

Análise da trajetória da vegetação pós-fogo utilizando séries temporais de imagens satélite

Bernardo Miguel Costa Fernandes

Dissertação para obtenção do Grau de Mestre em
Engenharia Florestal e dos Recursos Naturais

Orientadores: Dr. José Miguel Cardoso Pereira

Dra. Alana Kasahara Neves

Júri:

Presidente: Doutora, Joana Amaral Paulo, Professora auxiliar do Instituto Superior de Agronomia

Vogais: Doutor, Manuel Lameiras de Figueiredo Campagnolo, Professor associado com agregação do Instituto Superior de Agronomia; Doutora, Alana Kasahara Neves, Investigadora júnior do Instituto Superior de Agronomia

Agradecimentos

Gostaria de expressar a minha gratidão a todas as pessoas que contribuíram para a realização deste trabalho de pesquisa no âmbito da minha tese de mestrado.

Aos meus orientadores, José Miguel Cardoso Pereira e Alana Kasahara Neves, pela orientação fornecida, conhecimento especializado e apoio, fundamentais para a conclusão desta dissertação. Sem esta orientação não teria sido possível realizar este trabalho, por isso estou profundamente agradecido pela oportunidade de aprendizagem que me proporcionaram.

À minha família. Os meus pais, Vanda e David, pelo seu apoio incansável, por terem sempre acreditado em mim e por me terem fornecido a oportunidade de ingressar no meu percurso académico. Ao meu irmão, pelo apoio ao longo destes anos.

Aos meus colegas, com quem partilhei grandes momentos de convívio, amizade e companheirismo. Todos contribuíram para o meu sucesso académico, pelo bom ambiente vivido em contexto escolar e fora dele.

Agradeço também ao Instituto Superior de Agronomia por fornecer as condições propícias à minha formação académica e à realização desta tese de mestrado.

Resumo

Devido às alterações climáticas que se verificam atualmente, é possível observar-se um aumento na ocorrência de fogos de grandes dimensões, sendo este tipo de evento um dos principais responsáveis por alterações na cobertura e uso do solo. O ano de 2017 correspondeu, num passado recente, a um dos anos onde se observou uma maior área ardida no território português. Neste ano, arderam cerca de 555.222 ha, sendo que deste total, cerca de 46.586 ha correspondem à área ardida no incêndio de Pedrógão Grande, objeto de estudo desta dissertação. Na realização deste estudo pretende-se utilizar as séries temporais de imagens satélite Landsat para avaliar a recuperação da vegetação no período pós-fogo. Vão também ser analisados os fatores determinantes que afetam a recuperação da vegetação e como os padrões de recuperação pós-fogo se relacionam com estes fatores observados no pré-fogo e com a severidade do fogo. Na análise das séries temporais, será utilizado o algoritmo Continuous Change Detection and Classification (CCDC), com o suporte da plataforma Google Earth Engine (GEE), para obter informações sobre os valores de Greenness antes do fogo e em datas definidas após o fogo, assim como os valores de slope. Adicionalmente, foram extraídos diferentes dados de forma a permitir realizar uma análise do efeito de fatores determinantes na recuperação da vegetação. As diferentes classes de trajetória de recuperação foram obtidas através da classificação do tipo K-means. Os fatores determinantes a analisar neste trabalho são: a severidade do fogo, o uso e ocupação do solo, o número de anos desde o último fogo com uma área ardida considerável, o número de vezes que cada região da área de estudo ardeu no período temporal escolhido para análise e a topografia do local. Na realização deste estudo observou-se que ao longo do tempo a taxa de recuperação vai diminuindo e a densidade de vegetação vai aumentando. Foi também observado que a classe com menor severidade do fogo é constituída principalmente por florestas de eucalipto e que esta foi a primeira classe a obter valores de greenness da vegetação próximos dos observados no pré-fogo. Notou-se também que a ocorrência de fogos num passado recente terá um efeito positivo na severidade do fogo estudado, ao contrário da incidência de radiação solar que é responsável por se observar um aumento da severidade do fogo nestas regiões.

Palavras-chave: Landsat, CCDC, GEE, K-means e Greenness.

Abstract

Due to the current climate changes, it is possible to observe an increase in the occurrence of large-scale wildfires, with these types of events being one of the main causes of changes in land cover and land use. The year of 2017 corresponded, in a recent past, to one of the years in which a greater burned area was observed in Portuguese territory. In this year, the area burnt was around 555,222 ha, of which around 46,586 ha corresponded to the burned area in the Pedrógão Grande wildfire, the object of study in this dissertation. In this study, we intend to use time series of Landsat satellite images to assess vegetation recovery in the post-fire period. We will also analyze the driving factors that affect vegetation recovery and how post-fire recovery patterns relate to these driving factors observed pre-fire and to the fire severity. To analyze the time series, the Continuous Change Detection and Classification (CCDC) algorithm will be employed, supported by the Google Earth Engine (GEE) platform, which enables us to obtain information about Greenness values pre-fire and for the selected dates in post-fire as well as the values of slope. Additionally, different data were extracted to allow for an analysis of the effect of driving factors on vegetation recovery. The different recovery trajectory classes will be obtained through K-means classification. The driving factors to analyze in this study are: fire severity, the land use and occupation, the number of years since the last fire with a considerable burnt area, the number of times which region within the study area burnt in the time period selected and the topography. While carrying out this study it was observed that as time went by recovery rates would be slower and vegetation density would be higher. It was also observed that the class with the lowest fire severity is mainly made up of eucalyptus forests and that this was the first class to obtain greenness values close to the observed in the pre-fire. It was also noted that the occurrence of fires in the recent past will have a positive effect on the severity of the fire studied, unlike the incidence of solar radiation which is responsible for an increase in fire severity in these regions.

Keywords: Landsat, CCDC, GEE, K-means and Greenness.

Índice

Agradecimentos.....	II
Resumo.....	III
Abstract.....	IV
Índice de figuras.....	VI
Índice de tabelas.....	VIII
Índice de equações.....	IX
Lista de abreviaturas.....	X
1. Introdução.....	1
1.1 Objetivos desta dissertação.....	3
2. Estado de arte.....	4
2.1 Detecção remota, imagens de satélite e Landsat.....	4
2.2 Séries temporais e classificação de imagens de satélite.....	5
2.3 Algoritmo CCDC.....	7
2.4 Fatores determinantes para a recuperação da vegetação no pós-fogo.....	9
3. Dados e métodos.....	13
3.1 Área de estudo.....	13
3.2 Dados de imagens satélite.....	15
3.3 Google Earth Engine (GEE).....	18
3.4 Métodos.....	18
3.4.1 Continuous Change Detection and Classification (CCDC).....	19
3.4.2 Classificação das trajetórias de recuperação da vegetação no pós-fogo.....	23
3.4.3 Análise dos coeficientes do CCDC.....	24
3.4.4 Análise da influência da severidade do fogo na recuperação da vegetação.....	25
3.4.5 Análise da influência do uso e ocupação do solo na recuperação da vegetação.....	28
3.4.6 Análise da influência que a ocorrência de fogos anteriores tem na recuperação da vegetação.....	30
3.4.7 Análise da influência da topografia do local na recuperação da vegetação.....	32
4. Resultados.....	34
4.1 Classificação das trajetórias da recuperação da vegetação no pós-fogo.....	34
4.2 Análise dos fatores determinantes na recuperação da vegetação.....	41
5. Discussão.....	48
6. Considerações finais.....	51
7. Referências bibliográficas.....	53

Índice de figuras

Figura 2.1: Imagens que ilustram o que são séries temporais.....	6
Figura 3.1: Em a) localização da área de estudo e em b) composição Landsat RGB SWIR2-NIR-Red pré (15/06/2017) e pós (1/7/2017) fogo para o incêndio de Pedrógão Grande.....	14
Figura 3.2: Esquema da metodologia aplicada para a realização deste estudo.....	19
Figura 3.3: Série temporal Landsat a demonstrar um evento de perda florestal de 2017 em Pedrógão Grande, Portugal. Os pontos azuis correspondem aos valores observados na banda Greenness e as linhas coloridas representam os segmentos temporais do CCDC. Apesar da possibilidade de detectar um máximo de 6 segmentos, foram apenas encontrados 3 segmentos para este pixel.....	20
Figura 3.4: Fórmula de cálculo do dNBR na calculadora de rasters do QGIS.....	26
Figura 3.5 Reclassificação por tabela realizada para os níveis de severidade do fogo.....	27
Figura 3.6: Mapa do uso e ocupação do solo. Apenas estão representadas as classes que ocupam pelo menos 2% da área de estudo.....	28
Figura 3.7: Fórmula e parâmetros usados no cálculo da área dos polígonos.....	29
Figura 3.8: Mapa do número de anos desde o último fogo antes de 2017. Apenas foram considerados fogos que representem pelo menos 3% da totalidade da área ardida entre 1984 e 2016 para a área de estudo.....	30
Figura 3.9: Mapa do número de vezes que cada pixel da área de estudo ardeu desde 1984 até 2016. Onde apenas se consideraram fogos que representem pelo menos 3% da totalidade da área ardida entre 1984 e 2016 para a área de estudo.....	31
Figura 3.10: Mapa das topografias que ocupam pelo menos 1% da área de estudo.....	33
Figura 4.1: Classes resultantes da classificação não supervisionada do tipo k-means.....	35
Figura 4.2: Série temporal de Landsat para a banda Greenness e segmentos temporais do CCDC para um pixel da classe IR/EB, localizado numa floresta de eucaliptos, no fogo de Pedrógão Grande. O número máximo de segmentos possíveis é 6, contudo apenas foram encontrados 2 segmentos.....	36
Figura 4.3: Série temporal de Landsat para a banda Greenness e segmentos temporais do CCDC para um pixel da classe IM/EB, localizado numa floresta de eucaliptos, no fogo de Pedrógão Grande. O número máximo de segmentos possíveis é 6, contudo apenas foram encontrados 2 segmentos.....	36
Figura 4.4: Gráficos Boxplot dos coeficientes em a) SLP e em b) INTP da banda Greenness para a classe IR/EB.....	37

Figura 4.5: Gráficos Boxplot dos coeficientes em a) SLP e em b) INTP da banda Greenness para a classe IM/EL.....	38
Figura 4.6: Gráficos Boxplot dos coeficientes em a) SLP e em b) INTP da banda Greenness para a classe IM/EB.....	38
Figura 4.7: Gráficos Boxplot dos coeficientes em a) SLP e em b) INTP da banda Greenness para a classe IL/EL.....	39
Figura 4.8: Gráficos com os valores da mediana em a) de SLP e em b) de INTP, ao longo do tempo, para as diferentes classes de recuperação da vegetação.....	40
Figura 4.9: Imagem raster dos valores de dNBR com legenda para o respectivo nível de severidade do fogo.....	42
Figura 4.10: Percentagem dos níveis de severidade do fogo para cada classe de recuperação da vegetação.....	43
Figura 4.11: Percentagem dos tipos de uso e ocupação do solo para cada classe de recuperação da vegetação. Considerando apenas os tipos de uso e ocupação do solo que ocupam pelo menos 2% da área de estudo.....	44
Figura 4.12: Percentagem de área ardida em anos anteriores para cada classe. Apenas se consideraram fogos que representam pelo menos 3% da totalidade da área ardida até 2016.....	45
Figura 4.13: Percentagem do número de vezes que esta área ardeu entre os anos de 1984 e 2016 para as diferentes classes de recuperação.....	46
Figura 4.14: Percentagem do tipo de topografia observado para cada classe. Considerando apenas topografias que ocupam > 1% da área de estudo.....	47

Índice de tabelas

Tabela 3.1: Bandas Landsat 7 ETM+ (Enhanced Thematic Mapper), o seu comprimento de onda e resolução e os seus usos.....	15
Tabela 3.2: Bandas Landsat 8 OLI e TIRS, o seu comprimento de onda e resolução e os seus usos.....	16
Tabela 3.3: Parâmetros do CCDC, respetivas descrições e valores utilizados neste estudo.....	20
Tabela 3.4: Coeficientes do CCDC e a sua respetiva descrição.....	21
Tabela 3.5: Níveis de severidade obtidos a partir do cálculo do dNBR.....	26

Índice de equações

Equação 3.1: Fórmula utilizada para calcular o Δ INTP	23
Equação 3.2: Fórmula utilizada para calcular o NBR.....	25
Equação 3.3: Fórmula utilizada para calcular o dNBR.....	25

Lista de abreviaturas

CCDC - Continuous Change Detection and Classification

GEE - Google Earth Engine

IPCC - Painel Intergovernamental sobre Mudanças Climáticas

SITS - Séries temporais de imagens de satélite

MVC-NDVI - Maximum Value Composite-Normalized Difference Vegetation Index

NDVI - Normalized Difference Vegetation Index

MSS - Multi-Spectral Scanner

USGS - Inventário Geológico dos Estados Unidos

OLI - Operational Land Imager

TIRS - Thermal Infrared Sensor

SWIR - Infravermelho de onda curta

NIR - Infravermelho próximo

CEF - Centro de estudos Florestais

QGIS - Quantum Geographic Information System

NASA - Administração Nacional de Aeronáutica e do Espaço

ETM - Enhanced Thematic Mapper

TCT - Transformação tasseled cap

INTP - Intercept

SLP - Slope

Sin - Seno

Cos - Cosseno

API - Application Programming Interface

RMSE - Root Mean Square Error

OTB - OrfeoToolbox

GDAL - Geospatial Data Abstraction Library

IQR - Intervalo interquartil

NBR - Normalized Burn Ratio

dNBR - Differenced Normalized Burn Ratio

COS - Carta do Uso e Ocupação do Solo

DGT - Direção Geral do Território

IR/EB - Início rápido e estabilização brusca

IM/EL - Início médio e estabilização lenta

IM/EB - Início médio e estabilização brusca

IL/EL - Início lento e estabilização lenta

1. Introdução

O Painel Intergovernamental sobre Mudanças Climáticas [IPCC] (2023) faz referência, com um elevado grau de confiança, ao aumento acelerado da temperatura na superfície global, especialmente desde 1970, constituindo este acréscimo um fenómeno sem igual nos últimos dois milénios. É pertinente notar que este aumento se revela particularmente proeminente nas áreas terrestres em comparação com as massas de água. Além disso, o relatório referido salienta que eventos de calor extremo têm se tornado cada vez mais recorrentes e intensos desde meados do século XX.

Este aumento de eventos de calor extremo tem desencadeado um aumento substancial na frequência de incêndios de grandes proporções, em diversas regiões do mundo (San-Miguel-Ayanz et al., 2013). Tal fenómeno não pode ser atribuído unicamente ao aumento das temperaturas, estando também intrinsecamente relacionado com mudanças nos padrões de precipitação (Halofsky et al., 2020) e modificações no uso do solo, como o abandono de terras e a acumulação de materiais combustíveis, que têm desempenhado um papel significativo na alteração do regime de incêndios (Gouveia et al., 2010). Neste contexto, torna-se evidente que a combinação destes fatores contribuiu para um cenário crítico de incêndios florestais, o que destaca a urgência da adoção de medidas eficazes para mitigar os impactos associados a estas alterações climáticas.

Existem diversos elementos passíveis de exercer influência sobre o regime de fogo, compreendendo, entre outros, os seguintes fatores: o "tempo", que consiste numa combinação de parâmetros que traduzem a variabilidade climática observada numa determinada região (Nitschke e Innes, 2008); o clima, que por sua vez, corresponde à média do "tempo" ao longo de um período específico para a mesma localização geográfica (Nitschke e Innes, 2008); os padrões de combustível, que englobam características como o tipo, a humidade e a disponibilidade de material combustível (Kloster et al., 2012) e a topografia do local, que se caracteriza como um elemento ambiental de natureza mais estática, desempenhando contudo, um papel crucial na dinâmica dos fogos. Finalmente, o fator humano também se apresenta como um determinante significativo no comportamento dos fogos florestais, uma vez que os mesmos se encontram intrinsecamente ligados a variáveis sociais, económicas e tendências demográficas (Kloster et al., 2012).

Os fogos rurais assumem um papel de destaque enquanto agentes primordiais de modificação no uso e cobertura do solo, imputando efeitos adversos significativos nos âmbitos ecológicos, económicos e da saúde pública. É importante realçar que estes

impactos se afiguram de maneira ainda mais acentuada nas regiões de caráter Mediterrâneo na Europa, onde se verifica o registo do maior número de incêndios e de área ardida (San-Miguel-Ayanz et al., 2018), correspondendo a cerca de 85% de toda a área ardida no continente Europeu (San-Miguel-Ayanz et al., 2013). Estes eventos desencadeiam transformações substanciais no funcionamento dos ecossistemas, bem como na composição das espécies de flora e fauna, resultado da perda de biomassa e das alterações nas propriedades do solo. Como resultado, observa-se portanto uma redução na capacidade de resiliência destas áreas (Scheffer et al., 2015).

A resiliência de um ecossistema pode ser desagregada em dois componentes fundamentais: resistência e recuperação. A resistência denota a habilidade de um ecossistema em resistir a perturbações ambientais e a sua magnitude pode ser avaliada com base na extensão das alterações ocorridas nesse ecossistema. Esta magnitude de alterações frequentemente corresponde à severidade do fogo (De Keersmaecker et al., 2015). O segundo componente é a recuperação, que engloba o processo pelo qual o sistema retorna às condições de equilíbrio que eram observadas no período anterior à perturbação. A medição da recuperação pode ser realizada por meio do período decorrido desde o estado de distúrbio até conseguir um estado mais estável, mesmo que este último não corresponda completamente às condições observadas antes do incêndio (Hodgson et al., 2015).

Apesar dos esforços em prol da mitigação da ocorrência de incêndios, a capacidade de recuperação da vegetação possui o papel mais preponderante na determinação da resiliência de determinada região a tais eventos. Neste contexto, torna-se crucial compreender os fatores que influenciam o processo de recuperação, com o intuito de aprimorar a gestão das áreas sujeitas a esses distúrbios e, assim, mitigar os danos causados por eles.

Uma das abordagens mais eficazes para monitorar os padrões de vegetação durante e após catástrofes, como os incêndios, reside na utilização de imagens de satélite, dado que permitem a observação de áreas de interesse ao longo do tempo. A observação sistemática, utilizando um ou mais satélites, de uma região ao longo do tempo pode ser definida como uma série temporal de imagens de satélite (Petitjean et al., 2012). Com os avanços tecnológicos nesta área, têm sido desenvolvidos algoritmos que possibilitam a análise mais minuciosa da deteção de mudanças no uso e ocupação do solo e reduzindo o erro associado a este processo, sendo um exemplo notável destes algoritmos, o Continuous Change Detection and Classification (CCDC) (Zhu e Woodcock, 2014). Para se realizar a deteção de mudanças são utilizadas imagens da cobertura do solo em datas diferentes e é

comparado o espaço espectral destas imagens. Se os valores espectrais de um pixel se encontram numa região espectral associada a um tipo de cobertura do solo numa data e a outro tipo de cobertura numa data diferente, é possível concluir que ocorreu uma mudança no solo para a área medida por este pixel. Contudo, existem outros fatores que podem causar alterações nos valores espectrais dos pixels ao longo do tempo, como por exemplo, as alterações fenológicas sazonais e as diferentes fases observadas em culturas agrícolas (Kennedy et al., 2009).

Assim, a exploração aprofundada da aplicação deste algoritmo aprimorado revela-se de extrema importância para a obtenção de resultados de maior precisão e confiabilidade na análise dos efeitos dos incêndios florestais e na gestão subsequente das áreas afetadas.

1.1 Objetivos desta dissertação

O objetivo geral desta dissertação é identificar os padrões de recuperação da vegetação após o fogo, analisar diferentes fatores determinantes que vão afetar a recuperação da vegetação e perceber a influência que cada um destes fatores vai ter nos resultados obtidos. Neste contexto, esta dissertação tem como objetivos específicos responder a três questões fundamentais:

1. Quais são os distintos padrões de recuperação da vegetação que podem ser observados?
2. Quais são os fatores determinantes que exercem influência na recuperação no período pós-fogo?
3. Como se relacionam estes fatores com a cobertura do solo previamente observada, antes da ocorrência do incêndio?

Por meio desta investigação, pretende-se contribuir para o entendimento mais abrangente dos processos de recuperação pós-fogo e, assim, fornecer informações valiosas para a gestão e conservação de ecossistemas sujeitos a incêndios florestais.

