidade da água subterrânea. A recuperação ambiental dessas áreas, com técnicas agrícolas orgânicas e monitoramento da qualidade da água, é essencial para evitar contaminação.

A água da chuva interceptada e acumulada nos plásticos das estufas apresenta potencial para contribuir com a recarga do aquífero, desde que consiga infiltrar no solo e atingir a superfície do aquífero. Essa água pode ser considerada uma importante fonte adicional de recarga, desde que sejam criadas condições ideais para sua infiltração. Tal recarga adicional tem o potencial de complementar a recarga natural, ajudando a mitigar os impactos da exploração excessiva, bem como a resolver problemas associados aos rebaixamentos do nível

freático observados nos últimos anos. Além disso, essa contribuição pode atuar como barreira ao avanço da intrusão salina em áreas costeiras. Estimativas indicam que a água interceptada pelas estufas corresponde a aproximadamente 1,5 hm³/ano em anos com precipitação média, conforme relatado por Costa et al., 2021.

As mudanças na agricultura, como o aumento de citrinos e a introdução de abacateiros, devem ser acompanhadas de práticas sustentáveis, como irrigação eficiente, rotação de culturas e agricultura de precisão, que asseguram o uso racional dos recursos e a preservação do solo e da água. Essas ações garantem a sustentabilidade do aquífero e o equilíbrio entre o desenvolvimento económico e a preservação ambiental.

Recomenda-se a implementação de zonas de recarga protegidas, políticas de uso sustentável do solo e monitoramento contínuo para mitigar os impactos negativos e promover a gestão eficaz dos recursos hídricos da região.

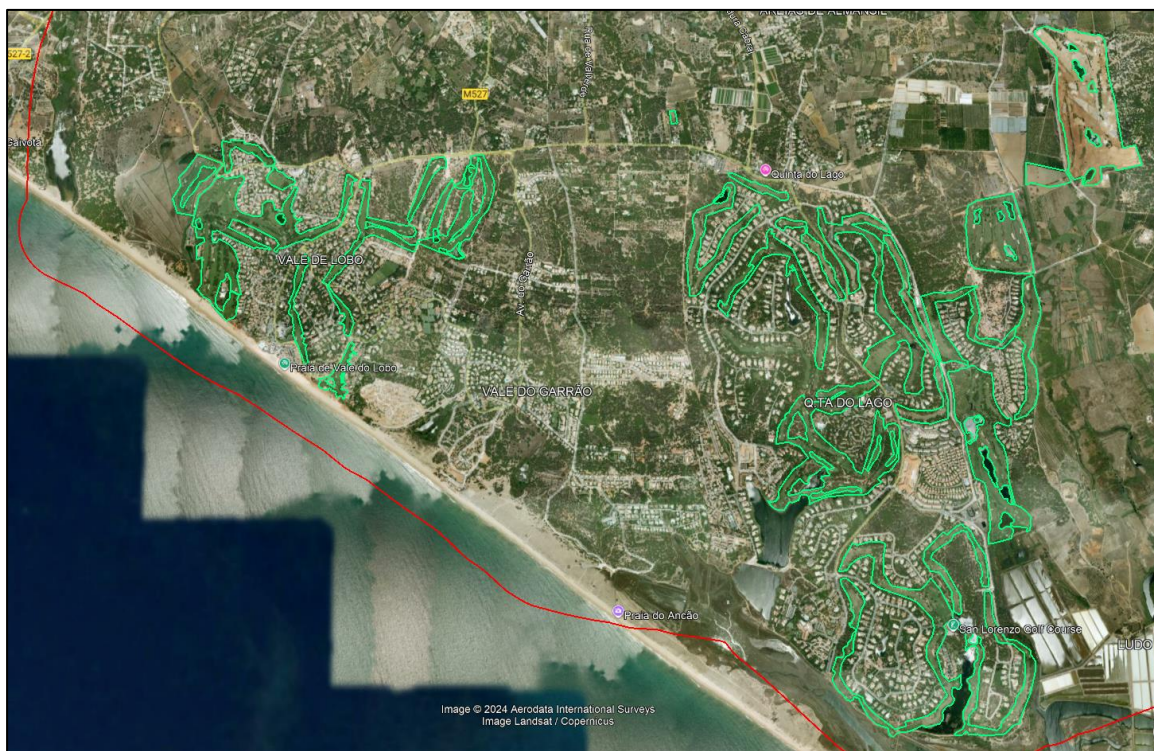


Figura 14 - Áreas de Campos de Golfes situados dentro do Aquífero Campina de Faro



Figura 15 - Ausência de dados sobre as áreas de golfe em 2007

As alterações de abacateiros e estufas entre os períodos, podem ser vistos nas Figuras 16 e 17.



Figura 16 - Classificação do uso e ocupação do solo em 2007 (esquerda) e 2021 (direita), destacando abacateiros (verde-escuro) e citrinos (laranja)



Figura 17 - Uso e ocupação do solo em 2007 (esquerda) e 2021 (direita): estufas (verde) e estufas abandonadas (verde-claro). Imagem final destaca estufas abandonadas

Para validar e comparar os resultados obtidos para 2007 e 2021, propõe-se utilizar a Carta de Uso e Ocupação do Solo (COS) de Portugal Continental para 2018 (Direção-Geral do Território (DGT), 2018). Esta carta é compatível com a nomenclatura da cartografia CORINE Land Cover, que é um produto de referência para a ocupação e uso do solo na Europa e em Portugal (Direção-Geral do Território, 2018). Utilizar o COS2018 permite identificar mudanças e padrões de ocupação do solo ao longo do tempo, além de abranger toda a área do estudo em questão. O COS2018 foi desenvolvido pela Direção-Geral do Território (DGT) e segue padrões rigorosos de recolha e processamento de dados, garantindo a confiabilidade e a validade das

informações. Isso assegura que esta pesquisa esteja alinhada com as normas e políticas nacionais e europeias de monitorização e gestão do solo. Apresentam-se os resultados (Figura 18) do uso e ocupação do solo ao nível mais detalhado das classes (nível 4 de acordo com o Anexo 2, Tabela 1 – Nomenclatura da COS2018).

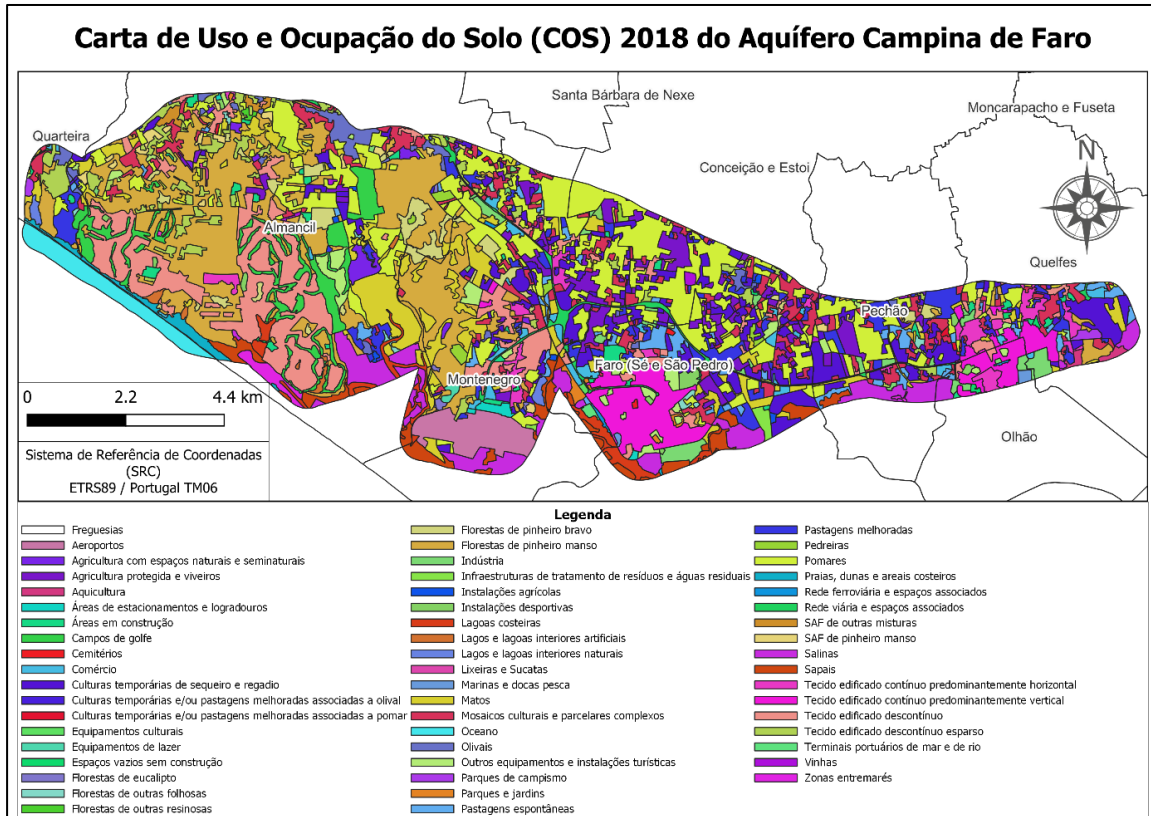


Figura 18 - Mapa de Uso e Ocupação do Solo do Aquífero Campina de Faro para 2018

No (Anexo 2, Tabela 2), apresenta-se a distribuição dos tipos de uso e ocupação do solo, calculada com base nas áreas correspondentes.

De acordo com a classificação COS2018, as áreas classificadas como megaclasse agricultura, apresentaram a maior taxa de ocupação do solo na área em estudo, correspondem a aproximadamente 3480,31 ha, o equivalente a 31,52% do território total da área de estudo, evidenciando a sua grande importância para a área de estudo. Predominantemente ocupado por pomares que corresponde a praticamente 43,56% de toda a área agrícola, conforme se consegue perceber na Figura 19. Estes pomares, essencialmente de citrinos, amendoeiras, figueiras e alfarrobeiras, representam um componente vital não apenas pela produção de alimentos, mas também pelo seu papel na manutenção da biodiversidade local e na estruturação da paisagem rural.

A utilização de técnicas avançadas de gestão da água, como a rega gota-a-gota, tem sido fundamental para a viabilidade destes pomares, especialmente num contexto de escassez hídrica

característica do Algarve. A eficiência hídrica é conseguida através da aplicação precisa de água diretamente nas raízes das plantas, minimizando as perdas por evaporação e maximizando a absorção pelas culturas. Além disso, a implementação de sensores de umidade do solo e de estações meteorológicas permite um monitoramento contínuo das condições ambientais, possibilitando ajustes em tempo real nas práticas de rega para otimizar o uso dos recursos hídricos.

A integração dos SIG na gestão agrícola tem trazido avanços significativos, permitindo mapear e analisar o uso do solo, monitorizar a saúde das culturas e planejar intervenções de manejo de forma eficiente. Os SIG facilitam a visualização e análise de dados em várias escalas, ajudando a identificar padrões e tendências para estratégias de gestão mais sustentáveis.

A análise espacial detalhada realizada com SIG revela não só a distribuição das áreas agrícolas, mas também a variabilidade dentro das parcelas, que pode influenciar a produtividade. Esta informação é crucial para a implementação de práticas de agricultura de precisão, que visam otimizar o rendimento das culturas e minimizar os impactos ambientais.

A capacidade de correlacionar dados climáticos, de solo e de vegetação numa plataforma integrada facilita a tomada de decisões informadas e a adoção de medidas proativas para enfrentar desafios como a variabilidade climática e a disponibilidade de água.

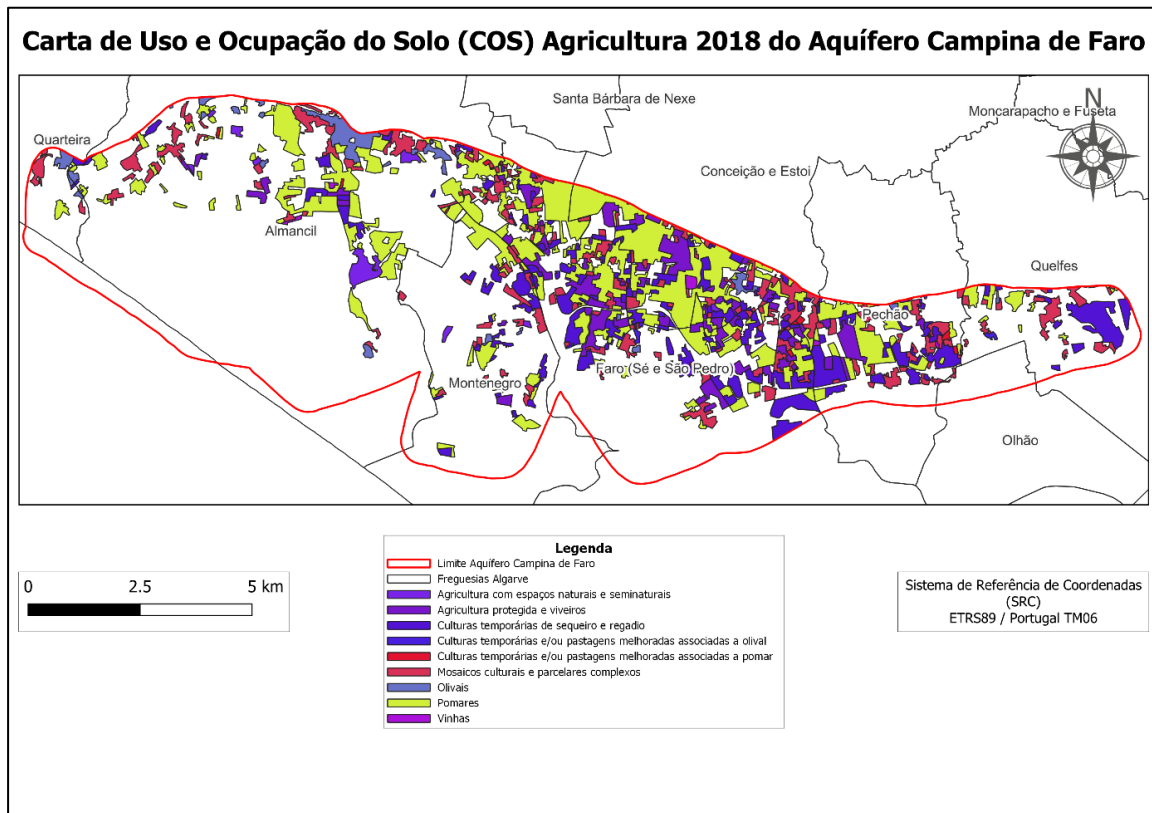


Figura 19 - Uso e Ocupação do Solo COS2018 Agricultura

A segunda maior área de ocupação é a dos Territórios Artificializados conforme Figura 20, que totalizam cerca de 3.350,70 ha, representando aproximadamente 30,35% da área total do sistema do aquífero. Dentro dessa área, 1.012,27 ha (ou 30,40%) correspondem a tecidos edificadas descontínuos, predominantemente ocupados por construções residenciais, e associados a áreas com vegetação e solo nu. Esta classe inclui também mosaicos de áreas cultivadas e construídas, destacando uma grande parcela de culturas familiares.

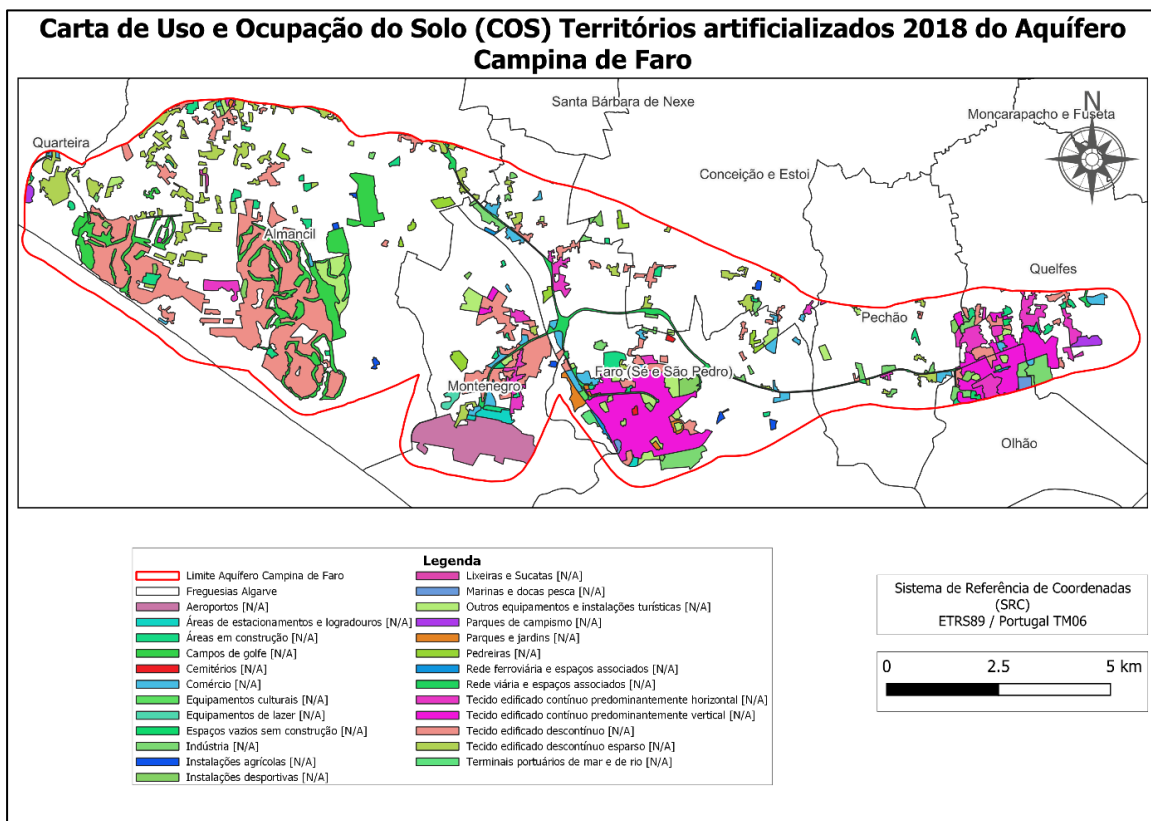


Figura 20 - Uso e Ocupação do Solo COS2018 Territórios Artificializados

A terceira maior área de ocupação é a das florestas conforme Figura 21, com aproximadamente 1.847,07 ha, o que representa 16,73% da área total do estudo.

Os diferentes usos e ocupações do solo na área de estudo afetam diretamente os recursos hídricos. A predominância agrícola, especialmente em pomares, leva a um alto consumo de água para rega e ao risco de contaminação devido ao uso de fertilizantes e pesticidas. Os territórios artificializados, com grandes áreas impermeabilizadas, reduzem a infiltração de água e aumentam o escoamento superficial, provocando inundações e poluição. Por outro lado, as áreas florestais são essenciais para a regulação do ciclo hidrológico, promovendo a infiltração e melhorando a qualidade da água.

Carta de Uso e Ocupação do Solo (COS) de Superfícies agroflorestais (SAF) e Florestas 2018 do Aquífero Campina de Faro

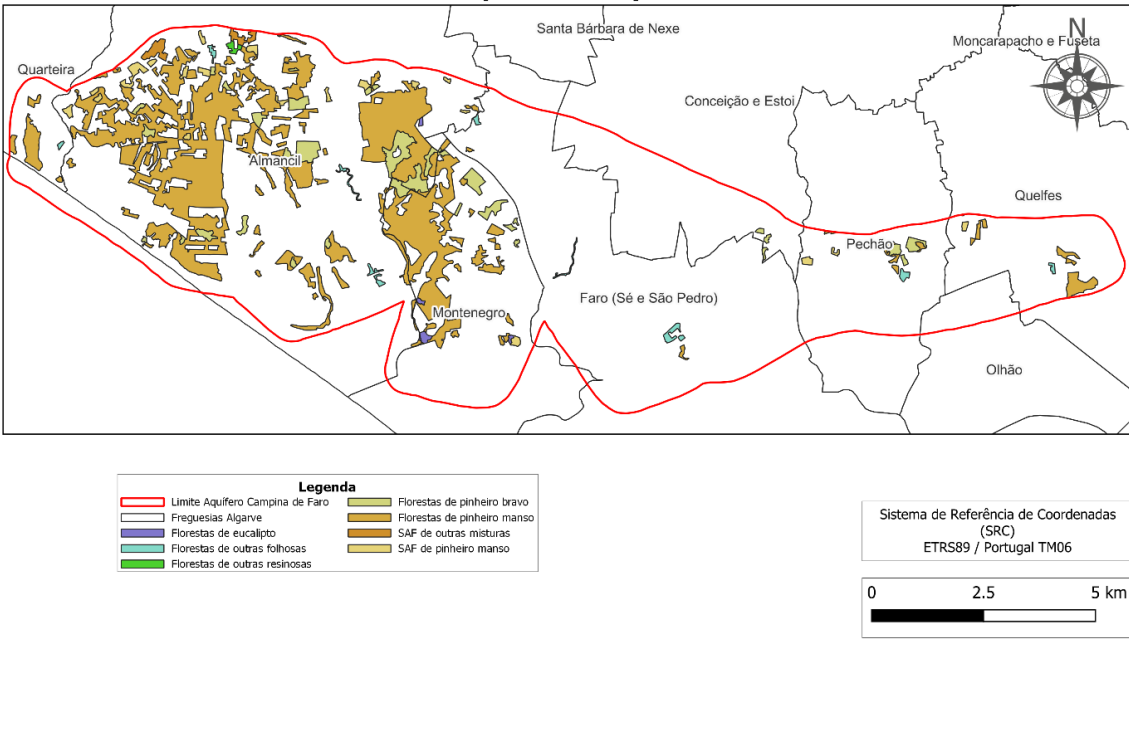


Figura 21 - Uso e Ocupação do Solo COS2018 SAF e Florestas

Nas Figuras 22 e 23, podem ser observados os outros tipos de uso e ocupação do solo.

Carta de Uso e Ocupação do Solo (COS) Pastagens 2018 do Aquífero Campina de Faro

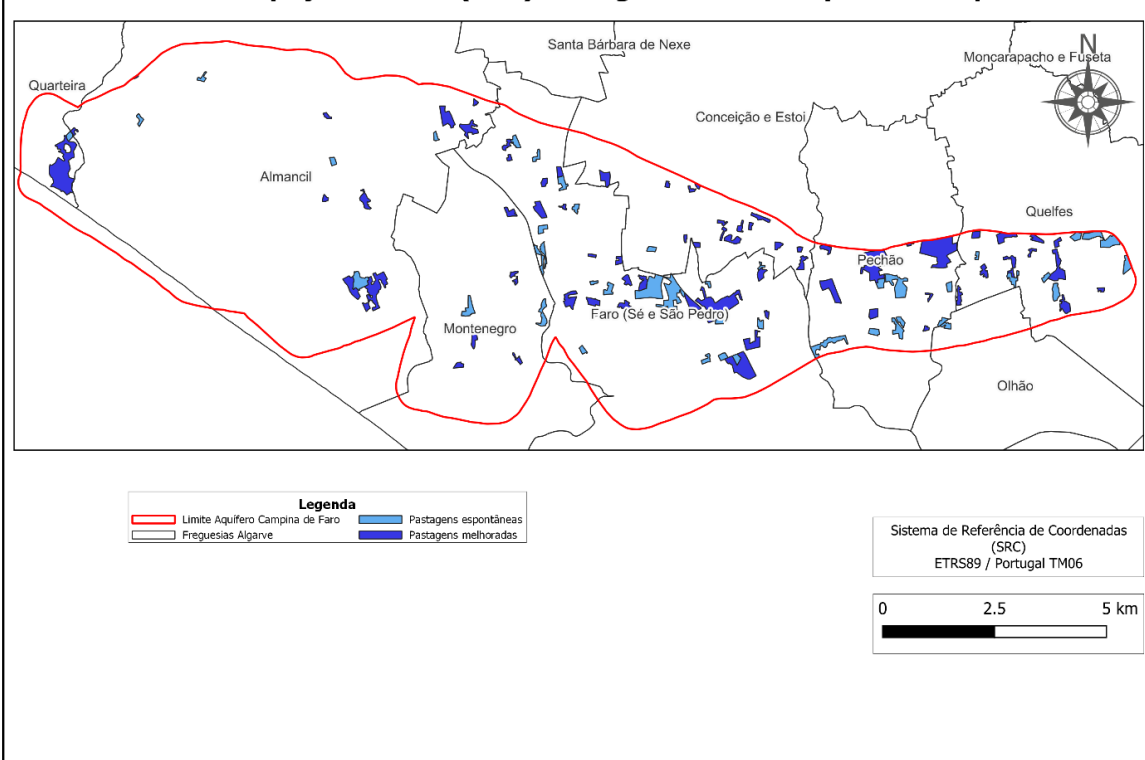


Figura 22 - Uso e Ocupação do Solo COS2018 Pastagens

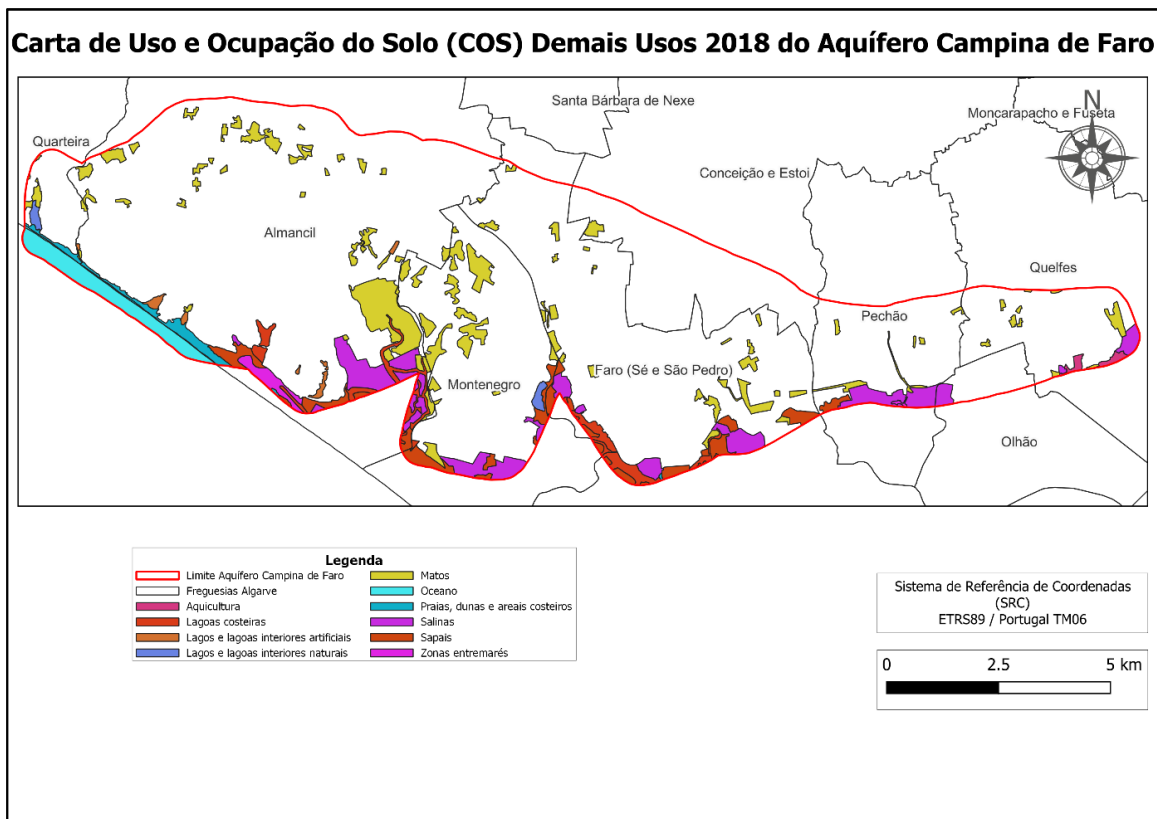


Figura 23 - Uso e Ocupação do Solo COS2018 Demais Usos (Matos, Espaços descobertos ou com pouca vegetação, Zonas húmidas e Massas de água superficiais)

5. Metodologia

5.1. Descrição geral da metodologia

Este capítulo descreve detalhadamente a metodologia adotada para a realização da análise espacial e a estimativa do uso da água nas áreas regadas, utilizando Sistemas de Informação Geográfica (SIG). A metodologia foi estruturada em várias etapas, incluindo a seleção e preparação dos dados, a classificação manual e automática, e a definição de parâmetros de referência para valores limiares. O objetivo é estabelecer uma base sólida para a análise e interpretação dos resultados obtidos, utilizando imagens de satélite e classificadores automáticos para identificar e classificar as principais culturas com áreas regadas na área de estudo correspondente ao Aquífero Campina de Faro.

Após classificar as culturas, calculou-se o volume de água aplicado nas áreas regadas, usando dados de deteção remota e algoritmos de aprendizagem automática para garantir uma análise precisa. O fluxograma abaixo (Figura 24 ou Anexo 13) mostra a metodologia utilizada para classificar as principais culturas e calcular o volume de água aplicado, utilizando imagens

de satélite e classificadores automáticos.

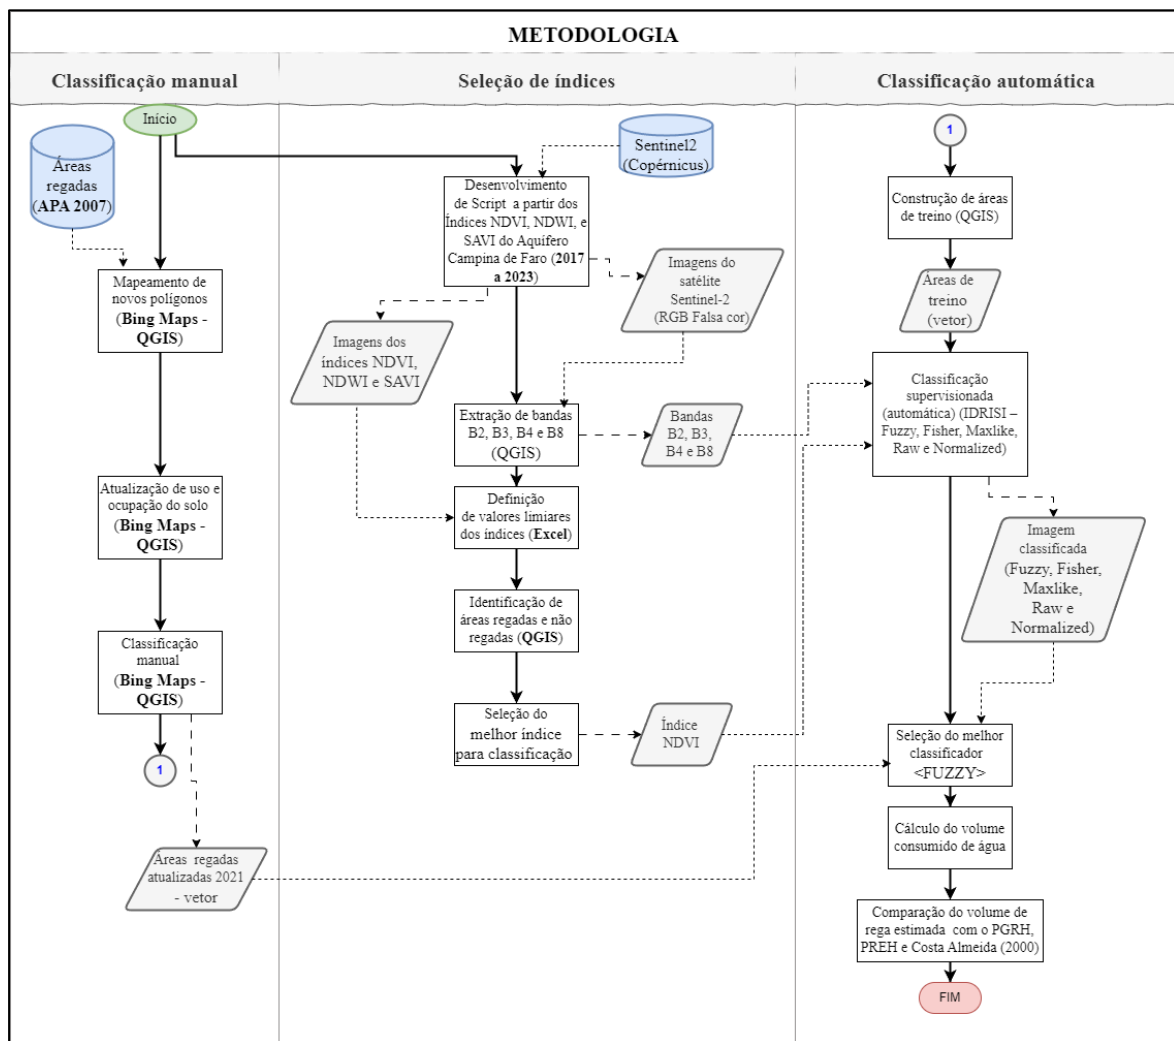


Figura 24 - Fluxograma da Metodologia

5.2. Aplicações informáticas utilizados

Para a obtenção e processamento das imagens de satélite, utilizou-se a plataforma online *Google Earth Engine*. Esta é uma plataforma de análise geoespacial baseada na nuvem, que permite aos usuários visualizar e analisar imagens de satélite da Terra de forma eficiente (Google Earth Engine, 2023).

Para a visualização e análise dos dados, foram utilizados o QGIS v3.28.3 (software de código aberto) e o ArcMap v10.6.1. (da ESRI). Para realizar a classificação supervisionada e correção das imagens por segmentação, utilizou-se o software *IDRISI 17.0*. (da *Clark University*).

Foi utilizado o sistema de coordenadas global de referência ETRS89 / Portugal TM06 (EPSG:3763), recomendado pela EUREF (*European Reference Frame*).

Para manipulação dos dados e obtenção de tabelas e gráficos, utilizou-se o Microsoft Excel 365.

5.3. Dados e Informação de base

Neste item, são descritos os dados e a base de dados utilizados no trabalho, que incluem informações base (imagens de satélite), informações auxiliares e dados obtidos por fotointerpretação. As imagens de satélite foram obtidas do satélite Sentinel-2 através de scripts desenvolvidos no *Google Earth Engine*. Esses scripts permitiram a seleção de imagens com base em parâmetros temporais, cobertura de nuvens, bandas espectrais, cálculo de índices e exportação das imagens.

As imagens fornecidas pelo *Google Earth Engine* já foram corrigidas para erros radiométricos e geométricos, eliminando a necessidade de pré-processamento adicional. Apenas foi necessário selecionar imagens com menor cobertura de nuvens e menor interferência atmosférica.

O período de análise foi de 2017 a 2023, dividido em período seco (julho a setembro) e período húmido (dezembro a março). Foi definido um limite de 30% de cobertura de nuvens para garantir uma boa visualização, já que a fotointerpretação exige imagens sem resíduos que possam dificultar a análise.

As bandas espectrais utilizadas variam conforme o índice Tucker (1979). Para os índices NDVI e SAVI, foram escolhidas as bandas B3, B4 e B8, com resolução de 10 metros por *pixel*. Para o índice NDWI, foram selecionadas as bandas B8 e B11, com resolução de 20 metros por *pixel*, conforme indicado no (Anexo 3, Tabela 1).

As bandas de cada imagem estão disponíveis em ficheiros separados, com projeção UTM Datum WGS 84. A delimitação da área de estudo, focada exclusivamente no aquífero Campina de Faro, foi feita a partir de um ficheiro *shapefile* compactado, que foi importado para o *Google Earth Engine*.

A linguagem de programação utilizada para elaborar os scripts com os parâmetros especificados foi o *JavaScript*. Os índices foram utilizados para determinar qual deles está melhor associado às áreas regadas e não regadas na área de estudo.

O Índice de Vegetação por Diferença Normalizada (NDVI) é amplamente utilizado para avaliar a saúde e densidade da vegetação, com valores que variam de -1 a 1, onde valores mais altos indicam vegetação saudável e valores mais baixos representam áreas com menos vegetação ou mesmo áreas não vegetadas. A relação entre o NDVI e a vegetação é bem

estabelecida porque o índice mede a fração de radiação absorvida e refletida pela vegetação durante a fotossíntese (Pettorelli et al., 2005). O NDVI é eficaz devido à forte absorção da vegetação na faixa do vermelho, devido a clorofila e à alta reflexão na faixa do infravermelho próximo, devido as estruturas das células das folhas (MELO et al., 2011).

A fórmula para o cálculo do NDVI (John R. Jensen, 1996) é dado por:

Equação 1 - NDVI

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

Onde *NIR* é a refletância no infravermelho próximo e *RED* é a refletância no vermelho.

O Índice de Vegetação Ajustado aos Efeitos do Solo (SAVI), desenvolvido por Townshend e Justice em 1981, considera a influência do solo na refletância. O SAVI é um índice de vegetação robusto, que é pouco afetado por condições atmosféricas adversas, como nuvens e neblina. O índice também é relativamente insensível a variações na textura do solo. A fórmula do SAVI (Huete, 1988) é:

Equação 2 - SAVI

$$SAVI = \frac{NIR-RED}{NIR+RED+L} \times (1 + L)$$

Onde *L* é um fator de ajuste, que leva em consideração a influência do solo na refletância da luz. Opta-se por *L=0* para áreas de vegetação densa e *L=1*, para áreas com pouca vegetação. O valor padrão frequentemente utilizado é 0,5 para situações intermédias de vegetação (Silva et al., 2005).

O Índice de Diferença Normalizada da Água (NDWI), proposto por Gao (1996), monitoriza a quantidade de água nas folhas. A absorção da água pela vegetação no comprimento de onda perto de 860 nm (*NIR*) é desprezível enquanto fraca absorção da água é indiciada nos 1.240 nm. Como resultado, o NDWI é sensível a alterações nos conteúdos de água nas folhas das plantas (Marques, 2018). A equação é dada por:

Equação 3 - NDWI

$$NDWI = \frac{NIR - SWIR}{NIR + SWIR}$$

Onde *NIR* é a refletância do Infravermelho próximo e *SWIR* é o Infravermelho de ondas curtas (*Shortwave Infrared*), normalmente em torno de 1.240 nm.

Através dos *scripts* (Anexo 3) executados na plataforma do *Google Earth Engine*, foi possível obter a visualização instantânea das imagens *Sentinel-2* de falsa cor (Anexo 3, Figura 1) e os índices NDVI (Anexo 3, Figura 2), SAVI e NDWI para o aquífero Campina de Faro.

Após a visualização no *Google Earth Engine*, é possível extrair os diferentes tipos de ficheiros no formato *GeoTIFF* ortorrectificadas para o *Google Drive* (ver exemplo: Anexo 3, Figuras 3 e 4).

Para organizar os ficheiros de acordo com o período temporal, foi adotada a seguinte convenção: PS representa o Período Seco e PU o Período Húmido (Anexo 3, Tabela 2).

Para alterar o sistema de referência de coordenadas das imagens de WGS 84 para ETRS 89 / Portugal TM06, utilizou-se o QGIS, exportando os ficheiros .TIF com o sistema de referência adequado.

Para obter as bandas separadas de cada período dos ficheiros Sentinel2_10m, recorreu-se à *calculadora raster* do QGIS, permitindo gerar os ficheiros de forma organizada para as classificações automáticas, como consta no (Anexo 3, Tabela 3).

Para definir os valores de referência para cada índice, utilizou-se o período seco de 2021. Este período serviu como base para a fotointerpretação e para a classificação manual das áreas regadas, conforme detalhado no capítulo seguinte.

