


Estudo de seca na Península Ibérica usando o *Google Earth Engine*



Ana Luísa Fernandes Silva

Mestrado em Engenharia Geográfica



Departamento de Geociências, Ambiente e Ordenamento do Território
2018

Orientador

Nelson Ribeiro Pires, Professor Assistente Convidado, Faculdade de
Ciências da Universidade do Porto

Coorientador



Maria Joana Afonso Pereira Fernandes, Professora Auxiliar, Faculdade de
Ciências da Universidade do Porto





Todas as correções determinadas
pelo júri, e só essas, foram efetuadas.
O Presidente do Júri,

Porto, ____/____/____



Índice

Índice	iii
Índice de Figuras	v
Índice de tabelas	vii
Índice de acrónimos	viii
Resumo	x
Abstract	xi
Agradecimentos	xii
Capítulo 1. Introdução	1
1.1. Objetivos	4
Capítulo 2. Contextualização	5
2.1. Formas de seca	5
2.1.1. Seca meteorológica	6
2.1.2. Seca agrícola	7
2.1.3. Seca hidrológica	7
2.1.4. Seca socioeconómica	8
2.2. Causas de seca	9
2.3. Monitorização da seca	10
2.3.1. Monitorização de seca em Portugal	10
2.3.2. Monitorização de seca em Espanha	11
2.3.3. <i>US Drought Monitor</i>	11
Capítulo 3. Metodologia	12
3.1. <i>Google Earth Engine – “A planetary-scale platform for Earth science data & analysis”</i>	12
3.1.1. Regras na utilização	12
3.1.2. Os prós e contras do GEE	15
3.2. A Detecção Remota e o estudo de seca	17

3.2.1.	Estudo da precipitação	19
3.2.2.	Estudo da vegetação: NDVI (<i>Normalized Difference Vegetation Index</i>)..	19
3.2.1.	Estudo da vegetação: NDMI (<i>Normalized Difference Moisture Index</i>).....	20
3.3.	Sensores	22
3.3.1.	TRMM (<i>Tropical Rainfall Measuring Mission</i>)	22
3.3.2.	CHIRPS (<i>Climate Hazards Group InfraRed Precipitation with Station data</i>)	23
3.3.1.	Landsat 5 e Landsat 8	24
3.4.	Área de estudo	26
3.4.1.	Ocupação do terreno	27
3.4.2.	Clima na península ibérica	28
Capítulo 4.	Análise dos resultados	30
4.1.	Estudo da precipitação na Península Ibérica entre 1990 e 2017	30
4.1.1.	Média anual de 2000 a 2017	32
4.1.2.	Acumulação anual de precipitação entre 2000 e 2017	34
4.1.3.	Anomalias de 2000 a 2017	36
4.1.4.	Estudo da precipitação anual – séries temporais.....	39
4.2.	Estudo da vegetação.....	43
4.2.1.	Análise da vegetação entre 2000 e 2017 com índice NDVI	43
4.3.	Estudo de humidade do solo	50
4.3.1.	Análise da humidade do solo entre 2000 e 2017 com índice NDMI	50
4.3.2.	Análise da aridez do solo entre 2013 e 2017 (Landsat 8)	53
Capítulo 5.	Conclusões	56
Capítulo 6.	Bibliografia	58