2. Estado de arte

O presente capítulo tem por objetivo fornecer uma exposição abrangente sobre as imagens de satélite e suas múltiplas aplicações, bem como discutir a utilização de séries temporais para a detecção de mudanças no uso e ocupação do solo, sendo também abordada a relevância crucial da detecção remota no contexto do estudo dos fogos florestais. Este capítulo propõem-se também a investigar os fatores determinantes que exercem impacto sobre o processo de recuperação da vegetação após fogos, assim como a delineação das diferenças do algoritmo CCDC em relação a outro algoritmo frequentemente utilizado na análise de alterações do solo, com o intuito de melhorar a compreensão do seu funcionamento e avaliar a sua eficácia.

2.1 Detecção remota, imagens de satélite e Landsat

A detecção remota, considerada como a aplicação de técnicas que permitem a obtenção de informações acerca de objetos sem a necessidade de um contacto direto, frequentemente utiliza satélites como plataformas para gerar informações na forma de imagens (Moskoliai et al., 2021). No cenário atual, observamos a presença de mais de 4000 satélites em órbita ao redor da Terra, sendo que cada um destes incorpora um ou mais sensores próprios, capazes de fornecer dados específicos através de imagens da superfície terrestre para um momento em particular (Chuvieco, 2023).

Os satélites de observação da Terra desempenham um papel fundamental na produção de imagens utilizadas em diversas áreas, tais como estudos climáticos, monitorização dos padrões de uso e cobertura do solo, aplicações militares e em setores florestais e agrícolas (Gamboa, 2017). As resoluções destas imagens possuem considerável importância na escolha dos dados apropriados para um determinado projeto. Existem quatro tipos de resolução que devem ser ponderadas: a resolução espacial, que indica o tamanho do menor elemento observável pelo sensor; a resolução espectral, que se relaciona com o número e a largura de cada canal espectral; a resolução radiométrica, que quantifica a capacidade de discernimento de pequenas variações na magnitude da energia eletromagnética; e, por último, a resolução temporal, que determina o intervalo de tempo entre a aquisição de duas imagens consecutivas que retratam o mesmo local (Moskoliai et al., 2021).

Dentre os satélites principais, destaca-se o Landsat, cuja importância decorre da disponibilidade de dados com um longo histórico de observações e uma média resolução espacial, o que o torna um recurso valioso para a análise das alterações na superfície terrestre ao longo de décadas (Kennedy et al., 2014). É relevante mencionar que, em anos anteriores, a detecção de mudanças no uso e cobertura do solo com base em dados Landsat era limitada devido aos custos elevados envolvidos (Loveland & Dwyer, 2012) e às exigências de recursos computacionais substanciais (Hansen & Loveland, 2012). No entanto, o uso destes dados tem-se tornado cada vez mais comum desde 2008, devido à disponibilidade de dados corrigidos geometricamente e radiometricamente, sem custos (Woodcock et al., 2008).

O programa Landsat teve início em 1972, com o lançamento do Landsat-1 e atualmente abriga nove satélites, tendo sido o mais recente lançado em 2021. Estes satélites têm melhorado consideravelmente com o avanço tecnológico, oferecendo um maior número de bandas espectrais e aprimorando a resolução espacial e temporal. Alguns dos benefícios associados à utilização destes satélites abrange aplicações cruciais, como suporte à agricultura, auxílio na tomada de decisões relacionadas com a gestão de alimentos e recursos hídricos, análise e gestão de desastres naturais, como incêndios, monitorização de florestas para detecção de pragas e desflorestação e acompanhamento do desenvolvimento urbano, entre outras aplicações (Wulder et al., 2019).

2.2 Séries temporais e classificação de imagens de satélite

As imagens de satélite e a detecção remota desempenham um papel crucial na obtenção de informações geográficas, oferecendo dados quantitativos e qualitativos que simplificam substancialmente as atividades de campo e reduzem o tempo necessário para a realização de estudos (Vaiphasa et al., 2011). Estas tecnologias desempenham um papel vital nesta era, onde a quantidade de dados recebidos pelos centros de processamento tem crescido exponencialmente, devido à constante evolução tecnológica (Zheng et al., 2012). Portanto, é imprescindível desenvolver e testar mecanismos eficientes para a extração e interpretação de informações provenientes de imagens satélite (Abburu & Golla, 2015).

Através da aquisição de imagens sucessivas ao longo do tempo, é possível criar séries temporais de imagens de satélite (SITS), as quais desempenham um papel fundamental em diversas aplicações, incluindo a classificação, segmentação, detecção de

anomalias e previsões (Huang et al., 2018). Na Figura 2.1 é possível observar-se uma representação do que são séries temporais.

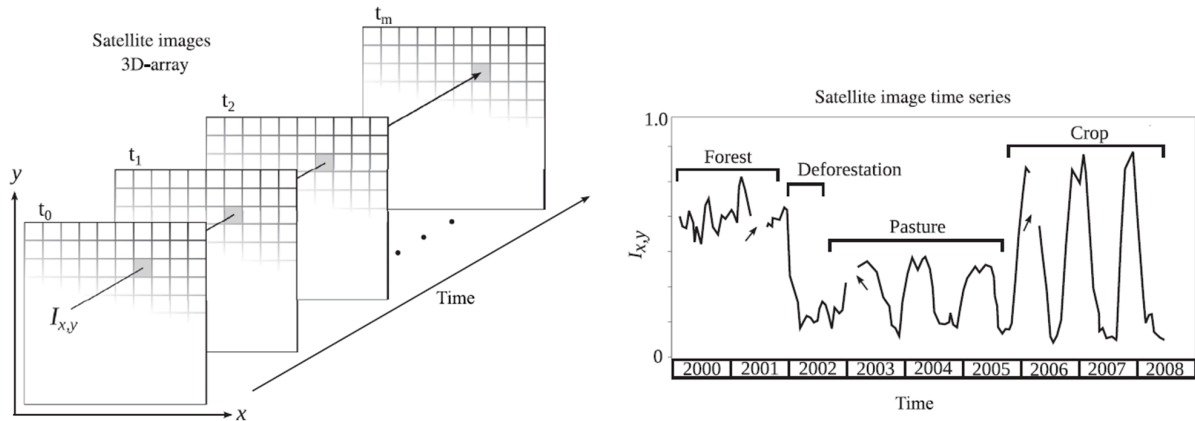


Figura 2.1: Imagens que ilustram o que são séries temporais. Fonte: Maus et al.(2019).

A classificação de imagens satélite, é definida como o processo de categorização de pixels, aos quais podem estar associadas séries temporais de dados, em classes de interesse (Karlsson, 2003). Essa etapa é fundamental na extração e interpretação de informações de interesse destas imagens. Esta classificação desempenha um papel crucial na modelação de dados espaciais, extração de informações geográficas, criação de mapas, interpretação visual e digital de imagens de satélite, pesquisas de campo, tomadas de decisão eficazes e na gestão em situações de catástrofes (Abburu & Golla, 2015).

Os métodos de classificação de imagens satélite podem ser agrupados em três categorias principais: automatizados, manuais e híbridos. Os métodos automatizados empregam algoritmos que são aplicados de forma sistemática a todas as imagens com o intuito de agrupar pixels em categorias de interesse. Estes métodos podem ser subdivididos em métodos supervisionados e não supervisionados. Os métodos supervisionados requerem uma amostra de treino e a precisão da classificação depende substancialmente desta etapa. Estes métodos usam algoritmos para simular o processo de aprendizagem humano, associando informações de interesse aos pixels da imagem e utilizam métodos de "machine learning" para definir as classes de interesse associadas a pixels individuais. A partição de imagens em regiões homogêneas, conhecida como segmentação de imagens, também pode ser utilizada para possibilitar a extração de novos atributos baseados nos segmentos (Palanivel & Duraisamy, 2012).

Por outro lado, as técnicas de classificação não supervisionada utilizam algoritmos de agrupamento para categorizar pixels em classes que não são previamente definidas, sendo então, da responsabilidade do analista associar informações de interesse às classes, de modo a obter imagens satélite devidamente classificadas. Um dos métodos mais utilizados nesta categoria, é o classificador do tipo K-means, que divide os dados em vários grupos, introduzindo um critério de similaridade, ou seja, os elementos dos grupos vão ser o mais semelhante possível e o utilizador determina o número de classes desejadas (Rekik, 2009).

Os métodos de classificação manual, embora eficazes e precisos, consomem mais tempo e são mais subjetivos do que os de classificação automática, visto que estão dependentes da percepção e experiência do analista. A classificação híbrida, por sua vez, combina as vantagens dos métodos automatizados e manuais, utilizando inicialmente métodos automatizados para uma classificação preliminar e posteriormente recorrendo a métodos manuais para refinar a classificação e corrigir possíveis erros (Abburu & Golla, 2015).

2.3 Algoritmo CCDC

Embora a criação de mapas de cobertura do solo a partir de dados de deteção remota seja considerada relativamente simples, a obtenção de mapas precisos é uma tarefa desafiadora (Zhu & Woodcock, 2014). Para melhorar a precisão na classificação de imagens de satélite, muitas vezes são utilizadas séries temporais como inputs. No entanto, o uso destas imagens pode introduzir dois problemas nos algoritmos de classificação. Primeiro, é necessário que nas datas selecionadas as imagens utilizadas estejam parcialmente livres de nuvens. Em segundo lugar, a maioria dos algoritmos assume que não ocorrem mudanças na cobertura do solo entre as datas das imagens, o que nem sempre é válido, especialmente quando se utilizam imagens com grandes intervalos temporais ou em áreas sujeitas a mudanças frequentes (Rogan et al., 2002).

Consequentemente, os mapas de cobertura do solo podem não ser capazes de identificar diretamente mudanças contínuas da cobertura do solo que podem ocorrer entre classificações (Friedl et al., 2010). Para abordar este desafio, foi desenvolvido um algoritmo, CCDC, que utiliza observações de satélite para minimizar os problemas mencionados. Inicialmente pensado para os satélites Landsat, também pode ser aplicado noutros satélites, como o Sentinel-2. O algoritmo CCDC é capaz de detetar mudanças na cobertura do solo

sempre que novas imagens estiverem disponíveis, ao comparar os dados previstos pelo modelo com os dados observados do Landsat e considera que um pixel sofreu uma mudança na cobertura do solo se essa alteração for observada em vários momentos consecutivos (Zhu & Woodcock, 2014).

O algoritmo CCDC desenvolvido por Zhu & Woodcock (2014) tem várias vantagens. É completamente automatizado e capaz de monitorizar diferentes tipos de mudanças na cobertura do solo assim que novas imagens estão disponíveis, gerando limiares de detecção de mudança a partir de observações originais e estimativas de modelo feitas separadamente para cada pixel. A monitorização contínua permite que o algoritmo utilize o maior número possível de imagens, tornando a rapidez com que deteta mudanças e segmenta a série temporal dependente principalmente da frequência de observações livres de nuvens disponíveis. Além disso, este não requer uma normalização relativa para cada imagem, visto que os modelos de séries temporais já incluem efeitos da fenologia e diferenças na incidência solar.

Comparando o CCDC com outro algoritmo, o LandTrendr, ambos automatizam a extração de características espectrais e informações de mudanças de padrão em séries temporais de imagens de satélite, criando o que chamamos de segmentação temporal. No entanto, utilizam diferentes domínios espectrais e temporais, bem como métodos distintos de extrapolação e atribuição de resultados de segmentação temporal. Ambos os algoritmos assumem que sequências de modelos lineares podem ser usadas para identificar e quantificar períodos de estabilidade e mudança nas propriedades do solo e estão, portanto, dependentes da disponibilidade de dados de elevada qualidade para caracterizar padrões e mudanças do solo de interesse. O LandTrendr utiliza uma segmentação temporal de observações ou compósitos anuais, baseada numa única banda ou índice de forma a gerar trajetórias de reflectância contínuas. Por outro lado, o CCDC utiliza todas as observações de elevada qualidade, isto é, observações limpas que não contêm nuvens ou ruído de múltiplas bandas ou índices para a detecção de mudanças e para caracterizar a variabilidade sazonal dentro dos segmentos (Pasquarella et al., 2022).

O LandTrendr requer menos esforço computacional do que o CCDC e pode ser aplicado em grandes áreas com facilidade. No entanto, os resultados da segmentação do CCDC incluem informações das dinâmicas sazonais intra-anuais e oferecem maior precisão na estimativa do momento das mudanças na cobertura do solo, o que pode ser importante para mapeamento e monitorização. Portanto, o CCDC é uma escolha mais adequada se for necessário obter informações dentro de um período anual e se houver um número suficiente de observações de elevada qualidade no período de interesse (Pasquarella et al., 2022).

Como o CCDC utiliza todas as observações disponíveis, ele é menos sensível a inputs e a pequenos parâmetros de mudança em comparação com o LandTrendr, no entanto, a extrapolação e a detecção de mudanças são mais sensíveis às condições iniciais e às mudanças na frequência de observações (Pasquarella et al., 2022).

Em resumo, o CCDC e o LandTrendr são algoritmos que diferem na forma de modelação e, portanto, é esperado que produzam resultados de detecção de mudanças distintos. O CCDC é mais adequado para a detecção de distúrbios de grande magnitude e mudanças na cobertura do solo com afinamento mínimo, podendo ser menos adequado na detecção de transições graduais na cobertura do solo que não estão associadas a eventos de distúrbios (Pasquarella et al., 2022).

2.4 Fatores determinantes para a recuperação da vegetação no pós-fogo

Os sensores de detecção remota desempenham um papel crucial ao fornecer informações globais com diferentes resoluções espaciais e em diferentes regiões espectrais. Estes sensores operam de forma contínua, observando constantemente a superfície da Terra, tornando-os particularmente adequados para análises multitemporais, o que explica em grande parte a sua ampla utilização em pesquisas e gestão relacionadas com o fogo (Chuvieco et al., 2020). Os dados obtidos por satélites desempenham funções essenciais em diferentes fases da gestão de incêndios. Ao serem usados antes do fogo contribuem para a redução dos impactos causados pelo fogo, estimando o risco de ocorrência de incêndios. Durante o fogo, os dados de satélite são bastante importantes na detecção de incêndios ativos e no estudo do seu comportamento (Wooster et al., 2021) e após o fogo, possibilitam a análise dos efeitos do fogo e o processo de recuperação da vegetação (San-Miguel-Ayanz et al., 2009).

Os fatores climáticos, os combustíveis e a topografia têm sido identificados como os principais fatores determinantes das características do fogo, como a intensidade, velocidade de propagação e severidade (Birch et al., 2015). O clima exerce uma influência indireta na propagação do fogo, através da influência na humidade dos combustíveis e uma influência direta através da ação do vento (Flannigan et al., 2005). A humidade dos combustíveis é particularmente relevante na definição de áreas de risco, visto que áreas com combustíveis secos são mais propensas à ignição e à propagação do fogo (Littell et al., 2009). A

disponibilidade de combustível varia tanto temporalmente devido ao crescimento da vegetação, quanto espacialmente dependendo da região, sendo também afetado pelos incêndios anteriores que vão afetar a disponibilidade de combustível e reduzindo a probabilidade de ocorrência de novos incêndios num futuro próximo. À medida que o tempo passa este efeito vai-se reduzindo com a acumulação de combustível (Holsinger et al., 2016).

A recuperação pós-fogo é influenciada por uma interação complexa de fatores bióticos e abióticos. Diversas variáveis geográficas, como a topografia, características do solo, a meteorologia e o clima desempenham um papel importante na determinação dos efeitos deste processo, assim como a severidade do incêndio, a composição da floresta antes do incêndio, a proximidade de áreas não afetadas pelo incêndio e as características das espécies arbóreas presentes no local (Chuvienco et al., 2020).

A recuperação pós-fogo em grandes áreas queimadas depende em grande medida do tipo de vegetação predominante. Regiões com florestas de coníferas, dominadas por pinheiro bravo (*Pinus pinaster*), tendem a exigir mais tempo para a recuperação da vegetação, enquanto áreas dominadas por eucalipto (*Eucalyptus globulus*) apresentam uma recuperação mais rápida (Gouveia et al., 2010). A dinâmica da vegetação pós-fogo em regiões com pinheiro bravo está mais relacionada com as condições após o incêndio, uma vez que a regeneração depende principalmente da germinação de sementes protegidas do fogo, armazenadas no solo ou na copa das árvores (Arianoutsou & Ne'eman, 2000), por outro lado, o eucalipto é mais influenciado pela densidade da vegetação observada antes do incêndio, uma vez que sua regeneração ocorre por rebrotamento, ou seja, o crescimento ocorre a partir de estruturas resistentes ao fogo (Hodgkinson, 1998). A elevada resiliência ao fogo das espécies de árvores que conseguem regenerar através de sementes e de rebrotamento também é observada para espécies de vegetação arbustiva que regeneram da mesma maneira e que vão ser um fator de extrema importância na recuperação da vegetação após o fogo, sobretudo nos primeiros anos (Catry et al., 2012).

Para obter estes resultados, Gouveia et al. (2010) utilizaram um clustering não supervisionado, utilizando o classificador K-means, da distribuição espacial dos valores mensais de MVC-NDVI (Maximum Value Composite-Normalized Difference Vegetation Index) em Portugal, assim como, da distribuição do tempo de recuperação da vegetação no pós-fogo vs. a densidade da vegetação e o tempo de recuperação vs. danos causados pelo fogo nas áreas queimadas dentro das regiões de pinheiro bravo e eucalipto selecionadas. A juntar a esta etapa, seguiu-se o ajustamento de um modelo monoparamétrico da recuperação da vegetação pós-fogo para o desvio mensal da média espacial do NDVI

(Normalized Difference Vegetation Index) nas áreas queimadas nas regiões dominadas por *Pinus pinaster* e por *Eucalyptus globulus*.

Díaz-Delgado et al. (2002) formularam a hipótese de que a capacidade de recuperação de um ecossistema diminui à medida que a frequência de incêndios aumenta. Estes observaram que as áreas queimadas apenas uma vez apresentaram uma recuperação superior em comunidades rebrotadoras, como o sobreiro (*Quercus suber*), azinheira (*Quercus ilex*) e o eucalipto, quando comparadas com comunidades não rebrotadoras, como o *Pinus sylvestris* e o *Pinus nigra*. Foram observados diferentes padrões de recuperação para florestas de pinheiros e de azinheira depois de vários fogos, tendo-se observado uma recuperação superior em florestas de azinheira, apesar das florestas de pinheiros terem demonstrado uma menor diminuição da capacidade de recuperação após o segundo fogo, isto acontece devido à elevada densidade observada nas florestas de azinheira. A recuperação após o segundo fogo neste tipo de ecossistema tende a diminuir, pois há uma menor taxa de sucesso no rebrotamento devido à falta de uma camada de herbáceas de crescimento rápido. Por outro lado, as florestas de pinheiros apresentam uma menor capacidade de recuperação inicial, uma vez que o crescimento a partir de sementes é mais lento, contudo, com a ocorrência de outro distúrbio num curto período, as comunidades secundárias de matagais ou pastagens resultantes do primeiro incêndio tendem a ter um crescimento maior após o segundo incêndio (Díaz-Delgado et al., 2002).

De forma a fazer esta observação, Díaz-Delgado et al. (2002) utilizaram mais de 100 imagens, de 1975 até 1993, do sensor MSS (Multi-Spectral Scanner) dos satélites Landsat 1,2,3, 4 e 5 após serem realizadas correções radiométricas e geométricas. O NDVI foi utilizado por fazer uma boa representação da biomassa verde, apesar de haver algumas ressalvas em relação a este índice. Apesar de os dados de NDVI não serem uma boa base para uma interpretação muito detalhada, podem revelar padrões e tendências gerais na quantidade relativa de vegetação. Contudo, quando existem grandes níveis de biomassa verde, a saturação do NDVI não vai refletir as variações na biomassa, o que causa um maior nível de erro e a necessidade de fazer uma transformação nos valores de NDVI para reduzir alguns problemas relacionados com a variabilidade fenológica e meteorológica. Este índice vai também ser afetado pela cor do solo subjacente, na fase em que a cobertura vegetal ainda é esparsa. Uma área foi considerada como ardida quando a subtração de imagens NDVI consecutivas foi superior aos valores limite definidos, estes valores foram obtidos através de modelos de regressão empíricos baseados em 21 fogos. Este procedimento permite reconhecer áreas que arderam mais do que uma vez durante o período de estudo.