5.3.1. Fonte de Dados Climáticos

Para caracterizar o clima do Algarve e, em particular, da região onde se encontra o Aquífero Campina de Faro, utilizaram-se diversas fontes de dados climáticos:

- Instituto Português do Mar e da Atmosfera (IPMA): Fornece dados meteorológicos detalhados, incluindo séries históricas de precipitação, temperatura e outros parâmetros relevantes.
- Agência Portuguesa do Ambiente (APA): Disponibiliza informações sobre recursos hídricos e a gestão do aquífero.
- Sistema Nacional de Informação de Recursos Hídricos (SNIRH): Plataforma que coleta, organiza, e dissemina dados sobre os recursos hídricos em Portugal.
- Rede de Estações Meteorológicas Automáticas (REMA) da Direção Regional de Agricultura e Pescas do Algarve (DRAPALG): A DRAPALG fornece dados meteorológicos essenciais para diversas atividades económicas e ambientais na região que dependem das condições climáticas na região do Algarve.

5.3.2. Métodos de Análise

Os dados climáticos são analisados através de duas técnicas principais para entender o impacto das condições climáticas no aquífero. Primeiro, realiza-se uma “análise estatística” para identificar tendências e padrões em séries temporais de dados climáticos. Em segundo lugar, utiliza-se o “geoprocessamento”, com ferramentas de SIG, para mapear a distribuição espacial das variáveis climáticas e sua relação com o aquífero.

5.4. Classificação Manual

A fotointerpretação, ou classificação manual do uso do solo, é uma técnica tradicional amplamente utilizada em estudos de geografia, planeamento urbano e gestão ambiental. Esta técnica envolve a análise visual de imagens aéreas ou de satélite para identificar e categorizar diferentes tipos de uso e cobertura do solo. Embora a classificação automática tenha ganho importância com o avanço das tecnologias de geoprocessamento, a fotointerpretação continua a ser uma abordagem valiosa devido à sua precisão e à capacidade de detetar detalhes que os algoritmos automáticos podem não captar.

No contexto da Campina de Faro, Algarve, a fotointerpretação foi utilizada para caracterizar e quantificar as áreas regadas, bem como para classificar os diferentes tipos de uso do solo na região em 2021. Esta análise manual permitiu identificar campos agrícolas e áreas de cultivo irrigado, fornecendo uma base sólida para validar e comparar métodos de classificação automática.

Previamente, a APA/ARH-Algarve (2007) forneceu ficheiros com a classificação do uso do solo para 2007 no aquífero Campina de Faro. Esses ficheiros incluíam um *shapefile* com atributos como “objectid”, “aquífero”, “área em m²”, “tipo de uso do solo” (incluindo categorias como área sem interesse agrícola, área urbana, citrinos, estufas, hortícolas, pomar, vinha, entre outros), “fonte”, “área regada”, e “perímetro”. A *shapefile* continha um total de 769 polígonos, correspondendo a 2.212,08 hectares.

A classificação manual iniciou-se em junho de 2022, após a definição das regras e critérios para identificar as áreas potencialmente regadas, estabelecidos em reuniões iniciais. Nessas reuniões, foram discutidas as principais culturas da área de estudo para atualizar a classificação do uso e ocupação do solo para 2021. A classificação foi auxiliada pelo *Bing maps* conforme Figura 25 e pelas imagens de satélite Sentinel-2 com resolução de 10 metros em falsa cor e cálculo do NDVI para os meses de julho a setembro (período seco) de 2021. No caso do NDVI, áreas com muita vegetação, como bosques não regados ou campos de golfe regados,

aparecem com tonalidades próximas do azul. Em contraste, áreas com menos vegetação são representadas em vermelho conforme Figura 26. Isso permitiu distinguir entre áreas regadas e não regadas, como, por exemplo, os campos de futebol com relva natural ou sintética conforme Figura 27.




Figura 25 - Delimitação em azul do Aquífero Campina de Faro no Bing Maps Aerial através do software QGIS



Figura 26 - Imagem a esquerda Bing Maps 2021 x Imagem a direita Sentinel 2 NVDI 2021




Figura 27 - Imagem de um campo de futebol regado - a esquerda Bing Maps 2021 x Imagem a direita Sentinel-2 NDVI 2021 com um valor médio de 0,85 de NDVI

A metodologia para a classificação manual das áreas de estudo consistiu em duas fases principais: a primeira fase envolveu a inclusão de novas áreas que não estavam mapeadas em 2007, e a segunda fase consistiu na atualização dos dados já existentes. A seguir, descrevem-se as etapas detalhadas de cada uma dessas fases.

5.4.1. Fase 1: Inclusão de Novas Áreas

Na primeira fase, foram mapeadas e identificadas novas áreas que não estavam incluídas na classificação de 2007. Durante esse processo, surgiram novos tipos de uso do solo, como campos de golfe, palmeiras, relvas, abacateiros e pastagens. Ao mesmo tempo, áreas sem interesse agrícola foram substituídas por zonas incultas, e pomares foram eliminados devido à falta de dados atualizados. Para garantir a precisão da classificação manual, foi criada uma coluna na tabela de atributos chamada "precisão", com o objetivo de avaliar o grau de confiabilidade de cada classificação realizada. Nesta coluna, foram atribuídos três valores: '0' para áreas com incertezas, correspondentes a locais onde os dados disponíveis são insuficientes ou inconsistentes, impossibilitando conclusões confiáveis; '0,5' para áreas com dúvidas, representando regiões onde os dados apresentam algum grau de confiabilidade, mas ainda possuem lacunas ou ambiguidades; e '1' para áreas com dados completos, consistentes e altamente confiáveis, permitindo conclusões com elevado grau de certeza. Esta categorização

foi aplicada a todos os tipos de uso do solo identificados.

5.4.2. Fase 2: Atualização dos Dados Existentes

A segunda fase envolveu a atualização das áreas previamente classificadas. Para isso, foi adicionada uma nova coluna na tabela de atributos, intitulada "t_usoAtual", para indicar o tipo de uso atual do solo. A coluna existente "t_uso" foi renomeada para "t_usoAntes", representando o uso anterior do solo. Nos casos de alteração no tipo de uso, o uso anterior foi mantido na coluna "t_usoAntes" e o novo uso foi registrado na coluna "t_usoAtual". Além disso, nesta fase, os polígonos existentes foram reavaliados e classificados conforme o grau de confiabilidade da classificação manual, seguindo o mesmo procedimento da primeira fase. Após a atualização dos dados, todos os polígonos foram integrados em um único arquivo shapefile, consolidando as informações para garantir a integridade dos dados e facilitar a análise subsequente. É proposto a elaboração de uma tabela para apresentar um resumo das principais alterações realizadas para cada tipo de solo, descrevendo o grau de alteração (inclusão de novos polígonos ou atualização dos existentes) e se o tipo de solo é regado ou não.

5.5. Parâmetro de referência para definir valores limiares

Este capítulo descreve a metodologia para identificar áreas regadas e não regadas com base nos índices de vegetação NDVI, NDWI e SAVI, extraídos de imagens de satélite *Sentinel 2* durante o período seco de 2021 (julho a setembro). Para definir os limiares que distinguem as áreas, foram calculados os valores da média, mediana, mínimos, máximos e o primeiro quartil (Q1) para cada índice e tipo de solo (11 classes) através da calculadora *raster* do QGIS conforme (Anexo 4, Tabela 1). Os resultados foram resumidos para identificar o Q1 de todas as classes, facilitando a definição dos limiares (Anexo 4, Tabela 2).

Os valores dentro do intervalo entre x e y são classificados como áreas regadas, onde x representa o limiar obtido pelo primeiro quartil e y é o valor máximo encontrado nas áreas consideradas regadas. A validação desses limiares é realizada utilizando a classificação manual de 2021 como referência. Esta etapa consiste em comparar os resultados classificados com os polígonos de uso do solo e dados de observação direta, possibilitando ajustes precisos nos limiares propostos.

A análise concentrou-se nas áreas classificadas manualmente em 2021, excluindo a imagem completa do aquífero Campina de Faro, e quantificou os *pixels* classificados como

regados e não regados em hectares. A ferramenta "r.report" do QGIS foi usada para criar um ficheiro .txt com os totais em hectares, distinguindo as áreas regadas de não regadas.

Durante o processo, foram identificados dois tipos de erros. O primeiro é o erro por omissão, onde áreas que deveriam ser classificadas como regadas, segundo a classificação manual, foram erroneamente identificadas como não regadas. Este erro ocorreu porque o limiar estabelecido estava abaixo do valor do primeiro quartil, levando a uma subclassificação das áreas. O segundo erro surge quando o método classifica áreas como regadas por estarem acima do limiar, embora, conforme a classificação manual de 2021, essas áreas não sejam efetivamente regadas. Este erro ocorreu devido a um ajuste inadequado do limiar, que não refletiu corretamente a distribuição real das áreas regadas.

Para identificar áreas regadas utilizando o NDWI, é necessário estabelecer um limiar específico para a região em questão, uma vez que não existe um valor universal aplicável a todas as situações. Geralmente, áreas regadas apresentam valores de NDWI mais elevados do que áreas não regadas, devido ao aumento da refletância da água nessas áreas. No entanto, o valor exato pode variar consoante o tipo de cultura, a quantidade de água aplicada e as condições ambientais.

Assim, para determinar o valor de NDWI que indica áreas regadas numa região específica, é recomendável realizar uma análise local. Isto envolve utilizar imagens de satélite ou outros dados de deteção remota da área e validar os resultados com informações de campo.

5.6. Classificação Automática

A metodologia de classificação automática deste estudo centra-se na aplicação dos classificadores *Fuzzy Artmap*, *Maxlike*, *Fisher*, *Normalized* e *Raw* no software *IDRISI Selva 17.0* para avaliar a sua eficácia na identificação de áreas regadas corretamente em SIG. Após a preparação e pré-processamento dos dados espaciais, cada classificador será aplicado de acordo com os seus parâmetros específicos. A análise dos desempenhos será realizada através de métricas estatísticas, com base em qual classificador conseguiu identificar de forma mais precisa as áreas que são regadas corretamente. O método que se revelar mais eficaz será então utilizado para calcular o volume total de água utilizado nas áreas identificadas, permitindo uma avaliação precisa e detalhada da gestão dos recursos hídricos. Esta abordagem permitirá escolher a metodologia mais adequada para diferentes contextos de aplicação em SIG, com um enfoque na precisão e na eficiência do uso da água.

5.6.1. *Fuzzy Artmap*

Este item descreve a metodologia aplicada para realizar a classificação automática utilizando o método *Fuzzy Artmap*, com ênfase na análise de áreas de cultivo regado dado que o objetivo é identificar um padrão comum para cada tipo de ocupação.

Para iniciar a classificação, optou-se pelo modo supervisionado. Utilizaram-se três bandas do satélite Sentinel-2 no sistema de referência WGS 84: a banda 3 (verde), que avalia a saúde da vegetação; a banda 4 (vermelho), associada à absorção pelas plantas saudáveis; e a banda 8 (NIR - Infravermelho Próximo), sensível à biomassa e à vegetação vigorosa. Adicionalmente, foi incluída a imagem *raster* NDVI com limiar superior a 0,20, que contém 12 classes (abacateiros, área fora do aquífero, campos de golfe, citrinos, estufas, hortícolas, palmeiras, pastagens, pomares, relvas, vinhas e viveiros), cobrindo o período seco de julho a setembro de 2021, em alinhamento com a classificação manual. Essas quatro imagens foram utilizadas nas fases de treino e de classificação.

Como dados de treino, que representem adequadamente as classes de interesse, foram selecionadas áreas previamente mapeadas como áreas regadas através da classificação manual de 2021, englobando diversos tipos de culturas, como abacateiros, áreas urbanas, campos de golfe, casa e jardim, citrinos, estufas, hortícolas, palmeiras, pastagens, relvas, vinhas e viveiros. Essas áreas foram delimitadas manualmente com base em imagens de satélite do Bing Maps em uma escala de 1:1 500, garantindo que o conjunto de treino fosse representativo e confiável.

As áreas de treino, de acordo com Foody (2002), servem como base para que o algoritmo *Fuzzy Artmap* aprenda as características espectrais que definem cada classe. É importante que essas áreas abranjam a diversidade de condições dentro de cada classe, incluindo diferentes estágios de crescimento das culturas ou variações na gestão da rega.

Para importar a imagem NDVI e as bandas do Sentinel-2, foi necessário convertê-las para 8 bits. A conversão foi realizada no software ArcMap 10.6.1, utilizando a opção "*Use Renderer*" na ferramenta *Export Raster Data*.

Propõe-se a utilização da ferramenta "*Overlay*" no *IDRISI* (Eastman, 2012c) para recortar as áreas das bandas B3, B4 e B8 de acordo com a imagem do NDVI. Esta operação multiplica cada banda pela imagem do NDVI, de modo que as áreas com valores acima do limiar de 0,20 mantêm-se, enquanto as áreas com valores abaixo de 0,20 são excluídas, otimizando assim o processamento das áreas que realmente interessam.

Para realizar a operação "*Overlay*" com sucesso, é necessário que as imagens tenham as mesmas dimensões em termos de linhas e colunas. No entanto, foram observadas discrepâncias

nas dimensões: as bandas tinham 3126 colunas e 872 linhas, enquanto a imagem do NDVI apresentava 3130 colunas e 882 linhas. Para corrigir esta diferença, propõe-se a georreferenciação da imagem NDVI utilizando a imagem da banda 3 (ou, alternativamente, as bandas 4 ou 8) através da ferramenta "Resample". Após este ajuste, a operação "Overlay" foi concluída com êxito (Figura 28).




Figura 28 - Imagem NDVI com valor limiar de 0.20 e as bandas 3, 4 e 8 sobrepostas após a operação Overlay

Propõe-se também a importação para o IDRISI dos polígonos das classes classificadas como áreas regadas na classificação manual de 2021. Antes de realizar a importação, é necessário através do software QGIS, criar um novo vetor no sistema de coordenadas de referência WGS 84 com as colunas "ID" e "Classe" para realizar a operação "Dissolver", a fim de agregar todos os polígonos de cada classe em um único polígono, fazendo com que tenha apenas 12 classes neste vetor. Após isto, é realizada a importação no IDRISI, posteriormente converte-se o formato de vetor para *raster* através da ferramenta "RASTERVETOR", resultando numa imagem com 12 classes representadas (Figura 29).




Figura 29 - Imagem raster das 12 classes classificadas como áreas regadas no IDRISI

Em resumo, para realizar a classificação utilizando o *Fuzzy Artmap*, propõe-se iniciar com o ano de 2021, que já possui uma referência baseada na classificação manual. Utiliza-se o modo de classificação supervisionada com valores padrão para a velocidade de aprendizagem e parâmetros de vigilância (*ART a* e *ART b*). As bandas B3, B4 e B8, juntamente com a imagem total do aquífero Campina de Faro com NDVI superior a 0,20, são usadas como dados de entrada. A digitalização das áreas de treino foi efetuada na imagem NDVI. O classificador treina

com base nas características dos *pixéis* dentro de cada classe e nas bandas específicas, alocando-os à classe correspondente. Após o treino, o modelo é aplicado a toda a região para classificar os *pixéis* em todas as classes.

O objetivo principal, ao concluir a classificação para o ano de 2021, é estabelecer uma base para os anos subsequentes. Dessa forma, não será necessária uma classificação manual para comparar os resultados das áreas já classificadas. Espera-se, assim, que a classificação automática forneça resultados fiáveis e coerentes, independentemente da localização geográfica e período temporal, garantindo que um determinado *pixel* seja corretamente classificado dentro de uma das 12 classes de ocupação existentes.

A Tabela 2 resume todas as 11 tentativas de classificações realizadas, que estão descritas detalhadamente ao longo deste subcapítulo 5.6.1, referente ao método *Fuzzy Artmap*. Esta tabela oferece uma visão geral das diversas tentativas de classificação, facilitando a compreensão dos resultados e das variações observadas ao longo do processo de análise.

Tabela 2 - Metodologia aplicada para realizar a classificação automática utilizando o método Fuzzy Artmap no Aquífero Campina de Faro

Tentativa	Objetivo	Dados de Entrada			Saída
	Identificar o Tipo de Uso e Ocupação dos Solos abaixo - 2021	Índice e limiar utilizado	Classes de Treino	Bandas	Resultados
1	12 classes: abacateiros, áreas urbanas, campos de golfe, casa e jardim, citrinos, estufas, hortícolas, palmeiras, pastagens, relvas, vinhas e viveiros	imagem raster NDVI com limiar superior a 0,20 do aquífero	12 classes: abacateiros, áreas urbanas, campos de golfe, casa e jardim, citrinos, estufas, hortícolas, palmeiras, pastagens, relvas, vinhas e viveiros	B3, B4 e B8	Falsos positivos (áreas classificadas como regadas que não são regadas) e Falsos negativos também foram detectados (áreas que são regadas e foram classificadas como não regadas)
2	2 classes: campos de golfe e citrinos	imagem raster NDVI com limiar superior a 0,20 do aquífero	2 classes: campos de golfe e citrinos	B3, B4 e B8	
3	9 classes: abacateiros, campos de golfe, casa e jardim, citrinos, hortícolas, palmeiras,	imagem raster NDVI com limiar superior a 0,20 do aquífero	9 classes: abacateiros, campos de golfe, casa e jardim, citrinos, hortícolas, palmeiras, relvas, vinhas e viveiros	B3, B4 e B8	Falsos positivos (áreas classificadas como regadas que não são regadas) e Falsos negativos também foram

Tentativa	Objetivo	Dados de Entrada			Saída
	Identificar o Tipo de Uso e Ocupação dos Solos abaixo - 2021	Índice e limiar utilizado	Classes de Treino	Bandas	Resultados
	relvas, vinhas e viveiros				detectados (áreas que são regadas e foram classificadas como não regadas)
4	9 classes: abacateiros, campos de golfe, casa e jardim, citrinos, hortícolas, palmeiras, relvas, vinhas e viveiros	imagem raster NDVI com limiar superior a 0,20 do aquífero com aplicação da ferramenta FILTER 7x7	9 classes: abacateiros, campos de golfe, casa e jardim, citrinos, hortícolas, palmeiras, relvas, vinhas e viveiros	B3, B4 e B8	
5	6 classes: abacateiros, campos de golfe, citrinos, hortícolas, áreas fora do aquífero e áreas com NDVI abaixo de 0,20 dentro do aquífero	imagem raster NDVI com limiar superior a 0,20 do aquífero Campina de Faro com aplicação da ferramenta <i>FILTER 7x7</i>	6 classes: abacateiros, campos de golfe, citrinos, hortícolas, áreas fora do aquífero e áreas com NDVI abaixo de 0,20 dentro do aquífero	B2, B3, B4 e B8	Falsos positivos (áreas classificadas como regadas que não são regadas) e
6	10 classes: abacateiros, áreas com NDVI abaixo de 0,20 dentro do aquífero, áreas fora do aquífero, campos de golfe, citrinos, florestas , hortícolas, salinas, sapais e zonas urbanas	imagem raster NDVI com limiar superior a 0,20 do aquífero	10 classes: abacateiros, áreas com NDVI abaixo de 0,20 dentro do aquífero, áreas fora do aquífero, campos de golfe, citrinos, florestas , hortícolas, salinas, sapais e zonas urbanas	B2, B3, B4 e B8	Falsos negativos também foram detectados (áreas que são regadas e foram classificadas como não regadas)
7	12 classes: abacateiros, áreas com NDVI abaixo de 0,20 dentro do aquífero, áreas fora do aquífero, campos de golfe, citrinos, estufas , florestas, hortícolas, salinas, sapais,	imagem raster NDVI com limiar superior a 0,20 do aquífero	12 classes: abacateiros, áreas com NDVI abaixo de 0,20 dentro do aquífero, áreas fora do aquífero, campos de golfe, citrinos, estufas , florestas, hortícolas, salinas, sapais, solos e zonas urbanas	B2, B3, B4 e B8	Falsos positivos (áreas classificadas como regadas que não são regadas) e Falsos negativos também foram detectados (áreas que são regadas e foram classificadas

Tentativa	Objetivo	Dados de Entrada			Saída
	Identificar o Tipo de Uso e Ocupação dos Solos abaixo - 2021	Índice e limiar utilizado	Classes de Treino	Bandas	Resultados
	solos e zonas urbanas				como não regadas)
8	9 classes: abacateiros, áreas com NDVI abaixo de 0,20 dentro do aquífero, artificial , campos de golfe, citrinos, florestas, hortícolas, salinas e solos	imagem raster NDVI com limiar superior a 0,20 do aquífero	9 classes: abacateiros, áreas com NDVI abaixo de 0,20 dentro do aquífero, artificial , campos de golfe, citrinos, florestas, hortícolas, salinas e solos	B2, B3, B4 e B8	
9	11 classes: abacateiros, areias, áreas fora do aquífero, áreas urbanas, caminhos, campos de golfe, citrinos, florestas, hortícolas, massas de água e solos	imagem raster NDVI com <i>Stretch</i> e limiar superior a 0,20 do aquífero Campina de Faro	11 classes: abacateiros, areias, áreas fora do aquífero, áreas urbanas, caminhos, campos de golfe, citrinos, florestas, hortícolas, massas de água e solos	B2, B3, B4 e B8	Falsos positivos (áreas classificadas como regadas que não são regadas) e Falsos negativos também foram detectados (áreas que são regadas e foram classificadas como não regadas)
10	4 classes: abacateiros, campos de golfe, citrinos e hortícolas	imagem raster NDVI com <i>Stretch</i> e limiar superior a 0,20 do aquífero Campina de Faro	11 classes: abacateiros, areias, áreas fora do aquífero, áreas urbanas, caminhos, campos de golfe, citrinos, florestas, hortícolas, massas de água e solos	B2, B3, B4 e B8	
11	4 classes: abacateiros, campos de golfe, citrinos e hortícolas	imagem raster NDVI com <i>Stretch</i> e limiar superior a 0,20 do aquífero Campina de Faro	11 classes: abacateiros, areias, áreas fora do aquífero, áreas urbanas, caminhos, campos de golfe, citrinos, florestas, hortícolas, massas de água e solos	B2, B3, B4 e B8	Margem de acerto aceitável para a ocupação citrinos (71,54%) no qual será replicado para as demais ocupações

Após realizar a classificação utilizando os dados propostos, como não se obteve sucesso nos resultados utilizando a metodologia inicial (para mais detalhes, verificar o capítulo 6.

Resultados), propõe-se uma reclassificação das áreas de treino. Foi selecionado apenas as áreas regadas com maior extensão em hectares dentro do aquífero da Campina de Faro, segundo a classificação manual, nomeadamente os campos de golfe e os citrinos. Para isolar estas classes de interesse, é utilizada a operação "*Reclass*" no *IDRISI*, especificamente para as classes 1 (campos de golfe) e 5 (citrinos). A nova reclassificação atribui o valor "um" aos intervalos de 0 a 0, de 2 a 4 e de 6 a 12, o valor "dois" ao intervalo da classe 1, e o valor "três" ao intervalo da classe 5. Após esta reclassificação, obtém-se uma imagem que destaca apenas os campos de golfe e citrinos, que é então utilizada como nova área de treino para uma nova classificação com o método *Fuzzy Artmap*.

Embora a nova classificação tenha sido aplicada, os resultados obtidos não atenderam às expectativas, conforme descrito no capítulo 6. Assim, propõe-se uma nova reclassificação das áreas de treino considerando nove classes (abacateiros, campos de golfe, casa e jardim, citrinos, hortícolas, palmeiras, relvas, vinhas e viveiros), excluindo as classes de área fora do aquífero, estufas e pastagens. No entanto, os resultados desta classificação também não foram os esperados.

Para melhorar a precisão dos *píxeis* na classificação com as nove classes, sugere-se utilizar a ferramenta "*FILTER*" com o filtro da mediana de 7x7, que suaviza o ruído sem alterar os valores originais dos *píxeis*. No entanto, esta abordagem também não resultou em melhorias significativas.

Com base nos insucessos das classificações anteriores, foi realizada uma simplificação das classes analisadas. Mantiveram-se as principais (abacateiros, campos de golfe, citrinos e hortícolas), acrescentando-se duas novas: áreas fora do aquífero e áreas com NDVI inferior a 0,20 dentro do aquífero. Além disso, ajustou-se o vetor de treino, removendo elementos irrelevantes como estradas e construções.

Para melhorar os resultados, implementou-se um script no *Google Earth Engine* para criar uma composição RGB com bandas de 10m (B2, B4 e B8). Esta imagem foi posteriormente refinada no QGIS, aplicando-se uma máscara de NDVI (>0,20). Embora tenha havido progressos, persistiram falsos positivos na classe de citrinos, especialmente em áreas florestais.

Como solução, revisaram-se as classes e incluíram-se novas categorias (florestas, salinas, sapais e zonas urbanas), totalizando dez. Contudo, esta abordagem introduziu distorções entre campos de golfe e citrinos. Por fim, agregaram-se as classes artificializadas em uma única categoria para reduzir os erros. Apesar das melhorias, os resultados continuam limitados, recomendando-se a aplicação de NDVI com *Stretch* e o aumento das áreas de treino para maior precisão.

Baseando-se na classificação manual de 2021, decidiu-se restringir a análise às principais áreas regadas (abacateiros, campos de golfe, citrinos e hortícolas), dado o insucesso da análise em toda a área de estudo. A classificação inicial apresentou uma baixa precisão para citrinos, com elevado número de "falsos negativos".

Para aprimorar o processo de classificação, foi utilizado um conjunto de treino ampliado, contemplando 11 categorias distintas, como abacateiros, massas de água, áreas fora do aquífero, áreas urbanas, areias, caminhos, campos de golfe, citrinos, florestas, hortícolas e solos. Foram empregadas as bandas B2, B3, B4, B8 e o índice NDVI ajustado por Stretch, com o objetivo de melhorar a separação espectral entre as classes. Este procedimento foi projetado para ser replicado nas demais categorias de áreas regadas, como abacateiros, campos de golfe e hortícolas, garantindo consistência na análise ao longo dos anos avaliados.

5.6.2. Maxlike

Para iniciar a classificação com o método *Maxlike*, é necessário criar assinaturas espectrais. Utilizou-se a ferramenta “*Makesig*”, considerando as bandas B2, B3, B4, B8 e o NDVI com *Stretch*. Cada assinatura espectral corresponde a uma classe, definidas com base nas utilizadas pelo classificador *Fuzzy Artmap*. Um novo vetor foi criado com 11 classes de treino (abacateiros, massas de água, áreas fora do aquífero, áreas urbanas, areias, caminhos, campos de golfe, citrinos, florestas, hortícolas e solos), onde cada classe recebeu um nome específico para definir as suas assinaturas espectrais.

Antes de proceder à nova classificação, sugere-se o uso da ferramenta *SIGCOMP*, disponível no *IDRISI*, para realizar uma análise de qualidade da classificação baseada nas assinaturas espectrais. O objetivo é garantir que cada classe de ocupação do solo possua uma assinatura espectral distinta e bem definida.

O *SIGCOMP* (*Signature Comparison*) é uma ferramenta projetada para realizar análises de mudanças temporais em séries de imagens de satélite. Esta ferramenta permite comparar assinaturas espectrais de diferentes períodos temporais para identificar e quantificar mudanças na cobertura do solo ou no uso da terra ao longo do tempo. O *SIGCOMP* é essencial para análises temporais detalhadas em dados de sensoriamento remoto, ajudando a identificar, quantificar e entender mudanças ambientais e de uso do solo.

Propõe-se realizar diferentes análises apenas para as classes de interesse a serem utilizadas na classificação:

1. Valores médios dos *píxeis* das várias bandas.

2. Valores mínimos e máximos.
3. Valores médios, mínimos e máximos.

Para garantir precisão nas análises de sensoriamento remoto e na classificação de uso e cobertura do solo, é essencial revisar cuidadosamente os polígonos de treino. Esse processo é especialmente importante em áreas onde a presença de caminhos de terra ou outros elementos não vegetados pode influenciar os valores espectrais obtidos para classes consideradas como regadas ou vegetadas.

O objetivo é obter um modelo, baseado na classificação de 2021, que permita identificar a cultura presente em cada um dos polígonos. Após a revisão dos polígonos de treino, foi realizada uma nova comparação das assinaturas espectrais pelo *SIGCOMP* para todas as classes (área fora, campos de golfe, hortícolas, urbano, caminhos, abacateiros, massas de água, citrinos, florestas, solo e areia), considerando os valores médios, mínimos e máximos.

Com base nessa análise, propõe-se uma nova revisão dos valores médios, mínimos e máximos apenas das classes de interesse para a classificação.

Após a análise e comparação das assinaturas espectrais existentes, foi proposta a criação de novas assinaturas utilizando a ferramenta *Makesig*. Para esta etapa, foram consideradas as bandas B2, B3, B4, B8 e o NDVI com Stretch, a fim de melhorar a discriminação entre as classes de interesse. Foram selecionadas novas áreas de treino e aplicado o método Maxlike, utilizando um fator de probabilidades iguais para cada assinatura espectral.

Para refinar a análise, decidiu-se focar apenas nas áreas regadas, conforme identificado na classificação manual de 2021, que serviu como referência. Em vez de analisar toda a área do aquífero da Campina de Faro, optou-se por recortar a área de estudo e concentrar a avaliação nos resultados obtidos dentro dessas regiões, priorizando inicialmente as áreas de citrinos.

Com base nas limitações observadas na primeira abordagem, foi necessário revisar o conjunto de treino. Foram incorporadas classes adicionais, abrangendo abacateiros, areias, áreas fora do aquífero, áreas urbanas, caminhos, campos de golfe, citrinos, florestas, hortícolas, massas de água e solos. As mesmas bandas espectrais (B2, B3, B4, B8) e o NDVI com *Stretch* foram novamente utilizados para gerar uma nova classificação.

Por fim, estabeleceu-se que este conjunto revisado de áreas de treino, juntamente com as classes selecionadas, seria utilizado como referência para a classificação em outros períodos temporais (2017 a 2020 e 2022 a 2023), com extensão do método para as demais classes de áreas regadas, incluindo abacateiros, campos de golfe e hortícolas.

5.6.3. Fisher (LDA)

O classificador *Fischer*, também conhecido como Análise Discriminante Linear (LDA, do inglês *Linear Discriminant Analysis*), é uma técnica estatística fundamental na classificação de padrões. Introduzida por Ronald A. Fisher em 1936, o LDA é amplamente utilizado em diversas áreas, incluindo a ciência da computação, biologia e, especialmente, em SIG para a classificação de dados geoespaciais (Fisher, 1936; McLachlan, 2004). No software *IDRISI*, o LDA é implementado como uma das ferramentas de classificação supervisionada, facilitando a discriminação de diferentes classes com base nas suas assinaturas espectrais.

O principal objetivo do LDA é maximizar a separação entre duas ou mais classes, projetando os dados em um espaço de menor dimensão, onde as classes são mais facilmente distinguíveis (Fukunaga, 1990). Ao contrário de classificadores como o *Maximum Likelihood (Maxlike)*, que considera distribuições multivariadas completas, o LDA busca uma combinação linear das variáveis que melhor separa as classes, minimizando a variabilidade dentro de cada uma.

No *IDRISI*, essa técnica é aplicada ao conjunto de dados espectrais, permitindo que o software crie funções discriminantes lineares. Essas funções são baseadas em médias e covariâncias estimadas a partir de amostras de treinamento fornecidas pelo usuário, permitindo uma classificação eficaz dos dados geoespaciais (Eastman, 2012b).

O classificador *Fischer (LDA)* no *IDRISI* é particularmente útil em cenários onde as classes possuem distribuições aproximadamente normais e onde a separação linear é adequada para distinguir as classes (McLachlan, 2004). No entanto, o LDA apresenta limitações, especialmente em situações onde as classes não são linearmente separáveis ou onde a presença de *outliers* pode comprometer a precisão da classificação (Fukunaga, 1990).

Apesar dessas limitações, o LDA continua sendo uma ferramenta valiosa no SIG, proporcionando uma base sólida para a classificação de dados geoespaciais, especialmente em estudos de uso e cobertura do solo (Bishop, 2006).

Para realizar a classificação pelo método *Fischer* no *IDRISI*, foram utilizadas as assinaturas espectrais das 11 classes previamente definidas nos classificadores *Fuzzy* e *Maxlike* (campos de golfe, citrinos, abacateiros, hortícolas, área urbana, área fora, massas de água, florestas, areia, caminhos e solo). Assim como nos métodos anteriores, recomenda-se restringir a análise aos resultados obtidos nas áreas classificadas manualmente em 2021, iniciando pela análise das áreas de citrinos.

A classificação pelo método *Fischer* foi realizada com base nas áreas de treino selecionadas e nas bandas B2, B3, B4, B8 e NDVI Stretch, utilizando a mesma abordagem

aplicada nos classificadores *Fuzzy* e *Maxlike*. O processo seguiu a mesma lógica de aplicação dos dados espectrais e das áreas de treino, a fim de garantir consistência entre as metodologias.

Dado o desempenho observado nesta classificação, considera-se que a área de treino resultante servirá como referência para as classificações dos anos de 2017 a 2020 e de 2022 a 2023. A metodologia aplicada será estendida para as demais classes, incluindo abacateiros, campos de golfe e hortícolas.

5.6.4. Raw e Normalized

O classificador *Raw* no *IDRISI* é uma técnica de classificação supervisionada que utiliza os valores espectrais originais das bandas de uma imagem para realizar a atribuição de classes. Este método baseia-se na premissa de que as assinaturas espectrais de diferentes classes podem ser comparadas diretamente, sem a necessidade de qualquer transformação ou normalização dos dados. O classificador *Raw* é especialmente útil quando as bandas espectrais possuem escalas semelhantes e contribuem de forma equivalente para a distinção entre classes de uso e cobertura do solo.

No classificador *Raw*, a distância euclidiana é utilizada como a métrica principal para determinar a proximidade entre as assinaturas espectrais de um pixel e as médias espectrais das classes de treinamento. Para cada pixel, o software calcula a distância euclidiana até as médias das classes, e o pixel é atribuído à classe cuja média estiver mais próxima.

Este método é relativamente simples e eficiente em termos computacionais, tornando-o uma opção atrativa para grandes conjuntos de dados onde a velocidade de processamento é uma consideração importante (Eastman, 2012b). No entanto, o uso dos valores espectrais *Raw* pode introduzir limitações, especialmente em casos em que as bandas espectrais apresentam variabilidades significativas, o que pode levar a classificações enviesadas.

O classificador *Raw* é amplamente utilizado em estudos de detecção remota onde as bandas espectrais têm variações mínimas ou onde os dados são relativamente homogêneos (Jensen, 2015). No entanto, em cenários onde as bandas espectrais diferem significativamente em termos de amplitude ou onde certas bandas são mais sensíveis a características específicas do terreno, o classificador *Raw* pode resultar em atribuições de classe menos precisas.

O classificador *Raw* no *IDRISI* oferece uma abordagem direta e eficiente para a classificação de dados espectrais. Embora tenha vantagens em termos de simplicidade e velocidade, é essencial considerar as características específicas das bandas espectrais ao optar por este método, especialmente em estudos que requerem alta precisão na distinção entre

classes.

O classificador *Normalized* no *IDRISI* é uma variante avançada do método de classificação por distância mínima, que incorpora a normalização dos valores espectrais antes de realizar a classificação. Esta técnica visa corrigir potenciais distorções causadas por diferenças na variabilidade das bandas espectrais, assegurando que cada banda contribua de forma equilibrada para o processo de classificação. A normalização é particularmente útil em estudos onde as bandas espectrais apresentam diferentes escalas ou são afetadas por variações ambientais distintas.

O classificador *Normalized* utiliza a mesma abordagem básica de distância euclidiana empregada pelo classificador *Raw*, mas com uma etapa adicional de normalização. Antes de calcular as distâncias, o *IDRISI* ajusta os valores espectrais para compensar a variabilidade Inter banda, garantindo que nenhuma banda domine a classificação devido à sua amplitude ou sensibilidade.

Esta normalização pode ser realizada de diferentes maneiras, dependendo do algoritmo específico implementado. O objetivo principal é assegurar que a distância calculada seja representativa da verdadeira similaridade entre as assinaturas espectrais, levando a uma classificação mais precisa e confiável (Richards & Jia, 2006).

O classificador *Normalized* é ideal para cenários onde as bandas espectrais têm diferentes escalas de valores ou onde algumas bandas são particularmente sensíveis a certos atributos da superfície, como a vegetação ou a umidade (Jensen, 2015). A normalização permite uma classificação mais equilibrada e precisa, especialmente em ambientes heterogêneos ou em estudos que envolvem múltiplas fontes de dados espectrais.

Por outro lado, o processo de normalização pode aumentar a complexidade computacional e o tempo de processamento, tornando este método menos adequado para grandes volumes de dados ou para situações em que a simplicidade e a rapidez são prioritárias.

O classificador *Normalized* no *IDRISI* oferece uma solução robusta para a classificação de dados espectrais, especialmente em contextos onde a variabilidade entre as bandas pode impactar a precisão da classificação. Ao normalizar os valores espectrais, este método proporciona uma análise mais equilibrada e precisa, sendo uma escolha preferida em estudos de sensoriamento remoto que envolvem dados complexos ou heterogêneos.

Para realizar as classificações com os métodos *Raw* e *Normalized* no *IDRISI*, foram utilizadas as assinaturas espectrais das mesmas 11 classes definidas para os classificadores *Fuzzy*, *Maxlike* e *Fisher* (campos de golfe, citrinos, abacateiros, hortícolas, área urbana, área fora, massas de água, florestas, areia, caminhos e solo). A análise foi restrita às áreas

classificadas manualmente em 2021, com foco particular nas áreas de citrinos.

A classificação foi executada com base nas áreas de treino e nas bandas B2, B3, B4, B8 e NDVI *Stretch*, seguindo o mesmo procedimento utilizado nos outros classificadores. Após a aplicação dos métodos *Raw* e *Normalized*, observou-se que os resultados não atenderam às expectativas, com desempenho inferior ao dos classificadores *Fuzzy*, *Maxlike* e *Fisher*.

Dado o desempenho observado, recomendou-se a não utilização dos métodos *Raw* e *Normalized* para as classificações dos anos subsequentes e para as classes restantes.

5.6.5. Segmentação

Para melhorar os resultados da classificação das classes, a ferramenta SEGMENTATION do software IDRISI pode ser muito útil. Ela agrupa pixels adjacentes com características espectrais semelhantes em polígonos homogêneos, facilitando a distinção entre diferentes classes de uso e cobertura do solo. A segmentação atua como um pré-processamento eficaz para a classificação, reduzindo o ruído e a variabilidade interna das classes, o que muitas vezes dificulta a precisão da classificação *pixel a pixel* tradicional. Ao aplicar essa técnica nas bandas B2 (azul), B3 (verde), B4 (vermelho), e B8 (infravermelho próximo), que fornecem informações cruciais sobre a vegetação e outras características do terreno, a segmentação pode ajudar a definir contornos mais precisos das culturas, melhorando a coerência e a exatidão dos resultados finais. Isso é particularmente útil em áreas agrícolas heterogêneas, onde a variabilidade dentro de uma mesma classe pode ser significativa. Dessa forma, a segmentação dos *pixels* contribui para a criação de objetos que refletem melhor as feições reais no terreno, potencializando a eficiência dos classificadores subsequentes e resultando em mapas de uso e cobertura do solo mais precisos e confiáveis.

A ferramenta *SEGCLASS* no *IDRISI* é projetada para realizar uma classificação segmentada, integrando as informações geradas pela segmentação de *pixels* com as imagens classificadas por diferentes classificadores, como *Fuzzy*, *Fischer* e *Maxlike*. Esta ferramenta combina o mapa de segmentos, criado pela ferramenta *SEGMENTATION*, com a classificação *pixel a pixel*, produzida pelos classificadores, para gerar um resultado mais refinado e preciso. Ao cruzar as informações dos segmentos com os resultados dos classificadores, o *SEGCLASS* assegura que a classificação respeite a homogeneidade dos segmentos, reduzindo ruídos e erros associados à variação espectral dentro de uma mesma classe. Isso é particularmente eficaz em áreas onde a classificação *pixel a pixel* pode falhar devido à alta heterogeneidade espectral ou a presença de transições suaves entre classes. O resultado é uma classificação mais coerente e

robusta, que alinha as vantagens de segmentação espacial com as características espectrais detalhadas identificadas pelos classificadores. Este processo é essencial para melhorar a precisão global do mapeamento, oferecendo uma representação mais fiel das unidades de cobertura do solo no contexto das análises de DR e SIG.