Índice de Figuras

Figura 1 - Organograma: os diferentes tipos de seca.....	5
Figura 2 - Exemplo da Interface do Google Earth Engine	13
Figura 3 - Funcionamento do método Reducer (Fonte: Google Earth Engine for Everyone, Google)	15
Figura 4 - Interações da energia na superfície da Terra e na atmosfera (Fonte: (Tempfli, Kerle, Huurneman, & Janseen, 2001)	17
Figura 5 - Exemplificação dos comprimentos de onda associados a diferentes objetos. Fonte: Geo.University	18
Figura 6 - Ilustração do TRMM e a sua instrumentação: TMI, VIRS, PR, LIS e CERES (Fonte: NASA, página de apresentação do sistema TRMM, Junho de 2018).....	22
Figura 7 - Mapa de ocupação de solo da Península Ibérica.....	27
Figura 8 - Zonas climáticas segundo a escala de Köppen, em Portugal e Espanha. Fonte: Atlas Climático da Península Ibérica - IPMA	28
Figura 9 - Mapas da precipitação média anual entre 2000 e 2017	33
Figura 10 - Mapas de precipitação total anual entre 2000 e 2017	35
Figura 11 - Anomalias de precipitação entre 2000 e 2017. A azul, os desvios em que a precipitação anual foi acima da média; a vermelho, os valores da precipitação abaixo da média; a amarelo, os valores em que a precipitação não difere da média. Média calculada entre 1990 e 2017	38
Figura 12 - Série temporal entre 01 de Janeiro de 1990 e 31 de Dezembro 2017, usando dados CHIRPS, para a região de estudo	39
Figura 13 - Precipitação (mm/pentad) ao longo do ano 2000.....	39
Figura 14 - Anomalias da média anual do NDVI em relação à média do NDVI entre 1991 e 2017, calculadas a partir de produtos Landsat 5 e 8	45
Figura 15 - Média do NDVI das primaveras entre 1990 e 2017 - sensores Landsat 5 e Landsat 8.....	46
Figura 16 Média do NDVI dos verões entre 1990 e 2017 - sensores Landsat 5 e Landsat 8	46
Figura 17 - Média do NDVI dos outonos entre 1990 e 2017 - sensores Landsat 5 e Landsat 8.....	46
Figura 18 - Média do NDVI dos invernos entre 1990 e 2017 - sensores Landsat 5 e Landsat 8.....	46

Figura 19 - Pontos selecionados para estudo das anomalias na saúde da vegetação através do NDVI.....	47
Figura 20 - Média do NDMI dos invernos entre 1990 e 2017 - sensores Landsat 5 e Landsat 8.....	50
Figura 21 - Média do NDMI das primaveras entre 1990 e 2017 - sensores Landsat 5 e Landsat 8.....	50
Figura 22 - Média do NDMI dos verões entre 1990 e 2017 - sensores Landsat 5 e Landsat 8.....	50
Figura 23 - Média do NDMI dos outonos entre 1990 e 2017 - sensores Landsat 5 e Landsat 8.....	50
Figura 24 - Anomalias da média anual do NDMI em relação à média do NDMI entre 1991 e 2017, calculadas a partir de produtos Landsat 5 e 8	51
Figura 25 - Índice de aridez médio calculado entre 2013 e 2017 (esquerda, topo), e médias anuais entre 2013 e 2017. Produtos Landsat 8.....	53
Figura 26 - Anomalias da aridez em relação à média, calculada entre 2013 e 2017 ..	54

Índice de tabelas

Tabela 1 - Bandas do Landsat 5. Fonte: GEE	24
Tabela 2 - Bandas do Landsat 8. Fonte: GEE	25
Tabela 3 - Mínimos e máximos dos mapas de precipitação média entre 2000 e 2017	32
Tabela 4 - Mínimos e máximos dos mapas de precipitação acumulada entre 2000 e 2017.....	34
Tabela 5 - Mínimos e máximos dos mapas de anomalias de precipitação anual entre 2000 e 2017	36
Tabela 6 - Anomalias NDVI das quatro estações do ano entre os anos de 2000 e 2017, nas nove regiões de estudo seleccionadas (Figura 35), em relação à média, calculada para os anos entre 1990 e 2017 (dados Landsat 5 e 8)	48
Tabela 7 - - Anomalias NDMI das quatro estações do ano entre os anos de 2000 e 2017, nas nove regiões de estudo seleccionadas (Figura 18), em relação à média, calculada para os anos entre 1990 e 2017 (dados Landsat 5 e 8)	52