De acordo com Ireland & Petropoulos (2015), as áreas com exposição a norte apresentam uma maior taxa de regeneração em comparação com as áreas expostas ao sul, o que evidencia a importância da exposição na regulação da capacidade de regeneração da vegetação e reflete a importância dos efeitos locais do microclima nos processos hidrológicos da recuperação da vegetação. Estas diferenças na regeneração pós-fogo podem influenciar e ser influenciadas pela variabilidade hidrológica e pela hidrofobia do solo, que, sem a gestão adequada, pode resultar em efeitos secundários do fogo perigosos (Cerdà & Doerr, 2005). Os principais efeitos secundários incluem o aumento do escoamento, inundações, fluxo de detritos, alterações nos padrões de fluxo sobre a terra e a erosão do solo, causada por mudanças físicas e químicas nos atributos do solo e pela remoção da cobertura do solo e da vegetação protetora (Shakesby & Doerr, 2006).

Em contextos mediterrânicos, Viana-Soto et al. (2017) observaram que as áreas expostas ao norte e as áreas com elevado declive apresentam uma taxa de regeneração maior, devido a uma menor taxa de evapotranspiração e maior humidade destas áreas.

Os resultados obtidos por Ireland & Petropoulos (2015) demonstram uma correlação significativa entre a severidade do fogo e o NDVI, ou seja, as áreas com uma maior severidade de fogo apresentaram uma diminuição mais acentuada no NDVI. Foi sugerido que as áreas com maior elevação continham uma elevada percentagem de cobertura florestal, tendo estas áreas experienciado uma queda inicial superior nos valores de NDVI e também demonstrado uma menor taxa de recuperação, isto deve-se à elevada biomassa observada nestas áreas florestais onde se iriam encontrar fogos mais intensos.

Pereira et al. (2016) observaram que a severidade do fogo tende a ser maior em declives expostos a oeste em comparação com aqueles expostos a este. Isso ocorre porque as áreas expostas a oeste recebem mais radiação solar durante a tarde, levando a uma maior taxa de evaporação e a redução da humidade no solo e na vegetação. Além disso, a inclinação das áreas declivosas também afeta a severidade do fogo, com áreas mais íngremes a serem mais suscetíveis a incêndios mais severos.

Isto foi também observado por Maingi & Henry (2007) que referiu que a severidade do fogo foi superior em zonas mais declivosas, o que pode indicar que a linha de fogo se tende a movimentar a favor do declive devido ao pré-aquecimento do combustível antes da combustão, o que facilita a propagação do fogo. Isto mostra a influência indireta da topografia na propagação do fogo, visto que vai afetar o tipo de combustível e sua disposição no local (Taylor & Skinner, 2003). Maingi & Henry (2007) analisaram também como a elevação afeta a severidade do fogo, observando que elevações superiores estão associadas a uma maior ocorrência de fogos.

3. Dados e métodos

No capítulo de dados e métodos pretende-se representar a área a ser estudada neste trabalho, descrever quais os dados utilizados na realização desta dissertação e a metodologia adotada para atingir os objetivos propostos anteriormente.

3.1 Área de estudo

Este estudo teve como base o fogo de grandes dimensões que deflagrou em junho de 2017, em Portugal. Este incêndio afetou um número elevado de concelhos, sendo estes afetados de formas distintas. O concelho de Pedrógão Grande foi responsável por 61% e o concelho de Góis por 37% dos cerca de 46586 ha de área ardida neste incêndio. A área queimada neste fogo deveu-se à junção de 2 frentes: a de Pedrógão grande, que abrangeu os concelhos de Castanheira de Pera, Figueiró dos Vinhos, Ansião, Alvaiázere, Penela e Sertã e a de Góis, afetando também os concelhos de Pampilhosa da Serra, Oleiros e Arganil.

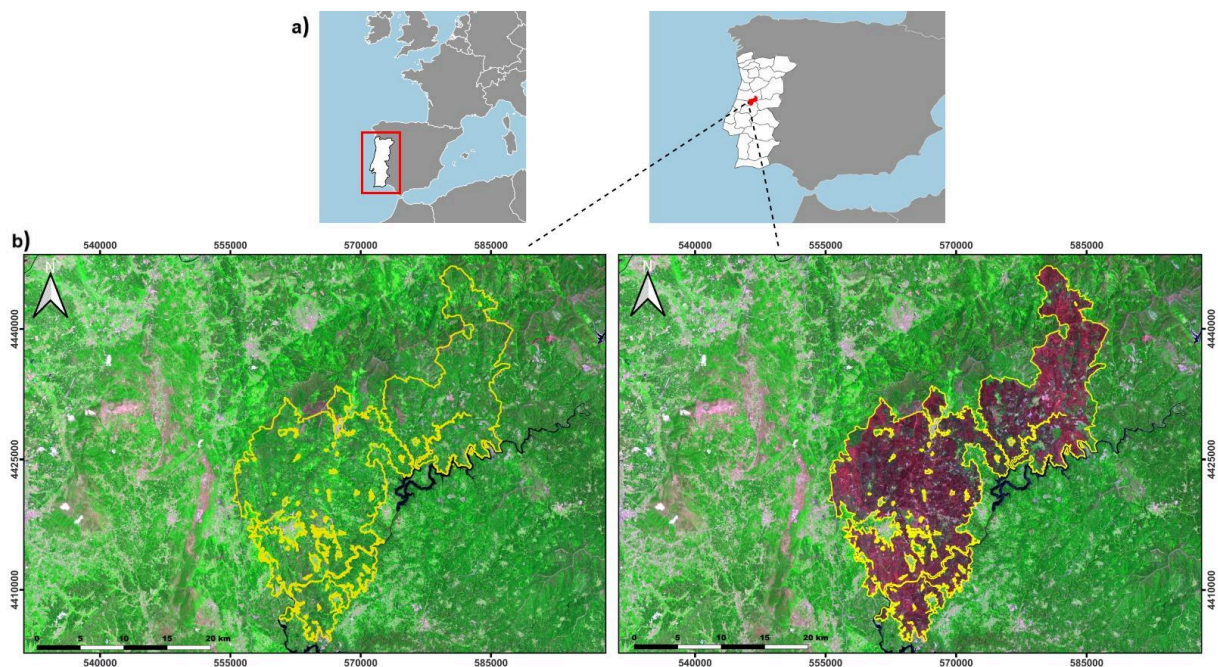


Figura 3.1: Em a) localização da área de estudo e em b) composição Landsat RGB SWIR2-NIR-Red pré (15/06/2017) e pós (1/7/2017) fogo para o incêndio de Pedrógão Grande.

O território afetado por este fogo era maioritariamente constituído por zonas florestais, onde se observavam grandes áreas de floresta de eucalipto e de pinheiro bravo. Para além deste tipo de coberto vegetal, era também possível observar áreas menores de florestas de outras folhosas, zonas agrícolas e matos. Esta área encontra-se sobretudo numa zona de encostas quentes, isto é, zonas com maior incidência de radiação solar. São também observadas algumas zonas topográficas do tipo vale e pico/cume. Segundo os Censos, o concelho de Pedrógão Grande apresentava uma densidade populacional de 30.2 habitantes/km² em 2011, tendo este valor diminuído para 26.3 habitantes/km², sendo por isso considerada uma região com baixa densidade populacional.

As imagens Landsat utilizadas na representação da área de estudo foram obtidas na plataforma Earth Explorer, disponibilizada pelo USGS (Inventário Geológico dos Estados Unidos) (<https://earthexplorer.usgs.gov/>). Foi selecionada a percentagem máxima de cobertura de nuvens de 20% para obter observações pouco nubladas do local de interesse e o satélite de onde se pretende retirar as imagens, sendo neste caso o Landsat 8-9 OLI/TIRS (Operational Land Imager/Thermal Infrared Sensor) Collection 2 Level-2 que fornece imagens da reflectância da superfície atmosféricamente corrigidas e da temperatura da superfície. A área de estudo localiza-se na órbita-ponto 204-32 e as datas das imagens pré e pós-fogo escolhidas foram de 15/06/2017 e 01/07/2017, respectivamente.

Após a escolha das imagens, foi necessário fazer download das bandas necessárias para fazer o compósito RGB de cor falsa, que facilita a observação de áreas queimadas. Neste caso, o compósito utilizado corresponde às bandas SWIR2 (Infravermelho de onda curta 2)-NIR (Infravermelho próximo)-RED, respetivamente, para as duas datas.

A seleção da área ardida foi realizada a partir do mapeamento anual de áreas queimadas para Portugal Continental, realizado pelo Laboratório de Detecção Remota do CEF (Centro de estudos Florestais), que possui uma base de dados do mapa de áreas queimadas em Portugal, também conhecido como Atlas de Fogos, constituída por mapas anuais desde 1975 até 2021 (Oliveira et al., 2011). Utilizando o QGIS (Quantum Geographic Information System) é possível analisar o mapa das áreas queimadas de 2017 e selecionar o fogo a ser analisado, obtendo assim a área queimada para o incêndio de Pedrógão Grande.

3.2 Dados de imagens satélite

Os satélites Landsat têm uma resolução espacial média e diversas bandas espectrais para registar eficientemente o uso e ocupação do solo e documentar mudanças derivadas das alterações climáticas, urbanização, seca, fogos e alterações da biomassa. Nesta dissertação utilizaram-se os satélites Landsat 7 e 8, sendo a harmonização entre as imagens dos diferentes satélites feita automaticamente pelo CCDC. O Landsat 8 foi desenvolvido numa colaboração entre a NASA (Administração Nacional de Aeronáutica e do Espaço) e a USGS. Este satélite foi lançado em fevereiro de 2013 e contém dois instrumentos científicos: o OLI e o TIRS. As tabelas 1 e 2 mostram as bandas disponíveis no satélite Landsat 7 e 8, respectivamente, o comprimento de onda, a resolução espacial e o seu uso principal no mapeamento da superfície do solo.

Tabela 3.1: Bandas Landsat 7 ETM+ (Enhanced Thematic Mapper), o seu comprimento de onda e resolução e os seus usos. Fonte: USGS.

Banda	Comprimento de onda (µm)	Resolução (metros)	Útil para o mapeamento
Banda 1- Blue	0,45-0,52	30	Batimetria, diferenciar solo de vegetação e vegetação conífera de caducifólia
Banda 2- Green	0,52-0,60	30	Vigor da vegetação
Banda 3- Red	0,63-0,69	30	Distingue encostas de vegetação
Banda 4- NIR (Infravermelho próximo)	0,77-0,90	30	Realça o conteúdo de biomassa e as linhas costeiras
Banda 5- SWIR (Infravermelho de onda curta)	1,55-1,75	30	Distingue o teor de humidade do solo e da vegetação e penetra nuvens finas
Banda 6- Térmica	10,40-12,50	60	Mapa térmico e estimativa humidade do solo
Banda 7- Infravermelho médio	2,09-2,35	30	Rochas alteradas hidrotérmicamente associadas a depósitos minerais
Banda 8- Pancromático	0,52-0,90	15	Melhor definição de imagem

Tabela 3.2: Bandas Landsat 8 OLI e TIRS, o seu comprimento de onda e resolução e os seus usos. Fonte: USGS

Banda	Comprimento de onda (µm)	Resolução (metros)	Útil para o mapeamento
Banda 1- Aerossóis costeiros	0,43–0,45	30	Estudos costeiros e aerossóis
Banda 2- Blue	0,45–0,51	30	Batimetria, diferenciar solo de vegetação e vegetação conífera de caducifólia
Banda 3- Green	0,53–0,59	30	Vigor da vegetação
Banda 4- Red	0,64-0,67	30	Distingue encostas de vegetação
Banda 5- NIR	0,85-0,88	30	Realça o conteúdo de biomassa e as linhas costeiras
Banda 6- SWIR 1	1,57-1,65	30	Distingue o teor de humidade do solo e da vegetação e penetra nuvens finas
Banda 7- SWIR 2	2,11-2,29	30	Melhoria na distinção do teor de humidade do solo e da vegetação e penetra de nuvens finas
Banda 8- Pancromático	0,50-0,68	15	Melhor definição de imagem
Banda 9- Cirros	1,36-1,38	30	Melhoria na deteção da contaminação de nuvens cirros
Banda 10- TIRS 1	10,60-11,19	100	Mapa térmico e estimativa da humidade do solo
Banda 11- TIRS 2	11,50-12,51	100	Melhoria no mapa térmico e na estimativa da humidade do solo

Ao representar os dados de um sensor num espaço multidimensional, onde cada eixo é uma banda espectral, os alvos (p.e., vegetação, solo, etc) apresentam distribuições características. As transformações tasseled cap (TCT) consistem em transformações lineares que realçam determinadas características nas imagens satélite, com base nas transformações desses eixos.

As TCT não só diminuem a dimensionalidade dos dados, como também transformam ortogonalmente as bandas originais num novo conjunto de eixos associados com

características físicas, originando os três componentes da TCT: Brightness, Greenness e Wetness. Primeiro, é definida uma rotação para separar a vegetação de características não vegetadas, mantendo a propriedade ortogonal entre a Brightness e Greenness. De seguida, os componentes Greenness e Wetness separaram ortogonalmente a água de características de vegetação. Por fim, a rotação ortogonal entre Brightness e Wetness foi implementada de forma a separar água de características de vegetação e não vegetação (Zhang et al., 2002).

A componente Greenness, usada neste trabalho, corresponde à medida do contraste entre a banda NIR e as bandas do visível. Esse contraste ocorre devido à dispersão de radiação infravermelha, resultante da estrutura celular da vegetação e a absorção da radiação do visível pelos pigmentos da planta (Baig et al., 2014). As componentes da TCT estão disponíveis como input no CCDC e não precisam ser calculadas separadamente.

3.3 Google Earth Engine (GEE)

O GEE é uma plataforma que utiliza a computação em nuvem, consistindo num catálogo de dados com dimensão de vários petabytes, prontos para análise, em conjunto com um serviço computacional de alta performance, intrinsecamente paralelo. Esta plataforma apresenta diversas vantagens que levam ao seu uso, e.g., tem um catálogo vasto de imagens de satélite disponíveis, o que leva a economizar muito tempo e espaço de armazenamento do disco, visto que não é necessário descarregar as imagens. Para além disto, o GEE permite realizar o processamento na nuvem, o que possibilita que o utilizador realize as tarefas de elevado custo computacional sem necessitar de equipamentos tão avançados (Zhang et al., 2021).

Através desta plataforma, foi possível utilizar o algoritmo CCDC. Especificando as variáveis que se pretendiam utilizar, extraíram-se informações sobre as mudanças observadas nas séries temporais e os coeficientes necessários para a classificação a realizar posteriormente.

3.4 Métodos

Na figura é possível observar-se um esquema da metodologia aplicada. Primeiramente, define-se a área de interesse utilizando mapas de fogos anteriores para delimitar a área do incêndio que se pretende estudar. Posteriormente, é feita uma segmentação temporal dos períodos pré e pós-fogo. Através desta segmentação, é extraído o coeficiente INTP (Intercept) da banda Greenness no período pré-fogo e os coeficientes INTP e SLP (Slope) nos 8 intervalos de tempos após o fogo, o que permite fazer o cálculo do Δ INTP a utilizar na classificação das trajetórias de recuperação da vegetação. Em paralelo, são utilizadas imagens do pré e pós-fogo para se calcular a severidade do fogo. A severidade do fogo e outros dados ambientais auxiliares são utilizados na análise do comportamento dos fatores determinantes associados ao fogo estudado. Cada uma das etapas mencionadas será melhor descrita nas secções seguintes.

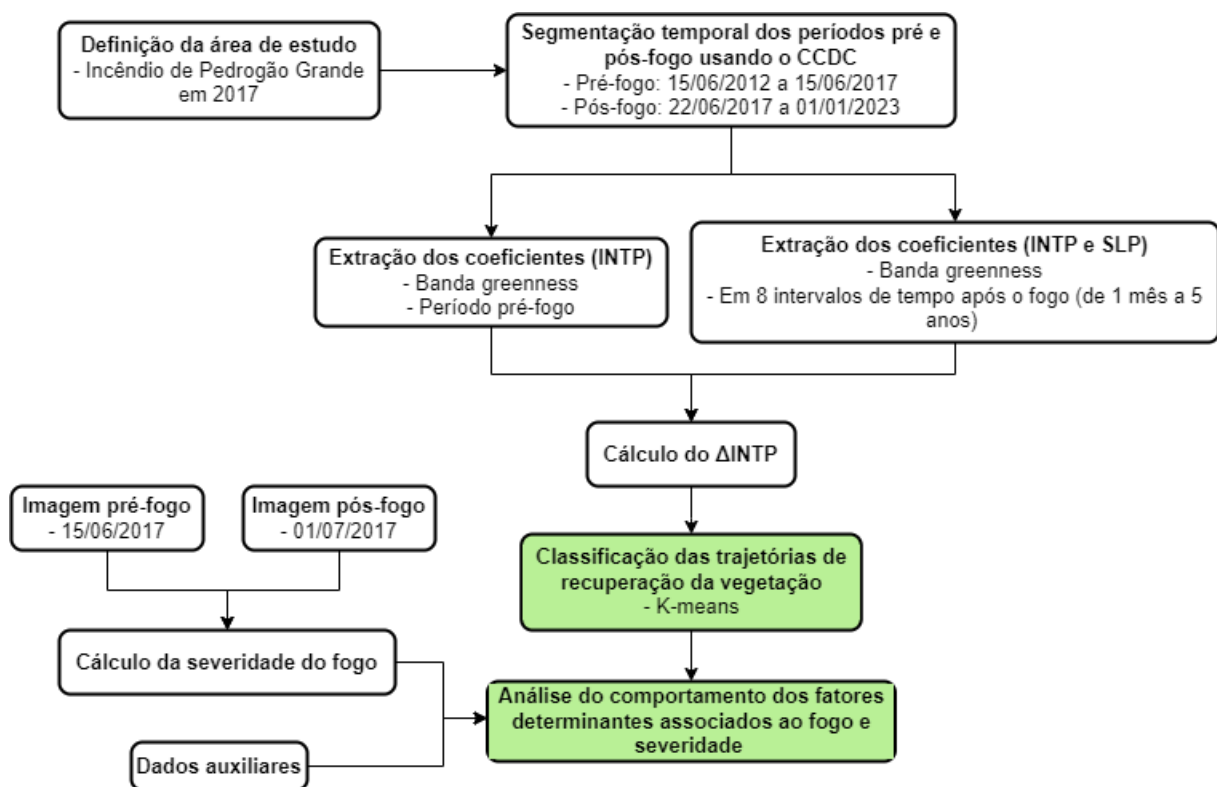


Figura 3.2: Esquema da metodologia aplicada para a realização deste estudo.

3.4.1 Continuous Change Detection and Classification (CCDC)

As mudanças espectrais são detetadas ao nível do pixel, sendo testadas para quebras estruturais em séries temporais de reflectância. No GEE, utilizando o CCDC, este processo é denominado por “segmentação temporal”, dado que as séries temporais de cada pixel são segmentadas de acordo com períodos de reflectância únicos, sendo isto realizado devido ao ajustamento de modelos de regressão para as bandas espectrais na série temporal. Este modelo de ajuste começa no início da série temporal e vai avançando no tempo com uma abordagem online, atualizando o modelo a cada observação/imagem nova para detetar a mudança. Os coeficientes originados dos modelos de regressão podem ser usados para prever observações futuras. Se os resíduos das observações excederem um limite estatístico em várias observações consecutivas, o algoritmo sinaliza que ocorreu uma mudança. Depois da mudança, um novo modelo de regressão é ajustado e o processo continua até ao fim da série temporal (Arévalo e Olofsson 2013).




Figura 3.3: Série temporal Landsat a demonstrar um evento de perda florestal de 2017 em Pedrógão Grande, Portugal. Os pontos azuis correspondem aos valores observados na banda Greenness e as linhas coloridas representam os segmentos temporais do CCDC. Apesar da possibilidade de detectar um máximo de 6 segmentos, foram apenas encontrados 3 segmentos para este pixel.

De forma a simplificar a utilização do CCDC, foi utilizada a API (Application Programming Interface) ('users/parevalo_bu/gee-ccdc-tools:ccdcUtilities/api') do GEE que facilita a implementação do CCDC. Para a realização deste trabalho, foram utilizados dados de imagens satélite provenientes dos Landsat 7 e 8, filtrados para nuvens, sombras de

nuvens, nevoeiro e pixéis saturados radiometricamente. O shapefile da área de estudo selecionada foi inserido no GEE para limitar a região em que seriam realizadas as segmentações temporais. Foram também selecionadas a banda e as datas iniciais e finais a utilizar. Após se obter a coleção de imagens, é necessário especificar os parâmetros do CCDC a utilizar, podendo estes ser observados na tabela 3.