5.7. Estimativa do uso da água nas áreas regadas

Para estimar o uso da água nas áreas regadas, foi realizada uma análise dos dados fornecidos pela DGADR - Direção-Geral de Agricultura e Desenvolvimento Rural (2024). O objetivo desta análise foi identificar as dotações médias de referência para diferentes culturas regadas, assumindo um uso eficiente da água, conforme estipulado na Portaria n.º 54-C/2023, de 27 de fevereiro.

De acordo com a DGADR, as dotações anuais de rega de referência foram estabelecidas para sete regiões agroclimáticas conforme Figura 30. Cada uma dessas regiões tem limites específicos, correspondendo aos concelhos associados. Essas dotações de referência ajudam a determinar a quantidade de água necessária para diferentes tipos de culturas, assegurando que o uso de água nas áreas regadas seja feito de forma eficiente e sustentável, respeitando as normas e critérios estabelecidos para cada região.



Figura 30 - Mapas das zonas agroclimáticas a considerar na Intervenção

Cada região agroclimática possui uma tabela com as dotações de rega de referência (m³/ha). Para este estudo, foi considerada a tabela "Dotações de rega de referência (m³/ha) para a região agroclimática do Algarve", conforme (Anexo 5, Tabela 1), referente à região agroclimática 7 - Algarve. A partir destes valores, foram estabelecidos dois cenários climáticos:

- Cenário A: aplicado a condições climáticas médias ou semi-húmidas;
- Cenário B: aplicado a condições climáticas secas.

O que determina se um ano é classificado como cenário A (condições climáticas médias) ou cenário B (condições climáticas secas) é o valor da precipitação de referência acumulada entre 1 de outubro e 30 de setembro. Para a zona agroclimática do Algarve, o valor de precipitação de referência para o ano de 2023 é de 509 mm (Figura 31). Assim, se o valor acumulado durante o ano hidrológico, de setembro a outubro, ficar abaixo da referência, o ano é considerado seco; caso contrário, é considerado um ano médio.

Zona Agroclimática	Estação Meteorológica de Referência	Precipitação de referência Valor Acumulado entre 01OUT-30SET	Precipitação acumulada 1out2022-30set2023
1. Norte e Centro Litoral	Coimbra	905 mm	Cenário B – Condições Secas
2. Norte Interior	Mirandela/Vila Real	509 mm/1074 mm	Cenário B – Condições Secas
3. Centro Interior	Castelo Branco	758 mm	Cenário B – Condições Secas
4. Santarém	Santarém	697 mm	Cenário B – Condições Secas
5. Alto Alentejo	Évora	609 mm	Cenário B – Condições Secas
6. Baixo Alentejo	Beja	572 mm	Cenário B – Condições Secas
7. Algarve	Faro	509 mm	Cenário B – Condições Secas

Figura 31 - Cenários climáticos a considerar em 2023 para cada zona agroclimática

De acordo com a tabela "Dotações de rega de referência (m³/ha)" no (Anexo 5, Tabela 1), são apresentados os valores de dotação por metro cúbico por hectare para os seis métodos/sistemas de rega (gota a gota, aspersão, pivô, microaspersão, canhão e subterrânea). Para este estudo, propõe-se a utilização do método de rega gota a gota, uma vez que é o método mais utilizado no Algarve devido à sua elevada eficiência no uso da água, ao aplicar a água diretamente na zona radicular das plantas, minimizando assim as perdas por evaporação e escoamento superficial.

A metodologia resume-se em identificar, anualmente, se o período é classificado como húmido (cenário A) ou seco (cenário B), com base na análise dos dados de precipitação. Esta classificação permite determinar os valores de referência de dotação da água em m³/ha para cada uma das culturas presentes neste estudo (citros, abacateiros e hortícolas) a exceção dos campos de golfe, no caso desta classe utilizou-se uma dotação de 10.000 L/m³ pelo autor do trabalho, por ser considerado um valor típico utilizado na rega para os campos de golfe. Com a dotação estabelecida, procede-se ao cálculo da área total em hectares, previamente classificada através do classificador automático *Fuzzy* (considerando exclusivamente as áreas identificadas

como regadas na classificação manual de 2021). O valor obtido é então multiplicado pela dotação anual, resultando no volume total de água em m³, utilizado para a cultura em questão.

6. Resultados e Discussão

O capítulo de Resultados e Discussão apresenta uma análise abrangente dos métodos de classificação utilizados e das respectivas contribuições para a compreensão do uso da terra e da água na área de estudo. Inicialmente, são comparados os resultados das classificações manual e supervisionada, recorrendo a diferentes classificadores, como *Fuzzy Artmap*, *Maxlike*, *Fisher*, *Raw* e *Normalized*, com o objetivo de avaliar a eficácia na identificação de tipos de solo e vegetação. Em seguida, é estimada a área de rega através de detecção remota, diferenciando parcelas agrícolas e não agrícolas, bem como áreas regadas e não regadas. O capítulo inclui também uma análise de dados de precipitação e estimativas do uso da água nas áreas regadas, comparando o volume de água extraído com os valores oficiais disponíveis, com o objetivo de validar e criticar as metodologias e dados utilizados.

6.1. Classificação Manual

Os resultados deste trabalho estão organizados em duas fases. Na primeira fase, a inclusão de áreas não mapeadas em 2007 resultou no aumento da área total para 3.052,61 ha, o que representa um crescimento de 38% em relação aos 2.212,08 ha registrados em 2007 conforme Tabela 3. Esse aumento levou ao surgimento de novos tipos de uso do solo, como campos de golfe, palmeiras, relvas, abacateiros e pastagens. Além disso, áreas sem interesse agrícola foram substituídas por zonas incultas, e pomares foram eliminados devido à falta de dados atualizados. Para avaliar a fiabilidade da classificação manual, foi introduzida uma coluna de "precisão" na tabela de atributos, que atribuiu diferentes valores de acordo com o grau de confiabilidade da classificação conforme Tabela 4.

Na segunda fase, as áreas previamente classificadas foram atualizadas. A coluna "t_uso" foi renomeada para "t_usoAntes", refletindo o uso anterior do solo, e foi criada a coluna "t_usoAtual" para registrar o uso atual. Nos casos de alteração no tipo de uso do solo, o uso anterior foi mantido em "t_usoAntes" e o novo uso foi registrado em "t_usoAtual". Durante esta fase, os polígonos existentes foram reavaliados e classificados de acordo com a fiabilidade da classificação manual. Após as atualizações, todos os polígonos foram integrados em um único arquivo *shapefile*.

Um resumo das principais alterações nos tipos de ocupação do solo pode ser consultado na Tabela 5. Para os abacateiros, 68% das alterações corresponderam à inclusão de novos polígonos, enquanto 32% foram atualizações, e a classificação indicou que o tipo de solo dos abacateiros é predominantemente regado.

Esses resultados mostram as modificações significativas no uso do solo, permitindo uma análise detalhada das mudanças ao longo do tempo e aumentando a confiabilidade da classificação manual dos tipos de solo e de sua ocupação.

Tabela 3 - Tipo de ocupação do solo x Quantidade de áreas classificadas em 2007 x 2021

Tipo de Ocupação do Solo	Hectares (ha) 2007	Hectares (ha) 2021	Diferença	Área Regada?
Abacateiros	0,00	68,45	68,45	Sim
Área Sem Interesse Agrícola	0,65	0,00	-0,65	Não
Área Urbana	568,38	755,68	187,30	Não
Casa e Jardim	86,17	72,59	-13,58	Não
Citrinos	888,53	1130,57	242,03	Sim
Citrinos Abandonados	205,87	206,28	0,41	Não
Estufas	281,85	76,36	-205,49	Sim
Estufas Abandonadas	15,92	127,86	111,94	Não
Golfes	0,00	329,57	329,57	Sim
Hortícolas	124,14	85,65	-38,49	Sim
Incultos	19,75	112,71	92,96	Não
Palmeiras	0,00	4,77	4,77	Sim
Pastagens	0,00	59,94	59,94	Sim
Pomares	1,26	0,00	-1,26	Sim
Relvas	0,00	2,71	2,71	Sim
Vinhas	1,71	0,40	-1,32	Sim
Viveiros	17,84	19,08	1,24	Sim
Total Geral	2212,08	3052,61	840,53	

Tabela 4 - Tipo de ocupação x Grau de confiabilidade da classificação manual

Tipo de ocupação x Grau de confiabilidade da classificação manual	0 (Incerteza) em hectares	0,5 (dúvida) em hectares	1 (certeza) em hectares	Total Geral (ha)
Abacateiro	2,04	9,35	57,05	68,45
área urbana			755,68	755,68
casa e jardim	1,52		71,07	72,59
Citrinos	16,05	311,71	802,80	1 130,57
Citrinos Abandonados	21,81	47,13	137,35	206,28
Estufas	2,50	10,89	62,97	76,36
Estufas abandonadas		26,87	100,99	127,86
Golfe			329,57	329,57
Hortícolas	22,22	21,94	41,49	85,65
Inculto		6,38	106,33	112,71
Palmeiras			4,77	4,77
Pastagem		0,53	59,41	59,94
Relva			2,71	2,71
Vinha	0,20		0,20	0,40
Viveiro		0,47	18,61	19,08
Total Geral	66,34	435,28	2 550,99	3 052,61

Tabela 5 - Resumo das alterações de cada tipo de solo

Tipo de Solo Atual	Descrição
Abacateiros	Muitas alterações, 68% foram inclusão de polígonos novos e 32% foram polígonos atualizados, trata-se de um solo regado.
Area Urbana	Poucas alterações, o que estava anteriormente estava tudo correto, apenas houve ajustes de polígono, trata-se de um solo não regado.
Casa e jardins	Muitas alterações, o que estava anteriormente contemplava a casa, foi corrigido abrangendo apenas os jardins, trata-se de um solo regado.
Citrinos	Muitas alterações, quase 50% foram inclusão de polígonos novos e 7,5% foram polígonos atualizados, trata-se de um solo regado.
Citrinos Abandonados	Muitas alterações, 42,5% foram inclusão de polígonos novos e 15,5% foram polígonos atualizados, trata-se de um solo não regado.
Estufas	Muitas alterações, 67% foram inclusão de polígonos novos e 0,2% foram polígonos atualizados, trata-se de um solo regado.
Estufas Abandonadas	Muitas alterações, 7% foram inclusão de polígonos novos e 84% foram polígonos atualizados, trata-se de um solo não regado.
Golfes	Muitas alterações, polígono novo, não havia informações anteriormente, trata-se de um solo regado.
Hortícolas	Muitas alterações, 48% foram inclusão de polígonos novos e 1% foram polígonos atualizados, trata-se de um solo regado.
Incultos	Muitas alterações, 0,03% foram inclusão de polígonos novos e 90% foram polígonos atualizados, trata-se de um solo não regado.
Palmeiras	Poucas alterações, polígono novo, quantidade por menor de informações, trata-se de um solo regado.
Pastagens	Poucas alterações, polígono novo, quantidade por menor de informações, trata-se de um solo regado.
Pomares	Não existem dados.
Relvas	Poucas alterações, polígono novo, quantidade por menor de informações, trata-se de um solo regado.
Vinhas	Poucas alterações devido a quantidade por menor de informações, trata-se de um solo regado.
Viveiros	Poucas alterações devido a quantidade por menor de informações, trata-se de um solo regado.

6.2. Escolha do Índice vegetativo

Para classificar as áreas regadas nos anos deste caso de estudo, propôs-se encontrar os valores limiares com base no período seco (julho a setembro) de 2021, que foi objeto de estudo da classificação manual. Para tal, realizou-se um conjunto de comparações com o intuito de identificar qual o índice e quais os valores que melhor se enquadravam e correspondiam às áreas regadas.

Foram obtidos os resultados da média, mediana, valores mínimos, máximos e o primeiro

quartil de cada tipo de solo (11 classes) para cada índice (NDVI, NDWI e SAVI), conforme o (Anexo 4, Tabela 1). Posteriormente, os resultados obtidos de cada classe e do respectivo índice foram inseridos numa única tabela, separados por índice, com o objetivo de encontrar o primeiro quartil de todas as classes (Anexo 4, Tabela 3).

Em alguns tipos de solo, os valores ficaram abaixo do limiar definido. No caso do NDVI, cujo limiar é 0,3, algumas culturas, como abacateiros, hortícolas, pastagens e vinhas, apresentam valores mais baixos. Isso ocorre porque os *píxeis* captam não só as culturas, mas também áreas adjacentes, como a terra, gerando interferências.

Os resultados para o índice SAVI mostram que ele é uma adaptação do NDVI, ajustando a escala do índice. Multiplicando os valores do primeiro quartil do NDVI por 1,5, obtêm-se os valores do primeiro quartil do SAVI para cada classe. Para simplificar, sugere-se usar um valor limiar único de 0,3 para o NDVI. Este valor é baseado no primeiro quartil das culturas, que é 0,27 (Anexo 4, Tabela 3). Usar 0,3 pode causar alguns erros: áreas não regadas podem ser identificadas como regadas (falsos positivos) e áreas regadas podem não ser identificadas como tal (falsos negativos), embora estejam corretamente classificadas manualmente como regadas. A presença de falsos positivos não é um problema, pois a análise foca apenas nas áreas manualmente classificadas como regadas para 2021. A principal preocupação é identificar os falsos negativos, ou seja, áreas regadas que não foram detetadas. Para isso, foi feita uma reclassificação no QGIS, com áreas regadas em verde, não regadas em vermelho, falsos positivos em amarelo e falsos negativos em preto, conforme ilustrado no (Anexo 4, Figura 1).

Com base nos resultados obtidos da reclassificação para a área total do aquífero, verificou-se que 12,80% (1.412,65 ha) das áreas foram classificadas como regadas, tanto pelo NDVI quanto pela classificação manual. Houve 3,25% (358,77 ha) de falso negativo, referindo-se a áreas que são regadas de acordo com a classificação manual, mas foram classificadas como não regadas. Além disso, 55,96% (6.177,72 ha) das áreas não regadas foram corretamente identificadas como tal, enquanto 28% (3.090,66 ha) foram falsamente classificadas como regadas, totalizando 11.039,80 ha na área do Aquífero Campina de Faro.

Ao avaliar apenas as culturas principais (citrinos, hortícolas, golfe e abacateiros), 79,75% (1.412,65 ha) foram corretamente identificadas como regadas, enquanto 20,25% (358,77 ha) foram falsos negativos. Reduzindo o valor limiar do NDVI para 0,20, os resultados mudaram significativamente: 14,47% (1.597,78 ha) foram classificados como regadas, 1,57% (173,64 ha) como falsos negativos, 46,71% (5.156,43 ha) das áreas não regadas foram corretamente identificadas, e 37,25% (4.111,95 ha) como falsos positivos. Com este limiar, 90,20% (1.597,78 ha) as culturas principais classificadas foram corretamente identificadas

como regadas, e 9,80% (173,64 ha) foram falsos negativos conforme (Anexo 4, Figura 2). Um limiar mais baixo melhora a identificação das áreas realmente regadas, aumentando a precisão em 1,67%, mas também eleva os falsos positivos em 9,25%.

Para definir os valores limiares do NDWI, propõe-se analisar o primeiro quartil da mediana das principais culturas, como golfe, citrinos, abacateiros e hortícolas. O objetivo é comparar esses resultados com os obtidos para o NDVI. Inicialmente, para o NDWI, foi sugerido usar o primeiro quartil (-0,04) para definir os valores mínimos e o terceiro quartil (0,09) para os valores máximos. As áreas situadas entre esses valores são consideradas regadas conforme (Anexo 4, Figura 3).

A reclassificação do aquífero revelou que apenas 5,39% (595,62 ha) das áreas foram corretamente identificadas como regadas. Foram encontrados 10,68% (1.179,31 ha) de falsos negativos, ou seja, áreas que são regadas segundo a classificação manual, mas foram identificadas como não regadas. Além disso, 57,82% (6.384,76 ha) das áreas não regadas foram corretamente identificadas, enquanto 26,10% (2.882,38 ha) foram incorretamente classificadas como regadas (falsos positivos). A área total considerada foi de 11.042,07 ha, ligeiramente maior do que a do NDVI devido ao tamanho dos *píxeis* de 20 metros do NDWI.

Dentre as áreas das culturas principais, 33,56% (595,62 ha) foram identificadas corretamente como regadas, enquanto 66,44% (1.179,31 ha) foram falsos negativos. Para melhorar a precisão, foram definidos novos limites de validação: 10% (-0,09) como mínimo e 90% (0,17) como máximo, com base na mediana de todos os polígonos do índice NDWI. Estes limites visam incluir todas as áreas regadas identificadas manualmente em 2021 (Anexo 4, Figura 4).

A reclassificação do aquífero mostrou que apenas 9,79% (1.081,81 ha) das áreas foram corretamente identificadas como regadas e 6,29% (694,44 ha) de falsos negativos. Além disso, 35,34% (3.904,53 ha) das áreas não regadas foram corretamente identificadas, enquanto 48,58% (5.367,64 ha) foram incorretamente classificadas como regadas (falsos positivos).

Dentre as áreas das culturas principais, 60,90% (1.081,81 ha) foram corretamente identificadas como regadas, e 39,10% (694,44 ha) foram falsos negativos. Os resultados também mostraram que muitos campos de golfe, localizados no canto inferior esquerdo do aquífero, não foram classificados como áreas regadas.

A Tabela 6 apresenta uma síntese dos resultados obtidos na reclassificação do uso do solo no aquífero Campina de Faro, comparando os métodos NDVI e NDWI em diferentes configurações de limiares.

Tabela 6 Resultados da reclassificação do uso do solo no aquífero Campina de Faro, comparando NDVI e

NDWI com diferentes limiares

Critério de Análise	Indicador	Valor Absoluto (ha)	Percentual (%)
NDVI - Limiar Original	Áreas regadas corretamente classificadas	1.412,65	12,8
	Falsos negativos	358,77	3,25
	Áreas não regadas corretamente identificadas	6.177,72	55,96
	Falsos positivos	3.090,66	28
NDVI - Culturas Principais	Regadas corretamente classificadas	1.412,65	79,75
	Falsos negativos	358,77	20,25
NDVI - Limiar Reduzido (0,20)	Áreas regadas corretamente classificadas	1.597,78	14,47
	Falsos negativos	173,64	1,57
	Áreas não regadas corretamente identificadas	5.156,43	46,71
	Falsos positivos	4.111,95	37,25
NDVI - Culturas Principais com Limiar Reduzido	Regadas corretamente classificadas	1.597,78	90,2
	Falsos negativos	173,64	9,8
NDWI - Limiar Original	Áreas regadas corretamente classificadas	595,62	5,39
	Falsos negativos	1.179,31	10,68
	Áreas não regadas corretamente identificadas	6.384,76	57,82
	Falsos positivos	2.882,38	26,1
NDWI - Culturas Principais	Regadas corretamente classificadas	595,62	33,56
	Falsos negativos	1.179,31	66,44
NDWI - Novos Limites de Validação	Áreas regadas corretamente classificadas	1.081,81	9,79
	Falsos negativos	694,44	6,29
	Áreas não regadas corretamente identificadas	3.904,53	35,34
	Falsos positivos	5.367,64	48,58
NDWI - Culturas Principais com Novos Limites	Regadas corretamente classificadas	1.081,81	60,9
	Falsos negativos	694,44	39,1

Após a realização de diversos testes com valores distintos, verificou-se que não é viável determinar um valor limiar "geral" aplicável a todas as culturas com base nos índices NDVI e NDWI. Por isso, propõe-se a interpretação dos valores limiares (mínimo e máximo) para cada tipo de uso e ocupação do solo, utilizando a ferramenta "*Value Tool*" e baseando-se no primeiro quartil obtida para cada cultura (Anexo 4, Tabela 1). Esta abordagem é especialmente relevante para culturas extensas na região do aquífero Campina de Faro, como campos de golfe, citrinos, abacateiros e hortícolas.

Na análise dos campos de golfe, reclassificou-se a imagem de satélite NDWI para o período seco de 2021, identificando a maioria das áreas regadas com valores entre 0,15 e 0,49.

O primeiro quartil de 0,20 conforme (Anexo 4, Tabela 1) foi desconsiderado porque não representava algumas áreas regadas. A análise com imagens do *Bing Maps* ajudou a definir e classificar as áreas regadas na região do aquífero Campina de Faro, conforme mostrado no (Anexo 4, Figura 5).

Para a classificação do NDVI, foi considerado o valor do primeiro quartil (0,61) para os campos de golfe, conforme indicado no (Anexo 4, Tabela 1), e o valor máximo de 1, de acordo com (Holben, 1986), conforme mostrado no (Anexo 4, Figura 6)

Algumas áreas classificadas como campos de golfe não foram identificadas como regadas nas imagens de satélite de 2021 devido aos valores baixos do NDVI (abaixo de 0,61) e do NDWI (abaixo de 0,15) conforme Figura 32. O NDVI, em particular, tem maior sensibilidade às mudanças radiométricas na zona do visível podendo apresentar mais falhas na identificação de áreas regadas. Além disso, a diferença na resolução das imagens (10 metros para o NDVI e 20 metros para o NDWI) também pode afetar os resultados, como mostrado nas Figuras 33 e 34.




Figura 32 - Imagens do campo de golfe: NDWI (0.15-0.49) à esquerda, Sentinel-2 em RGB ao centro e Bing Maps (2021) com falhas visíveis à direita



Figura 33 - Campo de golfe: NDVI (0.61-1) à esquerda, Sentinel-2 em RGB ao centro e Bing Maps (2021) com falhas visíveis à direita

Para melhor visualização dos resultados dos campos de golfe, as áreas classificadas como não regadas (falso negativo) que estavam na cor preta foram modificadas para a cor vermelha, afim de comparar os valores obtidos do NDWI com o NDVI.



Figura 34 - A esquerda imagem correspondente ao NDVI e a direita imagem correspondente ao NDWI

Com os limiares de 0,15 a 0,49 para o NDWI, 76,42% das áreas (250,69 ha) foram classificadas como regadas, enquanto 23,58% (77,37 ha) foram falsos negativos. Para o NDVI, com limiares de 0,61 a 1, 62,18% das áreas (203,89 ha) foram classificadas como regadas e 37,82% (124,02 ha) foram falsos negativos.

O NDWI apresentou melhor desempenho na identificação de áreas regadas com 76,42%, comparado a 62,18% do NDVI, uma diferença de 14,24%. Portanto, para identificar áreas regadas em campos de golfe, o NDWI é mais eficaz. No entanto, para quantificar o uso de água, o NDVI pode ser mais realista. A escolha do índice depende do objetivo da análise.

Os resultados das reclassificações das áreas de citrinos, abacateiros e hortícolas,

utilizando os índices NDVI e NDWI, estão no (Anexo 6).

Embora o índice NDWI tenha mostrado um desempenho superior na classificação das áreas regadas para a maioria das culturas analisadas, o índice NDVI foi escolhido para este estudo. A decisão de optar pelo NDVI baseia-se na constatação de que as diferenças entre os dois índices não são significativas. Além disso, o NDVI oferece vantagens adicionais, como uma estimativa mais realista do uso da água e maior sensibilidade às variações na biomassa verde. De acordo com Glenn et al., (2008) e Campos-Taberner et al., (2016), o NDVI tem sido amplamente utilizado para monitorar a vegetação e estimar o uso da água em diversos ecossistemas agrícolas. Esse índice também é amplamente aceito na literatura científica, facilitando comparações com estudos anteriores. Assim, apesar das vantagens do NDWI em detetar áreas regadas, o NDVI foi preferido devido à sua robustez e à sua abordagem consolidada para quantificar a vegetação e o uso da água.

6.3. Quantificação de *píxels* por índice e tipo de solo

Para apresentar os resultados da contagem de *píxels* para cada tipo de cultura com base nos índices NDVI, NDWI e SAVI, foram elaboradas as tabelas que se encontram no Anexo 7, nomeadamente as Tabelas 1, 2 e 3, que detalham as áreas bem classificadas e aquelas com desempenho inferior. A análise focou nas principais culturas: Campos de Golfe, Citrinos, Abacateiros e Hortícolas. O índice NDWI não foi utilizado para quantificar as demais áreas, pois apresentou resultados inferiores nas culturas principais estudadas.

Os resultados mostram que a eficácia dos índices varia. O NDVI demonstrou o melhor desempenho geral, com a maior taxa de classificação correta, especialmente com limiares mais baixos. O NDWI teve um desempenho moderado, sendo mais eficaz para algumas culturas específicas, mas não se destacou tanto quanto o NDVI para as principais culturas. O SAVI mostrou um desempenho intermediário, com algumas áreas, como Pastagem, apresentando uma alta incidência de falsos negativos. Em resumo, o NDVI foi o índice mais eficaz para a classificação das áreas regadas durante o período seco de 2021, seguido pelo SAVI. O NDWI, apesar de ter utilidade, não foi tão robusto para as principais culturas analisadas. A escolha do índice apropriado deve considerar a vegetação específica e as condições locais, sendo o NDVI a opção mais adequada para este estudo.

6.4. Classificação Supervisionada (*Fuzzy Artmap, Maxlike, Fischer, Raw e Normalized*)

Este capítulo apresenta os resultados de cinco métodos de classificação supervisionada — *Fuzzy Artmap*, *Maxlike*, *Fisher (LDA)*, *Raw* e *Normalized* —, com ênfase na análise da eficácia de cada abordagem na identificação dos diferentes tipos de solo.

6.4.1. Fuzzy Artmap

Durante o treinamento do classificador, o algoritmo *Fuzzy Artmap* analisou as áreas de treino, avaliando quais *pixéis* correspondiam às características espectrais das bandas utilizadas e alocando-os à classe apropriada. Após essa fase, o modelo treinado foi aplicado a toda a região de estudo para realizar a classificação dos *pixéis* em todas as 12 classes definidas.

O objetivo principal desta abordagem era estabelecer uma base robusta para a classificação automática dos anos subsequentes, eliminando a necessidade de uma nova classificação manual para comparação dos resultados das áreas já classificadas. Esperava-se que, ao concluir a classificação de 2021, o modelo pudesse fornecer resultados consistentes e confiáveis, independentemente da localização geográfica ou do período temporal, garantindo uma classificação precisa de cada *pixel* dentro de uma das 12 classes de ocupação.




Figura 35 - Classificação Fuzzy NDVI 0.20 com 12 classes Aquífero Campina de Faro

Após a aplicação da classificação com os dados propostos, os resultados apresentaram limitações em relação às expectativas (Figura 35). Observou-se que os campos de golfe (representados em roxo) foram, em grande parte, corretamente identificados em comparação com a classificação manual (delimitada a branco). Contudo, foram registrados 1.096,86 ha para esta classe, enquanto a classificação manual indicava 327,92 ha, evidenciando um número considerável de áreas classificadas como positivas incorretamente. No caso dos abacateiros (em laranja), foram identificados 114,50 ha, em contraste com os 68,62 ha registrados na classificação manual, resultando tanto em áreas classificadas incorretamente como em omissões. Para as demais classes, os resultados mostraram limitações na separação precisa entre

categorias. O algoritmo apresentou dificuldade em diferenciar classes com características espectrais semelhantes, refletindo uma precisão inferior ao esperado e comprometendo a qualidade da classificação final. Diante dos resultados insatisfatórios da classificação inicial, foi proposta a realização de várias tentativas (Anexo 8) até se alcançar um resultado satisfatório, conforme descrito abaixo.

Propõe-se uma nova classificação utilizando as seguintes áreas de treino que possui 11 classes (abacateiros, areias, áreas fora, áreas urbanas, caminhos, campos de golfe, citrinos, florestas, hortícolas, massas de água e solos), com menos polígonos, e aplicar as bandas B2, B3, B4, B8, além do NDVI com "*Stretch*", com o objetivo de melhorar a identificação das áreas de citrinos, reduzir falsos negativos e obter uma correspondência mais precisa com a classificação manual de 2021 (Figura 36).

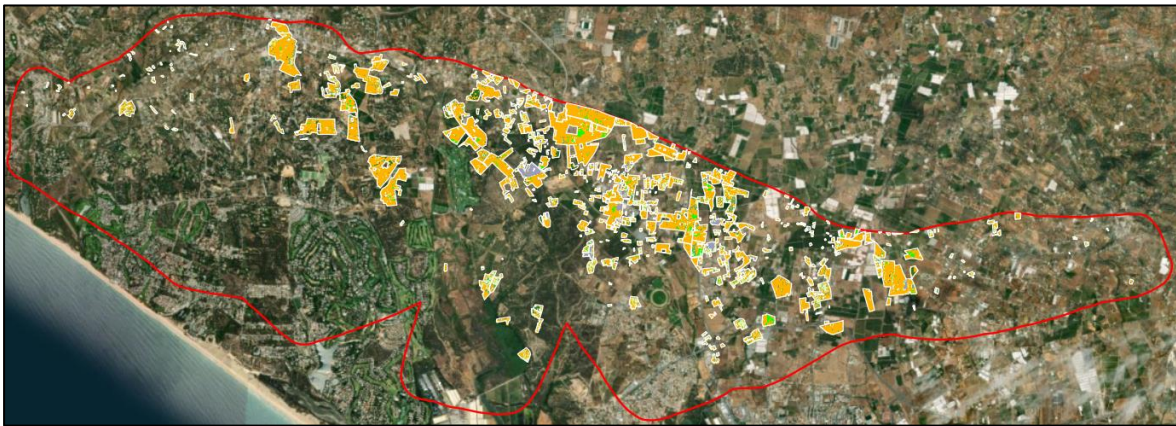


Figura 36 - Classificação Fuzzy dos citrinos para 2021 no período seco, com áreas de treino reduzidas

Após a nova classificação, os resultados mostraram uma melhoria significativa, com 785,04 hectares identificados como ocupados por citrinos, o que corresponde a aproximadamente 71,54% da área total de 1.097,28 hectares destinada a essa cultura.

Dado o desempenho melhorado, considera-se que esta configuração de área de treino, juntamente com as classes e parâmetros utilizados, será adotada como referência para a classificação dos anos subsequentes, de 2017 a 2020 e de 2022 a 2023. Esta metodologia será também aplicada às outras classes de interesse, como abacateiros, campos de golfe e hortícolas, com a expectativa de obter resultados consistentes e fiáveis ao longo de todo o período de estudo. A continuidade desta abordagem permitirá não só uma avaliação temporal mais sólida das áreas regadas, como também a validação da metodologia em diferentes anos e condições, reforçando a confiança nos resultados obtidos.

6.4.2. Maxlike

Os resultados obtidos com a criação das assinaturas espectrais, baseadas no vetor das 9 classes (abacateiros, citrinos, campos de golfe, casa e jardim, hortícolas, palmeiras, relvas, vinhas e viveiros), indicaram limitações significativas. Apesar da utilização das bandas B3, B4 e B8 no processo de classificação, a análise (Figura 37) demonstrou que as classes geradas não atingiram a precisão esperada. Observou-se uma definição inconsistente e imprecisa das classes quando comparadas à referência manual. Com base nesses resultados, propõe-se restringir a classificação às classes de campos de golfe e citrinos, conforme ilustrado na Figura 38.




Figura 37 - Classificação Maxlike com 9 classes



Figura 38 - Classificação Maxlike com as classes de Campos de Golfes e Citrinos

Os resultados da nova classificação com o método *Maxlike*, utilizando assinaturas espectrais para 9 classes, mostraram-se limitados. A classe de citrinos apresentou baixa precisão, com várias áreas equivocadamente classificadas como campos de golfe e outros falsos positivos. Esses resultados evidenciam a dificuldade do modelo em distinguir citrinos de outras classes, sugerindo que as assinaturas espectrais das bandas B3, B4 e B8 não foram suficientes para capturar adequadamente as características espectrais dos citrinos. Além disso, os resultados indicam a necessidade de ajustes nos parâmetros do método *Maxlike* para melhorar o desempenho da classificação.

Diante dos resultados pouco conclusivos, tornou-se necessário ajustar as assinaturas

espectrais, incorporando as bandas B2, B3, B4, B8 e o índice NDVI com a aplicação de "Stretch". Para isso, foi inserido um novo vetor contendo 11 classes de treino, que englobaram: campos de golfe, citrinos, abacateiros, hortícolas, área urbana, área fora, água, florestas, areia, caminhos e solo.

Os resultados obtidos com a nova classificação utilizando o método *Maxlike* e as assinaturas espectrais revisadas indicaram melhorias em relação à definição das classes. A análise de qualidade, realizada com a ferramenta *SIGCOMP*, demonstrou que as novas assinaturas espectrais possuem maior distinção entre as classes, especialmente no que diz respeito aos citrinos e áreas regadas.

A inclusão de áreas de treino revisadas e o ajuste dos fatores de probabilidades prévias resultaram em uma melhor correspondência entre as áreas classificadas e a referência manual de 2021. Os citrinos, que anteriormente apresentavam alta confusão com outras classes, mostraram resultados mais consistentes, embora alguns desafios persistam na identificação precisa de todas as áreas regadas (Figura 39). Mais detalhes sobre a análise das assinaturas espectrais encontram-se no (Anexo 9).

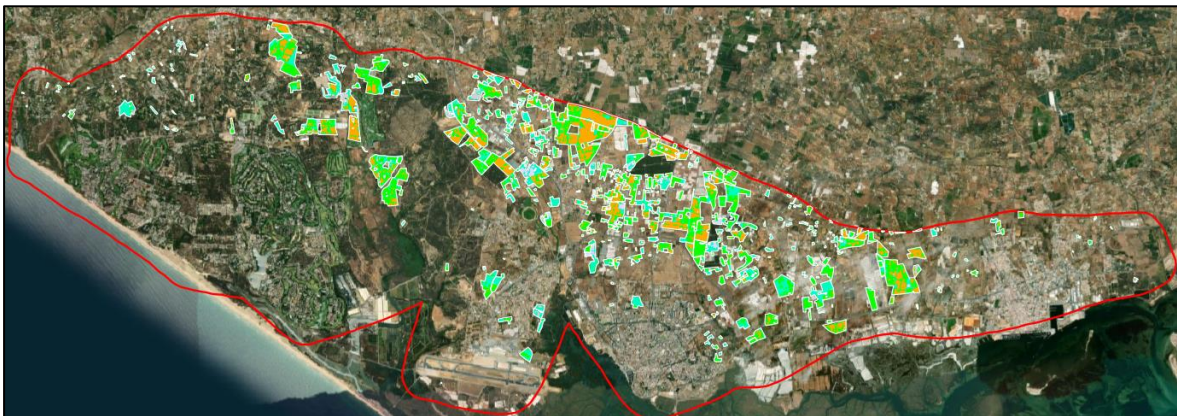


Figura 39 - Classificação *Maxlike* dos citrinos (cor laranja) para 2021 período seco

Após a aplicação da primeira classificação, apenas 241,37 hectares foram identificados como citrinos, correspondendo a 22% da área total de 1.097,28 hectares destinada a essa cultura. Diante do baixo desempenho, foi realizada uma nova classificação utilizando áreas de treino antigas, com menos polígonos (Figura 40).

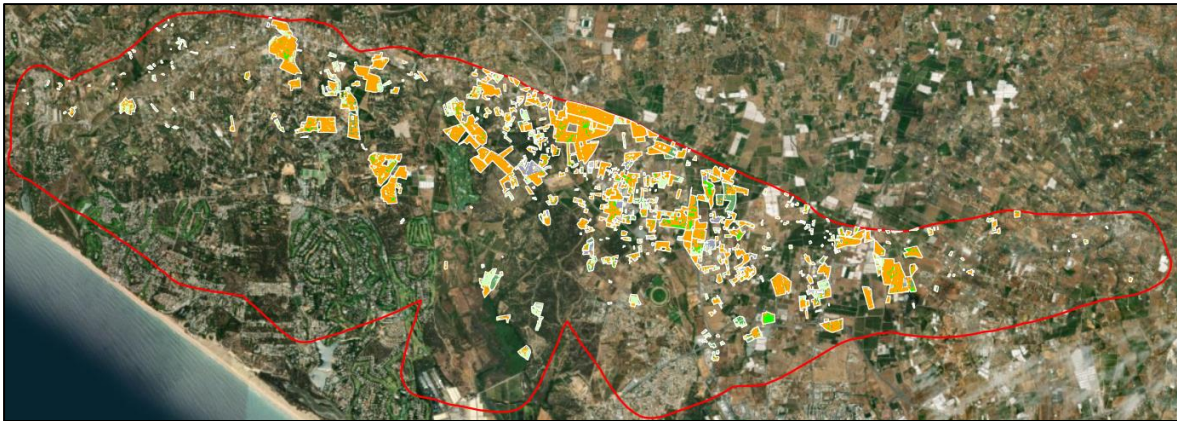


Figura 40 - Classificação Fisher dos citrinos para 2021 no período seco, com áreas de treino reduzidas

Os resultados da nova classificação indicaram uma melhora significativa, com 700,25 hectares identificados como citrinos, representando 63,82% da área total. Considerando o aumento da precisão, esta área de treino foi selecionada como referência para a classificação das imagens dos anos de 2017 a 2020 e de 2022 a 2023, abrangendo também outras classes, como abacateiros, campos de golfe e hortícolas.

6.4.3. Fisher (LDA)

A classificação pelo método *Fisher* no *IDRISI* utilizou as assinaturas espectrais das 11 classes previamente empregadas nos métodos *Fuzzy* e *Maxlike*. Os resultados iniciais mostraram inconsistências semelhantes às observadas anteriormente, reforçando a recomendação de restringir a análise às áreas classificadas manualmente em 2021, com foco inicial na classe de citrinos (Figura 41). Este recorte visa aprimorar a interpretação dos resultados, concentrando-se nas áreas de maior relevância para a avaliação do desempenho do método.

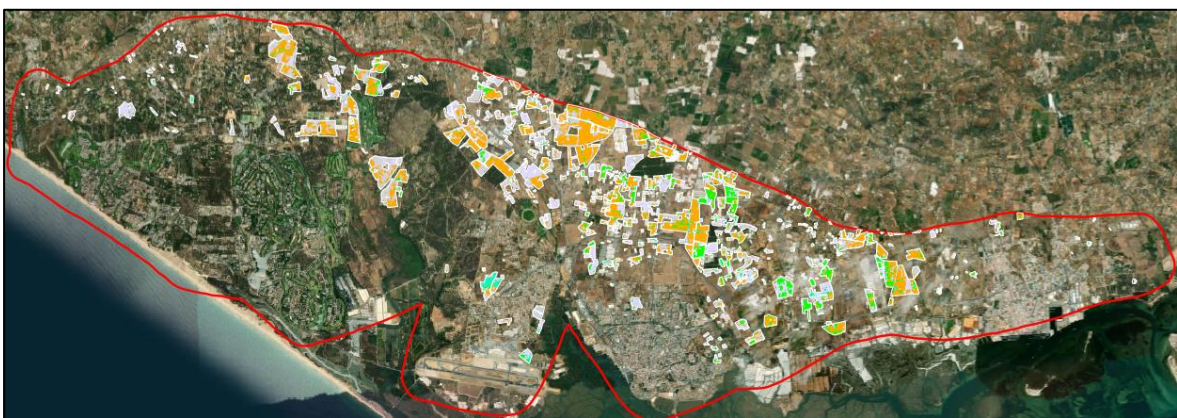


Figura 41 - Classificação Fisher dos citrinos para 2021 período seco

Após a classificação pelo método *Fisher*, foram identificados 391,76 hectares como

citrinos, correspondendo a aproximadamente 36% da área total de 1.097,28 hectares destinada a esta cultura. Este resultado representa o melhor desempenho entre os classificadores avaliados neste estudo.