Índice de acrónimos

API – *Application Programming Interface*

CERES – *Cloud and Earth Radiant Energy Sensor*

CHIRPS – *Climate Hazards Group InfraRed Precipitation with Station data*

CPU – *Unidade de Processamento Central (Central Processing Unit)*

DGT – *Direção Geral do Território*

DN – *Digital Number*

EROS – *Earth Resources Observation and Science*

ETM+ – *Enhanced Thematic Mapper Plus*

GEE – *Google Earth Engine*

GIS – *Geographic Information System*

GPCP – *Global Precipitation Climatology Project*

GPM – *Global Precipitation Measurement*

IA – *Índice de Aridez*

IDE – *Integrated Development Environment*

IPCC – *International Panel on Climate Change*

IPMA – *Instituto Português do Mar e da Atmosfera*

LIS – *Lightning Imaging Sensor*

MAPAMA – *Ministério da Agricultura e Pesca, Alimentação e Meio Ambiente*

MODIS – *Moderate Resolution Imaging Spectroradiometer*

MS – *Multispectral Scanner*

NASA – *National Aeronautics and Space Administration*

NASDA – *National Association of State Departments of Agriculture*

NDMI – *Normalized Difference Moisture Index*

NDVI – *Normalized Difference Vegetation Index*

OLI – *Operational Land Imager*

PDSI – *Palmer Drought Severity Index*

PR – *Precipitation Radar*

SLC – *Scan Line Corrector*

SPI – *Standard Precipitation Index*

TIRS – *Thermal Infrared Sensor*

TMI – *TRMM Microwave Imager*

TRMM – *Tropical Rainfall Measuring Mission*

USGS – *United States Geological Survey*

USDA – *United States Department of Agriculture*

VIRS – *Visible Infrared Radiometer*

WMO – *World Meteorological Organization*

Resumo

A seca é um fenómeno natural, caracterizado pela falta de precipitação numa dada região, e desde há muito tem vindo a afetar várias regiões do mundo. Sem previsibilidade, esta forma de desastre natural tem vindo a ser estudada numa tentativa de definir e classificar as suas ocorrências.

Nesta dissertação, foram usadas técnicas de deteção remota para estudar os principais fatores normalmente usados para aplicação no estudo da seca meteorológica, tais como a precipitação, vegetação, e humidade do solo, com foco particular no intervalo de tempo entre o ano 2000 e 2017, tendo como região de estudo toda a extensão da península ibérica.

Tal estudo foi possível graças ao uso do *Google Earth Engine*, a plataforma da Google que uniu vários tipos de dados espaciais numa única localização disponível a todos os seus utilizadores, incluindo, entre muitos outros, os dados usados nesta dissertação. Foram utilizados: i) o produto CHIRPS (*Climate Hazards Group InfraRed Precipitation with Station data*), (combinação de dados TRMM e de estações meteorológicas em terra), usado num estudo aprofundado da precipitação; ii) os produtos dos satélites Landsat 5 e Landsat 8, cuja combinação permitiu atingir a mesma extensão temporal adotada no estudo da precipitação, usados no cálculo dos índices de vegetação, o *Normalized Difference Vegetation Index* (NDVI), e no índice de humidade, *Normalized Difference Moisture Index* (NDMI). Por último, combinaram-se as análises de precipitação e de temperatura para o estudo de aridez de solo.

As conclusões obtidas em cada estudo foram comparadas com as ocorrências conhecidas de seca meteorológica, tendo estudo da precipitação revelado ser o mais promissor dos casos estudados.

Palavras-chave: Seca, Google Earth Engine, TRMM, Landsat, precipitação, vegetação, solo

Abstract

Drought is a natural phenomenon, characterized by the lack of precipitation over a given region, and as such, it has been affecting several regions in the world over the last years. Unpredictable, this form of natural disaster has been studied over the years, with the purpose of being able to properly define and classify its occurrences.

In this dissertation, remote sensing techniques were used to study the main factors on drought occurrences, namely: precipitation, vegetation, and soil moisture, with particular focus on the years 2000 through 2017, and considering the whole extent of the Iberian peninsula as the region of study.

Such study was only possible thanks to Google Earth Engine, the Google's platform that integrates and makes available several geospatial data from a single one location, including, the data used in this study – the product CHIRPS (*Climate Hazards Group InfraRed Precipitation with Station data*), which is a combination of TRMM data with *in situ* meteorological stations, used for a comprehensive study of precipitation; the products from the Landsat 5 and Landsat 8 satellites, a data set covering the same temporal span used in the precipitation study, applied to vegetation and soil moisture: the Normalized Difference Vegetation Index (NDVI) and the Normalized Difference Moisture Index (NDMI). Lastly, a combined analysis of precipitation and temperature was performed to study the soil's aridity.

The conclusions drawn in each study were compared to registered cases of drought that are known to have occurred, and the precipitation study turned out to be the most promising of the selected study cases.