Tabela 3.3: Parâmetros do CCDC, respetivas descrições e valores utilizados neste estudo.
Fonte: openMRV

Parâmetros	Descrição	Parâmetros utilizados
breakPointBands	Bandas a usar para calcular testes estatísticos e testar para alteração espectral	“GREENNESS”
minObservations	Número de observações consecutivas que excedem o valor limite para sinalizar uma mudança	6
chiSquare Probability	Limite estatístico que é calculado através dos resíduos do modelo e que segue uma distribuição de Qui-quadrado	0.99
minNumOfYears Scaler	Número de anos após o qual um novo modelo é ajustado durante o período de treino	1,33
dateFormat	Formato das datas	Anos decimais
lambda	Valor a utilizar para o ajuste da regressão LASSO	0,002
maxIterations	Iterações máximas para realizar um ajuste de regressão LASSO	10000

A regressão LASSO referida anteriormente, é uma técnica de regularização, utilizada no processo de ajuste do modelo do CCDC para reduzir o sobreajuste da série temporal.

Após correr o CCDC com os parâmetros acima definidos, são obtidos diversos coeficientes. Estes coeficientes e as suas respetivas descrições podem ser observados na Tabela 4.

Tabela 3.4: Coeficientes do CCDC e a sua respetiva descrição. Fonte: Adaptado de Arévalo e Olofsson (2023).

Coeficientes	Descrição
Intercept (INTP)	Valor da banda para o t médio do segmento temporal
Slope (SLP)	Inclinação da reta da regressão - tendência no longo prazo do conjunto de valores para a banda selecionada
Amplitude (Sin)	Variabilidade devido à sazonalidade
Phase (Cos)	Variabilidade fenológica
Root Mean Square Error (RMSE)	Erro quadrático médio de cada segmento temporal e banda
Magnitude	Resíduos normalizados durante o período de mudança, nos segmentos que detectaram mudança
tStart	Data de início de cada segmento temporal
tEnd	Data final de cada segmento temporal
tBreak	Data de “quebra” do segmento temporal quando é detetada uma mudança
numObs	Número de observações usadas em cada segmento temporal
changeProb	Valor que representa a probabilidade de mudança para cada banda usada para deteção de mudanças

Os coeficientes dos segmentos temporais podem ter vários usos, como a classificação de trajetórias de recuperação da vegetação. Cada segmento temporal pode ser descrito como uma função harmónica com “intercept”, “slope” e três pares de senos e cossenos que permitem que os segmentos temporais representem a sazonalidade que ocorre em diferentes escalas temporais. Estes coeficientes, em conjunto com o RMSE, que é obtido comparando cada valor Landsat previsto e real, são obtidos quando se corre o CCDC.

Após se determinarem as datas de interesse, é necessário especificar a banda usada como input no algoritmo CCDC para definir os segmentos temporais. Também é indicado o número máximo de segmentos temporais por cada píxel, sendo que não é obrigatório o CCDC identificar esse número de segmentos temporais.

Após a execução da segmentação temporal, é possível extrair os coeficientes desejados através da API, referida anteriormente, do GEE da biblioteca do GEE, definindo-se os seguintes parâmetros ordenados:

- Banda a selecionar: GREENNESS.
- Lista de coeficientes a extrair: INTP, SLP.
- Definição do comportamento a utilizar se não houver nenhum segmento temporal para a data pretendida: Utiliza-se o valor do segmento imediatamente depois da data desejada se nenhum segmento intersectar a data diretamente.

Como está representado na Tabela 4, o INTP extraído do CCDC representa o valor da banda analisada no tempo médio do segmento. Entretanto, foi necessário encontrar os valores das bandas para outras datas, além do tempo médio do segmento, para acompanhar devidamente a recuperação da vegetação após o fogo. Para isso, utilizou-se a equação da reta de regressão $y=ax+b$, sendo $y = \text{INTP}$, $a = \text{SLP}$ e $x = \text{tempo médio}$, para encontrar o valor de b . Obtendo a equação da reta de cada segmento temporal, foi possível calcular o INTP (y da equação de regressão) para outras datas de interesse além do tempo médio. As datas de interesse selecionadas para o pós-fogo foram as seguintes: 22-07-2017 (1 mês), 22-09-2017 (3 meses), 22-12-2017 (6 meses), 22-06-2018 (1 ano), 22-06-2019 (2 anos), 22-06-2020 (3 anos), 22-06-2021 (4 anos) e 22-06-2022 (5 anos). De seguida foi realizado o cálculo do INTP pré-fogo, definindo-se como data limite um período anterior à ocorrência do fogo, sendo escolhida a data 15-06-2017 e utilizando os mesmos parâmetros do CCDC a banda GREENNESS e selecionando apenas o coeficiente INTP.

Foi necessário dividir a área de estudo em 4 parcelas, de forma a ser possível correr o CCDC sem atingir o limite de memória. As 4 imagens obtidas, de cada parcela, contêm 32 bandas: INTP, SLP, Sin (seno) e Cos (Cosseno) para a banda GREENNESS nas 8 datas pós-fogo e apenas uma banda de intercept para o pré-fogo. Estas imagens vão ser exportadas para o google drive, de forma a ser possível fazer o download das mesmas e trabalhá-las no QGIS para se realizar a classificação pretendida.

É necessário tornar as 4 imagens obtidas numa só, sendo inicialmente realizada uma correção utilizando a ferramenta “ManageNoData” disponível no plugin OTB (OrfeoToolbox) (Grizonnet et al., 2017) do QGIS, responsável por tornar os valores “nodata” em valor 0. Posteriormente, fez-se a junção das 4 imagens obtidas através da ferramenta “Merge” do plugin GDAL (Geospatial Data Abstraction Library) existente no QGIS. Este processo foi realizado para as 4 imagens dos coeficientes pós-fogo e para o INTP pré-fogo.

3.4.2 Classificação das trajetórias de recuperação da vegetação no pós-fogo

Antes de se realizar a classificação, utilizou-se a calculadora raster do QGIS para calcular a variação dos valores de INTP desde o período anterior ao fogo até ao período posterior ao fogo para cada uma das 8 datas acima referidas.

$$\Delta\text{INTP} = \text{INTP}_{\text{pré-fogo}} - \text{INTP}_{\text{pós-fogo}} \quad (3.1)$$

De seguida utilizou-se a ferramenta “Junção” do QGIS para se fazer um empilhamento das 8 imagens de ΔINTP obtidas, para ser utilizada esta imagem como input na classificação.

A classificação a realizar sobre as imagens obtidas na secção anterior é não supervisionada, do tipo K-means. Este tipo de classificação corresponde a um método de partição que é usado para separar os dados em k clusters mutuamente exclusivos, tendo como objetivo minimizar a variação observada dentro dos clusters. Neste tipo de classificação, começa-se por separar os dados em k grupos, sendo o k predefinido pelo utilizador, de seguida são escolhidos k pontos, aleatoriamente, como centro dos clusters, seguido da atribuição de um pixel ao centro de cluster mais próximo, de acordo com a distância euclidiana e posteriormente calcula-se a média de todos os objetos em cada cluster. Por fim, são repetidos todos estes passos até que todos os pixels sejam atribuídos a algum cluster (Nithya et al., 2017). Esta classificação foi realizada no QGIS, utilizando a ferramenta “KMeansClassification” disponível no OTB (Grizonnet et al., 2017). Para escolher o número de classes da trajetória de recuperação da vegetação a obter (k), testou-se a classificação para 3, 5, 7 e 10 classes, de forma a perceber qual o número de classes mais adequado.

Através de uma análise visual das classificações resultantes, decidiu-se prosseguir com a classificação com 5 classes. Contudo, o mapa de classificação é composto por 4 classes uma vez que uma das classes detetou somente valores no data e resíduos de corpos de água e foi excluída das análises. Depois de realizada a classificação, é necessário converter a imagem raster para vetorial, onde se vai utilizar a opção “Selecionar por atributo” para selecionar as diferentes classes e de seguida a opção “Guardar elementos selecionados como...” para se obter as áreas ocupadas por cada classe de recuperação.

Para duas das classes resultantes desta classificação, foi escolhido um ponto para exemplificar o comportamento da série temporal, usando o API(<https://parevalo-bu.users.earthengine.app/view/visualize-ccdc>) (Arévalo et al., 2020).

3.4.3 Análise dos coeficientes do CCDC

Foi realizada uma análise dos coeficientes resultantes do CCDC de forma a perceber os padrões e tendências observados nas imagens para cada classe de recuperação. Esta análise foi realizada para os coeficientes “INTP” e “SLP” para a banda “GREENNESS” nas 8 datas referidas.

O limite de cada uma das quatro classes foi usado para recortar o raster dos coeficientes INTP e SLP da banda GREENNESS. De seguida, é utilizada a ferramenta “Píxeis raster para pontos” do QGIS para as bandas dos coeficientes a serem estudados das 8 imagens raster, obtendo-se assim os valores dos coeficientes INTP e SLP para a banda “GREENNESS” em cada pixel para criar os gráficos do tipo “Box and Whiskers” para os diferentes coeficientes, bandas e classes. É também realizada uma correção de forma a diminuir o número de outliers observados nos boxplots. Para isso, começa-se por calcular o IQR (Intervalo interquartil) através da diferença entre o 1º e o 3º quartil, de seguida é necessário subtrair $1.5 \times \text{IQR}$ ao 1º quartil para obter o limite de valores inferior e somar $1.5 \times \text{IQR}$ ao 3º quartil para obter o limite de valores superior do boxplot.

3.4.4 Análise da influência da severidade do fogo na recuperação da vegetação

Para estimar a severidade do fogo, é fundamental o cálculo do dNBR (Differenced Normalized Burn Ratio). Para o cálculo deste índice, são necessários valores de NBR (Normalized Burn Ratio) antes e após o fogo. O NBR permite destacar áreas queimadas em zonas de grandes fogos e é calculado através da seguinte fórmula:

$$NBR = \frac{NIR-SWIR2}{NIR+SWIR2} \quad (3.2)$$

As áreas queimadas apresentam valores de reflectância reduzidos nas bandas NIR e valores elevados de reflectância nas bandas SWIR. A diferença entre os valores de NBR no pré e pós-fogo, respetivamente, serve para calcular os valores de dNBR, que vão ser utilizados para estimar a severidade do fogo.

$$dNBR = NBR_{Préfogo} - NBR_{Pósfogo} \quad (3.3)$$

Valores elevados de dNBR indicam uma maior severidade do fogo, ou seja, os danos causados pelo fogo foram mais severos. De forma a obter os melhores resultados possíveis, é necessário conjugar a interpretação dos valores de dNBR com amostragem de campo, dado que os valores de dNBR podem variar de caso para caso. Contudo, o USGS propôs uma tabela de classificação para interpretar a severidade do fogo, sendo essa a seguinte:

Tabela 3.5: Níveis de severidade obtidos a partir do cálculo do dNBR, proposto pelo USGS.

Fonte: UN Spider

Nível de severidade	Intervalo de valores do dNBR (sem escala)
Promoção da recuperação elevada (pós-fogo)	-0,500 até -0,251
Promoção da recuperação reduzida (pós-fogo)	-0,250 até -0,101
Área não ardida	-0,100 até 0,99
Severidade baixa	0,100 até 0,269
Severidade Moderada-baixa	0,270 até 0,439
Severidade Moderada-elevada	0,440 até 0,659
Severidade elevada	0,660 até 1,300

Para realizar esta análise sobre o fogo da área de estudo, utilizou-se a ferramenta “v.clean” disponível no plugin “GRASS” do QGIS para solucionar erros de topologia do shapefile. Posteriormente, fez-se o recorte do raster das imagens Landsat pré e pós-fogo com shapefile da área de estudo, utilizando a opção “recortar raster por camada de

máscara”. O passo seguinte é o cálculo do dNBR através da “calculadora de rasters” do QGIS, escrevendo a fórmula que se pode observar na figura seguinte.

Expressão da calculadora de rasters

```
( ("Area_pre@2" - "Area_pre@1" ) / ( "Area_pre@2" + "Area_pre@1" ) ) -  
( ("Area_pos@2" - "Area_pos@1" ) / ( "Area_pos@2" + "Area_pos@1" ) )
```

Figura 3.4: Fórmula de cálculo do dNBR na calculadora de rasters do QGIS.

A “Area_pre@2” e “Area_pre@1” representam as bandas do NIR e SWIR2, respetivamente, no pré-fogo e a “Area_pos@2” e “Area_pos@1” representam as bandas do NIR e SWIR2, respetivamente, no pós-fogo. As bandas de NIR e SWIR estão representadas pelo número 2 e 1, respetivamente, devido às bandas utilizadas no compósito R(SWIR2)-G(NIR)-B(RED). Como resultado final, obtém-se uma imagem raster dos valores de dNBR para a área de estudo.

Depois de se obter esta imagem, pretende-se criar um gráfico que permita analisar o dNBR para as diferentes classes provenientes da classificação realizada anteriormente. Deve-se então utilizar a ferramenta “reclassificar por tabela” do QGIS, de forma a que seja atribuído um valor (1, 2, 3 e 4) a cada pixel para facilitar a associação às classes de severidade do fogo, como se observa na figura 3.5.

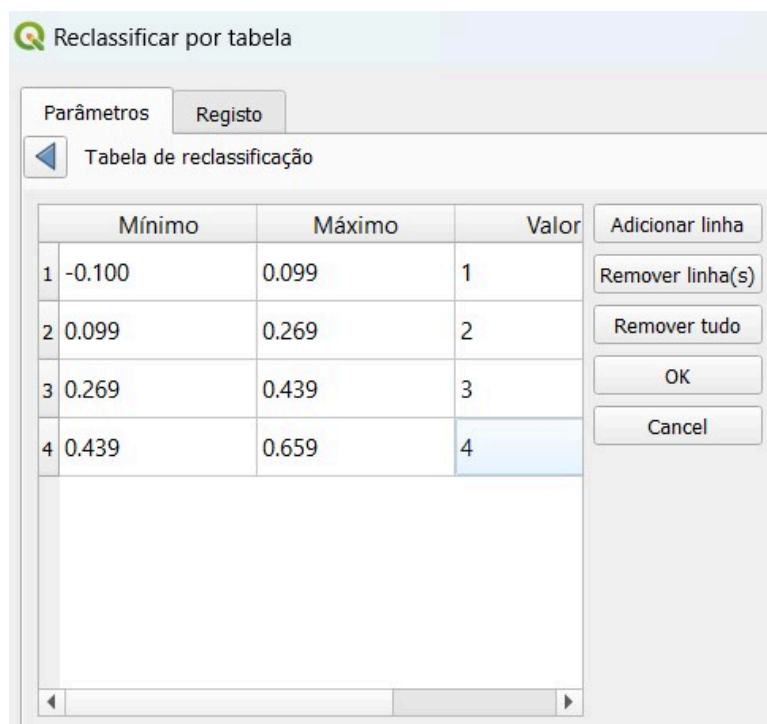


Figura 3.5 Reclassificação por tabela realizada para os níveis de severidade do fogo.

Utilizando os shapefiles de cada classe, obtidos na etapa anterior, vai ser feito um “recorte” no raster do dNBR reclassificado utilizando a ferramenta “recortar raster por camada de máscara”, o que irá resultar num raster de dNBR para cada classe. Nos rasters obtidos, vai ser realizado o “Relatório de valores únicos da camada raster”, de forma a obter informações da contagem de píxeis e a área para cada valor de nível de severidade.

3.4.5 Análise da influência do uso e ocupação do solo na recuperação da vegetação

Foi utilizada a COS (Carta de Uso e Ocupação do Solo) 2015 (DGT - Direção Geral do Território, 2015) para obter informações sobre o uso e ocupação do solo para o território de Portugal Continental. O shapefile transferido encontra-se, inicialmente, no sistema de coordenadas “EPSG:3763 - ETRS89 / Portugal TM06” sendo necessário projetá-lo para o sistema usado no projeto, que corresponde ao “EPSG:32629 - WGS 84 / UTM zone 29N”. Na figura seguinte é possível observar-se os tipos de uso e ocupação do solo para a área de estudo, estando apenas representadas as classes que representam pelo menos 2% da área de estudo.

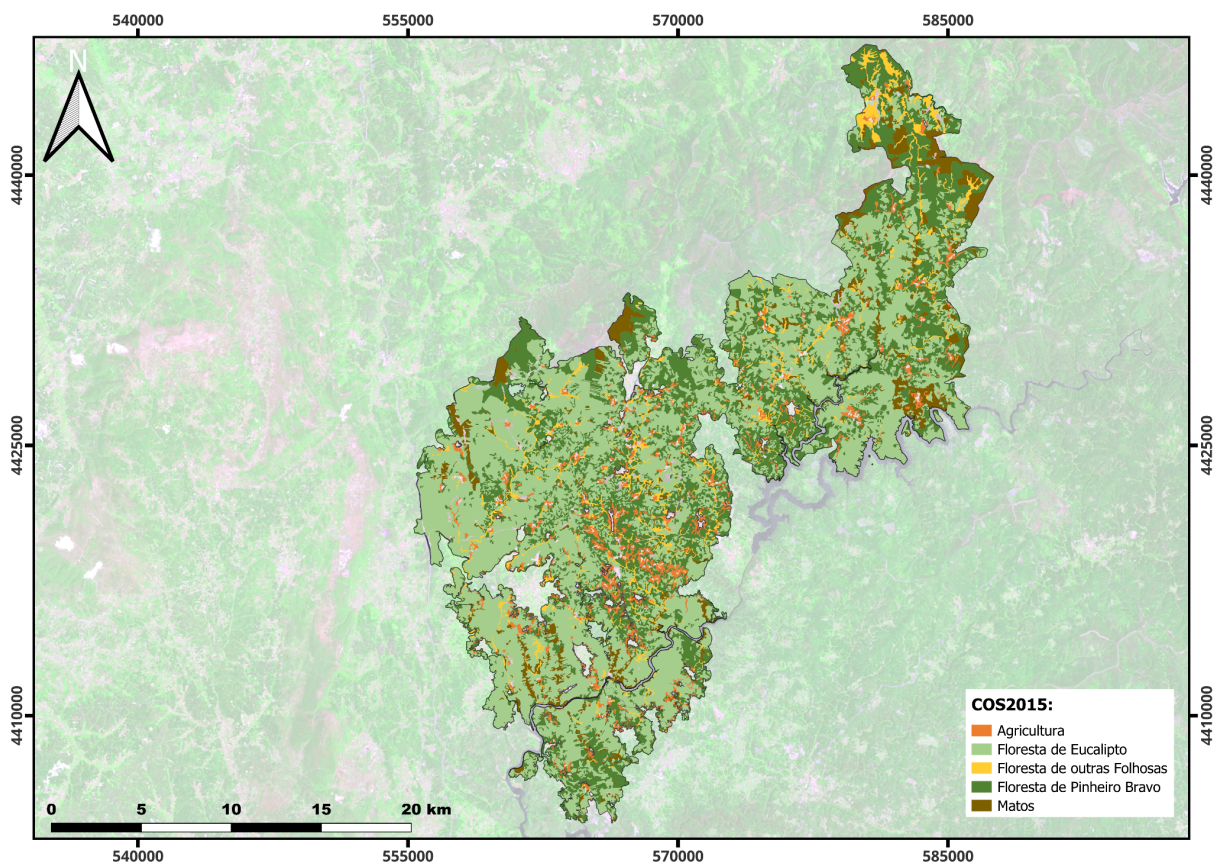


Figura 3.6: Mapa do uso e ocupação do solo. Apenas estão representadas as classes que ocupam pelo menos 2% da área de estudo.

O shapefile do uso e ocupação do solo vai ser recortado com os shapefiles das quatro classes obtidas anteriormente, utilizando a ferramenta “recortar” do QGIS, que permite fazer o recorte entre duas camadas vetoriais. Este shapefile contém quatro níveis de legenda do uso e ocupação do solo, sendo o primeiro mais simples (p.e agricultura e florestas) e o quarto mais detalhado (p.e vinhas e florestas de sobreiro). Para facilitar o cálculo da área de cada uso e ocupação do solo para as diferentes classes, utiliza-se a ferramenta “Dissolver”, que utiliza os níveis de legenda para agrupar todos os polígonos num só, de acordo com o nível selecionado. Neste estudo foi utilizado o nível 1 para as áreas não florestais e o nível 4, mais detalhado, para as áreas de floresta.