Diante desse avanço, propõe-se a realização de uma nova classificação utilizando as áreas de treino antigas, com menor número de polígonos, integrando as bandas B2, B3, B4, B8 e o NDVI *Stretch*, para refinar ainda mais os resultados (Figura 42).




Figura 42 - Classificação Fisher dos citrinos para 2021 no período seco, com áreas de treino simplificadas

Após a nova classificação, foram identificados 738,11 hectares como citrinos, representando aproximadamente 67,27% da área total de 1.097,28 hectares destinada a essa cultura. Dada a melhoria nos resultados em comparação com as classificações anteriores, decidiu-se utilizar esta área de treino como referência para a classificação dos anos de 2017 a 2020 e de 2022 a 2023. Além disso, esta abordagem será ampliada para incluir também as classes de abacateiros, campos de golfe e hortícolas.

6.4.4. Raw

Para a classificação pelo método *Raw* no *IDRISI*, foram utilizadas as mesmas assinaturas espectrais das 11 classes definidas para os classificadores *Fuzzy* e *Maxlike*. Assim como nos outros classificadores utilizados neste estudo, recomendou-se recortar e analisar os resultados exclusivamente nas áreas classificadas manualmente em 2021, começando pelos citrinos (Figura 43).

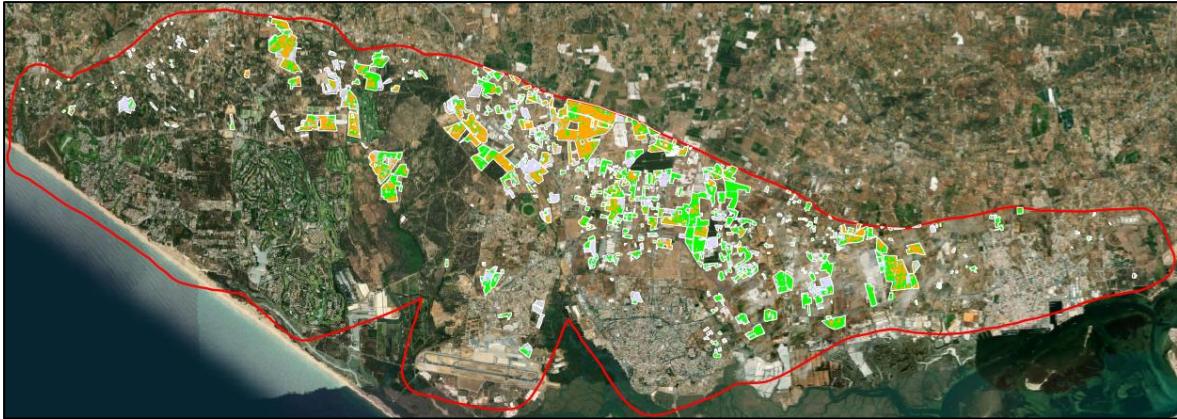


Figura 43 - Classificação Raw dos citrinos para 2021 período seco

Após a classificação, foram identificados apenas 283,26 hectares como citrinos, o que corresponde a cerca de 26% da área total de 1.097,28 hectares destinada a essa cultura, resultando em um desempenho insatisfatório. Como melhoria, propõe-se realizar uma nova classificação utilizando as áreas de treino antigas, com menos polígonos, conforme ilustrado na Figura 44.

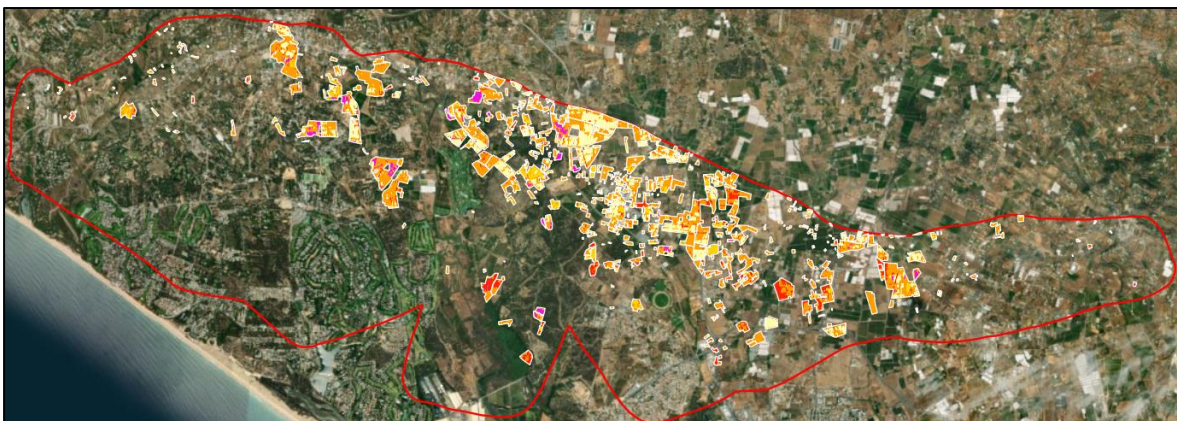


Figura 44 - Classificação Raw dos citrinos para 2021 período seco com áreas de treino com menos polígonos

Após a nova classificação, foram identificados 598,15 hectares como citrinos, o que corresponde a aproximadamente 54,51% da área total de 1.097,28 hectares dedicada a essa cultura. Embora tenha havido uma melhoria em relação ao resultado anterior, esse valor ainda é inferior aos obtidos com os classificadores *Fuzzy*, *Maxlike* e *Fischer*. Portanto, propõe-se não utilizar este classificador para os demais anos e classes, uma vez que os resultados alcançados com este método ficaram abaixo do esperado.

6.4.5. Normalized

Para realizar a classificação pelo método *Normalized* no *IDRISI*, são inseridas as

assinaturas espectrais das mesmas 11 classes definidas para os demais classificadores que fazem parte deste estudo, recomenda-se recortar e analisar os resultados exclusivamente nas áreas classificadas manualmente em 2021, iniciando pelos citrinos (Figura 45).

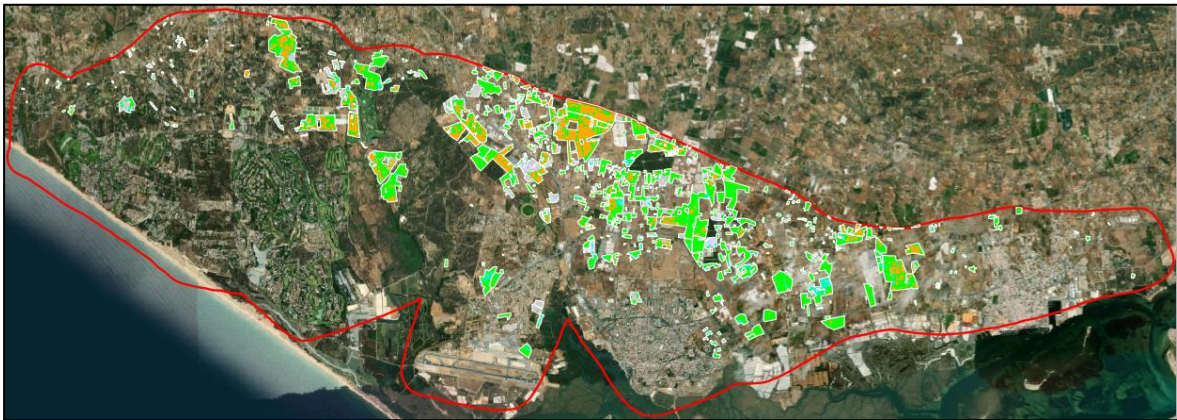


Figura 45 - Classificação Normalized dos citrinos (cor laranja) para 2021 período seco

Após a classificação, obteve-se apenas 207,01 hectares classificados como citrinos, o que representa cerca de 19% da área total de 1.097,28 hectares dedicada a essa cultura, o que não é considerado um bom resultado. Propõe-se realizar uma nova classificação utilizando as áreas de treino antigas (com menos polígonos), com as bandas B2, B3, B4, B8 e NDVI *Stretch* (Figura 46).

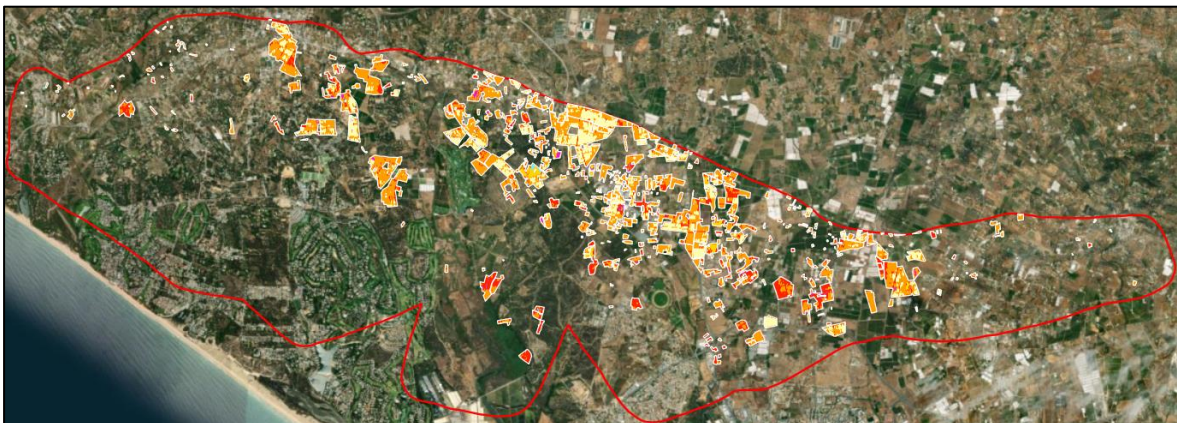


Figura 46 - Classificação Normalized dos citrinos para 2021 no período seco, com áreas de treino reduzidas

Após a nova classificação, foram identificados 600,35 hectares ocupados por citrinos, o que corresponde a aproximadamente 54,71% da área total de 1.097,28 hectares dedicada a essa cultura. Embora esse resultado seja superior ao anterior, ainda é inferior ao obtido com os classificadores *Fuzzy*, *Maxlike* e *Fischer*. Assim, propõe-se não utilizar este classificador para os demais anos e classes, visto que os resultados alcançados ficaram aquém do esperado.

6.4.6. Resultados Gerais

Com base nos resultados obtidos pelas classificações *Fuzzy*, *Maxlike*, *Fischer*, *Raw* e *Normalized* para a classe "citrinos" referente ao período seco de 2021, que foi o ano e período utilizado para a classificação manual, considerando as bandas B2, B3, B4, B8 e NDVI *Stretch*, em conjunto com a primeira área de treino, que possui um número reduzido de amostras para cada classe. Apresentam-se os resultados obtidos da classificação para as demais classes (abacateiros, campos de golfe e hortícolas) para o ano de 2021 conforme Tabela 7.

Tabela 7 - Total hectares classificados por cultura x método de classificação - Período Seco 2021

Culturas	Cítrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
<i>Fuzzy</i> (ha) classificados	785,04	155,31	38,78	42,64	1021,77
<i>Fischer</i> (ha) classificados	738,11	155,65	44,49	27,48	965,73
<i>Maxlike</i> (ha) classificados	700,25	187,37	45,75	42,91	976,29
<i>Raw</i> (ha) classificados	598,15	138,34	39,35	26,63	802,47
<i>Normalized</i> (ha) classificados	600,35	87,49	40,11	44,38	772,32
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
<i>Fuzzy</i> % classificados	71,54%	47,35%	56,69%	50,08%	
<i>Fisher</i> % classificados	67,27%	47,46%	65,04%	32,27%	
<i>Maxlike</i> % classificados	63,82%	57,13%	66,88%	50,40%	
<i>Raw</i> % classificados	54,51%	42,18%	57,53%	31,27%	
<i>Normalized</i> % classificados	54,71%	26,67%	58,64%	52,12%	
<i>Fuzzy</i> % acerto	49,72%	9,84%	2,46%	2,70%	64,72%
<i>Fischer</i> % acerto	46,75%	9,86%	2,82%	1,74%	61,17%
<i>Maxlike</i> % acerto	44,35%	11,87%	2,90%	2,72%	61,84%
<i>Raw</i> % acerto	37,89%	8,76%	2,49%	1,69%	50,83%
<i>Normalized</i> % acerto	38,03%	5,54%	2,54%	2,81%	48,92%

Os resultados obtidos a partir da aplicação dos diferentes classificadores (*Fuzzy*, *Fischer*, *Maxlike*, *Raw* e *Normalized*) no contexto da classificação de uso do solo destacam a superioridade do classificador *Fuzzy* em termos de precisão geral, atingindo 64,72% de acerto e uma correspondência significativa com as áreas de referência, especialmente para a cultura de Cítrinos, onde classificou 71,54% da área total. Embora os classificadores *Maxlike* e *Fischer* também apresentem desempenhos satisfatórios, especialmente em culturas como Golfe e Abacateiros, o *Fuzzy* se mostrou mais consistente na maioria das classes analisadas. Por outro lado, os classificadores *Raw* e *Normalized* demonstraram limitações evidentes, com menores

taxas de acerto e uma menor correspondência com as áreas de referência, evidenciando a necessidade de refinamentos metodológicos para aplicações futuras. Esses resultados reforçam a importância de uma escolha criteriosa dos algoritmos de classificação em projetos de mapeamento de uso do solo, onde a precisão e a correspondência com dados de referência são cruciais para a geração de informações confiáveis.

Propõe-se a utilização dos classificadores *Fuzzy*, *Maxlike* e *Fisher* para a classificação das classes (Citrinos, campos de golfe, abacateiros e hortícolas) para os anos de 2017 a 2020 e de 2022 a 2023. Esta escolha deve-se ao fato de que os classificadores *Raw* e *Normalized* não apresentaram resultados satisfatórios, não justificando a sua continuidade na análise dos anos subsequentes (Anexo 10, Tabela 1 à Tabela 6).

A análise comparativa dos classificadores aplicados entre os anos de 2017 e 2023 para as culturas de citrinos, golfe, abacateiros e hortícolas revelou padrões consistentes na eficácia dos métodos utilizados. Em termos de áreas classificadas e precisão, o classificador *Fischer* destacou-se como o mais eficaz para a cultura de citrinos, apresentando os maiores valores de hectares classificados e percentagens de acerto em vários anos, especialmente em 2017 e 2019. Para as culturas de golfe e abacateiros, o classificador *Maxlike* demonstrou um desempenho superior ao longo do período, sendo consistentemente o melhor em termos de área classificada e precisão, o que o torna uma escolha robusta para essas culturas. No caso das hortícolas, o classificador *Fuzzy* predominou na maioria dos anos, especialmente em 2023, onde obteve a maior área classificada e precisão. Esses resultados indicam que, embora não haja um único classificador ideal para todas as culturas, a escolha do algoritmo deve ser orientada pelas características específicas de cada cultura e pelo contexto temporal da análise. Assim, a seleção cuidadosa do classificador pode maximizar a precisão dos resultados em projetos de DR e SIG, contribuindo significativamente para a gestão agrícola e o monitoramento ambiental.

A análise comparativa dos classificadores entre 2017 e 2023 aponta o *Maxlike* como a melhor opção, apresentando o melhor desempenho consistente ao longo dos anos para todas as culturas analisadas (Anexo 11, Tabela 7). Embora o classificador *Fischer* tenha se destacado para citrinos e o *Fuzzy* para hortícolas em alguns anos, o *Maxlike* se mostrou mais robusto e confiável, especialmente para as culturas de golfe e abacateiros, dominando tanto em termos de hectares classificados quanto em precisão. Além disso, *Maxlike* apresentou resultados competitivos em outras culturas e manteve uma consistência notável ao longo dos anos. Portanto, para fins de simplificação e otimização dos processos de classificação no contexto de DR e SIG, *Maxlike* surge como o classificador mais equilibrado e eficaz, oferecendo a melhor combinação de precisão e aplicabilidade across-the-board para todas as culturas e anos

considerados.

6.4.7. Resultados Gerais com Segmentação

O processo de segmentação foi utilizado na classificação por regiões, integrando as imagens segmentadas das bandas B2 (azul), B3 (verde), B4 (vermelho), e B8 (infravermelho próximo) com a classificação obtida *pixel a pixel* pelos classificadores *Fuzzy*, *Fischer* e *Maxlike*. A Figura 47 mostra um exemplo da diferença entre a classificação *pixel a pixel* e por regiões (segmentada) do classificador *Fuzzy* para o ano de 2021 no período seco.




Figura 47 - Classificação Fuzzy de 2021 no Período Seco: sem segmentação (esquerda) e segmentada (direita) com tolerância de similaridade de 10

Foi iniciada segmentação para o ano de 2021, utilizando três valores de tolerância de similaridade (5, 10 e 20) para o classificador, afim de analisar qual das tolerâncias resulta em um maior aumento na quantidade de hectares regados. Com base nesses resultados, o valor mais adequado foi utilizado como padrão para os anos subsequentes. Além disso, propõe-se aplicar esta metodologia aos três classificadores, a fim de verificar se o *Maxlike* continua sendo a escolha mais adequada (Tabela 8).

Tabela 8 - Total hectares classificados segmentados por cultura x método de classificação - Período Seco 2021

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
Fuzzy (ha) classificados Seg 10	886,79	182,84	38,12	45,92	1153,68
Fischer (ha) classificados Seg 10	757,03	186,70	45,98	29,88	1019,59
Maxlike (ha) classificados Seg 5	733,04	196,91	45,28	45,10	1020,32
Maxlike (ha) classificados Seg 10	734,75	196,13	44,78	47,57	1023,23
Maxlike (ha) classificados Seg 20	714,40	191,02	45,37	47,67	998,46

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
<i>Fuzzy</i> % classificados Seg 10	80,82%	55,75%	55,74%	53,93%	
<i>Fischer</i> % classificados Seg 10	68,99%	56,92%	67,22%	35,09%	
<i>Maxlike</i> % classificados Seg 5	66,80%	60,04%	66,20%	52,96%	
<i>Maxlike</i> % classificados Seg 10	66,96%	59,80%	65,47%	55,86%	
<i>Maxlike</i> % classificados Seg 20	65,11%	58,24%	66,34%	55,98%	
<i>Fuzzy</i> % acerto Seg 10	56,17%	11,58%	2,41%	2,91%	73,07%
<i>Fischer</i> % acerto Seg 10	47,95%	11,83%	2,91%	1,89%	64,58%
<i>Maxlike</i> % acerto Seg 5	46,43%	12,47%	2,87%	2,86%	64,63%
<i>Maxlike</i> % acerto Seg 10	46,54%	12,42%	2,84%	3,01%	64,81%
<i>Maxlike</i> % acerto Seg 20	45,25%	12,10%	2,87%	3,02%	63,24%

A análise dos resultados da classificação segmentada para o período seco de 2021 indica que o classificador *Fuzzy*, utilizando a tolerância de similaridade 10, teve o melhor desempenho absoluto, com 1153,68 hectares classificados. A escolha da segmentação 10, baseada no desempenho do classificador *Maxlike*, foi crucial para alcançar a melhor combinação de precisão e área classificada. A tolerância de similaridade de 10 revelou-se a mais eficaz, proporcionando a maior área de hectares classificados corretamente. Portanto, para 2021 e anos subsequentes, recomenda-se aplicar esta configuração aos três classificadores — *Fuzzy*, *Fischer* e *Maxlike* — para avaliar a consistência do desempenho e verificar se o *Maxlike* continua a ser a escolha mais adequada ou se o *Fuzzy* mantém sua superioridade (Anexo 11, Tabela 1 à Tabela 6).

Ao longo dos anos analisados, de 2017 a 2023, o classificador *Fuzzy* demonstrou consistentemente o melhor desempenho em termos de hectares classificados e precisão (Anexo 11, Tabela 7), especialmente para as culturas de citrinos e hortícolas. Em particular, *Fuzzy* alcançou os maiores valores absolutos de hectares classificados em quase todos os anos, destacando-se como o classificador mais robusto para estas culturas. Entretanto, para as culturas de golfe e abacateiros, o classificador *Maxlike* frequentemente obteve resultados superiores em termos de precisão, apesar de uma menor área total classificada. O *Fischer*, apesar de ter mostrado bons resultados em alguns anos, não foi tão consistente quanto os outros dois classificadores. Com base nestes resultados, o *Fuzzy* destaca-se como a melhor opção geral para a classificação segmentada devido à sua robustez em diversas culturas e anos. O *Maxlike* pode ser considerado em situações onde a precisão em culturas específicas, como campos de golfe e abacateiros, é crucial. Assim, recomenda-se utilizar o *Fuzzy* com tolerância de similaridade de

10 (Seg 10) como método principal e complementar com o *Maxlike* em casos específicos para otimizar o desempenho em SIG.

A discussão sobre a escolha do método de classificação em áreas agrícolas, como citrinos e campos de golfe, revela a complexidade inerente à diversidade de tamanhos e características das culturas. Nas áreas maiores, como os citrinos, que representam uma parcela significativa (69,50%) da área total classificado do aquífero Campina de Faro, os métodos como *Fischer* e *Fuzzy* tendem a produzir melhores resultados, devido à maior homogeneidade e estabilidade radiométrica dessas culturas em comparação com as hortícolas. As hortícolas, por serem áreas pequenas e altamente variáveis, apresentam um desafio maior, já que o píxel de 10 metros frequentemente captura áreas externas indesejadas, o que compromete a precisão da classificação, mesmo após a segmentação. Essa variabilidade radiométrica, devido à diversidade de plantas englobadas no termo "hortícolas", naturalmente leva a maiores taxas de erro. Portanto, a escolha do método ideal de classificação depende diretamente do objetivo do estudo. Se o foco estiver nas culturas mais representativas, como os citrinos, é preferível optar por métodos como *Fischer* ou *Fuzzy*, que maximizam a precisão para essas áreas, mesmo que isso implique em menor precisão para as culturas menores. Por outro lado, se a necessidade for uma abordagem mais equilibrada entre as diferentes culturas, o *Fuzzy* se destaca como o método mais adequado. A decisão final, portanto, deve considerar o *trade-off* entre a precisão na cultura dominante e a performance geral nas demais culturas, com uma possível preferência por métodos que priorizem os citrinos, dada a sua importância relativa.

6.5. Estimativa do volume de água obtido nas áreas regadas

Para estimar o volume de água utilizado nas áreas regadas, é necessário identificar o método automático que melhor quantifica essas áreas. Neste estudo, o método que apresentou os melhores resultados em comparação com os demais foi o *Fuzzy*, com uma tolerância de similaridade de 10 segmentos. Este método foi selecionado para classificar as áreas regadas.

É igualmente essencial conhecer a área onde será aplicado o método escolhido, de forma a poder validá-lo. Neste estudo, propõe-se a utilização das áreas classificadas manualmente durante o período seco de 2021 como a referência para validação do método, pois essa classificação foi baseada numa análise rigorosa com recurso a imagem de satélite, visitas de campo e informações transmitidas por colegas e especialistas da área, no âmbito do projecto eGroundwater.

Após a escolha do método para quantificar a área de interesse, é também necessário

conhecer as dotações de rega de referência para os tipos de uso e ocupação do solo abordados neste estudo (citrinos, campos de golfe, hortícolas e abacateiros). Com base no cruzamento das informações das áreas classificadas como regadas e as dotações de rega, torna-se possível estimar o volume de água utilizado para o período definido neste estudo, de 2017 a 2023.

De acordo com a Direção-Geral de Agricultura e Desenvolvimento Rural (DGADR), (2023), a área de estudo situa-se na região agroclimática do Algarve, pelo que se usaram essas dotações anuais de rega de referência.

Os resultados da análise de precipitação estão apresentados no Anexo 12, Tabela 1. Com base nesses resultados, os anos hidrogeológicos de 2017, 2018, 2021 e 2023 foram classificados como "ano médio", e os anos de 2019, 2020 e 2022 como "ano seco".

Para determinar o valor de rega de referência em m³/ha para cada uma das culturas analisadas neste estudo (citrinos, abacateiros e hortícolas), considera-se o método de rega gota a gota devido à sua ampla aplicação na região do Algarve, com exceção dos campos de golfe, para os quais foi utilizada uma dotação de 10.000 m³/ha, conforme definido pelo autor na Tabela 9. O valor de rega para as hortícolas foi obtido através da média das seguintes culturas: agrião, alface, batata, cebola, couve, espinafre, melancia, melão, meloa, pepino e tomate.

Tabela 9 - Valores de rega de referência em m³/ha para o método de rega Gota a Gota considerando o ano médio e seco para os anos hidrogeológicos de 2017 a 2023

Ano	Cenário	Citrinos (Laranja/Limão) m³	Golfe (Relva) m³	Abacate m³	Hortícolas (Média) m³
2017	A - Ano Médio	6 010	10 000	6 346	5 011
2018	A - Ano Médio	6 010	10 000	6 346	5 011
2019	B - Ano Seco	6 930	10 000	6 959	5 572
2020	B - Ano Seco	6 930	10 000	6 959	5 572
2021	A - Ano Médio	6 010	10 000	6 346	5 011
2022	B - Ano Seco	6 930	10 000	6 959	5 572
2023	A - Ano Médio	6 010	10 000	6 346	5 011

A área total em hectares, classificada pelo classificador automático Fuzzy e considerando apenas as áreas regadas na classificação manual de 2021, foi calculada e multiplicada pela dotação anual. O volume total de água utilizado para cada cultura foi estimado em hm³ conforme Tabela 10. Em seguida, o volume de água nas áreas regadas foi estimado também a partir da classificação manual, para servir como parâmetro de comparação conforme

Tabela 11. A variação percentual do volume de água em hm³ entre a classificação automática e manual foi comparada, permitindo avaliar as diferenças e a precisão do método automático em relação à classificação manual conforme Tabela 12.

Tabela 10 - Estimativa do volume de água obtido em hm³ nas áreas regadas através da classificação automática para os anos hidrogeológicos de 2017 a 2023

Ano x Cultura	Abacateiros		Cítrinos		Golfe		Hortícolas		Qtd Total (ha)	Volume Total (hm ³)
	Qtd (ha)	Volume (hm ³)	Qtd (ha)	Volume (hm ³)	Qtd (ha)	Volume (hm ³)	Qtd (ha)	Volume (hm ³)		
2017	64,09	0,41	1.038,36	6,24	122,53	1,23	311,26	1,56	1.536,24	9,43
2018	49,54	0,31	1.062,35	6,38	182,36	1,82	236,37	1,18	1.530,62	9,71
2019	44,51	0,31	970,55	6,73	244,58	2,45	264,56	1,47	1.524,20	10,96
2020	61,77	0,43	1.074,98	7,45	206,26	2,06	185,76	1,04	1.528,77	10,98
2021	46,87	0,30	1.025,93	6,17	195,54	1,96	226,63	1,14	1.494,97	9,55
2022	54,55	0,38	978,52	6,78	233,34	2,33	259,72	1,45	1.526,13	10,94
2023	45,02	0,29	962,56	5,79	244,92	2,45	246,42	1,23	1.498,93	9,75

Tabela 11 - Estimativa do volume de água obtido em hm³ nas áreas regadas através da classificação manual para o ano hidrogeológicos de 2021

Ano x Cultura	Abacateiros		Cítrinos		Golfe		Hortícolas		Qtd Total (ha)	Volume Total (hm ³)
	Qtd (ha)	Volume (hm ³)	Qtd (ha)	Volume (hm ³)	Qtd (ha)	Volume (hm ³)	Qtd (ha)	Volume (hm ³)		
2021 - Classificação Manual	68,45	0,43	1.097,37	6,60	328,21	3,28	85,09	0,43	1.579,12	10,74

Tabela 12 - Variação percentual do volume de água entre a classificação automática x classificação manual de 2021

Ano x Cultura	Abacateiros %	Cítrinos %	Golfe %	Hortícolas %	Geral %
2017	-6,36%	-5,38%	-62,67%	265,80%	-12,16%
2018	-27,62%	-3,19%	-44,44%	177,79%	-9,60%
2019	-28,70%	1,98%	-25,48%	245,72%	2,03%
2020	-1,04%	12,96%	-37,16%	142,75%	2,23%
2021	-31,52%	-6,51%	-40,42%	166,34%	-11,02%
2022	-12,61%	2,82%	-28,90%	239,40%	1,89%
2023	-34,22%	-12,28%	-25,38%	189,60%	-9,16%

Para o ano de referência (2021), utilizando a classificação manual, obteve-se um volume de água de 10 738 049,40 m³, ou 10,74 hm³. Este valor foi posteriormente aplicado aos demais anos (2017 a 2023) através da classificação automática, incluindo 2021, com o objetivo de realizar uma análise temporal do volume de água utilizado. No subcapítulo a seguir, serão

comparados os valores obtidos com os valores oficiais.

Comparam-se os volumes de água estimados, obtidos a partir da classificação automática, com os valores obtidos pela classificação manual de 2021, conforme ilustrado no gráfico da Figura 48.

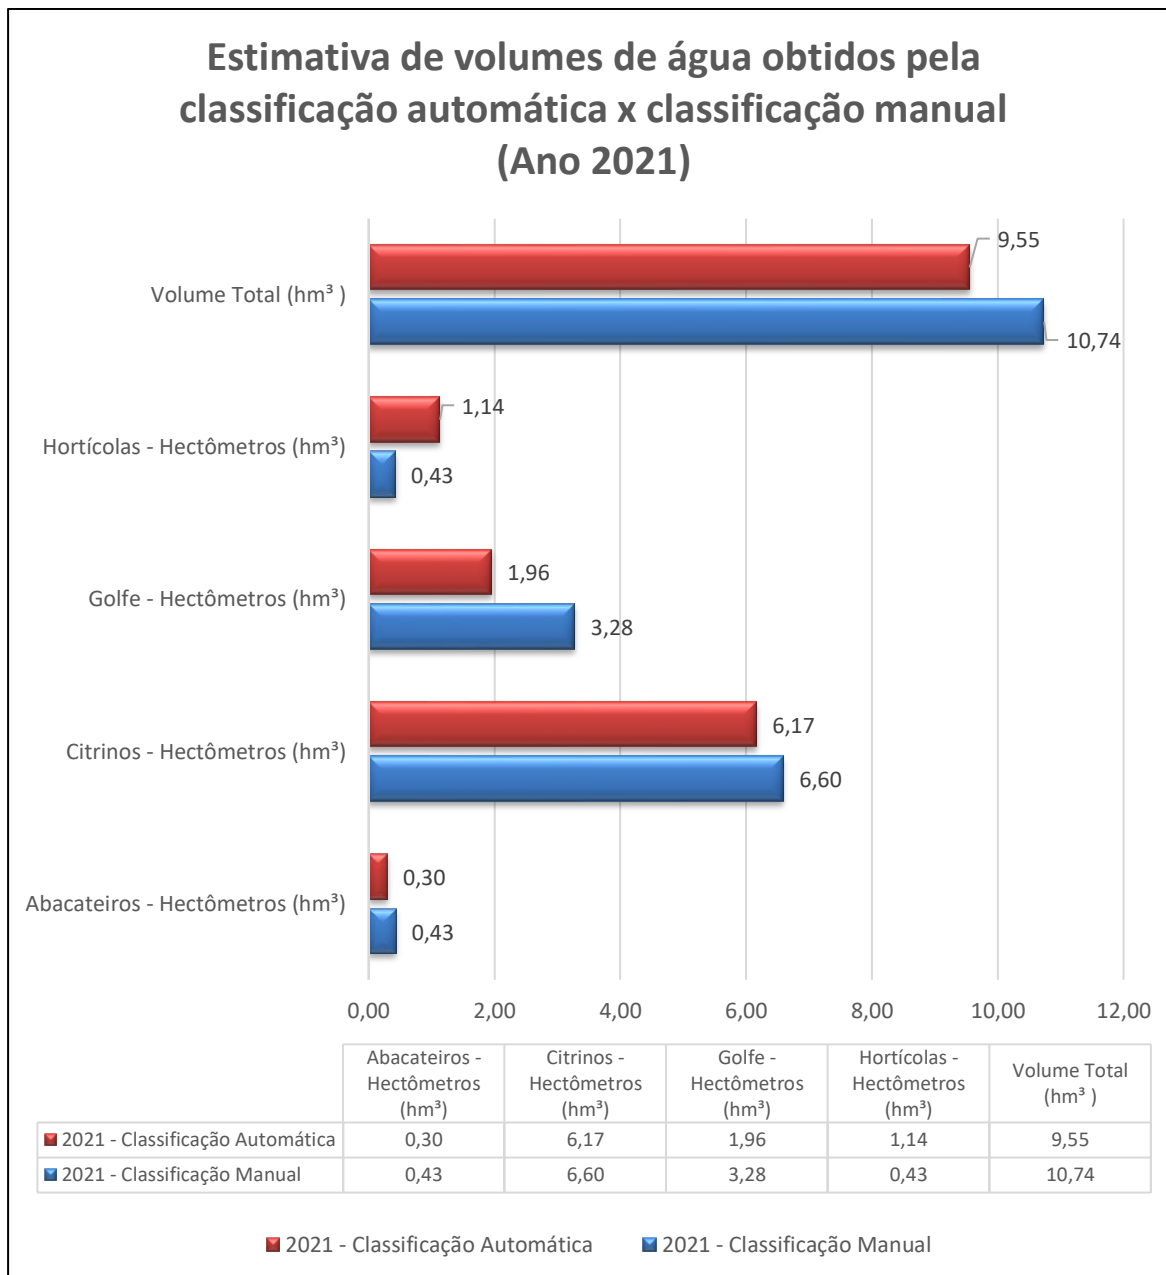


Figura 48 - Estimativa de volumes de água: classificação automática vs. manual (2021)

Comparam-se a quantidade em hectares obtidos a partir da classificação automática, com os valores obtidos pela classificação manual de 2021, conforme ilustrado no gráfico da Figura 49.




Figura 49 - Estimativa de hectares: classificação automática vs. manual (2021)

Para os abacateiros, a classificação manual estimou um volume de 434.354,30 m³ para uma área regada de 68,45 hectares. No entanto, a classificação automática para 2021 indicou uma área menor, de 46,87 hectares, e um volume de água de 297.428,50 m³, resultando numa precisão de 87,39% em comparação com a classificação manual.

No caso dos citrinos, a classificação manual indicou um volume de 6.595.201,50 m³ para uma área regada de 1.097,37 ha. A classificação automática estimou 1.025,93 ha e um volume de 6.165.861,88 m³, com uma precisão de 88,42%, o que demonstra um bom alinhamento entre os dois métodos.

Para os campos de golfe, a área regada classificada manualmente foi de 328,21 hectares,

com um volume de água estimado em 3.282.107,90 m³. Em contraste, a classificação automática para 2021 identificou uma área de 195,54 hectares e um volume de 1.955.416,54 m³, resultando numa precisão de 60,44%. Esta diferença sugere que a classificação automática subestimou a extensão das áreas de golfe regadas. Essa discrepância pode ser explicada por alguns fatores. O classificador fuzzy pode ter confundido parte dos campos de golfe com áreas hortícolas devido a semelhanças nas características físicas dessas superfícies, como a vegetação densa e padrões de rega semelhantes. Além disso, a imprecisão nos dados de entrada utilizados para treinar o modelo automático pode ter levado a uma classificação incorreta, agrupando erroneamente campos de golfe e hortícolas. Outro ponto a considerar é que a abordagem fuzzy, por trabalhar com pertencimentos parciais a múltiplas categorias, pode ter atribuído algumas áreas tanto a campos de golfe como a hortícolas, devido a características partilhadas, contribuindo para a subestimação das áreas de golfe regadas.

Nas hortícolas, a classificação manual estimou uma área regada de 85,09 hectares e um volume de 426.385,70 m³ de água, enquanto a classificação automática para 2021 indicou 226,63 hectares e um volume de 1.135.629,63 m³. Esta diferença significativa resultou numa precisão de 339,40%, mostrando que a classificação automática superestimou substancialmente as áreas regadas em comparação com a classificação manual. Tal como no caso dos campos de golfe, esta superestimação pode estar relacionada com o facto de o classificador fuzzy ter identificado erroneamente os campos de golfe como hortícolas, possivelmente devido a padrões visuais ou de rega semelhantes. A imprecisão nos dados de entrada e a natureza do classificador fuzzy, que permite o pertencimento parcial a diferentes categorias, também podem ter contribuído para essa avaliação exagerada das áreas regadas nas hortícolas.

A classificação manual apresentou uma variação positiva em relação à classificação automática em vários anos conforme Tabela 12, particularmente em 2017, 2018, 2021 e 2023, sugerindo que o método automático subestima o volume de água utilizado nesses anos, que foram classificados como anos húmidos. Por outro lado, nos anos de 2019, 2020 e 2022, a classificação automática indicou volumes ligeiramente superiores aos da classificação manual. Como esses anos foram considerados anos secos, utilizou-se mais água, o que resultou numa percentagem do volume quantificado superior em comparação com 2021, que foi um ano húmido.

Em resumo, a análise dos dados permitiu identificar as diferenças no volume de água utilizado entre as culturas analisadas no período de 2017 a 2023. Utilizando as dotações de rega de referência da região do Algarve e as áreas regadas obtidas através da classificação automática, os volumes de água por cultura foram calculados e estão apresentados na Tabela

10. A seguir, detalha-se os resultados para cada cultura.

Em 2017, os abacateiros tiveram uma área regada de 64,09 hectares e um volume de água utilizado de 406.733,15 m³. Ao longo dos anos, tanto a área regada quanto o volume de água diminuíram. Em 2023, a área regada foi reduzida para 45,02 hectares, com um volume de água de 285.723,68 m³. Isso representa uma redução de 29,77% na área regada e uma diminuição de 29,75% no volume de água aplicado.

Nos citrinos, a área regada manteve-se relativamente estável, com 1.038,36 hectares em 2017 e 962,56 hectares em 2023. O volume de água utilizado também sofreu uma ligeira queda, passando de 6.240.516,96 m³ em 2017 para 5.784.994,16 m³ em 2023, o que corresponde a uma redução de 7,30% na área e de 7,29% no volume de água.

Para os campos de golfe, verificou-se um aumento significativo nas áreas regadas, de 122,53 hectares em 2017 para 244,92 hectares em 2023, o que revela uma falha na classificação, especialmente nos anos de 2017 e 2018 onde ocorre maiores diferenças. Esta situação evidencia uma fragilidade do modelo, que não quantificou corretamente as áreas de golfe, possivelmente devido à interferência de ruído causado por jardins ou outros tipos de uso e ocupação do solo com características semelhantes. Segundo as imagens de satélite, os campos de golfe estiveram sempre presentes, mas os valores estimados para esses anos foram discrepantes, apresentando uma diferença de aproximadamente 100%. O volume de água utilizada seguiu a mesma tendência, aumentando de 1.225.315,85 m³ para 2.449.211,25 m³, refletindo um aumento de 99,85%.

Nas hortícolas, a área regada diminuiu de 311,26 hectares em 2017 para 246,42 hectares em 2023, uma redução de 20,83%. O volume de água utilizado também apresentou uma diminuição semelhante, passando de 1.559.722,15 m³ em 2017 para 1.234.821,36 m³ em 2023, o que corresponde a uma redução de 20,81%.

Esses resultados têm implicações importantes para a gestão de recursos hídricos. A redução no volume de água utilizado para culturas como abacateiros e citrinos revela uma ligeira diminuição de áreas regadas, que poderá estar associado a abandono de algumas parcelas agrícolas, o que poderá por sua vez estar associado a problemas de escassez hídrica.

No caso dos campos de golfe, a subestimativa pela classificação automática indica a necessidade de um refinamento no modelo *Fuzzy* para melhor capturar as áreas efetivamente regadas. Como os campos de golfe exigem grandes quantidades de água para manutenção, garantir a precisão na estimativa de suas áreas regadas é essencial para o planejamento hídrico regional.

A análise dos volumes de água utilizados nas áreas regadas entre 2017 e 2023 mostra

uma variação significativa nas diferentes culturas. Enquanto o método *Fuzzy* de classificação automática ofereceu uma boa precisão para algumas culturas, como citrinos e abacateiros, ele ainda enfrenta desafios em outras, como os campos de golfe e hortícolas.