Keywords: Drought, Google Earth Engine, TRMM, Landsat, precipitation, vegetation, soil

Agradecimentos

Ao Professor Nelson Pires e à Professora Dr. Joana Fernandes agradeço o apoio e orientação nesta dissertação, e por me terem permitido trabalhar a um ritmo próprio. Em particular ao professor Nelson Pires, que pensou no tema desta dissertação e que me deu a oportunidade de aprender e trabalhar com o *Google Earth Engine*, dando-me desta forma a possibilidade de não apenas elaborar esta dissertação, mas também de ter tido a felicidade de trabalhar por gosto.

Agradeço especialmente ao Bernardo, que me ouviu dias e noites, e que me apoiou durante toda esta fase, cheia de altos e baixos, além de ter estado presente durante todo o meu percurso, e que me arreliou em todas as horas certas, como sempre.

À Mariana, minha colega e amiga, que estive lá desde o começo, e que começou e acabou comigo esta última etapa. Agradeço pelas sugestões e paciência e sobretudo por me mandar fotografias de duas carinhas sorridentes que me alegravam fosse quando fosse.

À Rita, minha irmã de tudo menos de sangue, agradeço todas as inúmeras vezes que me ouviu e aconselhou, e que me lembrou sempre do que era importante.

Por último, mas não menos importante, agradeço aos meus pais, e aos meus amigos, que mais nada são que família, e que ouviram, incentivaram e lembraram sempre do que vale a pena.

Capítulo 1.

Introdução

O IPCC – *International Panel on Climate Change* – estabelece a definição de desastre natural como alterações no funcionamento normal de uma comunidade ou sociedade, devido a eventos físicos desastrosos que interajam ou influenciem as condições sociais. Estes derivam da combinação de fatores físicos que potenciam a sua ocorrência e da vulnerabilidade da zona (IPCC, 2012). Dos tipos de desastres naturais que podem afetar o Homem, a seca é dos fenómenos mais complexos, e que afeta mais pessoas, durante mais tempo (Pires et. all, 2010).

Por ter origem meteorológica e climatológica, características com permanente variabilidade, que se verificam em todas as escalas temporais e espaciais, o fenómeno da seca, devido à sua própria imprevisibilidade e escala temporal indefinível, difere de outros desastres naturais, que por norma ocorrem de forma rápida e deixam impactos visíveis. Os fenómenos de seca, são assim uma forma de desastre natural que não temos o poder de iniciar, como um fogo, ou prever quando se irá estabelecer. O comportamento deste fenómeno não só é imprevisível quanto à sua origem, como também os seus efeitos variam de região para região – uma semana sem chuva pode ser considerada como seca num clima tropical, enquanto que noutras regiões, esses sete dias são um período de tempo curto, no qual possa não ocorrer precipitação sem ser considerada seca, como acontece nas zonas desérticas.

As situações de seca são frequentes em Portugal Continental, trazendo consequências para os setores da agricultura e da pecuária, e afetando também os recursos hídricos e o bem-estar das populações. Em particular as regiões a sul do Tejo são as mais suscetíveis de ocorrência de seca, e por sua vez, também as mais afetadas (Pires et. all, 2010). Já em Espanha, por ter regiões consideravelmente mais extensas e áridas, também são frequentes as situações de seca, tendo-se registado situações de seca entre 1991 e 1995 na grande extensão do seu território (MAPAMA, 2018), trazendo desta forma consequências socioeconómicas para o país e que conduziram à implementação de um sistema de monitorização de seca a nível nacional.

Nesta dissertação são usadas técnicas de deteção remota para estudar os fatores principais no estudo da seca: a precipitação, a vegetação, e a humidade do solo. Num primeiro capítulo, é introduzido o objeto de interesse desta dissertação, no qual se descreve

o contexto do estudo e o problema abordado – a seca meteorológica, as suas diferentes formas, e as diferentes abordagens na sua definição e deteção.