Para fazer o cálculo da área, é utilizada a ferramenta “calculadora de campo”, disponível na tabela de atributos, onde se escreve a fórmula observada na figura 3.7, sendo a “\$area” calculada em m² e dividida por 10000 para obter o valor em ha da área dos polígonos, de acordo com as legendas observadas nos shapefiles do COS 2015 “dissolvidos” para cada classe obtida pela classificação realizada.

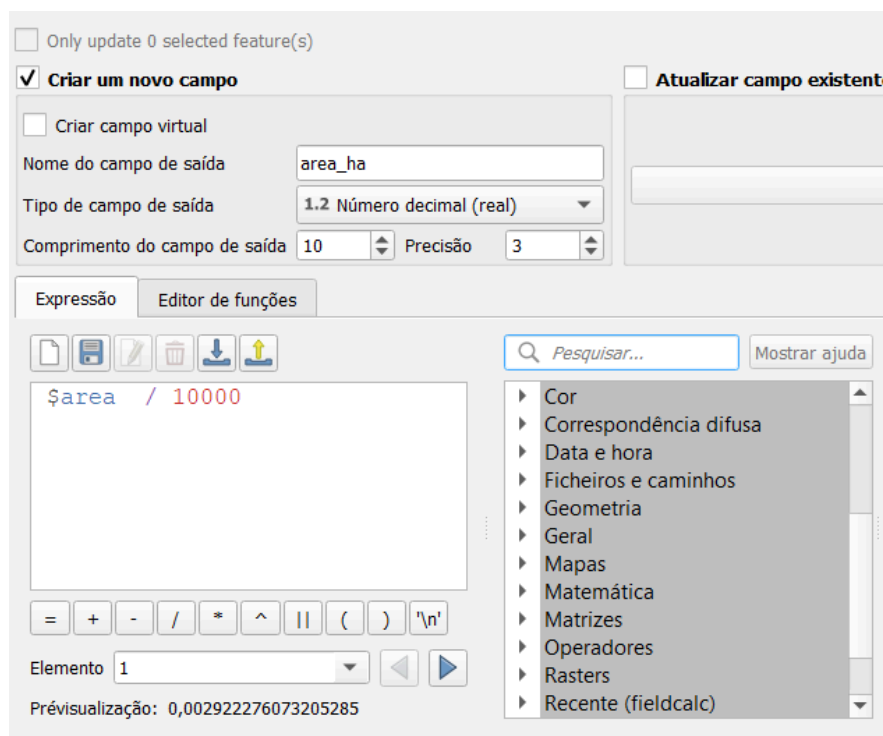


Figura 3.7: Fórmula e parâmetros usados no cálculo da área dos polígonos.

Os valores observados são depois utilizados para criar um gráfico que representa a percentagem de área de cada tipo de uso e ocupação do solo para as diferentes classes de recuperação. Serão considerados usos e ocupação do solo que representem valores de pelo menos 2% da área total em estudo.

3.4.6 Análise da influência que a ocorrência de fogos anteriores tem na recuperação da vegetação

De forma a avaliar como a ocorrência de fogos anteriores iria afetar a área ardida de interesse, começa-se por fazer o download dos shapefiles das áreas ardidas ao longo dos anos com ocorrência no território de Portugal Continental, como havia sido realizado para obter a área de estudo resultante do incêndio de Pedrógão Grande. Na figura seguinte, observa-se o número de anos desde a ocorrência do último fogo, representado em pelo menos 3% da área ardida entre 1984 e 2016 para a área de estudo.

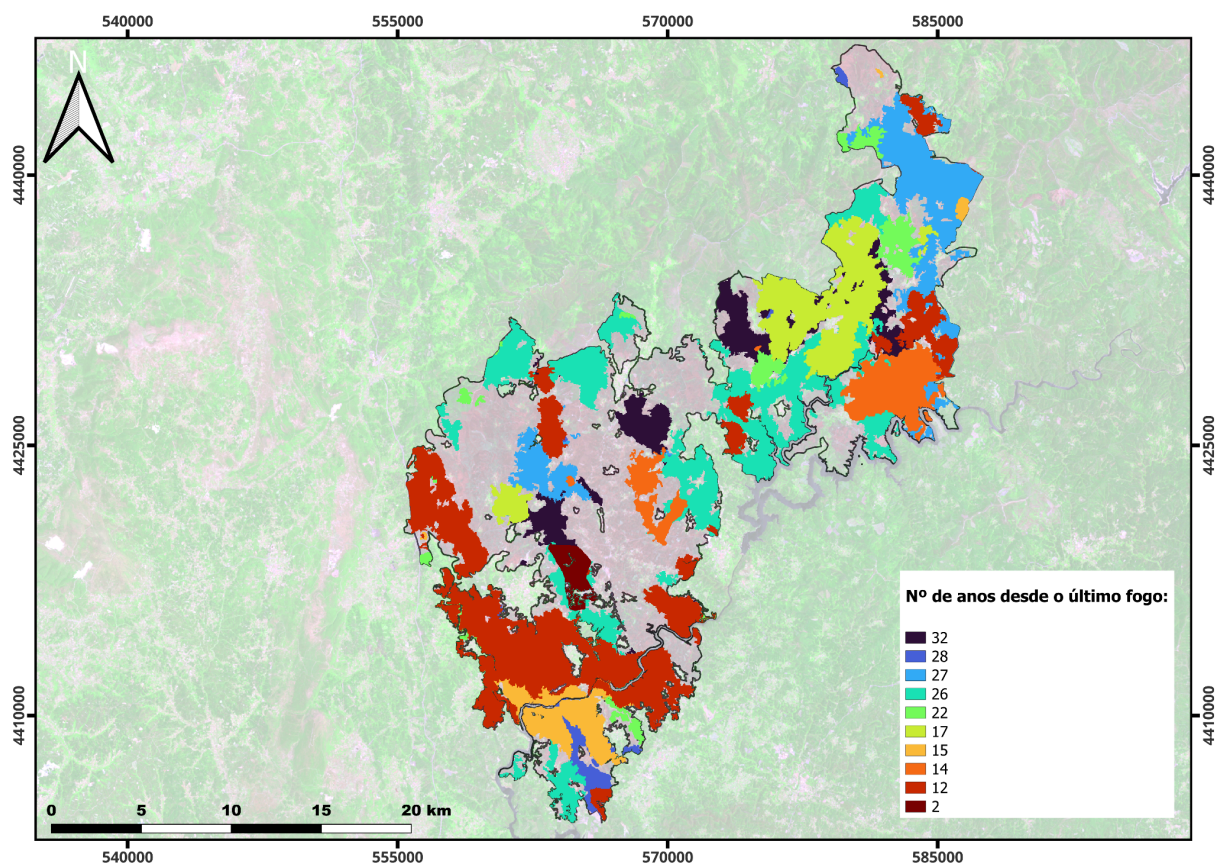


Figura 3.8: Mapa do número de anos desde o último fogo antes de 2017. Apenas foram considerados fogos que representem pelo menos 3% da totalidade da área ardida entre 1984 e 2016 para a área de estudo.

Em áreas que foram queimadas num ano específico e que correspondem aos shapefiles obtidos das classes resultantes da classificação, utiliza-se a ferramenta 'recortar' no QGIS. Isto é realizado para se obterem os polígonos das áreas queimadas desse ano, juntamente com a informação sobre a classe a qual essas áreas pertencem. Este

procedimento é necessário para calcular a área exata dessas regiões. Este processo foi realizado para os shapefiles das áreas ardidas todos os anos, de 1984 até 2016 e para as quatro classes obtidas.

O cálculo da área é realizado utilizando a “calculadora de campo” da tabela de atributos, como foi exemplificado na figura 3.7, utilizando-se também a expressão “sum” dos valores de área para se obter o valor total de área para essa classe no ano em questão. Estes valores de área permitem perceber a percentagem que a área ardida para um determinado ano representa para as diferentes classes. Apenas se vão considerar anos que representem valores de pelo menos 3% de toda a área ardida, na área de estudo, entre 1984 e 2016.

Foi também analisado o número de vezes que cada local da área de estudo ardeu desde 1984 até 2016, considerando os fogos representados na figura 3.8. .

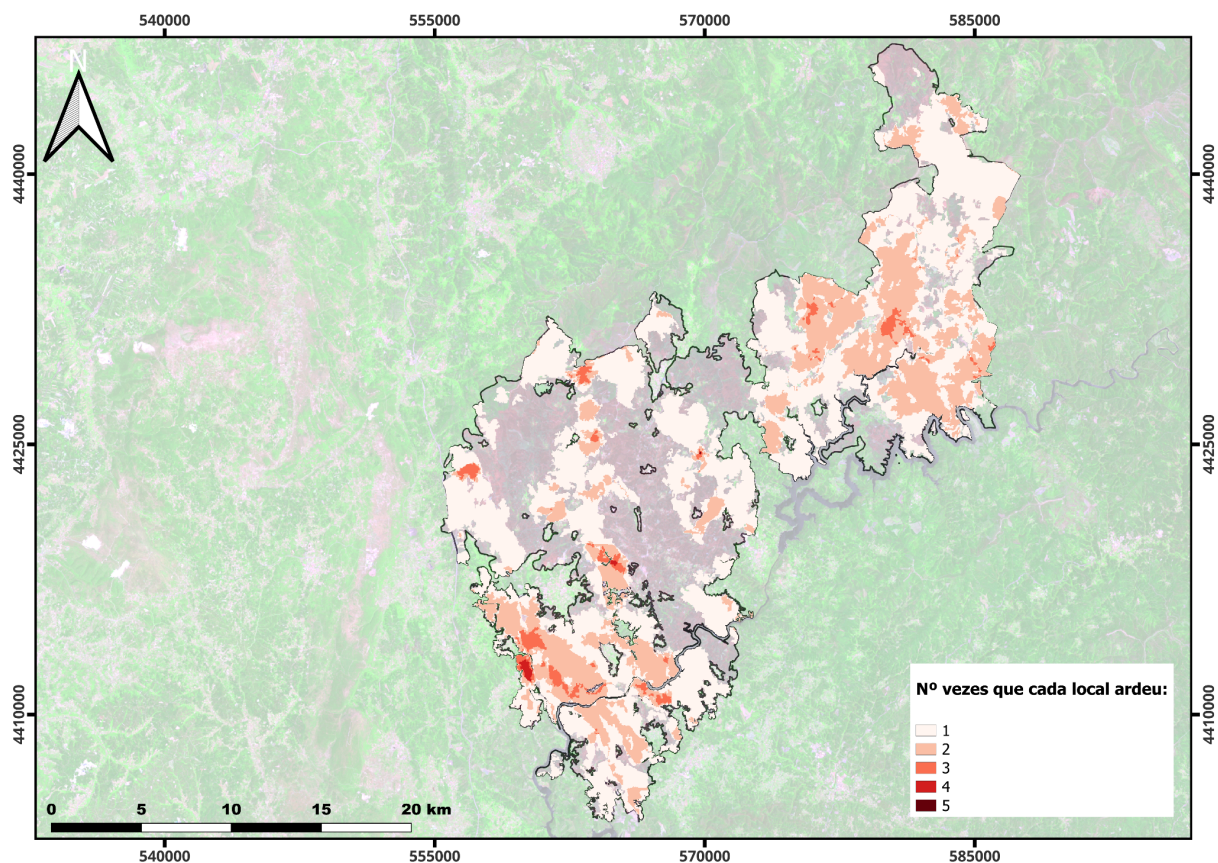


Figura 3.9: Mapa do número de vezes que cada pixel da área de estudo ardeu desde 1984 até 2016. Onde apenas se consideraram fogos que representem pelo menos 3% da totalidade da área ardida entre 1984 e 2016 para a área de estudo.

De forma a ser feita esta análise é necessário começar por transformar os polígonos das áreas ardidas de cada ano, representadas em pelo menos 3% da área queimada em camadas raster, utilizando a ferramenta “Rasterizer” do QGIS. De seguida, foi utilizada a ferramenta “Estatísticas da célula” do QGIS e selecionada a opção “Contagem” de forma a se obter o número de camadas raster que se sobrepõem num certo pixel. Posteriormente, recorta-se esta camada raster obtida com os shapefiles das 4 classes de recuperação da vegetação e por fim utiliza-se a ferramenta “Relatório de valores únicos” para se obter os valores da área do número de vezes que ardeu para cada classe. Tendo os valores da área para cada número de fogos que ocorreram dentro da área de estudo, é possível calcular-se a percentagem do número de ocorrências para cada classe.

3.4.7 Análise da influência da topografia do local na recuperação da vegetação

Para a análise da influência da topografia foi necessário utilizar os dados “ALOS Landform” (Theobald et al., 2015) disponíveis no GEE (https://developers.google.com/earth-engine/datasets/catalog/CSP_ERGo_1_0_Global_ALOS_Landforms), que fornece informações sobre a topografia observada globalmente. Estes dados são frequentemente usados como base para a modelação ecológica de espécies e biodiversidade para informar sobre atividades de planeamento de adaptação climática, devido à incerteza associada com as condições climáticas futuras. Esta caracterização de “landforms” tem uma grande vantagem para a adaptação do clima, porque isola as características que irão, provavelmente, permanecer na paisagem, o que permite aos gestores examinar e focar-se apenas nas variáveis de elevada incerteza, como as projeções de modelos climáticos de precipitação e temperatura (Theobald et al., 2015).

A classificação Landforms foi baseada na posição das encostas e nos processos físicos dominantes. Foram distinguidas quatro posições de encostas que formam uma sequência natural de unidades topográficas ao longo da encosta: pico/cume, encosta superior, encosta inferior e vale. De seguida, foram diferenciadas as posições dentro de cada uma das posições da encosta em função da orientação solar, de forma a mostrar como os processos ecológicos são bastante influenciados pela intensidade da exposição ao sol e ou sombra (Theobald et al., 2015). O tipo de vale foi também diferenciado, dado que, quando este tipo de áreas tem uma elevação máxima 5m acima do nível do mar é considerado um vale (estreito).

À semelhança do que foi feito anteriormente, começa-se por recortar a imagem raster da classificação Landforms pelas quatro classes de recuperação da vegetação obtidas através da classificação. Depois de concluída esta etapa, obtêm-se imagens raster que contêm os dados de topografia para cada classe. Sobre os rasters resultantes, será utilizada a ferramenta “Relatório de valores únicos da camada raster”, tal como foi feito para as imagens de dNBR, para obter a contagem dos píxeis e a área de cada tipo de topografia observado para cada classe.

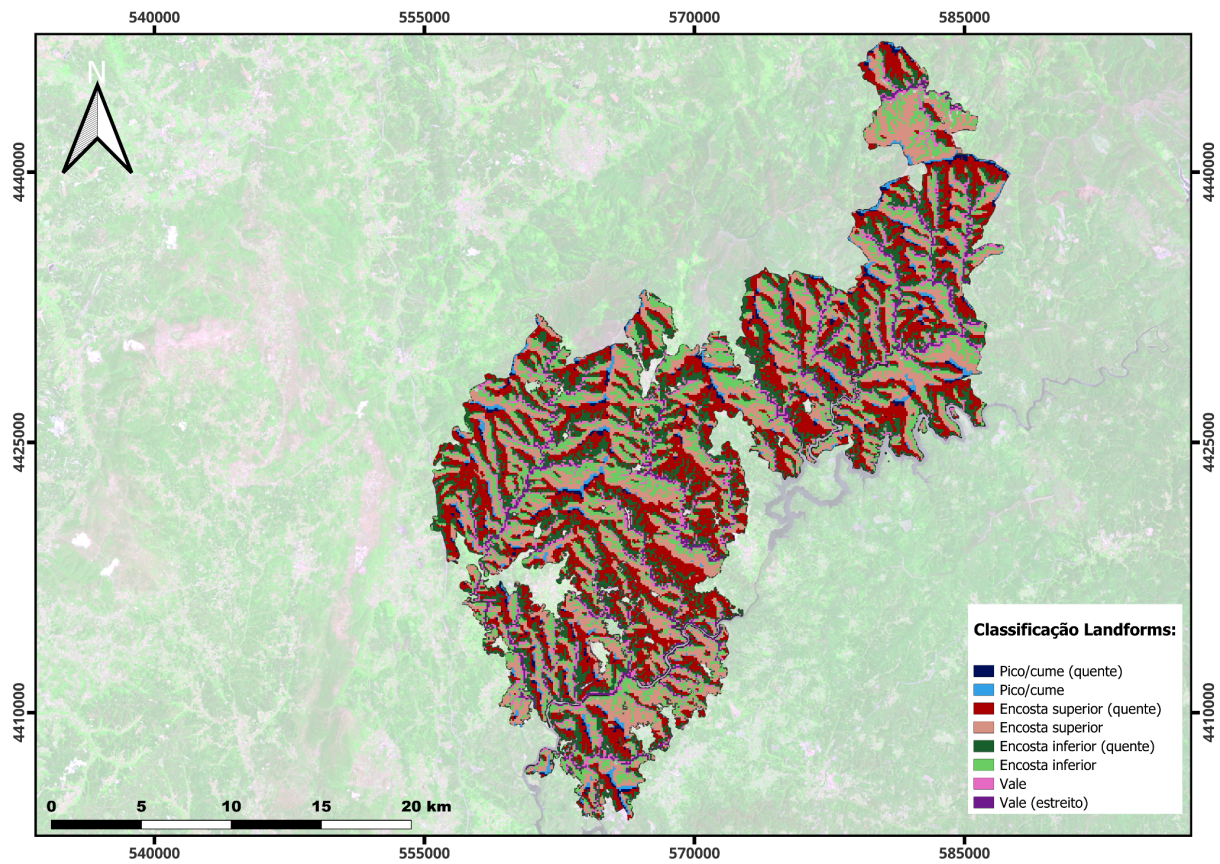


Figura 3.10: Mapa das topografias que ocupam pelo menos 1% da área de estudo.

4. Resultados

4.1 Classificação das trajetórias da recuperação da vegetação no pós-fogo

Foram obtidas quatro classes resultantes da classificação não-supervisionada, do tipo K-means. Analisando a figura 4.1 é possível observar que a classe de recuperação que tem uma maior representação é a classe de início médio e estabilização brusca (IM/EB), seguida pela classe de início médio e estabilização lenta (IM/EL). A classe de início lento e estabilização lenta (IL/EL) é a classe que se encontra menos representada na área de estudo. Esta classe apresenta-se em aglomerados ao longo da área de estudo, parecendo sempre ser envolta pela classe de início rápido e estabilização brusca (IR/EB), que é a segunda classe menos representada. Ao contrário da classe IL/EL, não se observam aglomerados da classe IM/EB, sendo esta representada por pequenas regiões espalhadas pela totalidade da área de estudo.

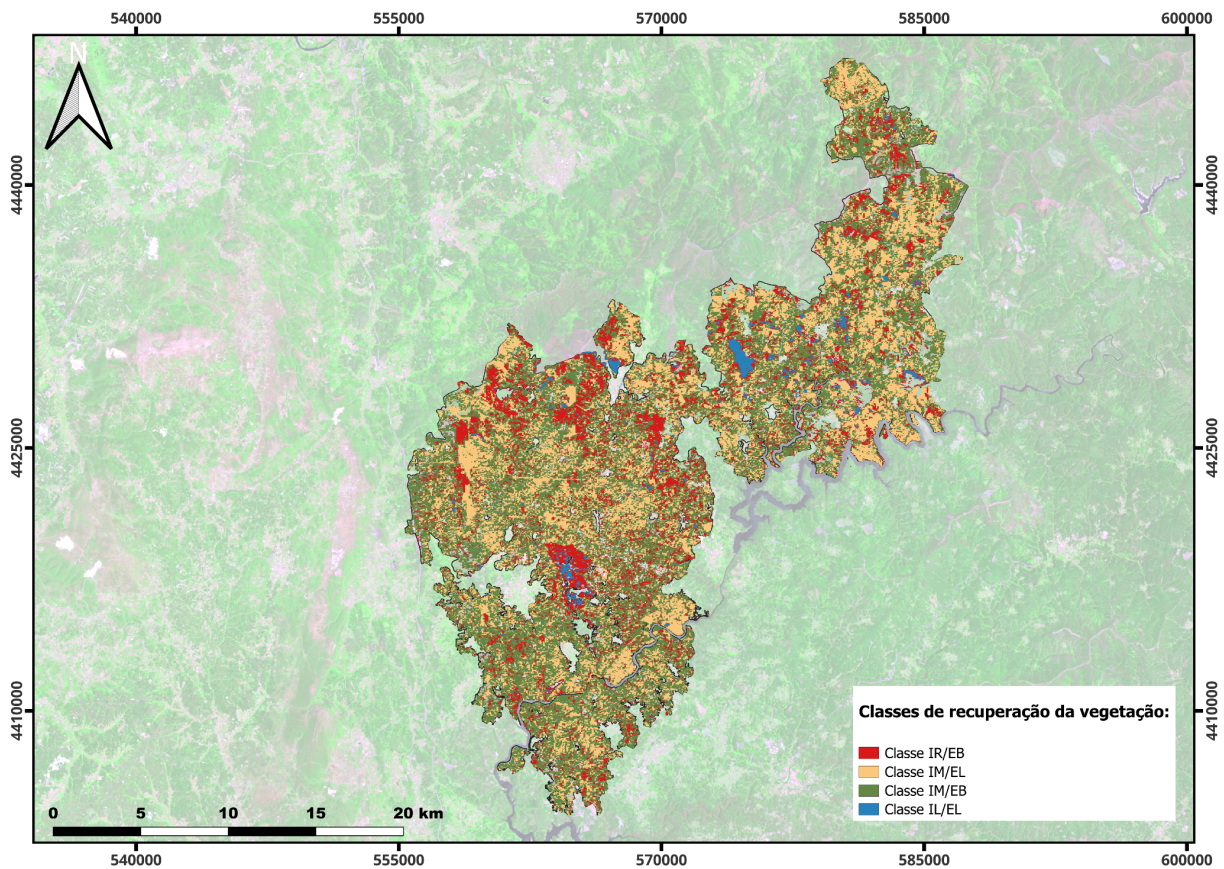


Figura 4.1: Classes resultantes da classificação não supervisionada do tipo k-means.