A comparação com a classificação manual de 2021 revela a importância de continuar aprimorando os modelos automáticos para obter estimativas mais precisas, especialmente em culturas com maior variabilidade de uso hídrico.

6.6. Comparação do volume de água obtido nas áreas regadas com os valores oficiais do PGRH, PREH e Costa Almeida (2000)

Neste subcapítulo, será realizada uma comparação entre os volumes de água utilizados nas áreas regadas, obtidos através do cruzamento das dotações de rega com a classificação automática com o método *Fuzzy*, e os valores de referência oficiais fornecidos pelo estudo dos Sistemas Aquíferos de Portugal Continental de Almeida et al., (2000), pelo PREH (Plano Regional de Eficiência Hídrica) através da APA (2020) e pelo PGRH (Plano de Gestão de Recursos Hídricos) também através da APA (2022). O objetivo é avaliar a precisão do método *Fuzzy* na quantificação das áreas regadas e, conseqüentemente, o volume de água utilizado, comparando esses resultados com as estimativas oficiais de recarga e saída do aquífero Campina de Faro, sendo que estas saídas se referem exclusivamente ao volume de água utilizado para rega e campos de golfe.

As recargas médias anuais do aquífero Campina de Faro, de acordo com diferentes autores, correspondentes aos anos anteriores à data de publicação de cada estudo, variam entre 10 hm³/ano, conforme Almeida et al., (2000), 9,16 hm³/ano estimadas pela APA (2020) e 7,9 hm³/ano, também de acordo com a APA (2022).

As saídas anuais de água utilizadas exclusivamente para rega, correspondentes aos anos anteriores à data de publicação de cada estudo, são estimadas em 12 hm³/ano por Almeida et al., (2000), 10,87 hm³/ano pela APA (2020) e 12,99 hm³/ano pela APA (2022).

Na Tabela 13, são comparados os volumes obtidos para as áreas regadas, através do método automático *Fuzzy*, com as estimativas oficiais de água extraída do aquífero, detalhando os valores para cada ano entre 2017 e 2023.

Tabela 13 - Comparativo volume captado estimados a partir do modelo x valor de extração de acordo com as estimativas oficiais

Ano	Jonat Marques (2024)	Almeida et al., (2000)			APA (2020)			APA (2022)		
	Volume Obtido classificador Fuzzy	Captação para agricultura	Captação para golfes	Volume Fuzzy x Captação Total	Captação para agricultura	Captação para golfes	Volume Fuzzy x Captação Total	Captação para agricultura	Captação para golfes	Volume Fuzzy x Captação Total
	hm ³	hm ³			hm ³			hm ³		
2017	9,43			-2,57			-1,44			-3,56
2018	9,71			-2,29			-1,16			-3,28
2019	10,96			-1,04			0,09			-2,03
2020	10,98	12	Sem informações	-1,02	7,624	3,25	0,11	9,74	3,25	-2,01
2021	9,55			-2,45			-1,32			-3,44
2022	10,94			-1,06			0,07			-2,05
2023	9,75			-2,25			-1,12			-3,24
	10,19	12,00			10,87			12,99		

Tabela 14 - Recarga média anual do volume de água segundo as estimativas dos principais autores: Almeida et al., (2000), APA (2020) e APA (2022)

Sistemas Aquíferos de Portugal Continental - Almeida et al., (2000)	PREH (Plano Regional de Eficiência Hídrica) - APA (2020)	PGRH (Plano de Gestão de Recursos Hídricos) - APA (2022)
Recarga Média Anual - hm³		
10	9,16	7,9

Os valores de volume captado estimados a partir do modelo aplicado são de:

2017 - 9,43 hm³

2018 - 9,71 hm³

2019 - 10,96 hm³

2020 - 10,98 hm³

2021 - 9,55 hm³

2022 - 10,94 hm³

2023 - 9,75 hm³

Verifica-se que na generalidade, os valores calculados são inferiores às estimativas oficiais. No caso do Almeida entre -1,02 a -2,57 hm³, no caso da APA 2020, entre -1,44 a + 0,09 hm³ e no caso da APA 2022 entre -2,01 a -3,56 hm³.

Apesar dos valores aparentemente subestimados pelo modelo, há que ter em consideração que o presente trabalho não inclui a classificação de volume de rega utilizado nas estufas, que poderá ser significativo, tal como de outras culturas de menor expressão na área do aquífero.

A comparação entre os volumes obtidos a partir da aplicação das dotações de rega às áreas regadas estimadas com o método *Fuzzy* e as estimativas de saída para rega e golfes sugere que o método automático *Fuzzy* apresenta uma boa precisão ao estimar o volume de água utilizado em áreas regadas, especialmente nos anos em que a utilização de água segue padrões mais estáveis. No entanto, a análise também mostra que, em todos os anos analisados, os volumes obtidos com o método *Fuzzy* são consistentemente inferiores às estimativas de saídas de água utilizadas para rega.

Essa diferença pode indicar uma subestimação, por parte do método *Fuzzy*, no volume total de água necessário para a rega. As possíveis causas dessa subestimação incluem limitações do modelo automático, que pode não captar com precisão todas as áreas regadas, especialmente em anos com variações significativas nas condições climáticas e nas práticas agrícolas, ou que as estimativas oficiais não contemplam a variabilidade da extracção, uma vez que foram estimadas para um dado período. Além disso, a calibração do modelo pode ser insuficiente, necessitando de ajustes mais específicos para captar as variações sazonais e regionais nas áreas regadas. Por fim, o método pode ter dificuldades em estimar com precisão a água necessária em anos húmidos ou secos, quando o uso de água tende a ser mais variável. Constata-se ainda que a metodologia não contempla a quantificação do volume de água usado nas estufas, uma vez que há uma grande incerteza em saber o que está plantando nestes casos.

Em suma, o método *Fuzzy* apresenta um desempenho satisfatório na identificação das

áreas regadas e, conseqüentemente no cálculo do volume de água utilizado com base nas dotações de rega da DGADR, mas a análise crítica sugere que uma calibração mais rigorosa e uma maior atenção aos fatores climáticos e de uso agrícola poderiam melhorar ainda mais a precisão dos resultados.

A análise realizada neste subcapítulo evidencia que o método *Fuzzy* apresenta limitações na precisão das estimativas de volume de água utilizado para rega, subestimando os valores em comparação com as saídas estimadas por diferentes autores. Embora o modelo ofereça uma aproximação aceitável das extracções de água do aquífero, é notável que ajustes e calibrações adicionais são necessários para melhorar sua precisão, especialmente em anos com condições climáticas variáveis e diferentes práticas agrícolas. No entanto, é importante reconhecer que os valores oficiais também têm as suas incertezas, e a única maneira de garantir o uso exato de água seria medir diretamente cada área, o que ainda poderia apresentar erros devido a possíveis falhas nos contadores.

O método apresentado, assim como qualquer outro, também possui erros e limitações, sendo uma estimativa que pode ser utilizada para acompanhar a variação das áreas regadas e, conseqüentemente, o consumo de água ao longo dos anos. No entanto, está na mesma ordem de grandeza dos valores oficiais e oferece uma abordagem que pode contribuir para estimar a evolução do uso da água nas áreas regadas ao longo do tempo. Portanto, o método *Fuzzy*, com ajustes adequados, pode servir como uma ferramenta valiosa para o monitoramento da gestão hídrica na região.

A recarga média anual do aquífero conforme Tabela 14, conforme os três principais autores, apresenta valores discrepantes quando comparados com os volumes de captação (extração) indicados para os mesmos anos. Segundo Almeida et al., (2000), a recarga média anual é de 10 hm³, enquanto o Plano Regional de Eficiência Hídrica (PREH) da APA (2020) estima uma recarga de 9,16 hm³. O Plano de Gestão de Recursos Hídricos (PGRH) da APA (2022) ajusta esse valor para 7,9 hm³, sugerindo uma redução da capacidade de recarga ao longo dos anos. Estes valores são inferiores às estimativas de captação de água, especialmente no caso de Costa Almeida (2000), que aponta uma extração de 12 hm³ para a agricultura. As estimativas da APA (2020) e APA (2022), que consideram volumes totais de captação de 10,87 hm³ e 12,99 hm³, respetivamente, também superam as médias anuais de recarga. Esta discrepância entre recarga e captação sugere que a exploração dos recursos hídricos pode estar a exceder a capacidade de reposição natural dos aquíferos, o que evidencia um possível cenário de sobre-exploração e a necessidade de uma gestão mais sustentável dos recursos hídricos para evitar impactos negativos a longo prazo.

7. Conclusão

Ao longo desta pesquisa, explorou-se o uso de Sistemas de Informação Geográfica (SIG) e técnicas de classificação supervisionada e não supervisionada para mapear e monitorar áreas agrícolas regadas e o uso de recursos hídricos na região do Aquífero Campina de Faro. Diversos métodos de classificação, como o *Fuzzy Artmap*, *Maxlike*, *Fisher*, *Raw* e *Normalized*, foram comparados para avaliar sua eficácia na identificação de áreas regadas e respectivas culturas. Consequentemente, procedeu-se à estimativa da quantidade de água utilizada com base em dotações de rega oficiais.

Os resultados obtidos ao longo deste estudo indicam que o método *Fuzzy Artmap* destacou-se como o mais robusto na classificação automática de áreas de culturas regadas, especialmente na classificação de culturas como citrinos e hortícolas. Este classificador demonstrou uma maior consistência em relação às outras abordagens, o que reforça sua aplicabilidade em projetos de monitoramento de uso do solo. A segmentação das imagens, com uma tolerância de similaridade de 10 — ou seja, agrupando pixéis que possuem uma diferença de cor de até 10 tonalidades —, também provou ser eficaz para aumentar a precisão na identificação das áreas regadas, demonstrando que o uso de técnicas segmentadas pode aprimorar significativamente os resultados de classificação.

Outro ponto de destaque foi a análise comparativa entre os índices vegetativos NDVI e NDWI, como uma primeira etapa para delimitar as áreas efetivamente regadas, à qual se seguiu a aplicação dos métodos automáticos para identificar o tipo de cultura. Nesta etapa o NDWI revelou-se mais eficaz na identificação de áreas regadas em determinadas culturas, como campos de golfe, enquanto o NDVI, embora menos preciso na delimitação de algumas áreas, apresentou uma melhor capacidade de identificar áreas efetivamente regadas e assim melhorar a estimativa do volume de água utilizado, o que o torna uma ferramenta valiosa para estudos hídricos.

Em termos de quantificação do uso da água, aplicaram-se as dotações de rega de 2024 da DGADR às áreas regadas identificadas através do método *Fuzzy*. Embora geralmente satisfatórios, os resultados referentes aos volumes de água usada na rega indicaram algumas discrepâncias quando comparados aos volumes oficiais fornecidos por fontes como o Plano de Gestão de Recursos Hídricos (PGRH) e o Plano Regional de Eficiência Hídrica (PREH). Estas diferenças podem ser atribuídas a limitações na calibração do modelo e à variabilidade das práticas agrícolas e climáticas. Adicionalmente, também poderão revelar incerteza dos volumes oficiais. Contudo, o método *Fuzzy* demonstrou estar dentro da mesma ordem de grandeza das

estimativas oficiais, destacando-se como uma ferramenta promissora para o monitoramento contínuo do uso da água em áreas regadas.

Diante dos desafios e das limitações encontrados, esta pesquisa oferece várias contribuições importantes. Primeiro, reforça a aplicabilidade de técnicas de classificação supervisionada, como o *Fuzzy Artmap*, em ambiente de SIG voltados ao monitoramento de uso do solo e gestão de recursos hídricos. Segundo, destaca a importância da segmentação na melhoria dos resultados de classificação, especialmente em áreas agrícolas heterogêneas. Por fim, propõe uma metodologia sólida para a estimativa de áreas regadas e identificação de culturas e assim, permitir estimar o volume de água usado, tornando esta numa ferramenta com um potencial enorme para a gestão sustentável de recursos hídricos em regiões agrícolas em que o acesso a dados de consumo de água é escasso.

O estudo também revela a necessidade de continuar aprimorando os métodos automáticos de classificação, especialmente em relação à calibração para diferentes culturas e condições climáticas. Embora a técnica *Fuzzy* tenha apresentado resultados satisfatórios, ajustes futuros podem aumentar sua precisão e eficácia, particularmente em áreas com maior variabilidade radiométricas.

Em conclusão, o presente trabalho oferece uma base metodológica relevante para futuros estudos em SIG aplicados à actividade agricultura e gestão hídrica. Ao combinar técnicas avançadas de classificação com análise de índices vegetativos e segmentação, ele contribui para uma melhor compreensão do uso da terra e da água em áreas regadas, fornecendo informações essenciais para a tomada de decisões na gestão de recursos naturais. A continuidade desta linha de pesquisa permitirá o desenvolvimento de ferramentas mais precisas e eficientes para mapear a área total do aquífero, o monitoramento ambiental, auxiliando na preservação e uso sustentável dos recursos hídricos em regiões agrícolas.

Este estudo ainda permitiu identificar o método Fuzzy como o mais eficaz na quantificação de áreas regadas, proporcionando bons resultados para culturas como citrinos e abacateiros. No entanto, constatou-se a necessidade de melhorar a sua precisão para áreas como campos de golfe e hortícolas. Esta fragilidade explica-se facilmente no caso dos campos de golfe, pela similaridade entre o relvado do golfe e dos jardins, que interferem na classificação do golfe. No caso das hortícolas, a razão pelo qual o modelo apresenta maus resultados prende-se com o facto que a classificação de hortícolas inclui vários tipos de culturas que apresentam um sinal espectral muito diferentes entre si, pelo que seria necessário separar as culturas de hortícolas entre si de forma a permitir a sua identificação automática de forma mais precisa.

A comparação com a classificação manual de 2021 demonstrou que, embora o método

automático tenha apresentado bons alinhamentos em alguns casos, ele ainda subestima ou superestima em outros. Estes resultados reforçam a importância de continuar a refinar os modelos automáticos para uma gestão mais eficiente dos recursos hídricos.

Em conclusão, a comparação entre o volume de água estimado na rega a partir da aplicação das dotações de rega ao método Fuzzy e as estimativas oficiais para os volumes de água utilizados nas áreas regadas demonstra que o modelo automático subestima o volume de água necessário em comparação com as saídas indicadas por diferentes autores. Embora a metodologia utilizada apresente uma boa precisão para estimar áreas regadas, ele mostra limitações em captar o volume total de água utilizado, especialmente em anos com variações climáticas significativas. Ajustes no modelo, levando em consideração fatores climáticos e práticas agrícolas, são essenciais para melhorar a sua precisão.

Finalizando, refere-se que a discrepância entre a recarga média anual do aquífero Campina de Faro e as diferentes estimativas de volumes de captado do aquífero indicam uma possível sobre-exploração dos recursos hídricos, sublinhando a importância de uma gestão hídrica mais eficiente e sustentável na massa de água.

Bibliografia

- Agência Portuguesa do Ambiente. (2007). Classificação de Uso e Ocupação do Solo. In *Administrações de Região Hidrográfica no Algarve*.
- Agência Portuguesa do Ambiente (APA). (2020). *Bases do Plano Regional de Eficiência Hídrica: Região do Algarve, Volume I - Memória descritiva*.
- Agência Portuguesa do Ambiente (APA). (2022). *Plano de Gestão de Região Hidrográfica, 3.º Ciclo | 2022–2027: Ribeiras do Algarve (RH8) - Fichas de Massa de Água*.
- Agência Portuguesa do Ambiente (APA). (2023). *Dados Piezométricos do Sistema Nacional de Informação de Recursos Hídricos (SNIRH)*.
<https://snirh.apambiente.pt/index.php?idMain=2&idItem=1&objCover=100290946&objSite=>
- Agência Portuguesa do Ambiente (APA). (2024, March 22). *Ano Hidrológico 2022/23 em revista*.
- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). *Crop evapotranspiration - Guidelines for computing crop water requirements - FAO Irrigation and drainage paper 56*. FAO.
- Almeida, C., Lopo, M., Jesus, M., & Gomes, A. (2000a). *Sistemas Aquíferos de Portugal Continental, vol. I*. <https://doi.org/10.13140/RG.2.1.1012.6160>
- Almeida, C., Lopo, M., Jesus, M., & Gomes, A. (2000b). *Sistemas Aquíferos de Portugal Continental: Vol. I*. Centro de Geologia da Universidade de Lisboa & Instituto Nacional da Água. <https://doi.org/10.13140/RG.2.1.1012.6160>
- Al-Rashed, A., & Youssef, M. (2023). Normalized Classifiers for Urban Green Analysis in Egypt. *Environmental Modelling & Software*, 59(6), 678–690.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Campos-Taberner, M., García-Haro, F. J., Camps-Valls, G., Grau-Muedra, G., Nutini, F., Crema, A., & Boschetti, M. (2016). Multitemporal and multiresolution leaf area index retrieval for operational local rice crop monitoring. *Remote Sensing of Environment*, 187, 102–118. <https://doi.org/10.1016/j.rse.2016.10.009>
- Carpenter, G. A., & Grossberg, S. (1987). A massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer Vision, Graphics, and Image Processing*, 37(1), 54–115.
- Carpenter, G. A., Grossberg, S., & Reynolds, J. H. (1991). ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network. *Neural Networks*, 4(5), 565–588. [https://doi.org/10.1016/0893-6080\(91\)90012-T](https://doi.org/10.1016/0893-6080(91)90012-T)
- Chen, L., & Wu, Z. (2020). Identification of Irrigated Areas Using Fuzzy Classifiers in China. *International Journal of Geographical Information Science*, 34(2), 345–362.
- Conese, C., & Maselli, F. (1992). Use of error matrices to improve area estimates with maximum likelihood classification procedures. *Remote Sensing of Environment*, 40(2), 113–124.
- Copernicus. (2022). *Copernicus Sentinel-2 Mission*. <https://sentiwiki.copernicus.eu/web/s2-mission>
- Costa, L., Hugman, R., Stigter, T., Monteiro, J., & Standen, K. (2021, September 6). *Assessing the Impact of Human Activity, Managed Aquifer Recharge and Climate Change scenarios on groundwater nitrate in south Portugal*.
- Costa, L. R. D., Hugman, R. T., Stigter, T. Y., & Monteiro, J. P. (2021). Predicting the impact of management and climate scenarios on groundwater nitrate concentration trends in southern Portugal. *Hydrogeology Journal*, 29(7), 2501–2516.
<https://doi.org/10.1007/s10040-021-02374-4>
- Direção Regional de Agricultura e Pescas do Algarve (DRAP Algarve). (2024, January). *Rede*

- de Estações Meteorológicas Automáticas da Drapalg.*
<https://www.drapalgarve.gov.pt/ema/pat.htm>.
- Direção-Geral de Agricultura e Desenvolvimento Rural (DGADR). (2023, April 18). *Intervenção Uso Eficiente da Água (UEA)*. <https://www.dgadr.gov.pt/eficiencia-hidrica/intervencao-uso-eficiente-da-agua-uea>.
- Direção-Geral do Território. (2018). *Especificações Técnicas da Carta de Uso e Ocupação do Solo (COS) de Portugal Continental para 2018*.
- Eastman, J. R. (2012a). *IDRISI Selva: A Comprehensive Guide to Image Processing and Spatial Analysis*. Clark Labs, Clark University.
- Eastman, J. R. (2012b). *IDRISI Selva: Guide to GIS and Image Processing*.
- Eastman, J. R. (2012c). *IDRISI Selva User Manual*. Clark Labs, Clark University.
- eGROUNDWATER. (2023, April 3). *Aquífero Campina de Faro*.
<https://www.egroundwater.com>.
- Ferreira, J. (2009). *Modelação do Balanço Hídrico em Cenários de Alterações Climáticas e Exploração dos Recursos Hídricos*. Universidade de Lisboa.
- Fisher, R. A. (1936). The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, 7(2), 179–188.
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185–201. [https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4)
- Foody, G. M., Lucas, R. M., Curran, P. J., & Honzak, M. (1992). Estimation of the areal extent of land cover classes that only occur at a sub-pixel level. *Canadian Journal of Remote Sensing*, 18(3), 198–206.
- Fukunaga, K. (1990). *Introduction to Statistical Pattern Recognition* (2nd ed.). Academic Press.
- Gao, B. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Glenn, E. P., Huete, A. R., Nagler, P. L., & Nelson, S. G. (2008). Relationship Between Remotely-sensed Vegetation Indices, Canopy Attributes and Plant Physiological Processes: What Vegetation Indices Can and Cannot Tell Us About the Landscape. *Sensors*, 8(4), 2136–2160. <https://doi.org/10.3390/s8042136>
- Gómez, R., & Martínez, F. (2021). MaxLike Classification for Urban Green Spaces: A Case Study in Spain. *Urban Forestry & Urban Greening*, 28(3), 201–215.
- Holben, B. N. (1986). Características das imagens compostas de valor máximo de dados temporais AVHRR. *International Journal of Remote Sensing*, 7(11), 1417–1434.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Jensen, J. R. (2015). *Introductory digital image processing: A remote sensing perspective* (4th ed.). Pearson.
- John R. Jensen. (1996). *Introductory digital image processing: a remote sensing perspective* (2°). Prentice-Hall.
- Lillesand, T. M., Kiefer, R. W., & Chipman, J. W. (2014). *Remote sensing and image interpretation* (7th ed.). John Wiley & Sons.
- Marques, F. J. M. (2018). *Utilidade agronómica dos índices NDVI e NDWI obtidos por imagem dos satélites Sentinel - 2: estudos de caso nas culturas de trigo, brócolo e arroz*. Universidade de Évora.
- McLachlan, G. J. (2004). *Discriminant Analysis and Statistical Pattern Recognition*. Wiley.
- MELO, E. T., SALES, M. C. L., & OLIVEIRA, J. G. B. de. (2011). Aplicação do Índice de Vegetação por Diferença Normalizada (NDVI) para Análise da Degradação Ambiental da Microbacia Hidrográfica do Riacho dos Cavalos, Crateús-CE. *Raega - O Espaço*

- Geográfico Em Análise*, 23. <https://doi.org/10.5380/raega.v23i0.24919>
- Oliveira, A., & al., et. (2019). Application of Fisher Classifiers for Agricultural Land Use in Portugal. *European Journal of Agronomy*, 10(1), 45–57.
- Patel, S., & al., et. (2022). Raw Data Classification for Crop Typing in Homogeneous Spectral Regions. *Remote Sensing Letters*, 14(5), 489–504.
- Pettorelli, N., Vik, J. O., Mysterud, A., Gaillard, J.-M., Tucker, C. J., & Stenseth, N. Chr. (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution*, 20(9), 503–510.
<https://doi.org/10.1016/j.tree.2005.05.011>
- Richards, J. A. (2013a). *Remote sensing digital image analysis*. Springer.
- Richards, J. A. (2013b). *Remote Sensing Digital Image Analysis* (5th ed.). Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-30062-2>
- Richards, J. A., & Jia, X. (2006). *Remote Sensing Digital Image Analysis: An Introduction* (4th ed.). Springer.
- Scheiffer, R. G., Pires Rosa, M., & Varanda, M. P. (2023). *Nature based solutions for water sensitive communities: governance challenges and opportunities in the subsystem Vale do Lobo, Campina de Faro aquifer, Loulé, Portugal*. Universidade do Algarve.
- Shan, J., Zhao, W., & Toth, C. K. (2008). Fuzzy ARTMAP neural network for urban classification using hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 46(8), 2118–2128.
- Silva, B. B., Silva, D., Lopes, G., Vieira, P., & Azevedo, P. (2005). *Balanço de radiação em áreas irrigadas utilizando imagens Landsat 5-TM*. 202, 243–252.
- Smith, J., & al., et. (2018). Fuzzy Classification of Agricultural Zones Using Remote Sensing in Southern France. *Journal of Applied Remote Sensing*, 12(4), 123–135.
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150.
[https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)

Anexos

Anexo 1 – Precipitação e Evapotranspiração Potencial de 2016 a 2023

Tabela 1 - Parâmetros Estatísticos dos valores de precipitação média anual mensal da série 2016/2023 da Estação Patacão de Faro

Estatística	Média	Min	q1	q2	q3	Máx	Mediana	Moda	Desv.
Out (mm)	66	10	22	45	109	144	45	0	50
Nov (mm)	95	14	33	43	132	280	43	0	88
Dez (mm)	105	15	53	63	112	327	63	0	98
Jan (mm)	37	3	27	47	49	61	47	0	18
Fev (mm)	63	2	29	63	96	128	63	0	46
Mar (mm)	88	8	25	90	115	238	90	0	74
Abr (mm)	60	3	17	28	93	171	28	0	58
Mai (mm)	19	0	5	14	21	66	14	0	21
Jun (mm)	6	0	0	3	4	31	3	0	10
Jul (mm)	0	0	0	0	0	0	0	0	0
Ago (mm)	0	0	0	0	0	2	0	0	1
Set (mm)	14	0	4	6	25	32	6	0	12

Tabela 2 - Valores de precipitação mensal pelo ano hidrológico da série 2016/2023 da Estação Patacão de Faro

Ano Hidrológico x Mês	Out (mm)	Nov (mm)	Dez (mm)	Jan (mm)	Fev (mm)	Mar (mm)	Abr (mm)	Mai (mm)	Jun (mm)	Jul (mm)	Ago (mm)	Set (mm)	Total (mm)
2016/2017	96	124	148	49	123	105	20	14	0	0	0	0	677
2017/2018	13	37	47	61	69	238	171	19	31	0	2	6	693
2018/2019	123	140	15	25	63	8	67	0	0	0	0	3	445
2019/2020	31	43	63	49	2	90	119	66	3	0	0	21	487
2020/2021	144	280	59	47	128	17	15	24	3	0	0	32	750
2021/2022	10	14	76	3	7	124	28	6	1	0	0	29	298
2022/2023	45	30	327	30	52	32	3	4	5	0	0	6	533

Tabela 3 - Acumulado mensal da evapotranspiração potencial (ET₀) em mm (calculada pelo método de Penman-Monteith) da Estação Patacão em Faro do período anual de 2016/2023. Observando que os meses de julho, agosto e setembro de 2021 não têm a informação - Direção Regional de Agricultura e Pescas do Algarve (DRAP Algarve)

Ano	Jan (mm)	Fev (mm)	Mar (mm)	Abr (mm)	Mai (mm)	Jun (mm)	Jul (mm)	Ago (mm)	Set (mm)	Out (mm)	Nov (mm)	Dez (mm)	Total (mm)
2016	54	74	119	128	162	217	216	208	165	104	67	57	1571

Ano	Jan (mm)	Fev (mm)	Mar (mm)	Abr (mm)	Mai (mm)	Jun (mm)	Jul (mm)	Ago (mm)	Set (mm)	Out (mm)	Nov (mm)	Dez (mm)	Total (mm)
2017	68	57	103	145	168	206	214	190	153	111	76	60	1552
2018	66	78	89	107	132	132	211	222	168	105	61	65	1436
2019	72	83	137	134	215	220	221	222	165	112	65	52	1698
2020	61	90	107	125	190	212	237	225	160	124	67	58	1654
2021	60	64	132	137	212	204	-	-	-	125	80	55	-
2022	71	82	85	139	199	215	220	184	139	91	60	42	1524
2023	62	67	114	167	185	188	220	205	132	98	69	56	1560

Anexo 2 – COS2018

Tabela 1 - COS2018

dgTerritório		Nomenclatura da Carta de Uso e Ocupação do Solo de Portugal Continental			
		COS2018			
Nível 1	Nível 2	Nível 3	Nível 4		
1. Territórios artificializados	1.1 Tecido edificado	1.1.1 Tecido edificado contínuo	1.1.1.1 Tecido edificado contínuo predominantemente vertical	1.1.1.2 Tecido edificado contínuo predominantemente horizontal	
		1.1.2 Tecido edificado descontínuo	1.1.2.1 Tecido edificado descontínuo	1.1.2.2 Tecido edificado descontínuo esparsa	
		1.1.3 Espaços vazios em tecido edificado	1.1.3.1 Áreas de estacionamento e logradouros	1.1.3.2 Espaços vazios sem construção	
	1.2 Indústria, comércio e instalações agrícolas	1.2.1 Indústria	1.2.1.1 Indústria	1.2.1.2 Comércio	1.2.1.3 Instalações agrícolas
		1.2.2 Comércio	1.2.2.1 Comércio	1.2.2.2 Instalações agrícolas	1.2.2.3 Infraestruturas de produção de energia renovável
		1.2.3 Instalações agrícolas	1.2.3.1 Instalações agrícolas	1.2.3.2 Infraestruturas de produção de energia não renovável	1.2.3.3 Infraestruturas de tratamento de resíduos e águas residuais
	1.3 Infraestruturas	1.3.1 Infraestruturas de produção de energia	1.3.1.1 Infraestruturas de produção de energia renovável	1.3.1.2 Infraestruturas de produção de energia não renovável	1.3.1.3 Infraestruturas para captação, tratamento e abastecimento de águas para consumo
		1.3.2 Infraestruturas de águas e tratamento de resíduos	1.3.2.1 Infraestruturas de tratamento de resíduos e águas residuais	1.3.2.2 Rede viária e espaços associados	1.3.2.3 Rede ferroviária e espaços associados
		1.3.3 Infraestruturas de águas e tratamento de resíduos	1.3.3.1 Infraestruturas de tratamento de resíduos e águas residuais	1.3.3.2 Rede viária e espaços associados	1.3.3.3 Rede ferroviária e espaços associados
	1.4 Transportes	1.4.1 Redes viárias e ferroviárias e espaços associados	1.4.1.1 Redes viárias e ferroviárias e espaços associados	1.4.1.2 Terminais portuários de mar e de rio	1.4.1.3 Estaleiros navais e docas secas
		1.4.2 Áreas portuárias	1.4.2.1 Terminais portuários de mar e de rio	1.4.2.2 Estaleiros navais e docas secas	1.4.2.3 Minimas e docas pesca
		1.4.3 Aeroportos e aeródromos	1.4.3.1 Aeroportos	1.4.3.2 Aeroportos	1.4.3.3 Aeródromos
	1.5 Áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção	1.5.1 Áreas de extração de inertes	1.5.1.1 Áreas de extração de inertes	1.5.1.2 Minas a céu aberto	1.5.1.3 Pedreiras
		1.5.2 Áreas de deposição de resíduos	1.5.2.1 Áreas de deposição de resíduos	1.5.2.2 Lixarias e Sucatas	1.5.2.3 Áreas em construção
		1.5.3 Áreas em construção	1.5.3.1 Áreas em construção	1.5.3.2 Campos de golfe	1.5.3.3 Instalações desportivas
	1.6 Equipamentos	1.6.1 Equipamentos desportivos	1.6.1.1 Equipamentos desportivos	1.6.1.2 Parques de campismo	1.6.1.3 Equipamentos de lazer
		1.6.2 Equipamentos de lazer e parques de campismo	1.6.2.1 Parques de campismo	1.6.2.2 Equipamentos de lazer	1.6.2.3 Equipamentos culturais
1.6.3 Equipamentos culturais		1.6.3.1 Equipamentos culturais	1.6.3.2 Cemitérios	1.6.3.3 Outros equipamentos e instalações turísticas	
1.7 Parques e jardins	1.7.1 Parques e jardins	1.7.1.1 Parques e jardins	1.7.1.2 Parques e jardins	1.7.1.3 Parques e jardins	
2. Agricultura	2.1 Culturas temporárias	2.1.1 Culturas temporárias de sequeiro e regadio e arrozais	2.1.1.1 Culturas temporárias de sequeiro e regadio	2.1.1.2 Arrozaes	
	2.2 Culturas permanentes	2.2.1 Vinhas	2.2.1.1 Vinhas	2.2.1.2 Pomares	
	2.2.2 Pomares	2.2.2.1 Pomares	2.2.2.2 Olivais	2.2.2.3 Olivais	
	2.2.3 Olivais	2.2.3.1 Olivais	2.2.3.2 Olivais	2.2.3.3 Olivais	
2.3 Áreas agrícolas heterogêneas	2.3.1 Culturas temporárias e/ou pastagens melhoradas associadas a culturas permanentes	2.3.1.1 Culturas temporárias e/ou pastagens melhoradas associadas a vinha	2.3.1.2 Culturas temporárias e/ou pastagens melhoradas associadas a pomar	2.3.1.3 Culturas temporárias e/ou pastagens melhoradas associadas a olival	
	2.3.2 Mosaicos culturais e parcelares complexos	2.3.2.1 Mosaicos culturais e parcelares complexos	2.3.2.2 Mosaicos culturais e parcelares complexos	2.3.2.3 Mosaicos culturais e parcelares complexos	
	2.3.3 Agricultura com espaços naturais e seminaturais	2.3.3.1 Agricultura com espaços naturais e seminaturais	2.3.3.2 Agricultura com espaços naturais e seminaturais	2.3.3.3 Agricultura com espaços naturais e seminaturais	
2.4 Agricultura protegida e viveiros	2.4.1 Agricultura protegida e viveiros	2.4.1.1 Agricultura protegida e viveiros	2.4.1.2 Agricultura protegida e viveiros	2.4.1.3 Agricultura protegida e viveiros	
3. Pastagens	3.1 Pastagens	3.1.1 Pastagens melhoradas	3.1.1.1 Pastagens melhoradas	3.1.1.2 Pastagens melhoradas	
		3.1.2 Pastagens espontâneas	3.1.2.1 Pastagens espontâneas	3.1.2.2 Pastagens espontâneas	
4. Superfícies agroflorestais (SAF)	4.1 Superfícies agroflorestais (SAF)	4.1.1 Superfícies agroflorestais (SAF)	4.1.1.1 SAF de sobreiro	4.1.1.2 SAF de azinheira	
			4.1.1.2 SAF de sobreiro	4.1.1.3 SAF de outros carvalhos	
			4.1.1.3 SAF de outros carvalhos	4.1.1.4 SAF de pinheiro manso	
			4.1.1.4 SAF de pinheiro manso	4.1.1.5 SAF de outras espécies	
			4.1.1.5 SAF de outras espécies	4.1.1.6 SAF de sobreiro com azinheira	
			4.1.1.6 SAF de sobreiro com azinheira	4.1.1.7 SAF de outras misturas	
5. Florestas	5.1 Florestas	5.1.1 Florestas de folhosas	5.1.1.1 Florestas de sobreiro	5.1.1.2 Florestas de azinheira	
			5.1.1.2 Florestas de azinheira	5.1.1.3 Florestas de outros carvalhos	
			5.1.1.3 Florestas de outros carvalhos	5.1.1.4 Florestas de castanheiro	
			5.1.1.4 Florestas de castanheiro	5.1.1.5 Florestas de eucalipto	
			5.1.1.5 Florestas de eucalipto	5.1.1.6 Florestas de espécies invasoras	
			5.1.1.6 Florestas de espécies invasoras	5.1.1.7 Florestas de outras folhosas	
5.1.2 Florestas de resinosas	5.1.2.1 Florestas de pinheiro bravo	5.1.2.2 Florestas de pinheiro manso	5.1.2.3 Florestas de outras resinosas		
	5.1.2.2 Florestas de pinheiro manso	5.1.2.3 Florestas de outras resinosas	5.1.2.4 Florestas de outras resinosas		
	5.1.2.3 Florestas de outras resinosas	5.1.2.4 Florestas de outras resinosas	5.1.2.5 Florestas de outras resinosas		
6. Matos	6.1 Matos	6.1.1 Matos	6.1.1.1 Matos	6.1.1.2 Matos	
			6.1.1.2 Matos	6.1.1.3 Matos	
			6.1.1.3 Matos	6.1.1.4 Matos	
7. Espaços descobertos ou com pouca vegetação	7.1 Espaços descobertos ou com pouca vegetação	7.1.1 Praias, dunas e áreas	7.1.1.1 Praias, dunas e áreas interiores	7.1.1.2 Praias, dunas e áreas costeiras	
			7.1.1.2 Praias, dunas e áreas costeiras	7.1.1.3 Praias, dunas e áreas costeiras	
			7.1.1.3 Praias, dunas e áreas costeiras	7.1.1.4 Praias, dunas e áreas costeiras	
8. Zonas húmidas	8.1 Zonas húmidas	8.1.1 Zonas húmidas interiores	8.1.1.1 Zonas húmidas interiores	8.1.1.2 Zonas húmidas interiores	
			8.1.1.2 Zonas húmidas interiores	8.1.1.3 Zonas húmidas interiores	
			8.1.1.3 Zonas húmidas interiores	8.1.1.4 Zonas húmidas interiores	
9. Massas de água superficiais	9.1 Massas de água interiores	9.1.1 Cursos de água	9.1.1.1 Cursos de água naturais	9.1.1.2 Cursos de água modificados ou artificializados	
			9.1.1.2 Cursos de água modificados ou artificializados	9.1.1.3 Cursos de água modificados ou artificializados	
	9.2 Planos de água	9.2.1 Planos de água	9.2.1.1 Planos de água	9.2.1.2 Planos de água	
		9.2.1.1 Planos de água	9.2.1.2 Planos de água		
	9.2.1 Lagoas costeiras	9.2.1.1 Lagoas costeiras	9.2.1.2 Lagoas costeiras	9.2.1.3 Lagoas costeiras	
		9.2.1.2 Lagoas costeiras	9.2.1.3 Lagoas costeiras		
	9.3.1 Lagoas costeiras	9.3.1.1 Lagoas costeiras	9.3.1.2 Lagoas costeiras	9.3.1.3 Lagoas costeiras	
		9.3.1.2 Lagoas costeiras	9.3.1.3 Lagoas costeiras		
	9.3.2 Lagoas costeiras	9.3.2.1 Lagoas costeiras	9.3.2.2 Lagoas costeiras	9.3.2.3 Lagoas costeiras	
		9.3.2.2 Lagoas costeiras	9.3.2.3 Lagoas costeiras		
9.3.3 Desembocaduras fluviais	9.3.3.1 Desembocaduras fluviais	9.3.3.2 Desembocaduras fluviais	9.3.3.3 Desembocaduras fluviais		
	9.3.3.2 Desembocaduras fluviais	9.3.3.3 Desembocaduras fluviais			
9.3.4 Oceano	9.3.4.1 Oceano	9.3.4.2 Oceano	9.3.4.3 Oceano		
	9.3.4.2 Oceano	9.3.4.3 Oceano			

Tabela 2 - Distribuição dos tipos de uso e ocupação do solo no Aquífero Campina de Faro em hectares e percentuais – Adaptado de (Direção-Geral do Território, 2018)