O segundo capítulo procura apresentar as técnicas de deteção remota que foram escolhidas para fazer este estudo. Começando pelo estudo da precipitação, em que foram usados dados CHIRPS (*Climate Hazards Group InfraRed Precipitation with Station data*) para fazer um estudo aprofundado para o período entre 1990 e 2017 da precipitação na península ibérica. De seguida, é efetuado um estudo da vegetação, através do cálculo do índice de vegetação de diferença normalizada (NDVI – *Normalized Difference Vegetation Index*) com dados Landsat, combinando os dados dos satélites Landsat 5 e Landsat 8 para se alcançar a mesma extensão temporal do estudo da precipitação. Por fim, como estudo de humidade do solo, e para melhor se compreender o estado da vegetação na zona de estudo, é também abordado o uso do índice de humidade, NDMI (*Normalized Difference Moisture Index*), que recorreu ao uso dos mesmos dados do estudo da vegetação.

O cálculo e manipulação dos dados acima mencionados foram feitos recorrendo ao uso do *Google Earth Engine*, a plataforma da Google que disponibiliza vários conjuntos de dados geoespaciais, entre eles os que foram utilizados nesta dissertação, e que permite ao utilizador recorrer ao poder de processamento dos seus servidores para rapidamente processar esse mesmo volume de dados. Esta ferramenta é, por si, um dos principais focos desta dissertação, pela diferença que traz para qualquer trabalho, em particular no âmbito da deteção remota, relativamente a outros *softwares* GIS.

O *Google Earth Engine* surgiu em maio de 2013 (Gallagher, 2013), com uma plataforma que combinava as já então conhecidas capacidades de mapeamento global que a empresa detinha com décadas de produtos disponibilizados tanto pela NASA como pela USGS (*US Geological Survey*). Um dos primeiros produtos apresentados foi o *Timelapse*, que mostrava a superfície da Terra ao longo das últimas três décadas à escala global. Na página web onde se introduz o produto, o utilizador pode fazer zoom sobre qualquer zona do globo e ver vídeos, onde constam milhares de imagens processadas para mostrar a evolução temporal da zona.

Não é incomum que amadores, estudantes ou profissionais neste ramo tenham que lidar com volumes de informação consideráveis; a diferença reside em como é possível trabalhar nesses volumes, e por quanto tempo, quer em processamento, quer a elaborar algoritmos para lidar com os dados. Muitas vezes, ao pensar num plano de abordagem de uma temática, é necessário considerar a extensão temporal e espacial tendo em conta o volume de dados com os quais é fisicamente possível trabalhar, já que estamos, muitas vezes, limitados aos computadores e dispositivos de armazenamento que possuímos para

proceder aos estudos. Dessa forma, por outro lado, também é comum investir em dispositivos que nos tragam maior capacidade de processamento, além de armazenamento, para ser possível alcançar objetivos mais ambiciosos no que toca a volume de dados, quer associados às extensões das regiões de estudo, ou o período de estudo pretendido – ou ambos.

Nesse sentido, o *Earth Engine* surge quase como libertando o utilizador dessas preocupações e cuidados a ter ao conceber o estudo a fazer, abrindo as portas para a possibilidade de se fazerem estudos à escala global, limitados apenas à extensão dos próprios dados – e, claro, aos conhecimentos do próprio utilizador. Numa nota mais pessoal, utilizar o *Earth Engine* foi sem dúvida diferente de qualquer trabalho antes feito: não ter o computador em “*stand-by*” enquanto processava os dados, função que muitas vezes obrigava a que nada mais pudesse ser feito no computador enquanto essa tarefa estivesse a decorrer; não esperar horas para a obtenção dos resultados, nem encher os dispositivos de armazenamento disponíveis quer com os dados a processar, quer com os resultados; são todos eles exemplos recorrentes de experiência que puderam ser ultrapassados ao trabalhar nesta plataforma.

1.1. Objetivos

Nesta dissertação pretende-se estudar a precipitação, a vegetação e a humidade do solo e verificar os comportamentos desses fatores ao longo dos anos, identificando desta forma a existência de padrões que possam ser associados à ocorrência de fenómenos de seca, com recurso ao *Google Earth Engine*.

Para tal, são criados mapas de precipitação para a região de estudo, recorrendo ao produto CHIRPS; e serão calculados os índices NDVI e NDMI, a partir de produtos gerados através das missões Landsat 5 e 8. Adicionalmente, serão criados mapas de aridez do solo, em que a aridez é expressa pela precipitação média anual em função da temperatura média anual.