Foram escolhidas 2 classes (IR/EB e IM/EB), para ilustrar os gráficos que correspondem a séries temporais de classes da classificação da trajetória de recuperação da vegetação no período após o fogo, com a data inicial de 22-06-2017. A classe IR/EB foi escolhida por se tratar de uma classe com uma grande percentagem de área ardida, ao contrário da classe IL/EL, mas que apresenta uma pequena diferença em relação às classes IM/EL e IM/EB na percentagem de área não ardida observada. As classes IM/EL e IM/EB são bastante semelhantes, sendo escolhida a classe IM/EB para esta representação de forma meramente aleatória. Ambos os pixels seleccionados para representar estas 2 classes encontram-se em florestas de Eucalipto, que correspondem ao tipo de uso e ocupação do solo mais comum para esta área de estudo. Os gráficos representativos da classe IR/EB e IM/EL estão representados nas figuras 4.2 e 4.3, respetivamente.




Figura 4.2: Série temporal de Landsat para a banda Greenness e segmentos temporais do CCDC para um pixel da classe IR/EB, localizado numa floresta de eucaliptos, no fogo de Pedrógão Grande. O número máximo de segmentos possíveis é 6, contudo apenas foram encontrados 2 segmentos.

Nos primeiros meses após o fogo, observa-se uma recuperação da vegetação mais rápida, observável pelo declive maior neste período. A partir do primeiro ano após o fogo observa-se uma recuperação contínua menos rápida. Os valores de Greenness foram reduzidos nos primeiros meses, observando-se um aumento regular nestes valores a partir do primeiro ano após o fogo.




Figura 4.3: Série temporal de Landsat para a banda Greenness e segmentos temporais do CCDC para um pixel da classe IM/EB, localizado numa floresta de eucaliptos, no fogo de Pedrógão Grande. O número máximo de segmentos possíveis é 6, contudo apenas foram encontrados 2 segmentos.

A recuperação da vegetação é um pouco mais rápida nos primeiros meses após o fogo, sendo a diferença de declive para os anos seguintes menos destacada que na figura anterior. À semelhança do que se observou na figura 4.2, os valores de Greenness vão aumentando gradualmente, observando-se um aumento regular a partir do primeiro ano após o fogo.

Foi realizada uma análise estatística dos coeficientes SLP e INTP, através de gráficos do tipo Boxplot. O coeficiente SLP foi escolhido para esta análise, dado que os seus valores permitem observar a tendência de recuperação da vegetação, isto é, quanto maior os valores de SLP mais rápida será a taxa de recuperação da vegetação. O coeficiente INTP é também bastante importante porque os seus valores indicam a Greenness, isto é, a densidade de vegetação observada, querendo isto dizer que quanto maior for o valor de INTP maior será a percentagem de coberto vegetal observada. Para facilitar a comparação de valores entre classes foram mantidas as mesmas escalas do eixo dos y, como se observa nas seguintes figuras:

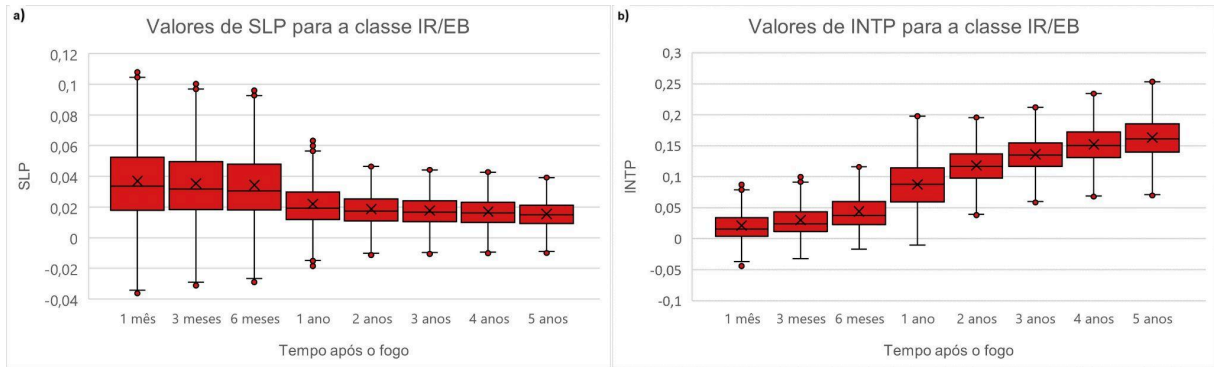


Figura 4.4: Gráficos Boxplot dos coeficientes em a) SLP e em b) INTP da banda Greenness para a classe IR/EB.

Os valores de SLP para a classe IR/EB, nos primeiros 6 meses, são os mais elevados de todas as classes, atingindo valores máximos próximos de 0,11. Assim como os valores de INTP são os mais elevados anos após o fogo, tomando valores máximos próximos de 0,2 1 ano após o fogo e valores superiores a 0,25 5 anos após o fogo. Observa-se uma grande variabilidade dos valores de SLP até 6 meses após o fogo, sendo os valores de SLP mínimos e máximos, para o primeiro mês de recuperação, -0,0358 e 0,1080, respetivamente e uma variabilidade elevada dos valores de INTP um ano após o fogo, com valores mínimos de cerca de -0,0104 e valores máximos de cerca de 0,1979, sendo esta variabilidade semelhante para os restantes períodos de anos após o fogo.

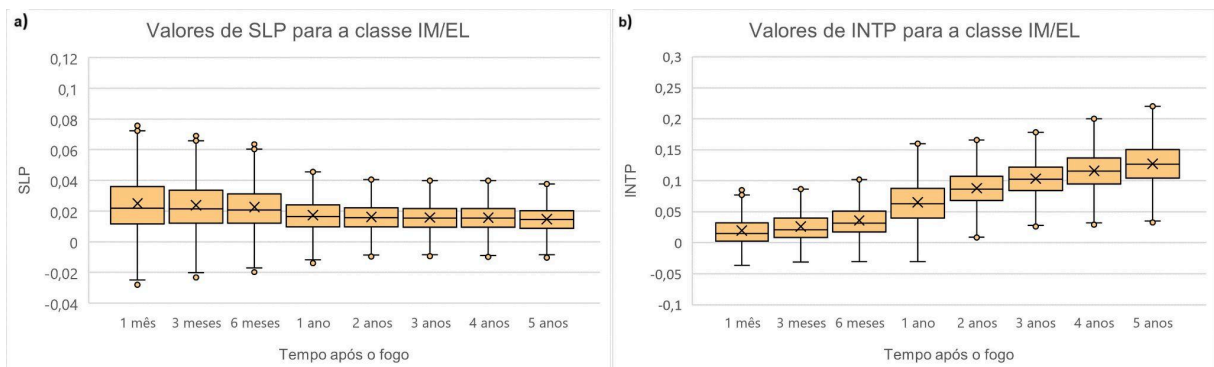


Figura 4.5: Gráficos Boxplot dos coeficientes em a) SLP e em b) INTP da banda Greenness para a classe IM/EL.

Nos primeiros 6 meses, os valores de SLP para a classe IM/EL são inferiores aos observados para a classe IR/EB, atingindo valores máximos de SLP de 0,0778 ao contrário dos valores próximos de 0,11 observados para a classe IR/EB. À semelhança do que foi referido anteriormente, é possível observar-se que os valores de INTP para a classe IM/EL

vão ser inferiores aos da classe IR/EB, anos após o fogo. Passado 1 ano da ocorrência do fogo a classe IM/EL observa valores máximos de 0,1610 e passados 5 anos da ocorrência do fogo este valor passa para 0,2219, sendo ambos inferiores aos observados para a classe IR/EB. A variabilidade de valores de SLP é maior até 6 meses após o fogo, onde se observam valores mínimos de -0,28 e máximos de 0,778. Observou-se também uma grande variabilidade de valores de INTp 1 ano após o fogo, tomando-se valores entre -0,0307 e 0,161. Esta variabilidade manteve-se nos anos seguintes.

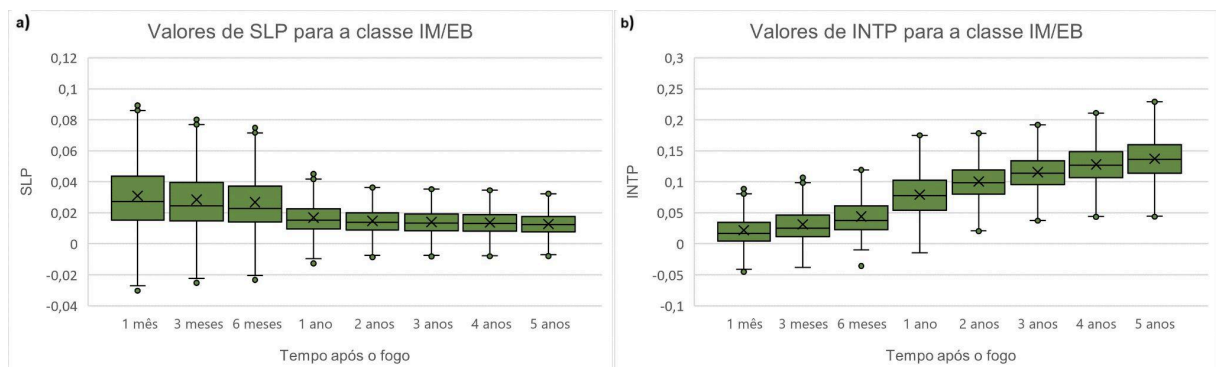


Figura 4.6: Gráficos Boxplot dos coeficientes em a) SLP e em b) INTp da banda Greenness para a classe IM/EB.

Os valores de SLP da classe IM/EB, nos primeiros 6 meses após o fogo, encontram-se situados entre os valores observados para a classe IR/EB e a classe IM/EL, atingindo-se valores máximos de 0,0914. A classe IM/EB toma valores máximos de INTp de 0,1758 1 ano após o fogo e 0,2302 5 anos após o fogo. Os valores da classe IM/EB para 1 ano após o fogo encontram-se entre os observados para a classe IR/EB e IM/EL, contudo os valores máximos da classe IM/EB para 5 anos após o fogo são superiores aos observados para a classe IM/EL, sendo apenas inferiores aos observados para a classe IR/EB. A variabilidade dos valores de SLP é bastante elevada nos primeiros 6 meses após o fogo, obtendo-se valores mínimos de -0,0303 e valores máximos de 0,0914. Existe uma grande variabilidade de valores de INTp 1 ano após o fogo, dado que estes valores estão contidos entre -0,0145 e 0,1758. Esta variabilidade é um pouco mais reduzida mas semelhante para as restantes datas, com exceção para os 6 meses após o fogo que apresenta uma variabilidade mais reduzida.

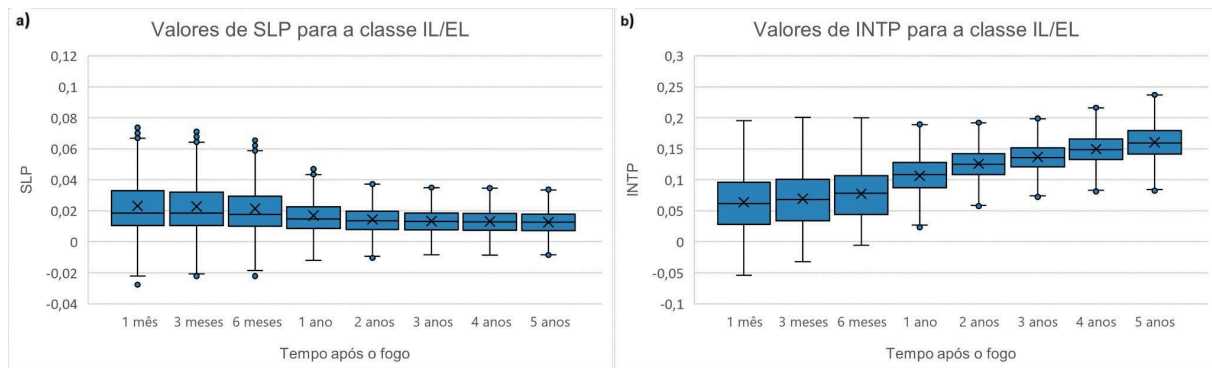


Figura 4.7: Gráficos Boxplot dos coeficientes em a) SLP e em b) INTP da banda Greenness para a classe IL/EL.

A classe IL/EL apresenta os valores de SLP mais reduzidos, para o período de 6 meses que sucede o fogo, tendo como valor máximo 0,0748. A classe IL/EL apresenta valores de INTP máximos próximos de 0,2 nos 6 primeiros meses após o fogo, de 0,1910 1 ano após o fogo e 0,2395 5 anos após o fogo. Os valores de INTP da classe IL/EL dos primeiros 6 meses após o fogo são bastante mais elevados que os das restantes classes, contudo 1 e 5 anos após o fogo estes valores são superados pelos da classe IR/EB. A variabilidade de SLP é elevada nos primeiros 6 meses, tendo valores entre -0,0277 e 0,0748. Ao contrário do que é observado nas outras classes, a variabilidade dos valores de INTP da classe IL/EL é superior nos primeiros 6 meses após o fogo, onde é possível observar-se valores mínimos de -0,054 e valores máximos próximos de 0,2. A partir do primeiro ano após o fogo esta variabilidade vai ser mais reduzida.

Para todos os gráficos boxplot foram observados 2 acontecimentos: Os valores de SLP diminuem ao longo do tempo, sendo superiores nos primeiros 6 meses após o fogo e havendo uma redução gradual destes valores depois dessa data e os valores de INTP vão aumentando com o passar do tempo, sendo este aumento mais rápido a partir do primeiro ano após o fogo.

Foram também construídos gráficos de linhas com marcadores, de forma a analisar os valores medianos de cada classe de recuperação da vegetação para as diferentes datas após o fogo, permitindo uma melhor comparação entre as diferentes classes obtidas, como representado na figura seguinte:

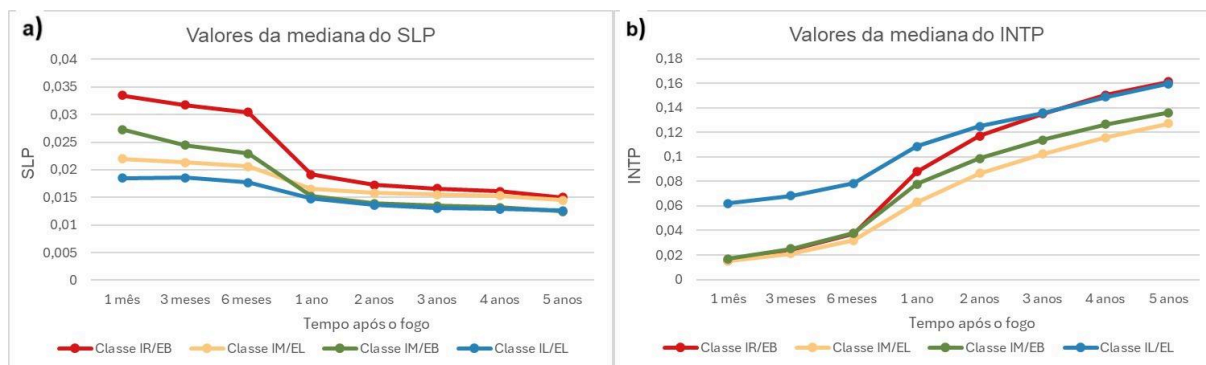


Figura 4.8: Gráficos com os valores da mediana em a) de SLP e em b) de INTP, ao longo do tempo, para as diferentes classes de recuperação da vegetação.

Inicialmente, os valores da mediana de SLP são mais elevados para a classe IR/EB e inferiores para a classe IL/EL. Observa-se também que durante os primeiros 6 meses a mediana de SLP da classe IM/EB é maior do que a da classe IM/EL, passando a ocorrer o contrário a partir do primeiro ano após o fogo, o que pode indicar uma desaceleração na recuperação da vegetação na classe IM/EB. A partir do primeiro ano após o fogo, os valores da mediana do SLP das diferentes classes vão ser semelhantes, mantendo-se assim até aos 5 anos após o fogo, contudo os valores de GREENNESS (INTP) vão ser diferentes. Inicialmente os valores de INTP das classes IR/EB, IM/EL e IM/EB estão bastante próximos, enquanto que os valores para a classe IL/EL são elevados. A partir do primeiro ano após o fogo, a diferença entre os valores medianos do INTP da classe IL/EL para as classes IR/EB, IM/EL e IM/EB vai ser mais reduzido, observando-se um aumento mais acentuado dos valores medianos para a classe IR/EB, que irá atingir valores superiores aos observados na classe IL/EL. As classes IM/EL e IM/EB vão ter uma diferença menor para as classes IR/EB e IL/EL, em comparação com o que foi observado nos primeiros meses após o fogo, continuando a apresentar valores semelhantes entre as 2 classes.

O gráfico da mediana do INTP mostra que o período de maior recuperação de vegetação ocorreu entre o 6º mês e o 1º ano, no entanto esse período corresponde à maior diminuição dos valores medianos de SLP, que representa a taxa de recuperação da vegetação. Isto pode estar relacionado com a variabilidade de dados, já que apenas se está a usar os valores medianos para esta análise ou usando a classe IR/EB como exemplo, apesar de haver uma diminuição dos valores de SLP entre os 6 meses e o 1º ano após o fogo, o valor de SLP para o 6º mês continua a ser elevado o que faz com que se obtenham valores de INTP elevados no período após o 6º mês, o que corresponde ao 1º ano.