Megaclasses (Nível 1)	Área (ha)	Área (%)	Subdivisões (Nível 4)	Área (ha)	Área (%)
1.Territórios artificializados	3350.70	30.35%	1.1.1.1.Tecido edificado contínuo predominantemente vertical	456.86	13.72%
			1.1.1.2.Tecido edificado contínuo predominantemente horizontal	190.14	5.71%
			1.1.2.1.Tecido edificado descontínuo	1012.27	30.40%
			1.1.2.2.Tecido edificado descontínuo esparsos	293.25	8.81%
			1.1.3.1.Áreas de estacionamento e logradouros	23.99	0.72%
			1.1.3.2.Espaços vazios sem construção	10.16	0.31%
			1.2.1.1.Indústria	137.16	4.12%
			1.2.2.1.Comércio	106.54	3.20%
			1.2.3.1.Instalações agrícolas	15.60	0.47%
			1.3.1.1.Infraestruturas de produção de energia renovável	0	0.00%
			1.3.1.2.Infraestruturas de produção de energia não renovável	0	0.00%
			1.3.2.1.Infraestruturas para captação, tratamento e abastecimento de águas para consumo	0	0.00%
			1.3.2.2.Infraestruturas de tratamento de resíduos e águas residuais	0	0.00%
			1.4.1.1.Redes viárias e espaços associados	102.76	3.09%
			1.4.1.2.Redes ferroviárias e espaços associados	8.73	0.26%
			1.4.2.1.Terminais portuários de mar e de rio	6.91	0.21%
			1.4.2.2.Estaleiros navais e docas secas	0	0.00%
			1.4.2.3.Marinas e docas pesca	10.79	0.32%
			1.4.3.1.Aeroportos	200.79	6.03%
			1.4.3.2.Aeródromos	0	0.00%
			1.5.1.1.Minas a céu aberto	0	0.00%
			1.5.1.2.Pedreiras	46.39	1.39%
			1.5.2.1.Aterros	0	0.00%
			1.5.2.2.Lixeiras e Sucatas	3.89	0.12%
			1.5.3.1.Áreas em construção	97.26	2.92%
			1.6.1.1.Campos de golfe	351.84	10.57%
			1.6.1.2.Instalações desportivas	42.71	1.28%
			1.6.2.1.Parques de campismo	18.50	0.56%
			1.6.2.2.Equipamentos de lazer	10.88	0.33%
			1.6.3.1.Equipamentos culturais	3.13	0.09%
1.6.4.1.Cemitérios	4.11	0.12%			
1.6.5.1.Outros equipamentos e instalações turísticas	152.41	4.58%			
1.7.1.1.Parques e jardins	22.46	0.67%			
2.Agricultura	3480.31	31.52%	2.1.1.1.Culturas temporárias de sequeiro e regadio	708.70	20.36%
			2.1.1.2.Arrozais	0	0.00%
			2.2.1.1.Vinhas	16.76	0.48%
			2.2.2.1.Pomares	1516.03	43.56%

Megaclases (Nível 1)	Área (ha)	Área (%)	Subdivisões (Nível 4)	Área (ha)	Área (%)
			2.2.3.1.Olivais	135.87	3.90%
			2.3.1.1.Culturas temporárias e/ou pastagens melhoradas associadas a vinha	0	0.00%
			2.3.1.2.Culturas temporárias e/ou pastagens melhoradas associadas a pomar	12.62	0.36%
			2.3.1.3.Culturas temporárias e/ou pastagens melhoradas associadas a olival	8.01	0.23%
			2.3.2.1.Mosaicos culturais e parcelares complexos	642.59	18.46%
			2.3.3.1.Agricultura com espaços naturais e seminaturais	64.26	1.85%
			2.4.1.1.Agricultura protegida e viveiros	375.46	10.79%
3.Pastagens	572.71	5.19%	3.1.1.1.Pastagens melhoradas	380.01	66.35%
			3.1.2.1.Pastagens espontâneas	192.70	33.65%
			4.1.1.1.SAF de sobreiro	0	0.00%
			4.1.1.2.SAF de azinheira	0	0.00%
			4.1.1.3.SAF de outros carvalhos	0	0.00%
4.Superfícies agroflorestais (SAF)	85.46	0.77%	4.1.1.4.SAF de pinheiro manso	60.78	71.12%
			4.1.1.5.SAF de outras espécies	0	0.00%
			4.1.1.6.SAF de sobreiro com azinheira	0	0.00%
			4.1.1.7.SAF de outras misturas	24.69	28.88%
			5.1.1.1.Florestas de sobreiro	0	0.00%
			5.1.1.2.Florestas de azinheira	0	0.00%
			5.1.1.3.Florestas de outros carvalhos	0	0.00%
			5.1.1.4.Florestas de castanheiro	0	0.00%
			5.1.1.5.Florestas de eucalipto	9.66	0.52%
			5.1.1.6.Florestas de espécies invasoras	0	0.00%
			5.1.1.7.Florestas de outras folhosas	33.32	1.80%
			5.1.2.1.Florestas de pinheiro bravo	203.12	11.00%
			5.1.2.2.Florestas de pinheiro manso	1596.09	86.41%
			5.1.2.3.Florestas de outras resinosas	4.89	0.26%
6.Matos	609.42	5.52%	6.1.1.1.Matos	609.42	100.00%
			7.1.1.1.Praias, dunas e areais interiores	0	0.00%
7.Espaços descobertos ou com pouca vegetação	69.65	0.63%	7.1.1.2.Praias, dunas e areais costeiros	69.65	100.00%
			7.1.2.1.Rocha nua	0	0.00%
			7.1.3.1.Vegetação esparsa	0	0.00%
			8.1.1.1.Pauis	0	0.00%
8.Zonas húmidas	268.67	2.43%	8.1.2.1.Sapais	225.95	84.10%
			8.1.2.2.Zonas entremarés	42.72	15.90%
			9.1.1.1.Cursos de água naturais	0	0.00%
			9.1.1.2.Cursos de água modificados ou artificializados	0	0.00%
			9.1.2.1.Lagos e lagoas interiores artificiais	24.26	3.21%
9.Massas de água superficiais	756.52	6.85%	9.1.2.2.Lagos e lagoas interiores naturais	22.47	2.97%
			9.1.2.3.Albufeiras de barragens	0	0.00%
			9.1.2.4.Albufeiras de represas ou de açudes	0	0.00%

Megaclasses (Nivel 1)	Área (ha)	Área (%)	Subdivisões (Nivel 4)	Área (ha)	Área (%)
			9.1.2.5.Charcas	0	0.00%
			9.2.1.1.Aquicultura	17.44	2.31%
			9.3.1.1.Salinas	391.63	51.77%
			9.3.2.1.Lagoas costeiras	139.05	18.38%
			9.3.3.1.Desembocaduras fluviais	0	0.00%
			9.3.4.1.Oceano	161.66	21.37%

Anexo 3 – Análise espectral e Índices de vegetação do Sentinel-2 (2017-2023)

Tabela 1 - Bandas Espectrais Sentinel 2 - Fonte: (Copernicus, 2022)

Resolução	Nr da Banda	Nome da Banda	Comprimento de Onda Central (nanômetro)	Combinações de Bandas
10 m	B02	Blue (Azul)	490	Cor Verdadeira RGB 04/03/02 Falsa Cor 1 e 2 RGB 08/04/03 e 04/08/03
	B03	Green (Verde)	560	
	B04	Red (Vermelho)	665	
	B08	NIR (Infravermelho Próximo)	842	
20 m	B05	Red Edge 1	705	SWIR 1 RGB 12/11/8A
	B06	Red Edge 2	740	
	B07	Red Edge 3	783	
	B08A	Red Edge 4	865	
	B11	SWIR 1	1610	
	B12	SWIR 2	2190	
60 m	B01	Aerossol	443	-
	B09	Water Vapor	940	
	B10	Cirrus	1375	

Scripts dos índices NDVI, SAVI e NDWI divididos em período seco e húmido de 2017 a 2023

Scripts do índice NDVI

```
//Script Sentinel2_ndvi_2017_PS
Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_ETRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
.filterBounds(table)
.filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2017,
2017, 'year'))
```

```

    .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagem Sentinel 2');

print(mean);

// Calcular NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

Export.image.toDrive({
  image: image_ndvi,
  description: 'Sentinel2_ndvi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_ndvi = {
  min: 0, max: 1, palette: 'FFFFFF, CE7E45, DF923D, F1B555,
  FCD163, 99B718, 74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
  011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'valores NDVI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem NDVI
Map.addLayer(image_ndvi, visParams_ndvi, 'Sentinel-2 NDVI');

//Script Sentinel2_ndvi_2017-2018_PU
Imports (1 entry)
var table =

```

```

ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2017,
2018, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagem Sentinel 2');

print(mean);

// Calcular NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

Export.image.toDrive({
  image: image_ndvi,
  description: 'Sentinel2_ndvi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_ndvi = {
  min: 0, max: 1, palette: 'FFFFFF, CE7E45, DF923D, F1B555,
FCD163, 99B718, 74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'valores NDVI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,

```

```

    folder: 'sentinel',
    region: table
  });

// Exportar Imagem NDVI
Map.addLayer(image_ndvi, visParams_ndvi, 'Sentinel-2 NDVI');

//Script Sentinel2_ndvi_2018_PS
Imports (1 entry)
  var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2018,
2018, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagem Sentinel 2');

print(mean);

// Calcular NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

Export.image.toDrive({
  image: image_ndvi,
  description: 'Sentinel2_ndvi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_ndvi = {
  min: 0, max: 1, palette: 'FFFFFF, CE7E45, DF923D, F1B555,
FCD163, 99B718, 74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,'

```

```

011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'valores NDVI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem NDVI
Map.addLayer(image_ndvi, visParams_ndvi, 'Sentinel-2 NDVI');

Script Sentinel2_ndvi_2018-2019_PU
Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2018,
2019, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagem Sentinel 2');

print(mean);

// Calcular NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

Export.image.toDrive({

```

```

    image: image_ndvi,
    description: 'Sentinel2_ndvi',
    scale: 10,
    folder: 'sentinel',
    region: table
  });

var visParams_ndvi = {
  min: 0, max: 1, palette: 'FFFFFF, CE7E45, DF923D, F1B555,
  FCD163, 99B718, 74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
  011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'valores NDVI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

//Script Sentinel2_ndvi_2019_PS
Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Image for SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel
  .filter(ee.Filter.calendarRange(2019, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']

```

```

}, 'Imagen Sentinel 2');

print(mean, 'Mean Image');

// Calculate NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

// Export NDVI image to Google Drive
Export.image.toDrive({
  image: image_ndvi,
  description: 'Sentinel2_ndvi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_ndvi = {
  min: 0, max: 1,
  palette:
'FFFFFF,CE7E45,DF923D,F1B555,FCD163,99B718,74A901,66A000,529400
,3E8601,207401,056201,004C00,023B01,012E01,011D01,011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'NDVI Values');

// Export image to Google Drive
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add NDVI layer to map
Map.addLayer(image_ndvi, visParams_ndvi, 'Sentinel-2 NDVI');

//Script Sentinel2_ndvi_2019-2020_PU
Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Image for SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

```

```

var img = IMGSentinel
  .filter(ee.Filter.calendarRange(2019, 2020, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean, 'Mean Image');

// Calculate NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

// Export NDVI image to Google Drive
Export.image.toDrive({
  image: image_ndvi,
  description: 'Sentinel2_ndvi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_ndvi = {
  min: 0, max: 1,
  palette:
  'FFFFFF,CE7E45,DF923D,F1B555,FCD163,99B718,74A901,66A000,529400
,3E8601,207401,056201,004C00,023B01,012E01,011D01,011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'NDVI Values');

// Export image to Google Drive
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add NDVI layer to map
Map.addLayer(image_ndvi, visParams_ndvi, 'Sentinel-2 NDVI');

```

```

// Script Sentinel2_ndvi_2020_PS
Imports (1 entry)
  var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Image for SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel
  .filter(ee.Filter.calendarRange(2020, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean, 'Mean Image');

// Calculate NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

// Export NDVI image to Google Drive
Export.image.toDrive({
  image: image_ndvi,
  description: 'Sentinel2_ndvi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_ndvi = {
  min: 0, max: 1,
  palette:
'FFFFFF,CE7E45,DF923D,F1B555,FCD163,99B718,74A901,66A000,529400
,3E8601,207401,056201,004C00,023B01,012E01,011D01,011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'NDVI Values');

// Export image to Google Drive

```

```

Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add NDVI layer to map
Map.addLayer(image_ndvi, visParams_ndvi, 'Sentinel-2 NDVI');

//Script Sentinel2_ndvi_2020-2021_PU
Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Image for SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel
  .filter(ee.Filter.calendarRange(2020, 2021, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean, 'Mean Image');

// Calculate NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

// Export NDVI image to Google Drive
Export.image.toDrive({
  image: image_ndvi,
  description: 'Sentinel2_ndvi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

```

```

var visParams_ndvi = {
  min: 0, max: 1,
  palette:
'FFFFFF,CE7E45,DF923D,F1B555,FCD163,99B718,74A901,66A000,529400
,3E8601,207401,056201,004C00,023B01,012E01,011D01,011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'NDVI Values');

//Script Sentinel2_ndvi_2021_PS
Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Image for SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel
  .filter(ee.Filter.calendarRange(2021, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean, 'Mean Image');

// Calculate NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

// Export NDVI image to Google Drive
Export.image.toDrive({
  image: image_ndvi,
  description: 'Sentinel2_ndvi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

```

```

var visParams_ndvi = {
  min: 0, max: 1,
  palette:
'FFFFFF,CE7E45,DF923D,F1B555,FCD163,99B718,74A901,66A000,529400
,3E8601,207401,056201,004C00,023B01,012E01,011D01,011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'NDVI Values');

// Export image to Google Drive
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add NDVI layer to map
Map.addLayer(image_ndvi, visParams_ndvi, 'Sentinel-2 NDVI');

// Script Sentinel2_ndvi_2021-2022_PU
Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Image for SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel
  .filter(ee.Filter.calendarRange(2021, 2022, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean, 'Mean Image');

```

```

// Calculate NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

// Export NDVI image to Google Drive
Export.image.toDrive({
  image: image_ndvi,
  description: 'Sentinel2_ndvi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_ndvi = {
  min: 0, max: 1,
  palette:
'FFFFFF,CE7E45,DF923D,F1B555,FCD163,99B718,74A901,66A000,529400
,3E8601,207401,056201,004C00,023B01,012E01,011D01,011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'NDVI Values');

// Export image to Google Drive
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add NDVI layer to map
Map.addLayer(image_ndvi, visParams_ndvi, 'Sentinel-2 NDVI');

//Script Sentinel2_ndvi_2022_PS
Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Image for SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less Than', 30);

var img = IMGSentinel
  .filter(ee.Filter.calendarRange(2022, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

```

```

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean, 'Mean Image');

// Calculate NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

// Export NDVI image to Google Drive
Export.image.toDrive({
  image: image_ndvi,
  description: 'Sentinel2_ndvi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_ndvi = {
  min: 0, max: 1,
  palette:
'FFFFFF,CE7E45,DF923D,F1B555,FCD163,99B718,74A901,66A000,529400
,3E8601,207401,056201,004C00,023B01,012E01,011D01,011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'NDVI Values');

// Export image to Google Drive
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add NDVI layer to map
Map.addLayer(image_ndvi, visParams_ndvi, 'Sentinel-2 NDVI');

//Script Sentinel2_ndvi_2022-2023_PU
Imports (1 entry)
var table =

```

```

ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2022,
2023, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagem Sentinel 2');

print(mean);

// Calcular NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

Export.image.toDrive({
  image: image_ndvi,
  description: 'Sentinel2_ndvi_2023',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_ndvi = {
  min: 0, max: 1, palette: 'FFFFFF, CE7E45, DF923D, F1B555,
FCD163, 99B718, 74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'valores NDVI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m_2023',
  scale: 10,

```

```

    folder: 'sentinel',
    region: table
  });

// Exportar Imagem NDVI
Map.addLayer(image_ndvi, visParams_ndvi, 'Sentinel-2 NDVI');

//Script Sentinel2_ndvi_2023_PS
Imports (1 entry)
  var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2023,
2023, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagem Sentinel 2');

print(mean);

// Calcular NDVI
var image_ndvi = imgClip.NormalizedDifference(['B8', 'B4']);

Export.image.toDrive({
  image: image_ndvi,
  description: 'Sentinel2_ndvi_2023',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_ndvi = {
  min: 0, max: 1, palette: 'FFFFFF, CE7E45, DF923D, F1B555,
FCD163, 99B718, 74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,'

```

```

011301'
};

Map.centerObject(table, 12);
print(image_ndvi, 'valores NDVI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m_2023',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem NDVI
Map.addLayer(image_ndvi, visParams_ndvi, 'Sentinel-2 NDVI');

```

Scripts do índice SAVI

Script Sentinel2_savi_2017_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2017,
2017, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagem Sentinel 2');

print(mean);

// Calculate SAVI

```

```

var SAVI = imgClip.expression(
  "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
    "L": 0.5,
    "NIR": imgClip.select("B8"),
    "RED": imgClip.select("B4")
  });

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_savi = {
  min: 0,
  max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');

// Export image
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add SAVI layer
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');

```

Script Sentinel2_savi_2017-2018_PU

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
.filterBounds(table)

```

```

    .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2017,
2018, 'year'))
    .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate SAVI
var SAVI = imgClip.expression(
  "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
    "L": 0.5,
    "NIR": imgClip.select("B8"),
    "RED": imgClip.select("B4")
  });

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_savi = {
  min: 0,
  max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');

// Export image
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,

```

```

    folder: 'sentinel',
    region: table
  });

// Add SAVI layer
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');

```

Script Sentinel2_savi_2018_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2018,
2018, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate SAVI
var SAVI = imgClip.expression(
  "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
    "L": 0.5,
    "NIR": imgClip.select("B8"),
    "RED": imgClip.select("B4")
  });

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi',
  scale: 10,
  folder: 'sentinel',
  region: table

```

```

});

var visParams_savi = {
  min: 0,
  max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');

// Export image
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add SAVI layer
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');

```

Script Sentinel2_savi_2018-2019_PU

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2018,
2019, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,

```

```

    bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate SAVI
var SAVI = imgClip.expression(
  "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
    "L": 0.5,
    "NIR": imgClip.select("B8"),
    "RED": imgClip.select("B4")
  });

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_savi = {
  min: 0,
  max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');

// Export image
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add SAVI layer
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');

```

Script Sentinel2_savi_2019_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E

```

```

TRS89");

// Imagen para SENTINEL 2
var IMGsentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGsentinel.filter(ee.Filter.calendarRange(2019,
2019, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate SAVI
var SAVI = imgClip.expression(
  "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
    "L": 0.5,
    "NIR": imgClip.select("B8"),
    "RED": imgClip.select("B4")
  });

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_savi = {
  min: 0,
  max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400, ' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');

```

```

// Export image
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add SAVI layer
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');

```

Script Sentinel2_savi_2019-2020_PU

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2019,
2020, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate SAVI
var SAVI = imgClip.expression(
  "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
    "L": 0.5,
    "NIR": imgClip.select("B8"),
    "RED": imgClip.select("B4")
  });

```

```

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_savi = {
  min: 0,
  max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');

// Export image
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add SAVI layer
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');

```

Script Sentinel2_savi_2020_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2020,
2020, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();

```

```

var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate SAVI
var SAVI = imgClip.expression(
  "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
    "L": 0.5,
    "NIR": imgClip.select("B8"),
    "RED": imgClip.select("B4")
  });

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_savi = {
  min: 0,
  max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');

// Export image
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add SAVI layer
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');

```

Script Sentinel2_savi_2020-2021_PU

```
// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2020,
2021, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate SAVI
var SAVI = imgClip.expression(
  "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
    "L": 0.5,
    "NIR": imgClip.select("B8"),
    "RED": imgClip.select("B4")
  });

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_savi = {
  min: 0,
  max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
```

```
    '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};
```

```
Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');
```

```
// Export image
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});
```

```
// Add SAVI layer
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');
```

Script Sentinel2_savi_2021_PS

```
// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");
```

```
// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);
```

```
var img = IMGSentinel.filter(ee.Filter.calendarRange(2021,
2021, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));
```

```
var mean = img.mean();
var imgClip = mean.clip(table);
```

```
Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');
```

```
print(mean);
```

```
// Calculate SAVI
var SAVI = imgClip.expression(
```

```

    "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
      "L": 0.5,
      "NIR": imgClip.select("B8"),
      "RED": imgClip.select("B4")
    });

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_savi = {
  min: 0,
  max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');

// Export image
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add SAVI layer
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');

```

Script Sentinel2_savi_2021-2022_PU

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

```

```

var img = IMGSentinel.filter(ee.Filter.calendarRange(2021,
2022, 'year'))
    .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate SAVI
var SAVI = imgClip.expression(
  "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
    "L": 0.5,
    "NIR": imgClip.select("B8"),
    "RED": imgClip.select("B4")
  });

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_savi = {
  min: 0,
  max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');

// Export image
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',

```

```

    region: table
  });

// Add SAVI layer
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');

```

Script Sentinel2_savi_2022_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2022,
2022, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate SAVI
var SAVI = imgClip.expression(
  "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
    "L": 0.5,
    "NIR": imgClip.select("B8"),
    "RED": imgClip.select("B4")
  });

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

```

```

var visParams_savi = {
  min: 0,
  max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');

// Export image
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add SAVI layer
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');

```

Script Sentinel2_savi_2022-2023_PU

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2022,
2023, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']

```

```

}, 'Imagen Sentinel 2');

print(mean);

// Calculate SAVI
var SAVI = imgClip.expression(
  "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
    "L": 0.5,
    "NIR": imgClip.select("B8"),
    "RED": imgClip.select("B4")
  });

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_savi = {
  min: 0,
  max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01, 011D01,
011301'
};

Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');

// Export image
Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Add SAVI layer
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');

```

Script Sentinel2_savi_2023_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

```

```

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2023,
2023, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B4', 'B3']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate SAVI
var SAVI = imgClip.expression(
  "float(((NIR-RED)/(NIR+RED+L))*(1+L))", {
    "L": 0.5, // media 0 - 1
    "NIR": imgClip.select("B8"),
    "RED": imgClip.select("B4")
  });

Export.image.toDrive({
  image: SAVI,
  description: 'Sentinel2_savi_2023',
  scale: 10,
  folder: 'sentinel',
  region: table
});

var visParams_savi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
};

Map.centerObject(table, 12);
print(SAVI, 'valores SAVI');

// Exportar a imagem

```

```

Export.image.toDrive({
  image: imgClip.select("B8", "B4", "B3", "B2"),
  description: 'Sentinel2_10m_2023',
  scale: 10,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem SAVI
Map.addLayer(SAVI, visParams_savi, 'Sentinel-2 SAVI');

```

Scripts do índice NDWI

Script Sentinel2_ndwi_2017_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2017,
2017, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B11']
}, 'Imagem Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({
  image: image_ndwi,
  description: 'Sentinel2_ndwi',
  scale: 20,

```

```

    folder: 'sentinel',
    region: table
  });

var visParams_ndwi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
          '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
};

Map.centerObject(table, 12);
print(image_ndwi, 'valores NDWI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B11"),
  description: 'Sentinel2_20m',
  scale: 20,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem NDWI
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');

```

Script Sentinel2_ndwi_2017-2018_PU

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2017,
2018, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,

```

```

    gamma: 1.0,
    bands: ['B8', 'B11']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({
  image: image_ndwi,
  description: 'Sentinel2_ndwi',
  scale: 20,
  folder: 'sentinel',
  region: table
});

var visParams_ndwi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
          '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
};

Map.centerObject(table, 12);
print(image_ndwi, 'valores NDWI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B11"),
  description: 'Sentinel2_20m',
  scale: 20,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem NDWI
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');

```

Script Sentinel2_ndwi_2018_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")

```

```

    .filterBounds(table)
    .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2018,
2018, 'year'))
    .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B11']
}, 'Imagem Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({
  image: image_ndwi,
  description: 'Sentinel2_ndwi',
  scale: 20,
  folder: 'sentinel',
  region: table
});

var visParams_ndwi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
          '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
};

Map.centerObject(table, 12);
print(image_ndwi, 'valores NDWI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B11"),
  description: 'Sentinel2_20m',
  scale: 20,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem NDWI

```

```
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');
```

Script Sentinel2_ndwi_2018-2019_PU

```
// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2018,
2019, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B11']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({
  image: image_ndwi,
  description: 'Sentinel2_ndwi',
  scale: 20,
  folder: 'sentinel',
  region: table
});

var visParams_ndwi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
};
```

```

Map.centerObject(table, 12);
print(image_ndwi, 'valores NDWI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B11"),
  description: 'Sentinel2_20m',
  scale: 20,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem NDWI
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');

```

Script Sentinel2_ndwi_2019_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2019,
2019, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B11']
}, 'Imagem Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({
  image: image_ndwi,
  description: 'Sentinel2_ndwi',

```

```

    scale: 20,
    folder: 'sentinel',
    region: table
  });

var visParams_ndwi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
          '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
};

Map.centerObject(table, 12);
print(image_ndwi, 'valores NDWI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B11"),
  description: 'Sentinel2_20m',
  scale: 20,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem NDWI
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');

```

Script Sentinel2_ndwi_2019-2020_PU

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2019,
2020, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,

```

```

    min: 0,
    gamma: 1.0,
    bands: ['B8', 'B11']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({
  image: image_ndwi,
  description: 'Sentinel2_ndwi',
  scale: 20,
  folder: 'sentinel',
  region: table
});

var visParams_ndwi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
          '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
};

Map.centerObject(table, 12);
print(image_ndwi, 'valores NDWI');

// Exportar a imagen
Export.image.toDrive({
  image: imgClip.select("B8", "B11"),
  description: 'Sentinel2_20m',
  scale: 20,
  folder: 'sentinel',
  region: table
});

// Exportar Imagen NDWI
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');

```

Script Sentinel2_ndwi_2020_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =

```

```

ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2020,
2020, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B11']
}, 'Imagem Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({
  image: image_ndwi,
  description: 'Sentinel2_ndwi',
  scale: 20,
  folder: 'sentinel',
  region: table
});

var visParams_ndwi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
  '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
};

Map.centerObject(table, 12);
print(image_ndwi, 'valores NDWI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B11"),
  description: 'Sentinel2_20m',
  scale: 20,
  folder: 'sentinel',
  region: table
});

```

```
// Exportar Imagem NDWI
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');
```

Script Sentinel2_ndwi_2020-2021_PU

```
// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2020,
2021, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B11']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({
  image: image_ndwi,
  description: 'Sentinel2_ndwi',
  scale: 20,
  folder: 'sentinel',
  region: table
});

var visParams_ndwi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
          '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
};
```

```

Map.centerObject(table, 12);
print(image_ndwi, 'valores NDWI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B11"),
  description: 'Sentinel2_20m',
  scale: 20,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem NDWI
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');

```

Script Sentinel2_ndwi_2021_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2021,
2021, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B11']
}, 'Imagem Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({
  image: image_ndwi,

```

```

    description: 'Sentinel2_ndwi',
    scale: 20,
    folder: 'sentinel',
    region: table
  });

var visParams_ndwi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
          '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
};

Map.centerObject(table, 12);
print(image_ndwi, 'valores NDWI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B11"),
  description: 'Sentinel2_20m',
  scale: 20,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem NDWI
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');

```

Script Sentinel2_ndwi_2021-2022_PU

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2021,
2022, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {

```

```

    max: 4000,
    min: 0,
    gamma: 1.0,
    bands: ['B8', 'B11']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({
  image: image_ndwi,
  description: 'Sentinel2_ndwi',
  scale: 20,
  folder: 'sentinel',
  region: table
});

var visParams_ndwi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
          '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
};

Map.centerObject(table, 12);
print(image_ndwi, 'valores NDWI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B11"),
  description: 'Sentinel2_20m',
  scale: 20,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem NDWI
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');

```

Script Sentinel2_ndwi_2022_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2

```

```

var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2022,
2022, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B11']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({
  image: image_ndwi,
  description: 'Sentinel2_ndwi',
  scale: 20,
  folder: 'sentinel',
  region: table
});

var visParams_ndwi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
          '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
};

Map.centerObject(table, 12);
print(image_ndwi, 'valores NDWI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B11"),
  description: 'Sentinel2_20m',
  scale: 20,
  folder: 'sentinel',
  region: table
});

```

```
// Exportar Imagem NDWI
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');
```

Script Sentinel2_ndwi_2022-2023_PU

```
// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagen para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2022,
2023, 'year'))
  .filter(ee.Filter.calendarRange(12, 3, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B11']
}, 'Imagen Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({
  image: image_ndwi,
  description: 'Sentinel2_ndwi',
  scale: 20,
  folder: 'sentinel',
  region: table
});

var visParams_ndwi = {
  min: 0, max: 1,
  palette: 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400,' +
          '3E8601, 207401, 056201, 004C00, 023B01, 012E01,
011D01, 011301'
```

```

};

Map.centerObject(table, 12);
print(image_ndwi, 'valores NDWI');

// Exportar a imagem
Export.image.toDrive({
  image: imgClip.select("B8", "B11"),
  description: 'Sentinel2_20m',
  scale: 20,
  folder: 'sentinel',
  region: table
});

// Exportar Imagem NDWI
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');

```

Script Sentinel2_ndwi_2023_PS

```

// Imports (1 entry)
var table =
ee.FeatureCollection("users/jonatmarques/uso_solo_CampinaFaro_E
TRS89");

// Imagem para SENTINEL 2
var IMGSentinel =
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(table)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);

var img = IMGSentinel.filter(ee.Filter.calendarRange(2023,
2023, 'year'))
  .filter(ee.Filter.calendarRange(7, 9, 'month'));

var mean = img.mean();
var imgClip = mean.clip(table);

Map.addLayer(imgClip, {
  max: 4000,
  min: 0,
  gamma: 1.0,
  bands: ['B8', 'B11']
}, 'Imagem Sentinel 2');

print(mean);

// Calculate NDWI
var image_ndwi = imgClip.NormalizedDifference(['B8', 'B11']);

Export.image.toDrive({

```

```

image: image_ndwi,
description: 'Sentinel2_ndwi_2023',
scale: 20,
folder: 'sentinel',
region: table
});

// Exportar Imagem NDWI
Map.addLayer(image_ndwi, visParams_ndwi, 'Sentinel-2 NDWI');

```

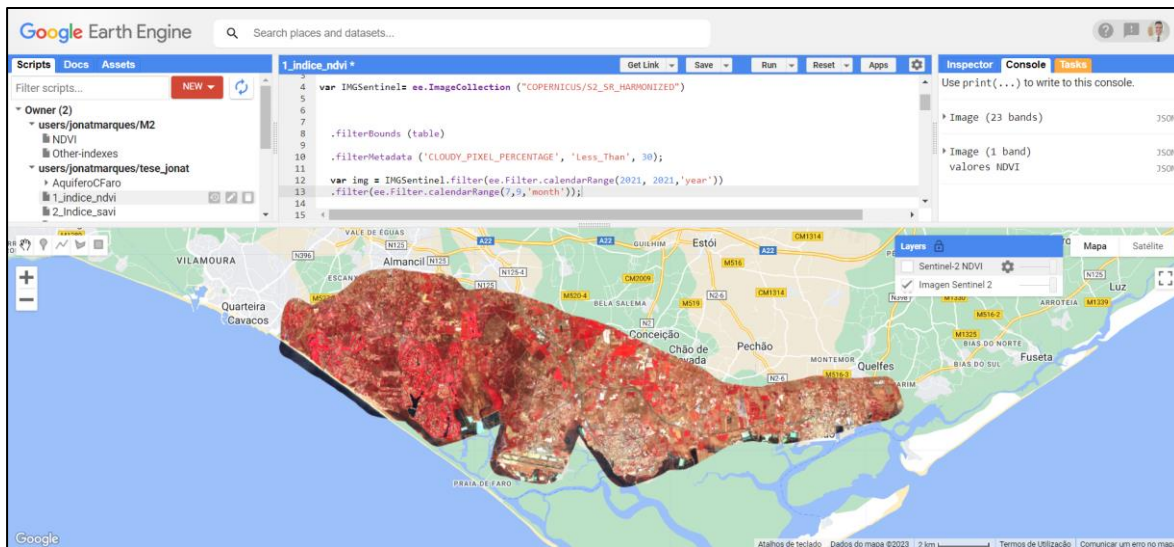


Figura 1 - Script minimizado com a imagem Sentinel2 para o período seco (julho a setembro) de 2021 disponível através do Google Earth Engine

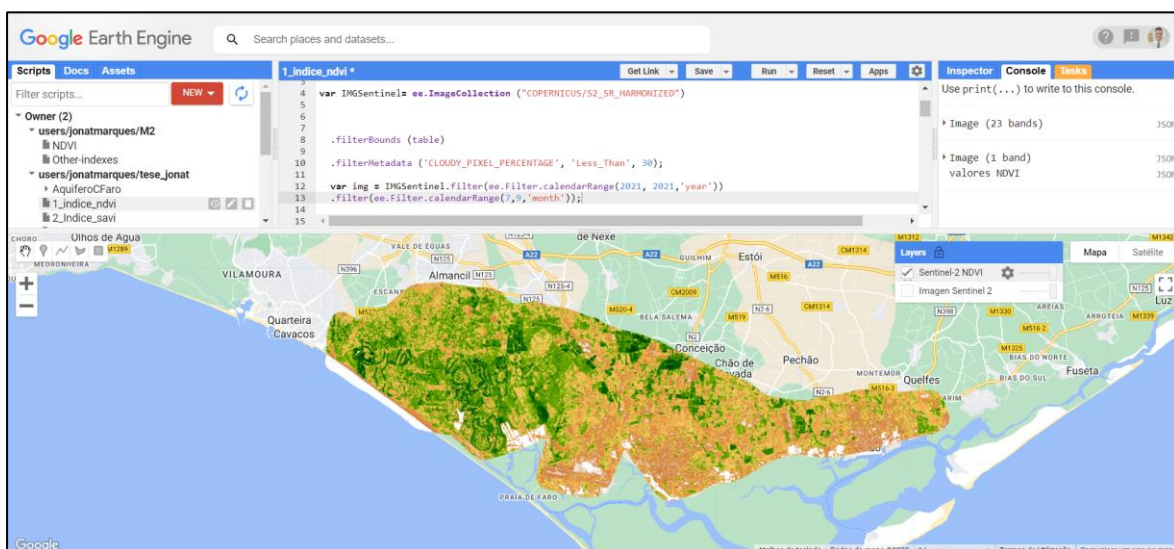


Figura 2 - Script minimizado com a imagem Sentinel 2 NDVI para o período seco (julho a setembro) de 2021 disponível através do Google Earth Engine

Após a visualização no *Google Earth Engine*, é possível extrair os diferentes tipos de ficheiros no formato *GeoTIFF* ortorectificadas para o *Google Drive* (Figuras 3 e 4).




Figura 3 - Imagem de Satélite Sentinel 2 referente ao período seco 2021 com renderização Multibanda colorida projetada no software QGIS




Figura 4 - Cálculo do índice NDVI para o período seco 2021 com renderização Banda simples falsa-cor projetada no software QGIS

Tabela 2 - Ficheiros extraídos do Google Earth Engine

Sentinel2_10m	Sentinel2_10m_NDVI
Sentinel2_10m_2017_PS	Sentinel2_ndvi_2017_PS
Sentinel2_10m_2017-2018_PU	Sentinel2_ndvi_2017-2018_PU
Sentinel2_10m_2018_PS	Sentinel2_ndvi_2018_PS
Sentinel2_10m_2018-2019_PU	Sentinel2_ndvi_2018-2019_PU
Sentinel2_10m_2019_PS	Sentinel2_ndvi_2019_PS
Sentinel2_10m_2019-2020_PU	Sentinel2_ndvi_2019-2020_PU
Sentinel2_10m_2020_PS	Sentinel2_ndvi_2020_PS
Sentinel2_10m_2020-2021_PU	Sentinel2_ndvi_2020-2021_PU
Sentinel2_10m_2021_PS	Sentinel2_ndvi_2021_PS
Sentinel2_10m_2021-2022_PU	Sentinel2_ndvi_2021-2022_PU
Sentinel2_10m_2022_PS	Sentinel2_ndvi_2022_PS
Sentinel2_10m_2022-2023_PU	Sentinel2_ndvi_2022-2023_PU
Sentinel2_10m_2023_PS	Sentinel2_ndvi_2023_PS

Tabela 3 - Separação de bandas espectrais Sentinel 2

Ano	Período	Banda	Nome ficheiro
2017	Período seco	B3	2017_PS_B3
2017	Período seco	B4	2017_PS_B4
2017	Período seco	B8	2017_PS_B8
2017	Período húmido	B3	2017_PU_B3
2017	Período húmido	B4	2017_PU_B4
2017	Período húmido	B8	2017_PU_B8
2018	Período seco	B3	2018_PS_B3
2018	Período seco	B4	2018_PS_B4
2018	Período seco	B8	2018_PS_B8
2018	Período húmido	B3	2018_PU_B3
2018	Período húmido	B4	2018_PU_B4
2018	Período húmido	B8	2018_PU_B8
2019	Período seco	B3	2019_PS_B3
2019	Período seco	B4	2019_PS_B4
2019	Período seco	B8	2019_PS_B8
2019	Período húmido	B3	2019_PU_B3
2019	Período húmido	B4	2019_PU_B4
2019	Período húmido	B8	2019_PU_B8
2020	Período seco	B3	2020_PS_B3
2020	Período seco	B4	2020_PS_B4
2020	Período seco	B8	2020_PS_B8
2020	Período húmido	B3	2020_PU_B3
2020	Período húmido	B4	2020_PU_B4
2020	Período húmido	B8	2020_PU_B8
2021	Período seco	B3	2021_PS_B3
2021	Período seco	B4	2021_PS_B4
2021	Período seco	B8	2021_PS_B8
2021	Período húmido	B3	2021_PU_B3
2021	Período húmido	B4	2021_PU_B4
2021	Período húmido	B8	2021_PU_B8
2022	Período seco	B3	2022_PS_B3
2022	Período seco	B4	2022_PS_B4
2022	Período seco	B8	2022_PS_B8
2022	Período húmido	B3	2022_PU_B3
2022	Período húmido	B4	2022_PU_B4
2022	Período húmido	B8	2022_PU_B8
2023	Período seco	B3	2023_PS_B3
2023	Período seco	B4	2023_PS_B4
2023	Período seco	B8	2023_PS_B8

Anexo 4 – Estatísticas dos índices NDVI, NDWI e SAVI

Tabela 1 - resultados da média, mediana, valores mínimos, máximos e o primeiro quartil de cada tipo de solo (11 classes) para cada índice (NDVI, NDWI e SAVI)

Classe	Índice	Ano	Nº de Polígonos	Média	Mediana	Mínimo	Máximo	1º Quartil
Abacateiro	NDVI	2021	31	0,42	0,37	0,08	0,83	0,26
Abacateiro	NDWI	2021	31	0,04	0,00	-0,20	0,37	-0,06
Abacateiro	SAVI	2021	31	0,63	0,55	0,12	1,24	0,40
Campos de Golfe	NDVI	2021	28	0,61	0,64	0,09	0,61	0,61
Campos de Golfe	NDWI	2021	28	0,23	0,23	-0,26	0,15	0,20
Campos de Golfe	SAVI	2021	28	0,92	0,96	0,13	0,91	0,91
Casa e Jardim	NDVI	2021	395	0,42	0,43	0,04	0,82	0,34
Casa e Jardim	NDWI	2021	395	0,06	0,05	-0,19	0,46	-0,01
Casa e Jardim	SAVI	2021	395	0,63	0,64	0,06	1,23	0,50
Citrinos	NDVI	2021	385	0,40	0,40	0,01	0,86	0,33
Citrinos	NDWI	2021	385	0,01	0,01	-0,28	0,46	-0,04
Citrinos	SAVI	2021	385	0,60	0,60	0,02	1,29	0,50
Estufas	NDVI	2021	55	0,13	0,10	-0,01	0,73	0,07
Estufas	NDWI	2021	55	-0,01	-0,01	-0,30	0,31	-0,04
Estufas	SAVI	2021	55	0,20	0,14	-0,01	1,09	0,11
Hortícolas	NDVI	2021	119	0,29	0,27	0,04	0,72	0,20
Hortícolas	NDWI	2021	119	-0,04	-0,05	-0,24	0,38	-0,10
Hortícolas	SAVI	2021	119	0,44	0,40	0,06	1,08	0,31
Palmeiras	NDVI	2021	2	0,50	0,54	0,12	0,75	0,54
Palmeiras	NDWI	2021	2	0,14	0,17	-0,14	0,31	0,54
Palmeiras	SAVI	2021	2	0,76	0,82	0,18	1,12	0,80
Pastagem	NDVI	2021	5	0,37	0,37	0,09	0,66	0,27
Pastagem	NDWI	2021	5	-0,01	-0,06	-0,18	0,17	-0,08
Pastagem	SAVI	2021	5	0,55	0,55	0,14	0,99	0,41
Relva	NDVI	2021	5	0,60	0,63	0,26	0,86	0,53
Relva	NDWI	2021	5	0,17	0,21	-0,01	0,37	0,09
Relva	SAVI	2021	5	0,89	0,95	0,39	1,28	0,80
Vinha	NDVI	2021	3	0,32	0,35	0,18	0,42	0,28
Vinha	NDWI	2021	3	-0,05	-0,05	-0,18	0,04	-0,09
Vinha	SAVI	2021	3	0,48	0,52	0,28	0,64	0,42
Viveiros	NDVI	2021	2	0,61	0,64	0,18	0,75	0,63
Viveiros	NDWI	2021	2	0,14	0,16	-0,13	0,24	0,16
Viveiros	SAVI	2021	2	0,92	0,96	0,27	1,13	0,95