Pretende-se desta forma identificar, para cada um destes fatores, as anomalias no tempo que correlacionem épocas e localizações onde tenha existido a ocorrência de secas meteorológicas, de forma a demonstrar-se que os dados utilizados poderão servir como indicadores viáveis na identificação deste tipo de fenómenos meteorológicos.

Capítulo 2.

Contextualização

2.1. Formas de seca

A seca resulta de um período de precipitação abaixo da média numa dada região, e está associada à escassez das reservas de água, que pode por sua vez ter origem em razões atmosféricas, superficiais ou nos lençóis freáticos. Este fenómeno natural difere das variações sazonais, cujo comportamento obedece a um padrão específico, pois a sua ocorrência é um processo de acumulação lenta, e porque seu início e fim são difíceis de prever (Kademani, 2006).

As secas podem ter um impacto substancial nos ecossistemas e na agricultura da região afetada, bem como atingir a economia local. Épocas de seca anuais nas zonas tropicais aumentam significativamente as hipóteses de uma seca de duração prolongada desenvolver, e consequentemente a probabilidade de aumento de ocorrência de incêndios florestais. Períodos de temperaturas significativas, a par de baixa precipitação, pioram o estado de seca por levarem a um aumento da evapotranspiração.




Figura 1 - Organograma: os diferentes tipos de seca

Um cenário de seca pode apresentar duração variável, podendo durar meses ou anos, pelo que diferentes parâmetros deverão ser tidos em conta quer na consideração do que leva ao estado de seca em si, quer no que toca aos diferentes tipos de seca. Wilhite e Glantz categoriza estas definições através de quatro formas básicas de medição dos diferentes estados de seca (Wilhite & Glantz, 1985): meteorológica, agrícola, hidrológica e socioeconómica (Figura 1).

2.1.1. Seca meteorológica

Regra geral, a seca meteorológica implica a falta de precipitação numa magnitude tal que pode afetar seriamente a vida normal da sociedade (Kademani, 2006). Nesta situação, existe um decréscimo significativo da precipitação na região em relação aos valores médios esperados.

Como métodos de deteção para a seca meteorológica, estudos demonstram que esta pode ser identificada através do cálculo do índice de aridez pelo método de Herbst (P.H. Herbst, 1966), que representa a diferença entre a evapotranspiração potencial e a real, sendo melhor aplicado sobre zonas onde tenha ocorrido seca prolongada. Existem outras abordagens, tais como o Índice de Seca Severa de Palmer, que avalia o nível de seca no espaço e no tempo, e cujo cálculo se baseia na precipitação na zona de estudo, evapotranspiração e balanços de água usada e reservada.

Herbst (P.H. Herbst, 1966) procurou estudar secas através do estudo da precipitação mensal, determinando a intensidade de uma seca e a sua duração com base em dados mensais. O índice de aridez (IA) tem uma abordagem semelhante, mas compara a precipitação efetiva anual com a evapotranspiração anual de forma a estabelecer um rácio entre a água fornecida e a água gasta.

Neste projeto, procurou-se fazer um estudo anual da precipitação, comparando os valores anuais com valores médios num intervalo de tempo alargado, de forma a estabelecerem-se anomalias anuais, e determinar o desvio anual de precipitação em relação à média.

Uma vez detetados os anos mais anormais em relação à média, em particular os que apresentam maior deficiência na precipitação anual, foram feitos também estudos a nível sazonal e mensal, de forma a observar posteriormente potenciais declives na saúde da vegetação local, resultantes do declínio da precipitação nesse ano.

2.1.2. Seca agrícola

A seca agrícola é definida pela resposta das plantações a dados indicadores. Esses indicadores podem ser meteorológicos, ou a própria resposta da vegetação face à falta de precipitação durante os períodos do seu crescimento. Tal pode levar ao défice da humidade presente no solo, causando assim sérios problemas aos ecossistemas agrícolas.

A seca agrícola está, portanto, associada ao decréscimo da precipitação, característico da seca meteorológica; a diferenças entre a evapotranspiração esperada e a real; a défices na água presente no solo; à redução de água disponível nos lençóis freáticos, característicos de uma seca hidrológica; e ao impacto que a deficiência nesses fatores têm na agricultura.