4.2 Análise dos fatores determinantes na recuperação da vegetação

Foram observados quatro níveis de severidade para o fogo em estudo. O tipo de severidade menos observado foi a severidade moderada-alta, que foi visível em apenas 3% da área de estudo, imediatamente a seguir vem a severidade que considera que não houve área ardida, que representa 6% da área de estudo. A classe de severidade mais observada é a severidade moderada-baixa, que representa 50% da área de estudo e a segunda mais comum é a severidade baixa que ocupa 41% da área de estudo. A imagem resultante do dNBR para a área de estudo pode ser observada na seguinte figura:

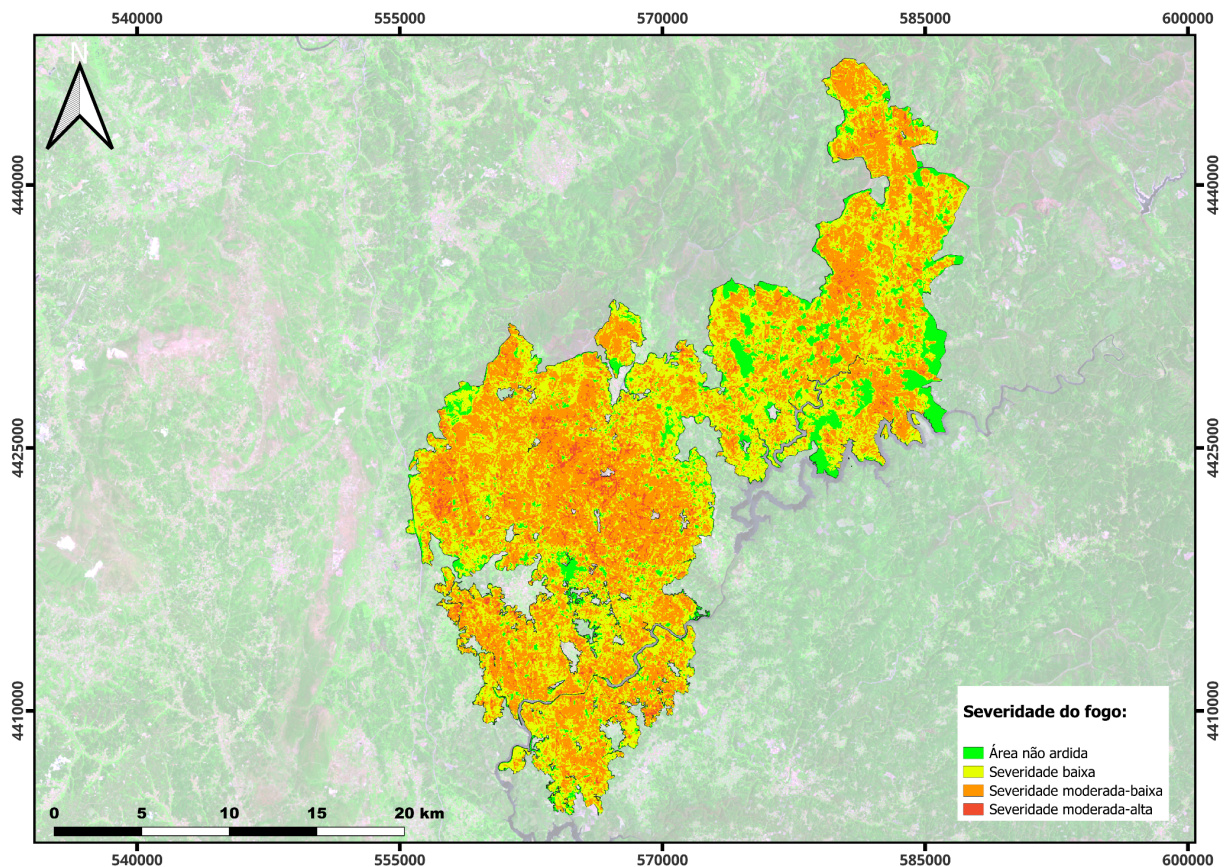


Figura 4.9: Imagem raster dos valores de dNBR com legenda para o respectivo nível de severidade do fogo.

No geral, pode-se observar que as classes mais severas ocorrem nas partes centrais do fogo, enquanto as severidades mais baixas se encontram mais próximas dos limites do fogo. Observam-se também zonas de áreas não ardidas dentro do perímetro da área ardida,

que correspondem a pequenos aglomerados de zonas verdes, que estão presentes devido à etapa de edição visual realizada no atlas dos fogos.

Tal como tinha sido referido no capítulo de materiais e métodos, a percentagem de cada índice de severidade do fogo, observada para o evento de estudo, nas diferentes classes está demonstrada na seguinte figura:




Figura 4.10: Percentagem dos níveis de severidade do fogo para cada classe de recuperação da vegetação.

Analisando este gráfico percebe-se que, para as classes IR/EB, IM/EL e IM/EB de recuperação da vegetação foi observado que, uma severidade baixa ou severidade moderada-baixa de fogo representa pelo menos 85% de todas as classes de recuperação e que apenas 3% da área ardida destas classes foi considerada como tendo uma severidade moderada-elevada. Nas classes IM/EL e IM/EB, pelo menos metade da área ardida corresponde a uma severidade moderada-baixa, sendo este valor um pouco inferior para a classe IR/EB e apenas 4% para a classe IL/EL. A classe IL/EL apresenta uma percentagem elevada de área não ardida de 73%, a classe IR/EB contém a segunda maior percentagem de área não ardida com 10% e as classes IM/EL e IM/EB apresentam apenas 4% de área não ardida.

Nas classes de recuperação da vegetação, é possível observar diferentes tipos de uso e ocupação do solo. A percentagem que cada um destes ocupa para cada classe pode ser observada na seguinte figura, considerando-se apenas tipos de uso e ocupação do solo que ocupam pelo menos 2% de toda a área de estudo.

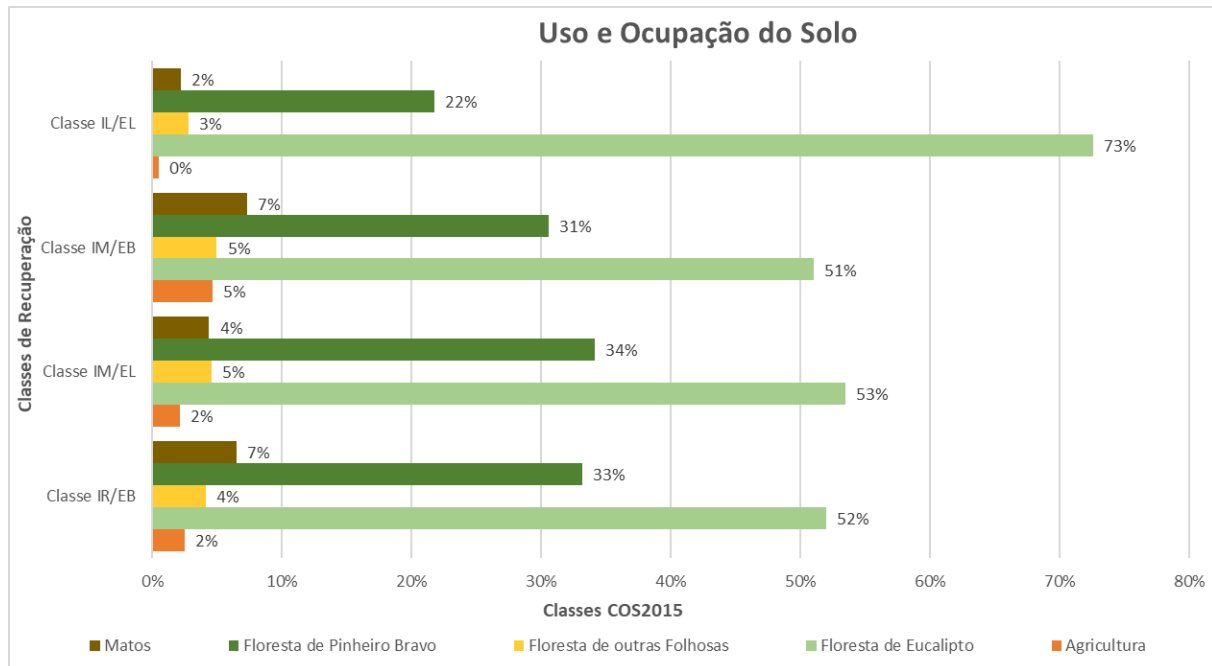


Figura 4.11: Percentagem dos tipos de uso e ocupação do solo para cada classe de recuperação da vegetação. Considerando apenas os tipos de uso e ocupação do solo que ocupam pelo menos 2% da área de estudo.

Na figura 4.11 é possível observar que a área de estudo é predominantemente ocupada por florestas de eucalipto e de pinheiro bravo, que em conjunto representam 80% ou mais da ocupação do solo para todas as classes, com especial atenção para a classe IL/EL onde estes dois tipos de floresta correspondem a 95% da área total desta classe. As florestas de eucalipto são o tipo de ocupação do solo principal observado para as diferentes classes de recuperação, representando pelo menos 50% da área de todas as classes e chegando aos 73% para a área da classe IL/EL. Os outros tipos de ocupação do solo com alguma representação nestas classes são: os matos, que representam 7% da área das classes IR/EB e IM/EB; as florestas de outras folhosas, que representam menos de 6% de todas as classes e a agricultura que é representada no máximo em 5% para a classe 2% e é praticamente inexistente na classe IL/EL.

Devido ao efeito que a ocorrência de fogos anteriores tem na recuperação da vegetação, foi construído um gráfico que permite observar, para cada classe, qual a percentagem da área que ardeu nos anos que antecederam o incêndio de 2017 de Pedrógão Grande. Considerou-se apenas os anos onde a área ardida corresponde a pelo menos 3% da área ardida da totalidade de área queimada que ocorreu até 2016, podendo-se observar o respetivo gráfico na seguinte figura:

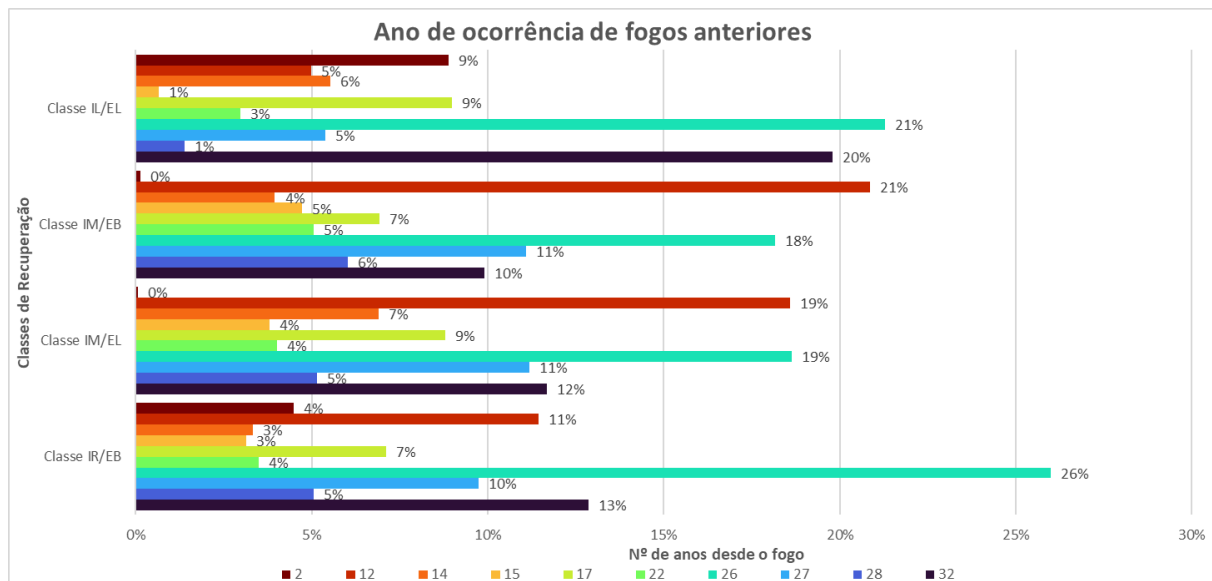


Figura 4.12: Percentagem de área ardida em anos anteriores para cada classe. Apenas se consideraram fogos que representam pelo menos 3% da totalidade da área ardida até 2016.

É possível observar que para todas as classes de recuperação da vegetação existem pelo menos 4 fogos que correspondem a cerca de 10% da área ardida na totalidade até 2017. Isto significa que pelo menos 40% da área ardida de cada classe é representada apenas por 4 fogos, ou seja, fogos com alguma dimensão. Para as classes IR/EB, IM/EL e IM/EB os anos de 1985, 1990, 1991 e 2005 são responsáveis por uma grande maioria da área queimada destas classes para a área de estudo. A área ardida da classe IL/EL é, no entanto, principalmente representada pelos fogos dos anos de 1985, 1991, 2000 e 2015. Os fogos de 1991 são responsáveis pelo maior número de área ardida observado para a classe IR/EB, IL/EL e classe IM/EL, nesta última, em igualdade com os fogos de 2005. Na classe IM/EB a área ardida causada pelos fogos de 2005 é superior à dos fogos de 1991. Nos últimos 10 anos antes de 2017, só ocorreram fogos consideráveis para as classes IR/EB e IL/EL. Estes fogos ocorreram em 2015 para ambas as classes e representam 4% e 9% da área ardida destas classes, respetivamente.

Foi também construído um gráfico de forma a perceber como o número de vezes que uma área ardeu, até ao ano de 2017, irá influenciar a recuperação da vegetação. Este gráfico considera apenas os fogos representados na figura 4.12 e representa a percentagem do número de vezes que esses fogos afetaram uma mesma área, para as diferentes classes de recuperação da vegetação, como é possível observar-se na figura seguinte:




Figura 4.13: Percentagem do número de vezes que esta área ardeu entre os anos de 1984 e 2016 para as diferentes classes de recuperação.

Observando este gráfico, é possível perceber que para as classes IR/EB, IM/EL e IM/EB os dois números de ocorrência de fogos mais comuns para estas áreas são 0 e 1 vez, correspondendo a 80% dos valores observados para estas 3 classes. A classe IL/EL é representada principalmente por locais que arderam 1 e 2 vezes, correspondendo a 60% da área desta classe. A ocorrência de 4 e 5 fogos é praticamente inexistente para as regiões da área de estudo. Observa-se também um número extremamente reduzido de regiões com 3 ocorrências de fogos para as classes IR/EB, IM/EL e IM/EB. Contudo esta ocorrência é observada numa parte maior da área de estudo para a classe IL/EL.

A topografia do local é também um fator bastante importante na recuperação da vegetação no pós-fogo. Foi por isso construído um gráfico, que pode ser observado na figura , onde está representada a percentagem que cada topografia ocupa nas classes da área de estudo da área ardida. Sendo apenas representadas topografias que significam pelo menos 1% da área de estudo.




Figura 4.14: Percentagem do tipo de topografia observado para cada classe. Considerando apenas topografias que ocupam mais de 1% da área de estudo.

Observa-se que as encostas superiores representam cerca de metade das topografias observadas para todas as classes. As encostas superiores (quentes) têm uma maior representação que as restantes topografias nas classes IR/EB, IM/EL e IL/EL onde representam 26%, 31% e 34%, respectivamente e 24% na classe IM/EB, em igualdade com a encosta superior. As duas encostas inferiores representam cerca de 40% da topografia de todas as classes excepto a classe IL/EL, onde representam apenas 30%. Nota-se também uma presença extremamente baixa em todas as classes para ambas as topografias do tipo pico/cume, sendo esta um pouco superior para a classe 3 e para a topografia de vale (estreito), apresentando esta última um valor quase inexistente para a classe IL/EL. A topografia do tipo vale também está pouco representada na área de estudo, sendo os seus valores um pouco superiores aos observados para as topografias do tipo pico/cume e vale (estreito), exceto para a classe IL/EL que encontra valores próximos das topografias referidas anteriormente.

5. Discussão

Analisando os gráficos boxplots desde a figura 4.4 à 4.7, é possível observar dois acontecimentos que ocorrem independentemente das classes de recuperação da vegetação a analisar. O primeiro acontecimento observado é a diminuição dos valores de SLP ao longo do tempo, o que significa que a velocidade de recuperação da vegetação é superior no período imediatamente após o fogo e que com o passar do tempo essa recuperação vai ser mais gradual. Este acontecimento vai ao encontro do que foi observado por Viana-Soto et al. (2020), que obteve, na generalidade, taxas de recuperação superiores pouco tempo após o fogo. Segundo González-De Vega et al. (2018) isto pode-se dever à colonização pós-fogo precoce de ervas e arbustos anuais.

O segundo acontecimento observado é o aumento dos valores de INTP ao longo do tempo, ou seja, quanto mais tempo passa após a ocorrência do fogo maior serão os valores de Greenness da vegetação. Isto acaba por ir ao encontro do que foi observado por Polychronaki et al. (2013), numa área de estudo dominada por diferentes espécies de pinheiro, onde apenas se atingiram os valores de NDVI pré-distúrbio 17 anos após a ocorrência do fogo. Neste estudo, observou-se algo semelhante para certas classes, mas com um período menor para se obterem valores medianos de INTP semelhantes aos observados no pré-fogo. A classe IR/EB e IM/EB obtiveram estes valores 2 e 4 anos após o fogo, respetivamente, contudo a classe IM/EL mesmo 5 anos após o fogo não atingiu os valores de INTP observados no pré-fogo. A classe IL/EL apresentou valores de INTP superiores logo no 1º mês após o fogo, o que pode significar que o fogo promoveu a regeneração, numa fase inicial desta classe, como foi sugerido por Pereira et al. (2016), onde se refere que os fogos de baixa severidade não afetam o banco de sementes mas removem a folhagem seca e promovem a germinação de sementes. Estes resultados obtidos para a classe IL/EL podem dever-se também às zonas que não arderam dentro do perímetro da área ardida. Deve-se também considerar a possibilidade da regeneração nestas áreas não ter sido feita de forma natural, podendo-se ter recorrido a replantações, que irão afetar os resultados obtidos neste estudo.

Ao observar os gráficos do coeficiente SLP da figura 4.4 à figura 4.7, verifica-se que a variabilidade de valores para este coeficiente é superior nos 6 primeiros meses após o fogo, especialmente para a classe IR/EB. Fazendo esta mesma observação para o coeficiente INTP verifica-se uma grande variabilidade de valores no 1º ano após o fogo, com exceção para a classe IL/EL que apresenta valores mais baixos. Esta última observação pode sugerir que ao fim de um ano se começam a diferenciar taxas de recuperação,

possivelmente em função da ocupação do solo pré-fogo, em cada local, bem como dos outros fatores que determinam a produtividade da vegetação, como a posição em encostas e a exposição à radiação solar.

A forma das curvas de SLP e INTP de Greenness sugere então que esta variável terá um comportamento semelhante ao observado por Gouveia et al. (2010), onde foi utilizado outro índice de vegetação, o NDVI e utilizou-se a modelagem baseada no modelo desenvolvido por Olson (1964). Isto é, à medida que o tempo passa, os valores de Greenness crescem em termos absolutos (INTP), mas a taxa de crescimento é cada vez menor (SLP).

Analisando os gráficos da severidade do fogo, figura 4.10 e do tipo de uso e ocupação do solo, figura 4.11, observou-se que a classe com menor severidade do fogo, a classe IL/EL, é principalmente constituída (73%) por florestas de eucalipto. Esta classe tem 73% da sua área representada por zonas consideradas como não ardidas, segundo o dNBR. Olhando também para os gráficos do tipo boxplot e dos valores medianos de cada classe, é possível observar que a classe IL/EL apresenta mais cedo valores de INTP, equivalentes aos valores de Greenness para a vegetação, próximos ou superiores aos observados para zonas de vegetação, antes da ocorrência do fogo. Foi também observado algo semelhante no artigo de Gouveia et al. (2010), onde as regiões dominadas por eucalipto tendem a apresentar uma recuperação mais rápida, sendo os fatores mais importantes nesta recuperação a densidade da vegetação no pré-fogo, visto que se trata de uma espécie que se regenera por rebrotamento das estruturas capazes de resistir ao fogo (Hodgkinson, 1998) e pela regeneração abundante por germinação de sementes estimuladas pelo fogo (Cremer, 1965), acumulando portanto os dois tipos de resposta regenerativa que fazem com que haja uma recuperação rápida da vegetação.

No gráfico do número de anos desde a ocorrência dos fogos anteriores, figura 4.12 é possível ver que quanto maior for a percentagem da área ardida 2 anos antes do incêndio em estudo, para uma dada classe, menor será a severidade do fogo em estudo para essa mesma classe. Isto pode acontecer porque a ocorrência de fogos é responsável por reduzir as cargas de combustível disponíveis, o que torna fogos futuros mais fáceis e menos caros de se conter (Houtman et al. 2013).

A análise do gráfico do número de vezes que a área de cada classe ardeu, figura 4.13 é semelhante ao realizado por Díaz-Delgado et al. (2002), havendo no entanto algumas diferenças. Esta tese considera um período anual de fogos anteriores muito superior, de 1984 até 2016, enquanto Díaz-Delgado et al. (2002) consideram fogos entre 1975 e 1993. Este intervalo de diferença faz com que o número de vezes que cada área ardeu seja

diferente para os dois estudos, tendo se observado áreas que arderam até 5 vezes para este artigo, enquanto o analisado para o de Díaz-Delgado et al. (2002) vá apenas até às 2 vezes. A classe com uma maior percentagem de área que ardeu 1 e 2 vezes antes do incêndio em estudo equivale à classe com menor severidade do fogo. Isto vai ao encontro do que foi referido no parágrafo anterior, onde uma área que não ardeu antes vai equivaler a uma maior severidade.

Pereira et al. (2016) observam uma maior severidade do fogo em áreas onde a incidência de radiação solar é maior, devido à maior taxa de evaporação e a diminuição da humidade do solo e da vegetação observadas nestas áreas. Esta observação vai ao encontro dos resultados obtidos nesta dissertação, uma vez que certos tipos de topografia (frios) não foram afetados pelo fogo, ou as suas áreas correspondem a valores tão reduzidos do total da área ardida em estudo que não chegam a ser representado no gráfico dos tipos de topografia.