Tabela 2 - Estatísticos (média, mediana, valores mínimos, máximos e o primeiro quartil) das áreas regadas (11 classes) para cada índice (NDVI, NDWI e SAVI)

Índice	Ano	Nº de Polígonos	Média	Mediana	Mínimo	Máximo	1º Quartil
NDVI	2021	976	0,40	0,40	0,01	0,86	0,31
NDWI	2021	976	0,03	0,02	-0,28	0,50	-0,04
SAVI	2021	976	0,52	0,50	0,02	1,29	0,38

Tabela 3 - Primeiro Quartil de cada uso e ocupação do solo dos índices NDVI, NDWI e SAVI para o período seco (julho a setembro) de 2021

NDVI - 2021 PS	
Uso e Ocupação do Solo	1º Quartil
Abacateiro	0,26
Casa e Jardim	0,34
Citrinos	0,33
Golfe	0,61
Hortícolas	0,20
Palmeiras	0,54
Pastagem	0,27
Relva	0,53
Vinha	0,28
Viveiros	0,63
<i>Média</i>	0,40
<i>Mediana</i>	0,34
<i>1º Quartil</i>	0,27

NDWI - 2021 PS	
Uso e Ocupação do Solo	1º Quartil
Abacateiro	-0,06
Casa e Jardim	-0,01
Citrinos	-0,04
Golfe	0,20
Hortícolas	-0,10
Palmeiras	0,16
Pastagem	-0,08
Relva	0,09
Vinha	-0,09
Viveiros	0,16
<i>Média</i>	0,02
<i>Mediana</i>	-0,03
<i>1º Quartil</i>	-0,07

SAVI - 2021 PS	
Uso e Ocupação do Solo	1º Quartil
Abacateiro	0,40
Casa e Jardim	0,50
Citrinos	0,50
Golfe	0,91
Hortícolas	0,31
Palmeiras	0,80
Pastagem	0,41
Relva	0,80
Vinha	0,42
Viveiros	0,95
<i>Média</i>	0,60
<i>Mediana</i>	0,50
<i>1º Quartil</i>	0,41




Figura 1 - Imagem NDVI reclassificada do Aquífero Campina de Faro para um limiar 0.30 : Áreas

regados (verde), não regados (vermelho), falsos positivos (amarelo) e falsos negativos (preto)

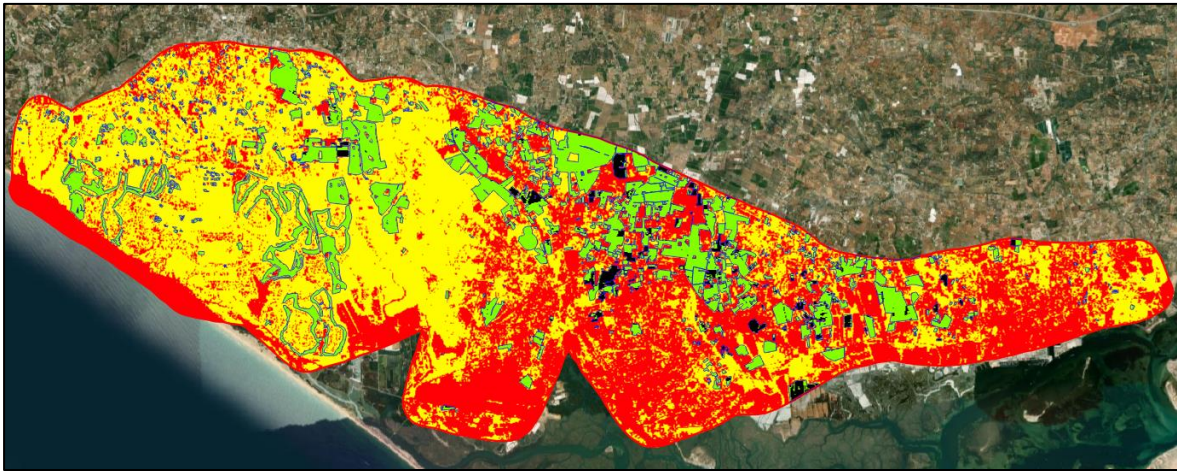


Figura 2 - Imagem NDVI reclassificada do Aquífero Campina de Faro para um limiar 0.20 : Áreas regados (verde), não regados (vermelho), falsos positivos (amarelo) e falsos negativos (preto)




Figura 3 - Imagem NDWI reclassificada do Aquífero Campina de Faro para um limiar entre -0.04 e 0.09: Áreas regados (verde), não regados (vermelho), falsos positivos (amarelo) e falsos negativos (preto)




Figura 4 - Imagem NDWI reclassificada do Aquífero Campina de Faro para um limiar entre -0.09 e 0.17: Áreas regadas (verde), não regadas (vermelho), falsos positivos (amarelo) e falsos negativos (preto)



Figura 5 - Resultado da reclassificação NDWI de 0.15 a 0.49 para os Campos de Golfe. Áreas consideradas regadas representadas na cor verde (76,42%), e áreas como não regadas (falso negativo) (23,58%) em preto



Figura 6 - Resultado da reclassificação NDVI de 0.61 até 1 referente aos Campos de Golfe. Onde áreas que são regadas estão em verde (62,18%), e áreas como não regadas (falso negativo) em preto (37,82%)

Anexo 5 – Dotações de rega de referência (m3/ha) para a região agroclimática do Algarve

Tabela 1 - Tabela com as dotações de rega de referência (m3/ha) para a região agroclimática do Algarve

CÓD CULTURA	DESCRIÇÃO CULTURA	ZONA 7 - CENÁRIO A - ANO MÉDIO - m3/hectare						ZONA 7 - CENÁRIO B - ANO SECO - m3/hectare					
		Dotação. Aspersão	Dotação Canhão	Dotação Pivot	Dotação Micro-Asp	Dotação Gota-a-Gota	Dotação 1Subterr	Dotação. Aspersão	Dotação Canhão	Dotação Pivot	Dotação Micro-Asp	Dotação Gota-a-Gota	Dotação 1Subterr
136	ABACATE				6346	6346	6179				6959	6959	6775
241	ABÓBORAS E ABOBORINHAS *	6560	7030	5790	5470	5470	5180	7560	8100	6670	6300	6300	5970
242	AGRIÃO	10880			9070	9070	8590	12540			10450	10450	9900
244	ALFACE *	2580	2580	2408	2258	2258	2124	2867	2867	2676	2508	2508	2360
111	ALFARROBA				4139	4139	4030				4538	4538	4419
059	ALGODÃO	7503	9111	7503				8227	9990	8227			
245	ALHO	5270	5650	4650	4390	4390	4160	5970	6390	5260	4970	4970	4710
293	ALHO FRANCÊS	3320	3560	2930	2770	2770	2620	3820	4100	3370	3190	3190	3020
108	AMEIXA				6980	6980	6610				8040	8040	7620
109	AMENDOA				7136	7136	6948				7780	7780	7575
130	AMENDOIM	7104	8627	7104	6528	6528	6357	7790	9459	7790	7158	7158	6970
201	AMORA				5123	5123	4989				5618	5618	5470
151	ANONA				6590	6590	6240				7590	7590	7190
311	ARAÇÁ				6880	6880	6520				7920	7920	7510
005	AVEIA	2550	2750	2250			2000	2900	3100	2550			2300
116	AVELÃ				7200	7200	6820				8290	8290	7850
067	AZEVEM	2620	2810	2320			2070	2970	3180	2620			2340
322	BAMBU				3910	3910	3700				4500	4500	4260
133	BANANA	10063	12219	10063	9247	9247	9004	11034	13399	11034	10139	10139	9873
103	BATATA *	4949	6009	4949	4548	4548	4428	5384	6538	5384	4948	4948	4818
127	BATATA DOCE	6379	7746	6379	5862	5862	5708	6995	8494	6995	6428	6428	6259
137	BERINGELA				6680	6680	6320				7690	7690	7290

CÓD CULTURA	DESCRIÇÃO CULTURA	ZONA 7 - CENÁRIO A - ANO MÉDIO - m3/hectare					
		Dotação. Aspersão	Dotação Canhão	Dotação Pivot	Dotação Micro-Asp	Dotação Gota-a-Gota	Dotação Subterr
317	BERSIM	2160	2320	1910			1710
032	BETERRABA	8130	9872	8130			7274
029	CANA DE AÇÚCAR	11954	14516	11954	10985	10985	10696
058	CÂNHAMO	9380	10050	8270	7810	7810	7400
321	CÁRTAMO	3520	3770	3110	2930	2930	2780
110	CASTANHA				7200	7200	6820
248	CEBOLA	7800	8350	6850	6500	6500	6150
249	CENOURA	6376	7742	6376	5859	5859	5705
003	CENTEIO	3000	3250	2650	2500	2500	2400
106	CEREJA				7135	7135	6947
004	CEVADA	3000	3250	2650	2500	2500	2400
115	CHA	9600	10280	8470	8000	8000	7580
316	CHICHARO	2860	3060	2520	2380	2380	2260
263	CHUCHU	6440	6900	5690	5370	5370	5090
157	CITRINOS *				6081	6081	5921
264	COLZA *	2900	3150	2600			2300
266	CONS FIXADORAS AZOTO (+ 50% FIX AZOTO)	8577	10414	8577			7674
267	CONSOCIAÇÕES ANUAIS E OUTRAS CULTURAS FORRAGEIRAS	8577	10414	8577			7674
250	COURGETTE	6870		6060	5730	5730	5420
254	COUVE *	6066		6066	5574	5574	5427
107	DAMASCO				6980	6980	6610
208	DIOSPIRO				7479	7479	7283
013	ERVILHA	1909	2318	1909		1754	1708

ZONA 7 - CENÁRIO B - ANO SECO - m3/hectare					
Dotação. Aspersão	Dotação Canhão	Dotação Pivot	Dotação Micro-Asp	Dotação Gota-a-Gota	Dotação Subterr
2450	2620	2160			1930
8914	10824	8914			7976
13108	15917	13108	12045	12045	11728
10800	11570	9530	9000	9000	8530
3990	4270	3520	3320	3320	3150
			8290	8290	7850
8250	8850	7300	6900	6900	6550
6991	8489	6991	6424	6424	6255
3400	3650	3000	2850	2850	2700
			7823	7823	7617
3400	3650	3000	2850	2850	2700
11020	11800	9720	9180	9180	8700
3240	3470	2860	2700	2700	2560
7420	7950	6550	6190	6190	5860
			6616	6616	6442
3300	3550	2900			2600
9404	11419	9404			8414
9404	11419	9404			8414
7920		6980	6600	6600	6250
6651		6651	6112	6112	5951
			8040	8040	7620
			8201	8201	7985
2077	2522	2077		1909	1858

CÓD CULTURA	DESCRIÇÃO CULTURA	ZONA 7 - CENÁRIO A - ANO MÉDIO - m3/hectare					
		Dotação. Aspersão	Dotação Canhão	Dotação Pivot	Dotação Micro-Asp	Dotação Gota-a-Gota	Dotação Subterr
048	ERVILHACA	2160	2320	1910		1800	1710
309	ESPARGOS	10838	13161	10838	9959	9959	9697
305	ESPINAFRE	1000	1100	900	850	850	800
014	FAVA	2523	3064	2523		2319	2258
230	FEIJÃO	4467	5424	4467		4105	3997
319	FEIJÃO FRADE	4467	5424	4467		4105	3997
085	FIGO				5082	5082	4949
091	FLORES E PLANTAS ORNAMENTAIS *	5485		5485	5041	5041	4908
203	FRAMBOESA				5123	5123	4989
323	FUNCHO	9600	10280	8470	8000	8000	7580
211	GINJA				6780	6780	6420
017	GIRASSOL	4647	5643	4647			4158
310	GOJI				5340	5340	5060
038	GRÃO DE BICO	2900	3150	2550	2450	2450	2300
286	GROSELHA				5180	5180	4900
128	INHAME	7110	7610	6270	5920	5920	5610
124	KIWI				7557	7557	7358
096	LARANJA				6010	6010	5700
315	LENTILHA	5860	6280	5170	4880	4880	4630
097	LIMÃO				6010	6010	5700
009	LINHO	8419	10223	8419	7736	7736	7533
044	LUZERNA *	9564	11613	9564			8557
105	MAÇÃ				6860	6860	6500
269	MARACUJÁ				6780	6780	6420
118	MARMELO				6590	6590	6240

ZONA 7 - CENÁRIO B - ANO SECO - m3/hectare					
Dotação. Aspersão	Dotação Canhão	Dotação Pivot	Dotação Micro-Asp	Dotação Gota-a-Gota	Dotação Subterr
2450	2620	2160		2040	1930
11792	14319	11792	10836	10836	10551
1150	1200	1000	950	950	900
2745	3334	2745		2523	2456
4860	5902	4860		4466	4349
4860	5902	4860		4466	4349
			5547	5547	5401
6015		6015	5527	5527	5381
			5618	5618	5470
11020	11800	9720	9180	9180	8700
			7810	7810	7400
5056	6139	5056			4524
			6150	6150	5830
3300	3550	2900	2750	2750	2600
			5960	5960	5650
8190	8770	7220	6820	6820	6460
			8222	8222	8006
			6930	6930	6560
6750	7230	5960	5630	5630	5330
			6930	6930	6560
9231	11209	9231	8483	8483	8259
10487	12734	10487			9383
			7910	7910	7490
			7810	7810	7400
			7590	7590	7190

CÓD CULTURA	DESCRIÇÃO CULTURA	ZONA 7 - CENÁRIO A - ANO MÉDIO - m3/hectare					
		Dotação. Aspersão	Dotação Canhão	Dotação Pivot	Dotação Micro-Asp	Dotação Gota-a-Gota	Dotação Subterr
283	MEDRONHO				4970	4970	4710
231	MELANCIA	4740	5756	4740		4356	4241
205	MELÃO	5318	6457	5318		4887	4758
232	MELOA	5740	6150	5060		4780	4530
006	MILHO	8545	10376	8545	7852	7852	7645
023	MILHO DOCE	6673	8103	6673	6132	6132	5971
202	MIRTILO				5123	5123	4989
204	MORANGO *	7737	9395	7737	7110	7110	6923
276	MOSTARDA	2900	3150	2600			2300
277	NABIÇA	1000	1100	900	850	850	800
233	NABO	1941	2356	1941	1783	1783	1736
119	NÊSPERA				6780	6780	6420
112	NOZ				7356	7356	7162
083	OLIVAL CONSERVA *				3950	3950	3750
083	OLIVAL INTENSIVO				3347	3347	3259
083	OLIVAL SEBE				3950	3950	3750
083	OLIVAL TRADICIONAL				1662	1662	1619
117	OUTROS PEQUENOS FRUTOS				5123	5123	4989
234	PEPINO *	6560	7030	5790	5470	5470	5180
093	PERA				6860	6860	6500
094	PÊSSEGO				6980	6980	6610
313	PHYSALIS				5340	5340	5060
078	PIMENTO	6594	8007	6594	6060	6060	5900
134	PISTACIOS				4199	4199	4089
312	PITAIA	1340	1430	1180	1110	1110	1060

ZONA 7 - CENÁRIO B - ANO SECO - m3/hectare					
Dotação. Aspersão	Dotação Canhão	Dotação Pivot	Dotação Micro-Asp	Dotação Gota-a-Gota	Dotação Subterr
			5720	5720	5420
5198	6312	5198		4776	4651
5831	7080	5831		5358	5217
6610	7080	5830		5510	5220
9369	11377	9369	8609	8609	8383
7317	8885	7317	6724	6724	6547
			5618	5618	5470
8484	10302	8484	7796	7796	7591
3300	3550	2900			2600
1150	1200	1000	950	950	900
2111	2564	2111	1940	1940	1889
			7810	7810	7400
			8066	8066	7853
			4450	4450	4250
			3642	3642	3546
			4450	4450	4250
			1823	1823	1775
			5618	5618	5470
7560	8100	6670	6300	6300	5970
			7910	7910	7490
			8040	8040	7620
			6150	6150	5830
7231	8780	7231	6644	6644	6469
			4605	4605	4483
1540	1650	1360	1280	1280	1220

CÓD CULTURA	DESCRIÇÃO CULTURA	ZONA 7 - CENÁRIO A - ANO MÉDIO - m3/hectare						ZONA 7 - CENÁRIO B - ANO SECO - m3/hectare					
		Dotação. Aspersão	Dotação Canhão	Dotação Pivot	Dotação Micro-Asp	Dotação Gota-a-Gota	Dotação 1Subterr	Dotação. Aspersão	Dotação Canhão	Dotação Pivot	Dotação Micro-Asp	Dotação Gota-a-Gota	Dotação 1Subterr
081	PLANTAS AROM., MEDICINAIS E CONDIMENTARES	8867		8867	8148	8148	7934	9647		9647	8865	8865	8632
142	PRADOS TEMPORÁRIOS	8577	10414	8577			7674	9404	11419	9404			8414
236	RABANETE	1941	2356	1941	1783	1783	1736	2111	2564	2111	1940	1940	1889
237	RÁBANO	1941	2356	1941	1783	1783	1736	2111	2564	2111	1940	1940	1889
209	ROMÃ				6019	6019	5861				6549	6549	6377
279	RÚCULA *	2580	2580	2408	2258	2258	2124	2867	2867	2676	2508	2508	2360
238	RUTABAGA	2070	2220	1830	1720	1720	1630	2340	2510	2070	1950	1950	1850
223	SABUGUEIRO (BAGA)				4970	4970	4710				5720	5720	5420
287	SERRADELA	2160	2320	1910	1800	1800	1710	2450	2620	2160	2040	2040	1930
018	SOJA	7508	9117	7508	6899	6899	6717	8232	9996	8232	7565	7565	7366
008	SORGO	6925	8408	6925	6363	6363	6196	7593	9220	7593	6977	6977	6793
042	TABACO *	5091	6182	5091	4678	4678	4555	5569	6763	5569	5118	5118	4983
261	TANGERA	7210	7730	6370	6010	6010	5700	8310	8900	7330	6930	6930	6560
155	TANGERINA	7210	7730	6370	6010	6010	5700	8310	8900	7330	6930	6930	6560
033	TOMATE *					6825	6645					7483	7286
240	TREMOCILHA	2160	2320	1910			1710	2450	2620	2160			1930
047	TREMOÇO	2523	3064	2523		2319	2258	2745	3334	2745		2523	2456
046	TREVO	4660	4990	4110			3670	5260	5640	4640			4160
001	TRIGO	3600	3850	3150			2850	4050	4350	3600			3200
007	TRITICALE	3070	3290	2710			2420	3470	3720	3060			2740
034	VINH P/ VINHO				2553	2553	2486				2778	2778	2705
034	VINHA P/ MESA				5438	5438	5295				5932	5932	5776

*Valores calculados com base nas normais climatológicas (1971-2000).
Restantes valores calculados com base nas normais climatológicas (1991-2020).

Anexo 6 – Resultados das reclassificações utilizando os índices NDVI e NDWI

Em seguida, propôs-se a reclassificação das áreas de "citrinos" usando o NDVI, com o primeiro quartil como valor mínimo (0,33) e o valor máximo definido como 1, conforme mostrado na Figura 1. Esta reclassificação foi comparada com a classificação manual para verificar se as áreas identificadas manualmente como citrinos foram corretamente incluídas na reclassificação com o valor limiar proposto.



Figura 1 - Resultado da reclassificação NDVI de 0.33 até 1 referente aos Citrinos. Onde áreas que são regadas estão em verde (76,83%), e áreas não regadas em vermelho "falso negativo" (23,17%).

Com a reclassificação das áreas de "citrinos" usando o NDVI, com valores de 0,33 (primeiro quartil) a 1. Encontrou-se que 76,83% das áreas (845,65 ha) foram classificadas como regadas, enquanto 23,17% (255,04 ha) foram identificadas como não regadas ("falsos negativos"), totalizando 1.100,69 ha. Já com o índice NDWI, usando valores de -0,04 (primeiro quartil) a 0,49 (valor máximo) conforme Figura 2.



Figura 2 - Resultado da reclassificação NDWI de -0.04 até 0.49 referente aos Citrinos. Onde áreas que são regadas estão em verde (78,77%), e áreas não regadas em vermelho "falso negativo" (21,23%)

Usando o índice NDWI com valores de -0,04 (primeiro quartil) a 0,49 (valor máximo), obteve-se que 78,77% das áreas (863,68 ha) foram classificadas como regadas, enquanto 21,23% (232,78 ha) foram identificadas como não regadas ("falsos negativos"), totalizando 1.096,46 ha.

Com base nos resultados da comparação entre a reclassificação dos valores limiares propostos para o NDVI e o NDWI nos citrinos, o índice NDWI apresentou a melhor classificação das áreas regadas, com 78,77% (863,68 ha), em comparação com 76,83% (845,65 ha) do NDVI, uma diferença pequena de 1,94%. Reclassificou-se o tipo de solo "abacateiros" usando o índice NDVI, com valores de 0,26 (primeiro quartil) a 1 (máximo), conforme Figura 3. A reclassificação mostrou que 86,90% das áreas (59,63 ha) foram identificadas como regadas, e 13,10% (8,99 ha) como não regadas ("falsos negativos"), totalizando 68,62 ha.



Figura 3 - Resultado da reclassificação NDVI de 0.26 até 1 referente aos Abacateiros. Onde áreas que são regadas estão em verde (86,90%), e áreas não regadas "falso positivo" em vermelho (13,10%).

Para o índice NDWI, utilizou-se o intervalo de -0,06 (primeiro quartil) a 0,49 (máximo), conforme Figura 4. Com esta reclassificação, 86,83% das áreas (59,40 ha) foram classificadas como regadas, enquanto 13,17% (9,01 ha) foram identificadas como não regadas ("falsos negativos"), totalizando 68,41 ha.



Figura 4 - Resultado da reclassificação NDWI de -0.06 até 0.49 referente aos Abacateiros. Onde áreas que são regadas estão em verde (86,83%), e áreas não regadas em vermelho "falso negativo" (13,17%).

Com base nos resultados obtidos da comparação entre a reclassificação dos valores limiares propostos para o NDVI e o NDWI nos abacateiros, o índice que apresentou a melhor classificação das áreas regadas foi o NDVI, com 86,90% (59,63 ha), em comparação com 86,83% (59,40 ha) do NDWI, uma diferença mínima de 0,23%.

Para a reclassificação do solo hortícola, usou-se o índice NDVI com valores de 0,20 (mínimo) a 1 (máximo), como mostrado na Figura 5. A reclassificação revelou que 69,67% das áreas (58,84 ha) foram identificadas como regadas, enquanto 30,33% (25,61 ha) foram classificadas como não regadas ("falsos negativos"), totalizando 84,44 ha.



Figura 5 - Resultado da reclassificação NDVI de 0.20 até 1 referente as Hortícolas. Onde áreas que são regadas estão em verde (69,67%), e áreas não regadas "falso positivo" em vermelho (30,33%).

Propôs-se a reclassificação do solo hortícola com o índice NDWI, usando valores de -0,10 (mínimo) a 0,49 (máximo), como mostrado na Figura 6. A reclassificação revelou que 73,52% das áreas (63,41 ha) foram classificadas como regadas, enquanto 26,48% (22,84 ha) foram identificadas como não regadas ("falsos negativos"), totalizando 86,25 ha de hortícolas.



Figura 6 - Resultado da reclassificação NDWI de -0.10 até 0.49 referente as hortícolas. Onde áreas que são regadas estão em verde (73,52%), e áreas não regadas em vermelho “falso negativo” (26,48%).

Com base nos resultados obtidos da comparação entre a reclassificação dos valores limiares propostos para o NDVI e o NDWI nas hortícolas, o índice que apresentou a melhor classificação das áreas regadas foi o NDWI, com 73,52% (63,41 ha), em comparação com 69,67% (58,84 ha) do NDVI, uma diferença de 3,85%.

Anexo 7 – Resultados da contagem de píxeis para cada tipo de cultura

Tabela 1 - Classificação NDVI das áreas bem regadas e não regadas (falso negativo) - período seco de 2021

Tipo de Ocupação	Limiar Mín.	Limiar Máx.	Bem Classificado (regado) hectare	%	Não Classificado (não regado - falso negativo) hectare	%	Total hectare
Abacateiro	0,26	1,00	59,63	86,90%	8,99	13,10%	68,62
<i>Casa e Jardim</i>	0,34	1,00	58,53	80,69%	14,00	19,31%	72,54
Citrinos	0,33	1,00	845,90	76,85%	254,79	23,15%	1100,69
Golfe	0,61	1,00	203,89	62,18%	124,02	37,82%	327,92
Hortícolas	0,20	1,00	58,84	69,67%	25,61	30,33%	84,44
<i>Palmeiras</i>	0,54	1,00	2,39	51,99%	2,20	48,01%	4,59
<i>Pastagem</i>	0,27	1,00	1,93	11,55%	14,79	88,45%	16,73
<i>Relva</i>	0,53	1,00	2,37	85,47%	0,40	14,53%	2,77
<i>Vinha</i>	0,28	1,00	0,18	51,16%	0,17	48,84%	0,35
<i>Viveiros</i>	0,63	1,00	11,30	59,21%	7,79	40,79%	19,09
Geral	0.20-1	1,00	1597,78	90,20%	173,64	9,80%	1771,42
Geral	0.30-1	1,00	1412,65	79,75%	358,77	20,25%	1771,42
Geral	0.40-1	1,00	1149,97	64,92%	621,45	35,08%	1771,42

Tabela 2 - Classificação NDWI das áreas bem regadas e não regadas (falso negativo) - período seco de 2021

Tipo de Ocupação	Limiar Mín.	Limiar Máx.	Bem Classificado (regado) hectare	%	Não Classificado (não regado - falso negativo) hectare	%	Total hectare
Abacateiro	-0,06	0,49	59,40	86,83%	9,01	13,17%	68,41
<i>Casa e Jardim</i>	-0,01	0,49					
Citrinos	-0,04	0,49	845,65	76,83%	255,04	23,17%	1100,69
Golfe	0,15	0,49	250,69	76,42%	77,37	23,58%	328,06
Hortícolas	-0,10	0,49	63,41	73,52%	22,84	26,48%	86,25
<i>Palmeiras</i>	0,16	0,49					
<i>Pastagem</i>	-0,08	0,49					
<i>Relva</i>	0,09	0,49					
<i>Vinha</i>	-0,09	0,49					
<i>Viveiros</i>	0,16	0,49					
Geral	0,15	0,49	1193,53	67,24%	581,46	32,76%	1774,99

NOTA: Apenas calculado para os principais tipos de ocupação do Solo (Abacateiros, Campos de Golfe, Citrinos e Hortícolas) e totalidade

Tabela 3 - Classificação SAVI das áreas bem regadas e não regadas (falso negativo) - período seco de 2021

Típo de Ocupação	Limiar Mín.	Limiar Máx.	Bem Classificado (regado) hectare	%	Não Classificado (não regado - falso negativo) hectare	%	Total hectare
Abacateiro	0,40	1,50	59,63	86,90%	8,99	13,10%	68,62
<i>Casa e Jardim</i>	0,50	1,50	58,53	80,69%	14,00	19,31%	72,54
Citrinos	0,50	1,50	840,19	76,36%	260,15	23,64%	1100,33
Golfe	0,91	1,50	203,89	62,18%	124,02	37,82%	327,92
Hortícolas	0,31	1,50	58,84	69,67%	25,61	30,33%	84,44
<i>Palmeiras</i>	0,80	1,50	2,39	51,99%	2,20	48,01%	4,59
<i>Pastagem</i>	0,41	1,50	1,84	10,93%	14,98	89,07%	16,82
<i>Relva</i>	0,80	1,50	2,30	85,05%	0,40	14,95%	2,70
<i>Vinha</i>	0,42	1,50	0,19	49,12%	0,19	50,88%	0,38
<i>Viveiros</i>	0,95	1,50	11,28	59,45%	7,69	40,55%	18,97
Geral	0.40-1.5	1,50	1481,20	83,62%	290,22	16,38%	1771,42
Geral	0.50-1.5	1,50	1335,32	75,38%	436,10	24,62%	1771,42
Geral	0.60-1.5	1,50	1149,84	64,91%	621,58	35,09%	1771,42

Anexo 8 – Resultados de classificações para o método *Fuzzy*

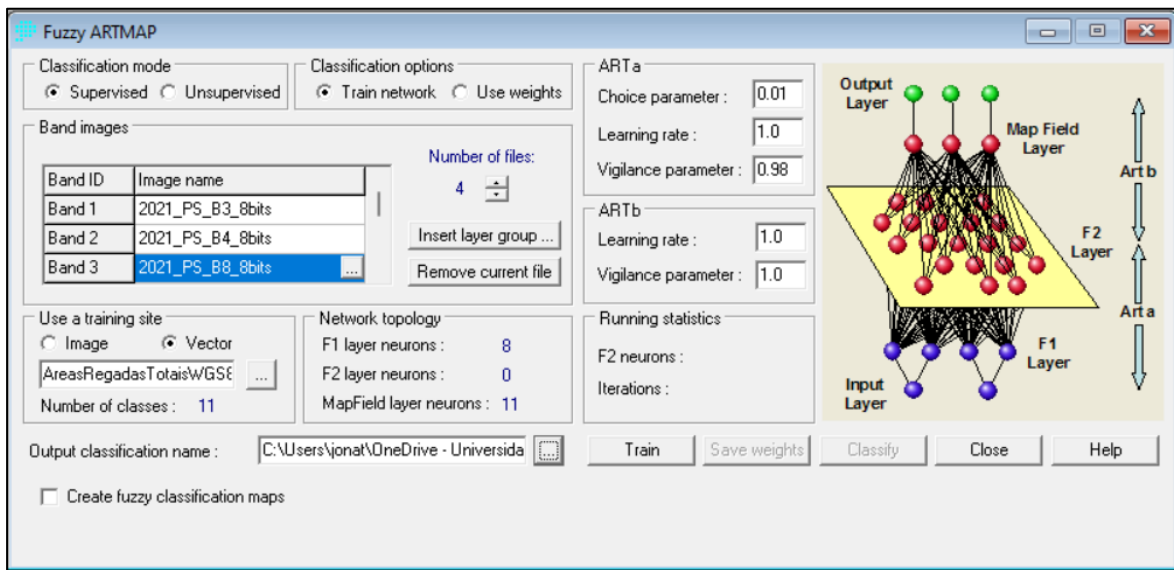


Figura 1 - Configuração dos dados para classificação *Fuzzy* para 2021

Diante dos resultados insatisfatórios da classificação inicial, foi proposta uma reclassificação das áreas de treino focando exclusivamente nas áreas regadas com maior extensão de hectares no aquífero Campina de Faro, conforme identificado na classificação manual. As classes selecionadas para este ajuste foram os campos de golfe e os citrinos, que representam as maiores áreas de cultivo irrigado.

Para isolar essas classes de interesse, foi utilizada a ferramenta "*Reclass*" do IDRISI, aplicada especificamente às classes 1 e 5, que representam, respectivamente, os campos de golfe e os citrinos. O processo de reclassificação atribuiu o valor "um" aos intervalos de 0 a 0, 2 a 4, e de 6 a 12, enquanto os valores "dois" e "três" foram atribuídos às classes 1 e 5, respectivamente. Essa operação resultou numa imagem binária que destacava exclusivamente as áreas de campos de golfe e citrinos, proporcionando uma nova base de treino para a classificação.

Com essa nova configuração, o método *Fuzzy Artmap* foi novamente aplicado, utilizando a imagem reclassificada como área de treino para realizar a classificação automática. A expectativa era de que a concentração do treino das duas classes dominantes (campos de golfe e citrinos) pudesse minimizar a confusão entre classes e melhorar a precisão do algoritmo.

No entanto, mesmo após a reclassificação e a aplicação da nova área de treino, os resultados permaneceram aquém do esperado. A análise indicou que o algoritmo continuou a apresentar dificuldades em diferenciar de forma eficaz as áreas regadas de campos de golfe e citrinos das demais classes, resultando novamente numa baixa taxa de precisão. A confusão entre as classes persistiu, sugerindo que outros fatores, como a complexidade espectral das áreas

de cultivo ou limitações intrínsecas do modelo, poderiam estar influenciando negativamente os resultados.

Esses resultados indicam que, apesar das tentativas de refinamento das áreas de treino e dos parâmetros utilizados, a abordagem atual com o método *Fuzzy Artmap* não foi suficiente para alcançar uma classificação precisa das áreas de interesse.




Figura 2 - Classificação *Fuzzy Artmap* NDVI 0.20 exclusivo campos de golfe (limites amarelo) e citrinos (limites branco) do Aquífero Campina de Faro

Após a classificação realizada com o *Fuzzy Artmap*, observou-se que a maior parte das áreas de campos de golfe (delimitadas por limites amarelos) foi corretamente identificada. No entanto, as áreas de citrinos não foram classificadas de acordo com os limites definidos pelos polígonos brancos (Figura 2).

Diante da persistência de resultados insatisfatórios nas tentativas anteriores de classificação, foi proposta uma nova reclassificação das áreas de treino, desta vez considerando um conjunto reduzido de nove classes. As classes selecionadas foram: abacateiros, citrinos, campos de golfe, casa e jardim, hortícolas, palmeiras, relvas, vinhas e viveiros. As classes “área urbana,” “pastagem,” e “estufas” foram removidas do conjunto de treino, com o intuito de simplificar o modelo e focar em tipos de ocupação do solo com maior homogeneidade espectral e relevância para o estudo das áreas de cultivo regado.

Esta reclassificação teve como objetivo reduzir a complexidade do problema, eliminando classes que poderiam estar introduzindo ruído e dificultando a discriminação correta pelo algoritmo *Fuzzy Artmap*. A hipótese subjacente a essa abordagem era que a remoção das classes menos representativas ou com características espectrais mais ambíguas permitiria ao classificador concentrar-se nas áreas de maior interesse agrícola, melhorando, assim, a precisão e a confiabilidade dos resultados.

Com a nova configuração das áreas de treino, o método *Fuzzy Artmap* foi reaplicado para a classificação automática das imagens. A expectativa era de que, com a redução das

classes e o refinamento das áreas de interesse, o algoritmo poderia alcançar uma melhor diferenciação entre os tipos de uso do solo, minimizando erros de classificação e aumentando a precisão na detecção das áreas regadas.




Figura 3 - Classificação Fuzzy com 9 classes (abacateiros, citrinos, campos de golfe, casa e jardim, hortícolas, palmeiras, relvas, vinhas e viveiros)

No entanto, após a nova classificação com o conjunto ajustado de nove classes, os resultados continuaram a apresentar inconsistências (Figura 3). Os resultados da nova classificação com nove classes utilizando o método *Fuzzy Artmap* não atingiram o desempenho esperado. Observou-se que a classe citrinos representada em verde, em particular, apresentou um número significativo de áreas classificadas como falsos positivos. Esses falsos positivos ocorreram quando regiões foram erroneamente identificadas como pertencentes à classe citrinos (verde), mas que, na realidade, estavam fora dos polígonos que foram classificados manualmente (polígonos brancos).

Essa discrepância indica que o algoritmo *Fuzzy Artmap*, mesmo com a redução para nove classes, continuou a apresentar limitações na sua capacidade de discriminar corretamente entre as diferentes classes de uso do solo. A ocorrência de falsos positivos em áreas fora dos polígonos de referência manual sugere que o modelo pode estar superestimando a presença de determinadas classes, especialmente em regiões onde a variação espectral é ambígua ou onde características espectrais sobrepostas tornam difícil a distinção precisa.

A elevada taxa de falsos positivos na classe verde evidencia a necessidade de uma abordagem mais sofisticada ou de um modelo alternativo que consiga distinguir de forma mais precisa as sutis diferenças espectrais entre áreas de cultivo e outras formas de ocupação do solo. Esses resultados indicam que, mesmo após a redução do número de classes e os esforços para refinar o conjunto de treino, o método *Fuzzy Artmap* enfrentou dificuldades em lidar com a diversidade espectral presente nas áreas de cultivo irrigado.

Para melhorar os resultados das classificações anteriores e tentar corrigir a presença de

falsos positivos, foi utilizada a ferramenta "*FILTER*" pela mediana com uma janela de 7x7 no software IDRISI conforme Figuras 4 e 5. Este filtro foi aplicado com o objetivo de suavizar a imagem e reduzir o ruído sem modificar significativamente os valores originais dos *pixels*. O filtro funciona substituindo o valor de cada célula pela mediana dos valores de suas células vizinhas dentro de uma janela de tamanho especificado (por exemplo, 3x3, 5x5, 7x7), buscando refinar a imagem *raster* e facilitar a conversão posterior para vetor.




Figura 4 - Aplicação do Filter pela Mediana com tamanho 7x7 das classes campos de golfe e citrinos




Figura 5 - Vetor resultando da aplicação do Filter pela Mediana com tamanho 7x7 aplicando zoom na classe campos de golfe com imagem NDVI Sentinel-2

Apesar desta abordagem, que visava reduzir o ruído e melhorar a definição das classes de uso do solo, os resultados não alcançaram o êxito esperado. A aplicação do filtro pela

mediana não conseguiu corrigir suficientemente os problemas de classificação, mantendo-se os erros anteriores, como a presença de falsos positivos em áreas que, de acordo com a análise do NDVI do Sentinel-2, não deveriam ser classificadas como regadas.

A tentativa de suavizar os dados *raster*, ainda que tenha contribuído para uma redução marginal de ruídos na imagem, não solucionou os desafios principais enfrentados na discriminação precisa entre as classes de uso do solo no aquífero Campina de Faro.

Para enfrentar as dificuldades observadas nos resultados de classificação, propôs-se a redução das classes de análise para quatro principais categorias: abacateiros, campos de golfe, citrinos e hortícolas, que representam as maiores áreas regadas em hectares no aquífero Campina de Faro. Adicionalmente, foram incluídas duas novas classes: áreas fora do aquífero Campina de Faro e áreas com valores de NDVI abaixo de 0,20 dentro do aquífero. Com base nessa reestruturação, uma nova área de treino foi criada, excluindo elementos irrelevantes como estradas de terra e construções, para refinar os polígonos e focar apenas nas áreas efetivamente regadas.

Além desse refinamento, um novo *script* foi desenvolvido no *Google Earth Engine* para gerar uma imagem RGB utilizando a banda B2 do Sentinel-2, resultando em uma combinação de bandas B2, B4 e B8, todas com resolução de 10 metros. A imagem gerada foi processada no QGIS, onde apenas a banda 2 foi extraída, convertida para o formato de 8 bits e recortada com base na máscara do NDVI acima de 0,20. O objetivo desta etapa adicional foi avaliar se a inclusão da banda B2 na classificação futura com o método *Fuzzy Artmap* poderia aprimorar a distinção entre as classes e aumentar a precisão dos resultados.

A Após a aplicação da nova classificação com os parâmetros ajustados, os resultados obtidos foram os mais promissores, em comparação com as tentativas anteriores.

Na imagem resultante (Figura 6), os abacateiros são destacados em amarelo, os campos de golfe em vermelho, os citrinos em verde e as hortícolas em azul. Os polígonos em branco representam a classificação manual de 2021 das áreas regadas.