A saúde de uma planta depende das suas características biológicas, do estado do seu crescimento, propriedades físicas e químicas do seu solo e das condições meteorológicas. Ao estudar a possibilidade de ocorrência de uma seca agrícola, deve-se ter atenção às várias suscetibilidades de uma plantação e a outros fatores que possam influenciar o seu desenvolvimento. No entanto, caso se registe a ocorrência de seca, esta tornará a terra potencialmente incapaz para cultivo ao longo do ano, o que por sua vez poderá originar graves consequências para a vida humana local.

A Organização Meteorológica Mundial (*World Meteorological Organization*) define esta forma de seca pelos níveis de humidade presente no solo, e o comportamento das plantações associado a esses níveis de humidade. Numa publicação de 1975, teoriza-se que o comportamento das plantações face a alterações à humidade presente no solo é dependente do tipo de cultivo (Annual Report of the World Meteorological Organization, 1975).

2.1.3. Seca hidrológica

A seca hidrológica está associada ao efeito que a ausência ou diminuição severa de precipitação numa região tenha nas correntes à superfície ou sob a superfície, como por exemplo reservatórios, lagos ou lençóis freáticos.

A frequência e severidade de uma seca hidrológica é frequentemente definida por uma corrente ou bacia hidrográfica. É comum que uma seca hidrológica surja fora de fase com a ocorrência de uma seca meteorológica ou de uma seca agrícola, uma vez que leva mais tempo a que a ausência de precipitação leve à manifestação de alterações em sistemas hidrológicos como a humidade no solo e correntes internas.

No entanto, apesar de demorar muito mais tempo a manifestar-se e ser a forma mais extrema de seca, este é o tipo de seca que pode trazer maiores consequências a nível socioeconómico devido ao maior impacto sobre sistemas hidrológicos, como rios e

reservatórios, que servem sistemas como a irrigação e a navegação, o funcionamento das estações hidroelétricas, e dos quais dependem habitats de vida selvagem. É por isso considerado que o impacto da seca hidrológica traria consequências para o dia-a-dia da população e vida animal na região da sua ocorrência.

2.1.4. Seca socioeconómica

Finalmente, a seca socioeconómica ocorre quando a procura de determinados bens (água, grãos alimentares, peixe, energia hidroelétrica) excede a oferta, devido a menores reservas de água que resultam de um défice na precipitação, associado à seca meteorológica.

Não sendo objeto de estudo diretamente neste projeto, é importante mencionar esta forma de seca pela importância que traz a esta temática. Apesar de ainda ser difícil prever com precisão, e até de definir o conceito de seca, é importante que existam estudos que ajudem a compreender o comportamento deste fenómeno, de forma a podermos prevenir o mais atempadamente possível as suas consequências.

2.2. Causas de seca

Apesar de a sua definição depender de vários fatores, a seca tem a sua origem na falta de precipitação por um período extenso de tempo, normalmente mais do que uma época anual, que leva à falta de água para alguma atividade, grupo ou setor ambiental. A seca está também relacionada com a época sazonal em que a precipitação cesse.

Outros fatores, como as altas temperaturas, ventos fortes ou humidade relativa baixa estão fortemente relacionados com a seca. Na literatura, as secas podem ser definidas com base em diferentes variáveis (Kademani, 2006):

1. Precipitação
2. Evapotranspiração
3. Correntes internas
4. Humidade do solo
5. Vegetação

No caso dos dois primeiros parâmetros, a precipitação e a evapotranspiração, observa-se que estes são os indicadores das condições para que uma seca meteorológica se estabeleça; as correntes internas são indicativas de secas hidrológicas e, por fim, a humidade do solo e a vegetação referem-se a secas agrícolas.

O período de seca e o conjunto de fatores que o determinam variam de estudo para estudo e de país para país, como já foi dito. No caso da precipitação, uma distribuição temporal da precipitação é mais importante que o total de precipitação ao longo de uma estação, ou ao longo de um mês. (Thiruvengadachari & Gopalkrishna, 1993) confirmou que a eficiência na precipitação varia no tempo e no espaço, o que limita o uso dos valores de precipitação como único indicador de seca.