Tipicamente, na parte superior das encostas o solo é mais fino e há menos área de terreno a drenar água para cada local do que na parte inferior das encostas (Fazlollahi Mohammadi et al., 2016), portanto, é expectável que na parte superior, sobretudo quando expostas à radiação solar (quente), a recuperação seja mais lenta. O que vai ao encontro do que foi observado por Zhong et al. (2023) e neste estudo, na figura 4.14, onde as classes IM/EL e IL/EL apresentam as maiores percentagens de encostas superiores e encostas quentes e ambas as classes têm a menor taxa de recuperação, no período inicial de recuperação da vegetação.

6. Considerações finais

Na realização deste trabalho observou-se que a classe IR/EB obteve valores de Greenness da vegetação próximos do observado no pré-fogo cerca de 2 anos após a ocorrência do fogo, esta classe tem representada 10% da sua área considerada como não ardida. As classes IM/EL e IM/EB são bastante semelhantes, sendo observados valores de taxa de recuperação iniciais e de Greenness da vegetação um pouco superiores para a classe IM/EB e uma severidade do fogo um pouco superior para a classe IM/EL. Apesar destas semelhanças, as duas classes atingem valores próximos dos observados no pré-fogo em datas distintas, a classe IM/EB apresenta estes valores 2 anos após o fogo enquanto que a classe IM/EL só se aproxima destes valores 5 anos após o fogo. Esta diferença pode-se dever pela maior percentagem de encostas superiores e encostas quentes observadas nas classe IM/EL, quando comparadas com a classe IM/EB. A classe IL/EL é a mais distinta de todas, observando-se valores de verdura da vegetação próximos aos do período pré-fogo apenas 1 mês depois do fogo, esta classe é caracterizada por ter a maioria da sua área ocupada por áreas não ardidas e por florestas de eucalipto.

A realização deste trabalho é bastante importante para compreender os fatores que vão ser determinantes na recuperação da vegetação após os incêndios. Este tema de extrema relevância vai-se tornando cada vez mais importante devido às alterações climáticas vividas atualmente e previstas para o futuro, que irão contribuir para o aumento da ocorrência e da severidade de fogos futuros.

Para se obter os resultados pretendidos neste trabalho foram utilizadas imagens satélite. Este tipo de imagens permite realizar observações constantes de grandes regiões ao longo do tempo, tornando-se uma das melhores formas de monitorizar padrões de vegetação após a ocorrência de incêndios. Para realizar a monitorização destes padrões de vegetação foi utilizado o algoritmo CCDC, que é totalmente automatizado e capaz de monitorizar vários tipos de mudança do solo com novas imagens disponíveis. A utilização deste algoritmo na realização deste trabalho é bastante importante, dado que se trata de um algoritmo pouco utilizado neste tipo de estudos e que tem propriedades que o tornam bastante vantajoso para este tipo de análise, como ser completamente automatizado, ser capaz de monitorizar diferentes tipos de mudança na cobertura do solo assim que existem novas imagens e não requerer uma normalização relativa para cada imagem e para diferentes Landsats.

Apesar deste estudo ter sido realizado de forma rigorosa, é necessário referir que existem certas limitações associadas a este. Uma destas limitações está associada ao CCDC que apesar das suas vantagens, é um algoritmo bastante custoso computacionalmente e, mesmo utilizando o GEE, torna-se difícil trabalhar com grandes áreas. Isto pode ser observado neste estudo, onde foi necessário dividir a área de estudo para ser possível exportar os dados do CCDC. Outra limitação deste trabalho é a área de estudo utilizada, que é resultante de apenas 1 incêndio de grandes dimensões. De forma a ser possível realizar-se uma análise mais completa e obter-se resultados mais conclusivos, é necessário realizar estudos semelhantes com uma quantidade maior de áreas queimadas representativas, que incluam fogos de diferentes tamanhos, diferentes anos e regiões.

É importante referir que, apesar destas limitações, os resultados obtidos neste trabalho fornecem informações importantes sobre os processos de recuperação da vegetação e os seus fatores determinantes, contudo é necessário que estudos futuros tenham em consideração estas limitações e procurem atenuá-las. Recomenda-se também que, em futuros trabalhos, seja feita uma modelação dos fogos com os parâmetros ambientais analisados, de forma a conseguir quantificar com maior precisão a contribuição que cada um destes parâmetros terá na recuperação da vegetação.

7. Referências bibliográficas

- Abburu, S., & Golla, S. B. (2015). Satellite image classification methods and techniques: A review. *International journal of computer applications*, 119(8).
- Arévalo, P., Bullock, E. L., Woodcock, C. E., & Olofsson, P. (2020). A suite of tools for continuous land change monitoring in google earth engine. *Frontiers in Climate*, 2, 576740.
- Arévalo, P., & Olofsson, P. (2023). Interpreting Time Series with CCDC. In *Cloud-Based Remote Sensing with Google Earth Engine: Fundamentals and Applications* (pp. 353-375). Cham: Springer International Publishing.
- Arianoutsou, M., & Ne'eman, G. (2000). Post-fire regeneration of natural *Pinus halepensis* forests in the east Mediterranean Basin. *Ecology, biogeography and management of Pinus halepensis and P. brutia forest ecosystems in the Mediterranean basin*. Backhuys Publishers, Leiden, The Netherlands, 269-290.
- Baig, M. H. A., Zhang, L., Shuai, T., & Tong, Q. (2014). Derivation of a tasseled cap transformation based on Landsat 8 at-satellite reflectance. *Remote Sensing Letters*, 5(5), 423-431.
- Banskota, A., Kayastha, N., Falkowski, M. J., Wulder, M. A., Froese, R. E., & White, J. C. (2014). Forest monitoring using Landsat time series data: A review. *Canadian Journal of Remote Sensing*, 40(5), 362-384.
- Birch, D. S., Morgan, P., Kolden, C. A., Abatzoglou, J. T., Dillon, G. K., Hudak, A. T., & Smith, A. M. (2015). Vegetation, topography and daily weather influenced burn severity in central Idaho and western Montana forests. *Ecosphere*, 6(1), 1-23.
- Carta de Uso e Ocupação do Solo(2015). Disponível no website da Direção Geral do Território em <https://dados.gov.pt/pt/datasets/carta-de-uso-e-ocupacao-do-solo-2015/>.
- Catry, F. X., Moreira, F., Cardillo, E., & Pausas, J. G. (2012). Post-fire management of cork oak forests. *Post-fire management and restoration of southern European forests*, 195-222.
- Cerdà, A., & Doerr, S. H. (2005). Influence of vegetation recovery on soil hydrology and erodibility following fire: an 11-year investigation. *International Journal of Wildland Fire*, 14(4), 423-437.
- Chuvieco, E., Aguado, I., Salas, J., García, M., Yebra, M., & Oliva, P. (2020). Satellite remote sensing contributions to wildland fire science and management. *Current Forestry Reports*, 6, 81-96.
- Chuvieco, Emílio (2023). *Fundamentals of Satellite Remote Sensing: An Environmental Approach*, 3rd Edition. CRC Press, 416 pp.

- Cremer, K. W. (1965). Effects of fire on seedshed from *Eucalyptus regnans*. *Australian Forestry*, 29(4), 252-262.
- De Keersmaecker, W., Lhermitte, S., Tits, L., Honnay, O., Somers, B., & Coppin, P. (2015). A model quantifying global vegetation resistance and resilience to short-term climate anomalies and their relationship with vegetation cover. *Global Ecology and Biogeography*, 24(5), 539-548.
- Díaz-Delgado, R., Lloret, F., Pons, X., & Terradas, J. (2002). Satellite evidence of decreasing resilience in Mediterranean plant communities after recurrent wildfires. *Ecology*, 83(8), 2293-2303.
- Fazlollahi Mohammadi, M., Jalali, S. G. H., Kooch, Y., & Said-Pullicino, D. (2016). Slope gradient and shape effects on soil profiles in the northern mountainous forests of Iran. *Eurasian soil science*, 49, 1366-1374.
- Flannigan, M. D., Logan, K. A., Amiro, B. D., Skinner, W. R., & Stocks, B. J. (2005). Future area burned in Canada. *Climatic change*, 72(1-2), 1-16.
- Friedl, M. A., Sulla-Menashe, D., Tan, B., Schneider, A., Ramankutty, N., Sibley, A., & Huang, X. (2010). MODIS Collection 5 global land cover: Algorithm refinements and characterization of new datasets. *Remote sensing of Environment*, 114(1), 168-182.
- Gamboa, J. C. B. (2017). Deep learning for time-series analysis. *arXiv preprint arXiv:1701.01887*.
- González-De Vega, S., De las Heras, J., & Moya, D. (2018). Post-fire regeneration and diversity response to burn severity in *Pinus halepensis* Mill. forests. *Forests*, 9(6), 299.
- Gouveia, C., DaCamara, C. C., & Trigo, R. M. (2010). Post-fire vegetation recovery in Portugal based on spot/vegetation data. *Natural Hazards and Earth System Sciences*, 10(4), 673-684.
- Grizonnet, M., Michel, J., Poughon, V., Inglada, J., Savinaud, M., & Cresson, R. (2017). Orfeo ToolBox: Open source processing of remote sensing images. *Open Geospatial Data, Software and Standards*, 2(1), 1-8.
- Halofsky, J. E., Peterson, D. L., & Harvey, B. J. (2020). Changing wildfire, changing forests: the effects of climate change on fire regimes and vegetation in the Pacific Northwest, USA. *Fire Ecology*, 16(1), 1-26.
- Hansen, M. C., & Loveland, T. R. (2012). A review of large area monitoring of land cover change using Landsat data. *Remote sensing of Environment*, 122, 66-74.
- Hodgkinson, K. C. (1998). Sprouting success of shrubs after fire: height-dependent relationships for different strategies. *Oecologia*, 115, 64-72.
- Hodgson, D., McDonald, J. L., & Hosken, D. J. (2015). What do you mean, 'resilient'?. *Trends in ecology & evolution*, 30(9), 503-506.
- Holsinger, L., Parks, S. A., & Miller, C. (2016). Weather, fuels, and topography impede wildland fire spread in western US landscapes. *Forest ecology and management*, 380, 59-69.

- Houtman, R. M., Montgomery, C. A., Gagnon, A. R., Calkin, D. E., Dietterich, T. G., McGregor, S., & Crowley, M. (2013). Allowing a wildfire to burn: estimating the effect on future fire suppression costs. *International Journal of Wildland Fire*, 22(7), 871-882.
- Huang, Y., Chen, Z., Yu, T., Huang, X., & Gu, X. (2018). Agricultural remote sensing big data: management and applications. *J Integr Agric* 17: 1915–1931.
- IPCC, 2023: Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (eds.)]. IPCC, Geneva, Switzerland, 184 pp.
- Ireland, G., & Petropoulos, G. P. (2015). Exploring the relationships between post-fire vegetation regeneration dynamics, topography and burn severity: A case study from the Montane Cordillera Ecozones of Western Canada. *Applied Geography*, 56, 232-248.
- Karlsson, A. (2003). *Classification of high resolution satellite images*. Thesis for the degree of Master of Science in Engineering Physics. Ecole Polytechnique Fédérale de Lausanne.
- Kauth, R. J., & Thomas, G. S. (1976, January). The tasselled cap—a graphic description of the spectral-temporal development of agricultural crops as seen by Landsat. In *LARS symposia* (p. 159).
- Kennedy, R. E., Townsend, P. A., Gross, J. E., Cohen, W. B., Bolstad, P., Wang, Y. Q., & Adams, P. (2009). Remote sensing change detection tools for natural resource managers: Understanding concepts and tradeoffs in the design of landscape monitoring projects. *Remote sensing of environment*, 113(7), 1382-1396.
- Kennedy, R. E., Andréfouët, S., Cohen, W. B., Gómez, C., Griffiths, P., Hais, M., ... & Zhu, Z. (2014). Bringing an ecological view of change to Landsat-based remote sensing. *Frontiers in Ecology and the Environment*, 12(6), 339-346.
- Key, C., Benson, N., 2005. Landscape assessment: Ground measure of severity; the composite burn index, and remote sensing of severity, the normalized burn index. In: Lutes, D., Keane, R., Caratti, J., Key, C., Benson, N., Sutherland, S., Gangi, L. (Eds.), General Technical Report RMRS-GTR-164-CD LA. USDA Forest Service, Rocky Mountains Research Station, pp. 1–51
- Kloster, S., Mahowald, N. M., Randerson, J. T., & Lawrence, P. J. (2012). The impacts of climate, land use, and demography on fires during the 21st century simulated by CLM-CN. *Biogeosciences*, 9(1), 509-525.
- Littell, J. S., McKenzie, D., Peterson, D. L., & Westerling, A. L. (2009). Climate and wildfire area burned in western US ecoprovinces, 1916–2003. *Ecological Applications*, 19(4), 1003-1021.
- Loveland, T. R., & Dwyer, J. L. (2012). Landsat: Building a strong future. *Remote Sensing of Environment*, 122, 22-29.
- Maingi, J. K., & Henry, M. C. (2007). Factors influencing wildfire occurrence and distribution in eastern Kentucky, USA. *International Journal of Wildland Fire*, 16(1), 23-33.

- Moskolaï, W. R., Abdou, W., Dipanda, A., & Kolyang. (2021). Application of deep learning architectures for satellite image time series prediction: A review. *Remote Sensing*, 13(23), 4822.
- Nithya, K., Shanmugasundaram, R., & Santhiyakumari, N. (2017, March). Study of salem city resource management using k-means clustering. In *2017 Conference on Emerging Devices and Smart Systems (ICEDSS)* (pp. 79-83). IEEE.
- Nitschke, C. R., & Innes, J. L. (2008). Climatic change and fire potential in south-central British Columbia, Canada. *Global Change Biology*, 14(4), 841-855.
- Oliveira, S. L., Pereira, J. M., & Carreiras, J. M. (2011). Fire frequency analysis in Portugal (1975–2005), using Landsat-based burnt area maps. *International Journal of Wildland Fire*, 21(1), 48-60.
- Olson, J. S. (1964). Gross and net production of terrestrial vegetation. *The Journal of Animal Ecology*, 99-118.
- Palanivel, M., & Duraisamy, M. (2012). Color textured image segmentation using ICICM-interval type-2 fuzzy C-means clustering hybrid approach. *Engineering Journal*, 16(5), 115-126.
- Pasquarella, V. J., Arévalo, P., Bratley, K. H., Bullock, E. L., Gorelick, N., Yang, Z., & Kennedy, R. E. (2022). Demystifying LandTrendr and CCDC temporal segmentation. *International Journal of Applied Earth Observation and Geoinformation*, 110, 102806.
- Pereira, P., Cerdà, A., Lopez, A. J., Zavala, L. M., Mataix-Solera, J., Arcenegui, V., ... & Novara, A. (2016). Short-term vegetation recovery after a grassland fire in Lithuania: The effects of fire severity, slope position and aspect. *Land Degradation & Development*, 27(5), 1523-1534.
- Petitjean, F., Inglada, J., & Gançarski, P. (2012). Satellite image time series analysis under time warping. *IEEE transactions on geoscience and remote sensing*, 50(8), 3081-3095.
- Petitjean, F., Kurtz, C., Passat, N., & Gançarski, P. (2012). Spatio-temporal reasoning for the classification of satellite image time series. *Pattern Recognition Letters*, 33(13), 1805-1815.
- Polychronaki, A., Gitas, I. Z., & Minchella, A. (2013). Monitoring post-fire vegetation recovery in the Mediterranean using SPOT and ERS imagery. *International Journal of Wildland Fire*, 23(5), 631-642.
- Ray, T. W. (1994). A FAQ on vegetation in remote sensing. *California: Div. of Geological and Planetary Sciences California Institute of Technology*.
- Rekik, A., Zribi, M., Hamida, A. B., & Benjelloun, M. (2009). An optimal unsupervised satellite image segmentation approach based on pearson system and k-means clustering algorithm initialization. *methods*, 8(9).
- Rogan, J., Franklin, J., & Roberts, D. A. (2002). A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. *Remote sensing of environment*, 80(1), 143-156.

- San-Miguel-Ayanz, J., Pereira, J. M., Boca, R., Strobl, P., Kucera, J., & Pekkarinen, A. (2009). Forest fires in the European Mediterranean region: mapping and analysis of burned areas. In E. Chuvieco (Ed.). *Earth observation of wildland fires in Mediterranean ecosystems* (p. 189-203). Germany: Springer.
- San-Miguel-Ayanz, J., Moreno, J. M., & Camia, A. (2013). Analysis of large fires in European Mediterranean landscapes: Lessons learned and perspectives. *Forest Ecology and Management*, 294, 11-22.
- San-Miguel-Ayanz, J., Durrant, T., Boca, R., Libertà, G., Branco, A., DE, R., ... & JACOME, F. O. (2018). *Forest Fires in Europe, Middle East and North Africa 2018*.
- Scheffer, M., Carpenter, S. R., Dakos, V., & van Nes, E. H. (2015). Generic indicators of ecological resilience: inferring the chance of a critical transition. *Annual Review of Ecology, Evolution, and Systematics*, 46, 145-167.
- Shakesby, R. A., & Doerr, S. H. (2006). Wildfire as a hydrological and geomorphological agent. *Earth-Science Reviews*, 74(3-4), 269-307.
- Taylor, A. H., & Skinner, C. N. (2003). Spatial patterns and controls on historical fire regimes and forest structure in the Klamath Mountains. *Ecological Applications*, 13(3), 704-719.
- Theobald, D. M., Harrison-Atlas, D., Monahan, W. B., & Albano, C. M. (2015). Ecologically-relevant maps of landforms and physiographic diversity for climate adaptation planning. *PloS one*, 10(12), e0143619
- Vaiphasa, C., Piamduaytham, S., Vaiphasa, T., & Skidmore, A. K. (2011). A Normalized Difference Vegetation index (NDVI) Time-series of idle agriculture lands: A preliminary study. *Engineering Journal*, 15(1), 9-16.
- Viana-Soto, A., Aguado, I., & Martínez, S. (2017). Assessment of post-fire vegetation recovery using fire severity and geographical data in the mediterranean region (Spain). *Environments*, 4(4), 90.
- Viana-Soto, A., Aguado, I., Salas, J., & García, M. (2020). Identifying post-fire recovery trajectories and driving factors using landsat time series in fire-prone mediterranean pine forests. *Remote Sensing*, 12(9), 1499.
- Woodcock, C. E., Allen, R., Anderson, M., Belward, A., Bindschadler, R., Cohen, W., ... & WULDER, M. A. W. R. (2008). Free access to Landsat imagery. *SCIENCE VOL 320: 1011*.
- Wooster, M. J., Roberts, G. J., Giglio, L., Roy, D. P., Freeborn, P. H., Boschetti, L., ... & San-Miguel-Ayanz, J. (2021). Satellite remote sensing of active fires: History and current status, applications and future requirements. *Remote Sensing of Environment*, 267, 112694.
- Wulder, M. A., Loveland, T. R., Roy, D. P., Crawford, C. J., Masek, J. G., Woodcock, C. E., ... & Zhu, Z. (2019). Current status of Landsat program, science, and applications. *Remote sensing of environment*, 225, 127-147.

Zhang, X., Schaaf, C. B., Friedl, M. A., Strahler, A. H., Gao, F., & Hodges, J. C. (2002, June). MODIS tasseled cap transformation and its utility. In *IEEE International Geoscience and Remote Sensing Symposium* (Vol. 2, pp. 1063-1065). IEEE.

Zhang, X., Liu, L., Chen, X., Gao, Y., Xie, S., & Mi, J. (2021). GLC_FCS30: Global land-cover product with fine classification system at 30 m using time-series Landsat imagery. *Earth System Science Data*, 13(6), 2753-2776.

Zheng, X., Sun, X., Fu, K., & Wang, H. (2012). Automatic annotation of satellite images via multifeature joint sparse coding with spatial relation constraint. *IEEE Geoscience and Remote Sensing Letters*, 10(4), 652-656.

Zhong, C., Oguchi, T., & Lai, R. (2023). Effects of Topography on Vegetation Recovery after Shallow Landslides in the Obara and Shobara Districts, Japan. *Remote Sensing*, 15(16), 3994.

Zhu, Z., & Woodcock, C. E. (2014). Continuous change detection and classification of land cover using all available Landsat data. *Remote sensing of Environment*, 144, 152-171.