Figura 6 - Classificação Fuzzy Artmap NDVI 0,20 com as bandas B2, B3, B4 e B8 do Sentinel-2 das classes Abacateiros, Campos de Golfe, Citrinos, Hortícolas, áreas fora do aquífero e áreas com valores de NDVI abaixo de 0,20 dentro do aquífero Campina de Faro

No entanto, a análise dos resultados evidenciou que a classificação dos citrinos foi a principal fonte de erros. O algoritmo erroneamente classificou várias florestas e outras áreas não regadas como áreas de citrinos, resultando em um número considerável de falsos positivos. Essa imprecisão sugere que, apesar das melhorias alcançadas com a nova configuração, a diferenciação entre citrinos e outras classes, especialmente vegetação não regada como florestas, ainda representa um desafio significativo.

Diante desses resultados, decidiu-se não quantificar a quantidade de *pixels* corretamente classificados em relação à classificação manual de 2021, uma vez que a presença de falsos positivos, especialmente na classe de citrinos, compromete a confiabilidade da avaliação quantitativa de precisão.

Diante dos resultados anteriores e visando aprimorar a classificação automática, foi proposta a criação de quatro novas classes no vetor de treino: zonas urbanas, florestas, sapal e salinas. Essas novas categorias foram adicionadas para abordar especificamente os tipos de cobertura do solo que apresentaram confusão significativa nas classificações anteriores, totalizando assim 10 classes no conjunto de treino: abacateiros, campos de golfe, citrinos, hortícolas, zonas urbanas, florestas, sapal, salinas, áreas fora do aquífero e áreas com valores de NDVI abaixo de 0,20 dentro do aquífero Campina de Faro.

Esta abordagem buscou aprimorar o modelo *Fuzzy Artmap* para distinguir com maior precisão entre classes de uso do solo, corrigindo erros anteriores, como florestas confundidas com citrinos. A adição de novas classes visou aumentar a precisão da classificação, reduzindo falsos positivos e oferecendo um mapa mais representativo.

Após a nova classificação com o método *Fuzzy Artmap*, utilizando um conjunto de treino expandido, obteve-se os seguintes resultados (Figura 7).




Figura 7 - Classificação Fuzzy Artmap NDVI 0.20 com as bandas B2, B3, B4 e B8 do Sentinel-2 das classes Abacateiros, Campos de Golfe, Citrinos, Hortícolas, Zonas Urbanas, Florestas, Sapal, Salinas, áreas fora do aquífero e áreas com valores de NDVI abaixo de 0,20 dentro do aquífero Campina de Faro

Verificou-se uma melhora nos resultados em comparação com as tentativas anteriores. Parte das áreas anteriormente classificadas como citrinos foram corretamente classificadas nas novas classes propostas, como zonas urbanas, florestas, sapal e salinas, o que indica uma redução na confusão entre as categorias.

No entanto, apesar dessa melhoria, ainda é possível identificar visualmente a presença significativa de falsos positivos na classe de citrinos. Muitas áreas continuam sendo erroneamente classificadas como citrinos, mesmo não sendo áreas de cultivo irrigado. Essa persistência de erros de classificação sugere que, embora o modelo tenha se beneficiado da inclusão das novas classes, ele ainda enfrenta dificuldades em distinguir com precisão entre citrinos e outras coberturas do solo que compartilham características espectrais semelhantes.

Os resultados revelam que, apesar dos progressos realizados, ainda são necessários ajustes adicionais para reduzir a ocorrência de falsos positivos e melhorar a precisão global do modelo. Para aumentar a exatidão da classificação e distinguir melhor entre as diversas culturas, propôs-se a criação de novos polígonos para cada classe, ampliando as áreas de treino. Foram também incluídas duas novas classes: solo e estufas, com o objetivo de representar de forma mais fiel as variações na cobertura do solo e diminuir a confusão entre categorias na classificação automática. Esta abordagem visou captar com maior detalhe as características espectrais específicas de cada tipo de uso do solo, especialmente em áreas onde as classes anteriores geravam falsos positivos, como os citrinos. Após a execução da nova classificação, com os ajustes efetuados, os resultados são apresentados na Figura 8.




Figura 8 - Classificação Fuzzy Artmap NDVI 0,20 com as bandas B2, B3, B4 e B8 do Sentinel-2 das 12 classes Abacateiros, Campos de Golfe, Citrinos, Hortícolas, Zonas Urbanas, Florestas, Sapal, Salinas, solo, estufas, , áreas fora do aquífero e áreas com valores de NDVI abaixo de 0,20 dentro do aquífero Campina de Faro

Após a nova classificação, observou-se que muitos campos de golfe foram incorretamente reclassificados como citrinos, destacando uma distorção espectral significativa entre estas duas categorias. Além disso, a presença de falsos positivos para citrinos ainda era alta, indicando que o modelo continua a ter dificuldades em diferenciá-los com precisão

Para melhorar a precisão, propôs-se uma reestruturação das classes, agrupando zonas urbanas, estufas, áreas fora do aquífero e sapais em uma nova classe denominada "artificial." Esta abordagem visa simplificar a diferenciação espectral e tornar a classificação mais robusta. As classes agora são: abacateiros, campos de golfe, citrinos, hortícolas, florestas, solo e artificial.

Foi realizada uma nova classificação com essas categorias ajustadas para avaliar se o novo agrupamento reduz os erros de classificação, especialmente a confusão entre campos de golfe e citrinos (Figura 9).




Figura 9 - Classificação Fuzzy Artmap NDVI 0,20 com as bandas B2, B3, B4 e B8 do Sentinel-2 das classes Abacateiros, Campos de Golfe, Citrinos, Hortícolas, Florestas, Solo, Artificial e áreas com valores de NDVI abaixo de 0,20 dentro do aquífero Campina de Faro

Após a nova classificação, observou-se uma melhoria marginal nos resultados, mas a

precisão ainda não atingiu o nível desejado. Apesar das alterações nas classes, os campos de golfe continuam a ser classificados erroneamente, não apenas em suas áreas reais, mas também em regiões destinadas a hortícolas e citrinos. Além disso, a classe de citrinos ainda exhibe falsos positivos em áreas não destinadas ao cultivo irrigado.

Verificou-se também que as hortícolas foram corretamente classificadas em poucas áreas, mostrando que o modelo ainda enfrenta dificuldades significativas para distinguir esta categoria. Por outro lado, a classe dos abacateiros apresentou resultados satisfatórios, sendo bem delimitada em relação às suas áreas de cultivo.

Estes resultados indicam que, embora alguns avanços tenham sido alcançados, a classificação automática ainda não reflete com precisão as áreas de treino propostas. Persistem problemas de confusão entre as classes, especialmente em áreas com características espectrais semelhantes, sugerindo a necessidade de mais ajustes no modelo ou na definição das áreas de treino para alcançar uma classificação mais precisa e confiável.

Dado que as classificações anteriores não atingiram os resultados esperados, propôs-se uma nova abordagem que inclui, além das bandas espectrais B2, B3, B4 e B8, o uso do NDVI com "*Stretch*". O principal objetivo da aplicação do "*Stretch*" é ajustar a distribuição dos valores de *pixel* da imagem para melhorar a visualização dos dados e realçar características específicas, aumentando potencialmente a eficácia da classificação.

Foi ainda adicionado um novo vetor ajustado, com um acréscimo de áreas de treino para as classes de interesse: campos de golfe, citrinos, hortícolas, abacateiros, urbano, água, florestas, areia, caminhos e solo. Essa reconfiguração visa aumentar a representatividade das classes durante a classificação.

Nesta nova análise, opta-se por focar exclusivamente nas áreas regadas — campos de golfe, citrinos, hortícolas e abacateiros — com base na classificação manual de 2021, que serve como referência. Em vez de abarcar toda a área do aquífero Campina de Faro, a análise será concentrada nas categorias de maior interesse, permitindo uma avaliação mais rigorosa, especialmente nas zonas de citrinos, que foram mais problemáticas nas classificações anteriores (Figura 10).

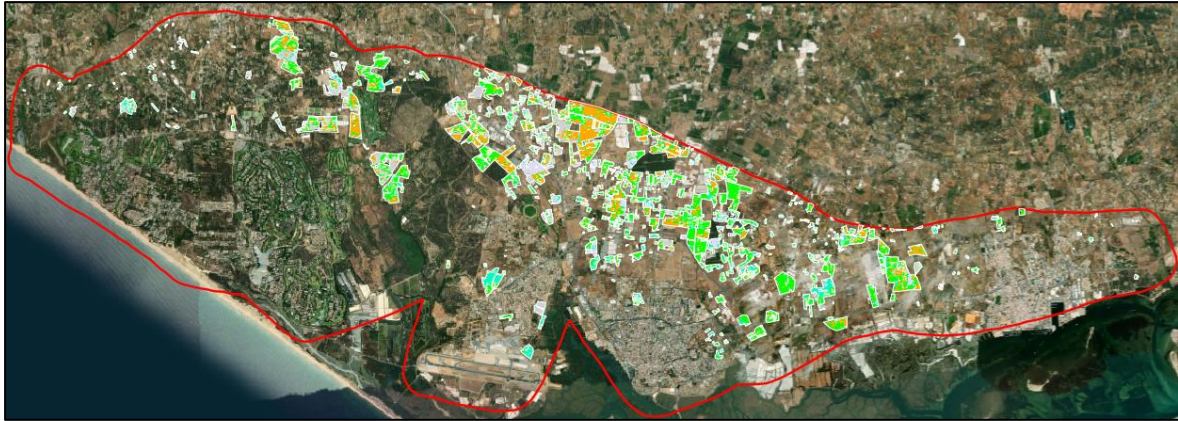


Figura 10 - Classificação Fuzzy dos citrinos (cor laranja) para 2021 período seco

Após a nova classificação focada nas áreas de citrinos, observou-se que apenas 171,35 hectares foram corretamente identificados como citrinos, o que corresponde a apenas 16% da área total de 1.097,28 hectares de citrinos. Este resultado demonstra uma baixa eficácia na identificação correta da classe, evidenciando a presença significativa de falsos negativos, onde áreas de citrinos não foram reconhecidas adequadamente.

Anexo 9 – Resultados com a ferramenta SIGCOMP

Para a análise realizada, optou-se por utilizar inicialmente o *SIGCOMP* para calcular os valores médios dos pixels das várias bandas espectrais, incluindo B2, B3, B4, B8 e NDVI com "Stretch". Esta abordagem concentrou-se na avaliação dos valores médios como uma estratégia para identificar padrões e variações espectrais médias nas diferentes classes de uso do solo.

O uso dos valores médios dos pixels permitirá observar tendências gerais e detectar variações radiométricas entre as imagens, oferecendo insights iniciais sobre as características de cada classe de uso do solo. Este passo preliminar fornecerá uma base para análises mais detalhadas e ajudará na definição de critérios para classificações subsequentes. (Figura 1).




Figura 1 - Comparativo de valores da Média dos pixels por banda de todas as classes via SIGCOMP

A análise das assinaturas espectrais das diferentes classes de uso e cobertura do solo, utilizando as bandas B2, B3, B4, B8 e o NDVI *Stretch*, revelou padrões distintos que auxiliam na discriminação de superfícies terrestres. As classes vegetais, como hortícolas, abacateiros e florestas, apresentaram alta refletância na banda B8 (infravermelho próximo) e valores elevados de NDVI *Stretch*, evidenciando uma densa cobertura vegetal e boa saúde da vegetação. Em contraste, as classes como solo e áreas urbanas mostraram baixos valores nessas bandas, caracterizando áreas com pouca ou nenhuma cobertura vegetal.

A classe de água apresentou baixas respostas espectrais em todas as bandas, especialmente em B4 (vermelho) e B8, confirmando suas características de alta absorção e baixa refletância. Essas distinções espectrais são fundamentais para o mapeamento preciso do

uso do solo e para entender as dinâmicas ambientais observadas no estudo, melhorando a eficácia das classificações de cobertura e uso do solo.

Diante dos padrões observados nas assinaturas espectrais, é proposta uma nova análise focada nos *valores mínimos e máximos* dos *pixels* para cada classe de uso e cobertura do solo. Esta abordagem permitirá identificar a amplitude completa das variações espectrais dentro de cada classe, fornecendo uma compreensão mais detalhada da variabilidade interna.

A análise dos valores mínimos e máximos auxiliará na detecção de outliers e na identificação de possíveis sobreposições entre classes espectrais, garantindo que as assinaturas sejam suficientemente distintas para melhorar a precisão do mapeamento. Essa avaliação é crucial para refinar ainda mais o modelo de classificação e ajustar os critérios para distinguir com precisão cada classe de uso do solo (Figura 2).




Figura 2 - Comparativo de valores mínimo e máximo dos pixels por banda de todas as classes via SIGCOMP

A análise dos valores mínimos e máximos das assinaturas espectrais, obtidos com o SIGCOMP para as bandas B2, B3, B4, B8 e NDVI Stretch, revelou diferenças significativas entre as classes de uso e cobertura do solo. No entanto, observou-se que há confusões espectrais devido à interseção das faixas de valores mínimos e máximos entre as diferentes classes, dificultando a distinção clara entre elas. Idealmente, os valores mínimos e máximos de cada classe deveriam ser apresentados de forma isolada para cada tipo de ocupação, o que não ocorre nesta configuração.

As classes vegetais, como hortícolas, abacateiros e florestas, apresentaram valores

máximos elevados na banda B8 (infravermelho próximo) e no NDVI *Stretch*, indicativos de vegetação densa e saudável. Em contraste, as classes de solo e urbano exibiram valores significativamente mais baixos nessas bandas, refletindo superfícies predominantemente não vegetadas. A classe de água, por sua vez, apresentou valores consistentemente baixos em todas as bandas, confirmando sua característica de baixa refletância, típica de corpos d'água.

Estas diferenças nos extremos espectrais são fundamentais para melhorar a precisão na classificação, destacando a importância de ajustar as análises para evitar confusões entre classes e garantir uma separação clara das assinaturas espectrais.

Com base nas observações anteriores e visando aprimorar a distinção entre as classes de uso e cobertura do solo, propõe-se uma nova análise focada nos *valores médios, mínimos e máximos* apenas das classes de interesse que serão utilizadas na classificação. Esta abordagem permitirá uma compreensão mais detalhada das características espectrais de cada classe, minimizando confusões e sobreposições entre elas.

Ao focar exclusivamente nas classes de interesse, a análise buscará identificar com maior precisão os padrões espectrais únicos de cada categoria, incluindo suas variações internas e os limites espectrais que as separam. Esta análise mais refinada é essencial para melhorar a precisão do modelo de classificação, garantindo que cada classe de uso do solo seja representada de maneira clara e distinta, facilitando a identificação correta em futuros mapeamentos (Figura 3).




Figura 3 - Comparativo de valores médio, mínimo e máximo dos píxeis por banda das classes hortícolas, abacateiros, campos de golfe e citrinos via SIGCOMP

A comparação das assinaturas espectrais das classes hortícolas, abacateiros, campos de golfe e citrinos, utilizando as bandas B2, B3, B4, B8 e o NDVI *Stretch*, revelou padrões distintos que refletem as características específicas de cada tipo de vegetação através dos diferentes níveis radiométricos.

As classes de abacateiros e citrinos apresentaram comportamentos espectrais semelhantes, com baixa variabilidade nas bandas visíveis (B2, B3 e B4) e um aumento acentuado na banda B8 e no NDVI *Stretch*, sugerindo a presença de vegetação densa e homogênea. Em contraste, a classe hortícola demonstrou uma maior amplitude de variação nos valores máximos e mínimos, indicando uma diversidade interna na cobertura vegetal.

A classe de campos de golfe destacou-se pela sua curva espectral ascendente até a banda B8, refletindo a combinação característica de áreas vegetadas com solo exposto, comum nestes ambientes.

Para assegurar uma precisão nos resultados na classificação do uso e cobertura do solo foi essencial rever cuidadosamente os polígonos de treino de todas as classes. Este processo é particularmente crítico em áreas onde a presença de caminhos de terra ou outros elementos não vegetados possam influenciar os valores espectrais obtidos para classes consideradas como "regadas". Posterior à revisão dos polígonos de treino, foram criadas novas assinaturas espectrais para todas as classes (Área fora, campos de golfe, hortícolas, urbano, caminhos, abacateiros, água, citrinos, florestas, solo e areia).

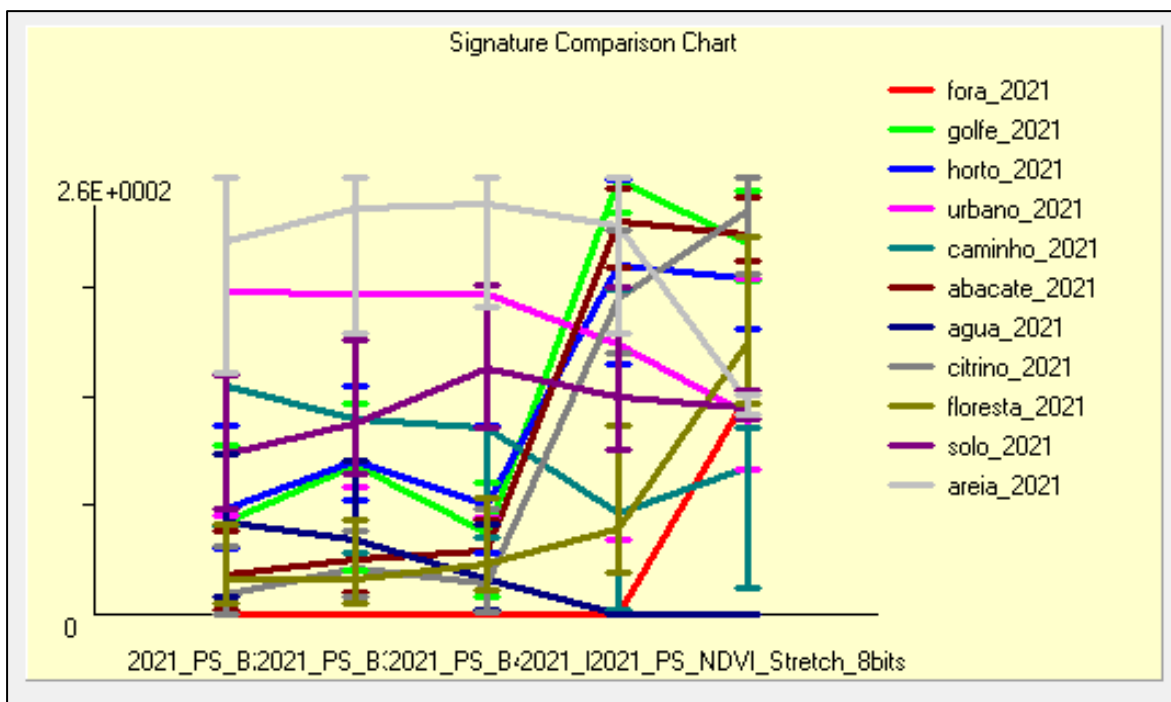


Figura 4 - Novo comparativo de valores médio, mínimo e máximo dos píxeis por banda das classes Área fora, campos de golfe, hortícolas, urbano, caminhos, abacateiros, água, citrinos, florestas, solo e areia via SIGCOMP

Considerando os valores médios, mínimos e máximos (Figura 4), observa-se que as assinaturas espectrais das classes hortícolas, abacateiros, campos de golfe e citrinos revelam padrões claros na reflectância das diferentes classes de vegetação. Nas bandas visíveis (B2, B3, B4), a variação é limitada, com valores médios indicando uma mistura entre vegetação e superfícies expostas. A banda B8 destaca-se pelos seus valores máximos elevados, particularmente em *horto* e *golfe*, o que indica vegetação densa e saudável. O NDVI *Stretch*, por sua vez, confirma essa tendência, com valores médios elevados que sugerem uma vegetação vigorosa, especialmente em áreas regadas como *horto*.

A análise dos valores médios, mínimos e máximos apenas das classes de interesse que será utilizado na classificação é apresentada na Figura 5.




Figura 5 - Novo comparativo de valores médio, mínimo e máximo dos píxeis por banda das classes hortícolas, abacateiros, campos de golfe e citrinos via SIGCOMP

As variações nos valores mínimos, máximos e médios observadas nas bandas visíveis permitem diferenciar de forma eficiente as classes, com *golfe* e *horto* a exibirem maior reflectância em B4, em contraste com *abacate* e *citrino*, que apresentam valores mais baixos. A banda B8, crucial para a separação das classes vegetadas, revela diferenças claras que podem ser exploradas pelos algoritmos de classificação para distinguir entre diferentes tipos de vegetação. Finalmente, o NDVI *Stretch* oferece uma discriminação adicional, destacando as áreas vegetadas com valores elevados, o que é crucial para uma categorização automática precisa e eficaz. No entanto, com base nos resultados obtidos, é provável que ocorram erros, devido às sobreposições das assinaturas espectrais, especialmente entre os campos de golfe e

hortícolas, e entre os abacateiros e citrinos.

**Anexo 10 – Total hectares classificados por cultura x método de classificação
(2017 a 2023)**

Tabela 1 - Total hectares classificados por cultura x método de classificação - Período Seco 2017

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
Fuzzy (ha) classificados	789,07	109,04	40,38	47,86	986,35
Fischer (ha) classificados	830,23	141,48	38,21	18,30	1028,22
Maxlike (ha) classificados	726,60	132,78	42,66	23,58	925,61
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
Fuzzy % classificados	71,91%	33,25%	59,03%	56,21%	
Fisher % classificados	75,66%	43,13%	55,86%	21,49%	
Maxlike % classificados	66,22%	40,48%	62,36%	27,70%	
Fuzzy % acerto	49,98%	6,91%	2,56%	3,03%	62,47%
Fischer % acerto	52,59%	8,96%	2,42%	1,16%	65,13%
Maxlike % acerto	46,02%	8,41%	2,70%	1,49%	58,63%

Tabela 2 - Total hectares classificados por cultura x método de classificação - Período Seco 2018

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
Fuzzy (ha) classificados	782,67	157,24	38,90	45,70	1024,52
Fischer (ha) classificados	736,76	162,95	38,67	22,53	960,92
Maxlike (ha) classificados	716,42	123,61	46,78	39,87	926,68
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
Fuzzy % classificados	71,33%	47,94%	56,88%	53,67%	
Fisher % classificados	67,14%	49,68%	56,54%	26,46%	
Maxlike % classificados	65,29%	37,69%	68,39%	46,82%	
Fuzzy % acerto	49,57%	9,96%	2,46%	2,89%	64,89%
Fischer % acerto	46,67%	10,32%	2,45%	1,43%	60,86%
Maxlike % acerto	45,38%	7,83%	2,96%	2,53%	58,69%

Tabela 3 - Total hectares classificados por cultura x método de classificação - Período Seco 2019

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
Fuzzy (ha) classificados	751,89	202,93	41,22	45,18	1041,22
Fischer (ha) classificados	838,25	184,52	42,08	16,49	1081,34
Maxlike (ha) classificados	734,43	223,14	43,60	32,94	1034,11

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
<i>Fuzzy % classificados</i>	68,52%	61,87%	60,27%	53,06%	
<i>Fisher % classificados</i>	76,39%	56,26%	61,53%	19,37%	
<i>Maxlike % classificados</i>	66,93%	68,03%	63,75%	38,69%	
<i>Fuzzy % acerto</i>	47,62%	12,85%	2,61%	2,86%	65,95%
<i>Fischer % acerto</i>	53,09%	11,69%	2,67%	1,04%	68,49%
<i>Maxlike % acerto</i>	46,52%	14,13%	2,76%	2,09%	65,50%

Tabela 4 - Total hectares classificados por cultura x método de classificação - Período Seco 2020

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
<i>Fuzzy (ha) classificados</i>	808,10	178,62	38,59	42,77	1068,08
<i>Fischer (ha) classificados</i>	768,13	152,94	42,11	25,01	988,19
<i>Maxlike (ha) classificados</i>	760,09	216,03	43,54	33,19	1052,85
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
<i>Fuzzy % classificados</i>	73,65%	54,46%	56,41%	50,23%	
<i>Fisher % classificados</i>	70,00%	46,63%	61,56%	29,37%	
<i>Maxlike % classificados</i>	69,27%	65,87%	63,66%	38,98%	
<i>Fuzzy % acerto</i>	51,18%	11,31%	2,44%	2,71%	67,65%
<i>Fischer % acerto</i>	48,65%	9,69%	2,67%	1,58%	62,59%
<i>Maxlike % acerto</i>	48,14%	13,68%	2,76%	2,10%	66,69%

Tabela 5 - Total hectares classificados por cultura x método de classificação - Período Seco 2022

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
<i>Fuzzy (ha) classificados</i>	661,87	168,36	41,38	50,82	922,43
<i>Fischer (ha) classificados</i>	628,03	152,10	44,78	36,95	861,86
<i>Maxlike (ha) classificados</i>	609,04	199,33	48,38	58,93	915,68
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
<i>Fuzzy % classificados</i>	60,32%	51,33%	60,50%	59,68%	
<i>Fisher % classificados</i>	57,24%	46,37%	65,46%	43,40%	
<i>Maxlike % classificados</i>	55,50%	60,77%	70,73%	69,21%	
<i>Fuzzy % acerto</i>	41,92%	10,66%	2,62%	3,22%	58,43%
<i>Fischer % acerto</i>	39,78%	9,63%	2,84%	2,34%	54,59%
<i>Maxlike % acerto</i>	38,58%	12,63%	3,06%	3,73%	58,00%

Tabela 6 - Total hectares classificados por cultura x método de classificação - Período Seco 2023

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
Fuzzy (ha) classificados	720,33	186,98	29,90	50,74	987,95
Fischer (ha) classificados	736,57	130,20	48,74	21,81	937,33
Maxlike (ha) classificados	580,21	207,70	51,91	39,33	879,14
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
Fuzzy % classificados	65,65%	57,01%	43,71%	59,59%	
Fisher % classificados	67,13%	39,70%	71,25%	25,62%	
Maxlike % classificados	52,88%	63,33%	75,89%	46,19%	
Fuzzy % acerto	45,62%	11,84%	1,89%	3,21%	62,58%
Fischer % acerto	46,65%	8,25%	3,09%	1,38%	59,37%
Maxlike % acerto	36,75%	13,16%	3,29%	2,49%	55,68%

Abaixo, apresenta-se a Tabela 7 com os melhores classificadores para cada cultura entre 2017 e 2023, incluindo os valores em hectares e as percentagens de acerto.

Tabela 7 - Melhores classificadores para cada cultura entre os anos de 2017 a 2023, incluindo os valores em hectares e percentagens de acerto

Ano	Cultura	Melhor Classificador	Hectares Classificados (ha)	% Acerto
2017	Citrinos	<i>Fischer</i>	830,23	52,59%
2017	Golfe	<i>Fischer</i>	141,48	11,69%
2017	Abacateiros	<i>Fuzzy</i>	40,38	2,56%
2017	Hortícolas	<i>Fuzzy</i>	47,86	3,03%
2018	Citrinos	<i>Fuzzy</i>	782,67	49,57%
2018	Golfe	<i>Fischer</i>	162,95	10,32%
2018	Abacateiros	<i>Maxlike</i>	46,78	2,96%
2018	Hortícolas	<i>Fuzzy</i>	45,7	2,89%
2019	Citrinos	<i>Fischer</i>	838,25	53,09%
2019	Golfe	<i>Maxlike</i>	223,14	14,13%
2019	Abacateiros	<i>Maxlike</i>	43,6	2,76%
2019	Hortícolas	<i>Fuzzy</i>	45,18	2,86%
2020	Citrinos	<i>Fuzzy</i>	808,1	51,18%
2020	Golfe	<i>Maxlike</i>	216,03	13,68%
2020	Abacateiros	<i>Maxlike</i>	43,54	2,76%
2020	Hortícolas	<i>Fuzzy</i>	42,77	2,71%
2021	Citrinos	<i>Fuzzy</i>	785,04	49,72%
2021	Golfe	<i>Maxlike</i>	187,37	11,87%
2021	Abacateiros	<i>Maxlike</i>	45,75	2,90%

Ano	Cultura	Melhor Classificador	Hectares Classificados (ha)	% Acerto
2021	Hortícolas	<i>Maxlike</i>	42,91	2,72%
2022	Citrinos	<i>Fuzzy</i>	661,87	41,92%
2022	Golfe	<i>Maxlike</i>	199,33	12,63%
2022	Abacateiros	<i>Maxlike</i>	48,38	3,06%
2022	Hortícolas	<i>Maxlike</i>	58,93	3,73%
2023	Citrinos	<i>Fischer</i>	736,57	46,65%
2023	Golfe	<i>Maxlike</i>	207,7	13,16%
2023	Abacateiros	<i>Maxlike</i>	51,91	3,29%
2023	Hortícolas	<i>Fuzzy</i>	50,74	3,21%

Anexo 11 – Total hectares classificados segmentados por cultura x método de classificação (2017 a 2023)

Tabela 1 - Total hectares classificados segmentados por cultura x método de classificação - Período Seco 2017

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
Fuzzy (ha) classificados Seg 10	912,54	114,29	39,29	51,94	1118,06
Fischer (ha) classificados Seg 10	879,83	170,64	39,02	13,93	1103,42
Maxlike (ha) classificados Seg 10	796,54	145,10	43,65	19,75	1005,05
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
Fuzzy % classificados Seg 10	83,16%	34,85%	57,45%	61,00%	
Fisher % classificados Seg 10	80,18%	52,03%	57,04%	16,36%	
Maxlike % classificados Seg 10	72,59%	44,24%	63,82%	23,20%	
Fuzzy % acerto Seg 10	57,80%	7,24%	2,49%	3,29%	70,82%
Fischer % acerto Seg 10	55,73%	10,81%	2,47%	0,88%	69,89%
Maxlike % acerto Seg 10	50,45%	9,19%	2,76%	1,25%	63,66%

Tabela 2 - Total hectares classificados segmentados por cultura x método de classificação - Período Seco 2018

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
Fuzzy (ha) classificados Seg 10	910,53	173,24	38,44	45,82	1168,03
Fischer (ha) classificados Seg 10	768,29	192,54	38,55	23,41	1022,78
Maxlike (ha) classificados Seg 10	769,00	126,78	47,54	38,90	982,22
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
Fuzzy % classificados Seg 10	82,98%	52,82%	56,20%	53,81%	
Fisher % classificados Seg 10	70,02%	58,70%	56,35%	27,49%	
Maxlike % classificados Seg 10	70,08%	38,65%	69,51%	45,69%	
Fuzzy % acerto Seg 10	57,67%	10,97%	2,43%	2,90%	73,98%
Fischer % acerto Seg 10	48,66%	12,20%	2,44%	1,48%	64,78%
Maxlike % acerto Seg 10	48,71%	8,03%	3,01%	2,46%	62,21%

Tabela 3 - Total hectares classificados segmentados por cultura x método de classificação - Período Seco 2019

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
Fuzzy (ha) classificados Seg 10	849,01	229,46	41,07	53,01	1172,55
Fischer (ha) classificados Seg 10	851,69	214,31	43,07	14,08	1123,15
Maxlike (ha) classificados Seg 10	763,52	241,98	44,34	33,22	1083,06
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
Fuzzy % classificados Seg 10	77,37%	69,96%	60,05%	62,26%	
Fisher % classificados Seg 10	77,62%	65,34%	62,97%	16,54%	
Maxlike % classificados Seg 10	69,58%	73,78%	64,82%	39,01%	
Fuzzy % acerto Seg 10	53,78%	14,53%	2,60%	3,36%	74,27%
Fischer % acerto Seg 10	53,94%	13,57%	2,73%	0,89%	71,14%
Maxlike % acerto Seg 10	48,36%	15,33%	2,81%	2,10%	68,60%

Tabela 4 - Total hectares classificados segmentados por cultura x método de classificação - Período Seco 2020

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
Fuzzy (ha) classificados Seg 10	927,51	195,86	43,60	43,51	1210,48
Fischer (ha) classificados Seg 10	787,92	181,54	43,60	20,11	1033,18
Maxlike (ha) classificados Seg 10	805,35	220,17	45,06	31,24	1101,82
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
Fuzzy % classificados Seg 10	84,53%	59,71%	63,75%	51,10%	
Fisher % classificados Seg 10	71,81%	55,35%	63,75%	23,62%	
Maxlike % classificados Seg 10	73,39%	67,13%	65,88%	36,68%	
Fuzzy % acerto Seg 10	58,75%	12,41%	2,76%	2,76%	76,67%
Fischer % acerto Seg 10	49,91%	11,50%	2,76%	1,27%	65,44%
Maxlike % acerto Seg 10	51,01%	13,95%	2,85%	1,98%	69,79%

Tabela 5 - Total hectares classificados segmentados por cultura x método de classificação - Período Seco 2022

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
Fuzzy (ha) classificados Seg 10	645,41	188,67	44,94	58,29	937,30
Fischer (ha) classificados Seg 10	645,41	182,94	47,21	38,48	914,03
Maxlike (ha) classificados Seg 10	625,07	209,02	50,05	65,95	950,10
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
<i>Fuzzy % classificados Seg 10</i>	58,82%	57,52%	65,70%	68,45%	
<i>Fisher % classificados Seg 10</i>	58,82%	55,78%	69,02%	45,19%	
<i>Maxlike % classificados Seg 10</i>	56,97%	63,73%	73,17%	77,45%	
<i>Fuzzy % acerto Seg 10</i>	40,88%	11,95%	2,85%	3,69%	59,37%
<i>Fischer % acerto Seg 10</i>	40,88%	11,59%	2,99%	2,44%	57,89%
<i>Maxlike % acerto Seg 10</i>	39,59%	13,24%	3,17%	4,18%	60,18%

Tabela 6 - Total hectares classificados segmentados por cultura x método de classificação - Período Seco 2023

Culturas	Citrinos	Golfe	Abacateiros	Hortícolas	Total
Total (ha)	1097,28	327,99	68,40	85,15	1578,82
<i>Fuzzy (ha) classificados Seg 10</i>	808,66	210,74	26,52	56,50	1102,42
<i>Fischer (ha) classificados Seg 10</i>	769,95	150,90	50,34	23,04	994,24
<i>Maxlike (ha) classificados Seg 10</i>	613,94	225,39	51,58	44,03	934,94
Total (ha) %	69,50%	20,77%	4,33%	5,39%	100,00%
<i>Fuzzy % classificados Seg 10</i>	73,70%	64,25%	38,77%	66,36%	
<i>Fischer % classificados Seg 10</i>	70,17%	46,01%	73,59%	27,06%	
<i>Maxlike % classificados Seg 10</i>	55,95%	68,72%	75,41%	51,71%	
<i>Fuzzy % acerto Seg 10</i>	51,22%	13,35%	1,68%	3,58%	69,83%
<i>Fischer % acerto Seg 10</i>	48,77%	9,56%	3,19%	1,46%	62,97%
<i>Maxlike % acerto Seg 10</i>	38,89%	14,28%	3,27%	2,79%	59,22%

Abaixo, apresenta-se a Tabela 7 com os melhores classificadores (com segmentação) para cada cultura entre 2017 e 2023, incluindo os valores em hectares e as percentagens de acerto.

Tabela 7 - Melhores classificadores segmentados para cada cultura entre os anos de 2017 a 2023, incluindo os valores em hectares e percentagens de acerto

Ano	Cultura	Melhor Classificador	Hectares Classificados (ha)	% Acerto
2017	Citrinos	<i>Fuzzy</i>	912,54	57,80%
2017	Golfe	<i>Fischer</i>	170,64	10,81%
2017	Abacateiros	<i>Maxlike</i>	43,65	2,76%
2017	Hortícolas	<i>Fuzzy</i>	51,94	3,29%
2018	Citrinos	<i>Fuzzy</i>	910,53	57,67%
2018	Golfe	<i>Fischer</i>	192,54	12,20%
2018	Abacateiros	<i>Maxlike</i>	47,54	3,01%
2018	Hortícolas	<i>Fuzzy</i>	45,82	2,90%
2019	Citrinos	<i>Fischer</i>	851,69	53,94%
2019	Golfe	<i>Maxlike</i>	241,98	15,33%
2019	Abacateiros	<i>Maxlike</i>	44,34	2,81%
2019	Hortícolas	<i>Fuzzy</i>	53,01	3,36%
2020	Citrinos	<i>Fuzzy</i>	927,51	58,75%
2020	Golfe	<i>Maxlike</i>	220,17	13,95%
2020	Abacateiros	<i>Maxlike</i>	45,06	2,85%
2020	Hortícolas	<i>Fuzzy</i>	43,6	2,76%
2021	Citrinos	<i>Fuzzy</i>	886,79	56,17%
2021	Golfe	<i>Maxlike</i>	196,13	12,42%
2021	Abacateiros	<i>Maxlike</i>	45,28	2,87%
2021	Hortícolas	<i>Fuzzy</i>	45,92	2,91%
2022	Citrinos	<i>Fuzzy</i>	645,41	40,88%
2022	Golfe	<i>Maxlike</i>	209,02	13,24%
2022	Abacateiros	<i>Maxlike</i>	50,05	3,17%
2022	Hortícolas	<i>Maxlike</i>	65,95	4,18%
2023	Citrinos	<i>Fuzzy</i>	808,66	51,22%
2023	Golfe	<i>Maxlike</i>	225,39	14,28%
2023	Abacateiros	<i>Maxlike</i>	51,58	3,27%
2023	Hortícolas	<i>Fuzzy</i>	56,5	3,58%

Anexo 12 – Dados base para estimar o volume de água obtido nas áreas regadas

Tabela 1 - Total de precipitação acumulada para os anos hidrogeológicos de 2017 a 2023

MES	ANO	P(mm)	MES	ANO	P(mm)	MES	ANO	P(mm)	MES	ANO	P(mm)	MES	ANO	P(mm)	MES	ANO	P(mm)	MES	ANO	P(mm)
OUT	2016	95,6	OUT	2017	12,8	OUT	2018	122,6	OUT	2019	31,4	OUT	2020	144,2	OUT	2021	10	OUT	2022	44,8
NOV	2016	123,6	NOV	2017	36,6	NOV	2018	140,2	NOV	2019	43	NOV	2020	280,4	NOV	2021	13,6	NOV	2022	30
DEZ	2016	147,8	DEZ	2017	47	DEZ	2018	15,4	DEZ	2019	63,4	DEZ	2020	58,6	DEZ	2021	76,4	DEZ	2022	327
JAN	2017	48,8	JAN	2018	60,7	JAN	2019	24,8	JAN	2020	48,6	JAN	2021	46,8	JAN	2022	2,6	JAN	2023	29,6
FEV	2017	122,6	FEV	2018	69,2	FEV	2019	63	FEV	2020	2	FEV	2021	128,2	FEV	2022	6,8	FEV	2023	51,8
MAR	2017	105,4	MAR	2018	237,8	MAR	2019	8,4	MAR	2020	89,6	MAR	2021	17,2	MAR	2022	124,2	MAR	2023	31,8
ABR	2017	19,6	ABR	2018	171	ABR	2019	67,2	ABR	2020	119,2	ABR	2021	15	ABR	2022	27,6	ABR	2023	2,8
MAI	2017	13,6	MAI	2018	18,8	MAI	2019	0	MAI	2020	66	MAI	2021	24	MAI	2022	6,4	MAI	2023	4,2
JUN	2017	0	JUN	2018	31,2	JUN	2019	0	JUN	2020	3,4	JUN	2021	2,8	JUN	2022	0,8	JUN	2023	4,6
JUL	2017	0	JUL	2018	0	JUL	2019	0,2	JUL	2020	0	JUL	2021	0,2	JUL	2022	0,2	JUL	2023	0
AGO	2017	0	AGO	2018	1,8	AGO	2019	0	AGO	2020	0	AGO	2021	0	AGO	2022	0,4	AGO	2023	0
SET	2017	0	SET	2018	5,8	SET	2019	3	SET	2020	20,6	SET	2021	32,4	SET	2022	29	SET	2023	6,2
	Total Acumulado	677		Total Acumulado	692,7		Total Acumulado	444,8		Total Acumulado	487,2		Total Acumulado	749,8		Total Acumulado	298		Total Acumulado	532,8

Anexo 13 – Fluxograma da metodologia