2.3. Monitorização da seca

2.3.1. Monitorização de seca em Portugal

Em Portugal, a monitorização de secas está ao encargo do Instituto Português do Mar e da Atmosfera (IPMA), que recorre ao estudo do índice mensal de seca PDSI (*Palmer Drought Severity Index*), de modo poder comunicar a distribuição de seca no território continental e estudos de comparação com os 10 meses anteriores. Para o cálculo do índice de seca, o IPMA recorre a dados de temperatura e precipitação obtidos na sua própria rede de estações.

Adicionalmente, o IPMA disponibiliza o índice SPI (*Standard Precipitation Index*) para o estudo da situação de seca no território continental, que consiste no desvio de precipitação em relação à média para um período de tempo específico, dividido pelo desvio padrão do período a que diz respeito essa média (Instituto Português do Mar e da Atmosfera, 2018).

Num relatório da Associação Portuguesa de Riscos, Prevenção e Segurança (Pires, Silva, & Mendes, Riscos de secas em Portugal Continental, 2010), são identificados vários períodos de seca em Portugal Continental, sendo divididos em duas listas conforme duração e intensidade do período de seca. Os períodos são os seguintes:

- 1933 – 1935, num período de 26 meses em que a zona afetada foi o Porto; 15 meses em Lisboa e 28 meses em Beja;
- 1943 – 1946, em que novamente o Porto foi afetado por 38 meses, Lisboa 26 meses e Évora e Beja 29 meses;
- 1973 – 1976, em que Lisboa foi afetada por 28 meses e Évora 18 meses;
- 1979 – 1982, afetando Évora por 33 meses;
- 1991 – 192/3, em que Lisboa e Beja foram afetadas por 22 meses, e Évora 18 meses
- 2004 – 2006, em que Beja foi afetada por 33 meses, e Évora, Lisboa e Porto durante 16 meses.

O relatório destaca várias ocorrências de seca, em particular nas zonas do Porto, Lisboa, Beja e Évora, como zonas em que ocorreram secas, moderadas a extremas, entre 1941 e 2006, e que portanto se consideraram alvo de observação particular para esta dissertação.

Mais recentemente, o mês de Outubro de 2017, em Portugal, foi o mais quente dos últimos 20 anos, numa altura em que se considerava haver estado de seca na Europa. No final de outubro, todo o território de Portugal continental foi considerado como estando em

situação de seca severa (24,8%) e extrema (75,2%) (Instituto Português do Mar e da Atmosfera, 2018)

Ao mesmo tempo, em Espanha, na região da nascente do rio Douro registou-se consideravelmente mais seca, velicando-se também um declínio de água disponível nas barragens para apenas 40% da sua capacidade.

2.3.2. Monitorização de seca em Espanha

De forma análoga a Portugal, em Espanha, o Ministério da Agricultura e Pesca, Alimentação e Meio Ambiente (MAPAMA) realiza um acompanhamento mensal dos indicadores de estado de seca hidrológica em todas as Demarcações Hidrográficas intercomunitárias, publicando um mapa com os valores indicadores correspondentes ao último dia de cada mês, bem como a informação resumida do estado de seca nesse mês (MAPAMA, 2018).

O mapa elaborado é categorizado em cinco classes: uma sem dados, e quatro que traduzem o estado de seca na região – normal, pré-alerta, alerta e emergência.

2.3.3. US Drought Monitor

O U.S. *Drought Monitor* é o programa para monitorização de secas nos Estados Unidos da América, desenvolvido pelo Centro Nacional de Mitigação de Secas na Universidade de Nebraska, em Lincoln, e financiado pelo departamento económico da USDA, consistindo no mapeamento das condições de seca, em tempo real, no território dos Estados Unidos. O seu propósito é dar a conhecer à população as zonas em que esteja a ocorrer seca, a sua severidade, e a sua extensão espacial, bem como a escala temporal do evento de seca a decorrer. O modelo, apresentado semanalmente, é determinado manualmente através da análise de diversos indicadores de seca, e desenhado segundo esses indicadores... A análise é baseada não apenas na precipitação, mas também por indicadores como o PDSI (*Palmer Drought Severity Index*) bem como pela contribuição de 400 analistas distribuídos pelo território nacional. No mapa, constam as quatro formas de seca já enunciadas: meteorológica, hidrológica, agrícola e socioeconómica, e categorizam os níveis de seca em 5 classes, partindo de D0, anormalmente seco (categoria em que não se considera seca estabelecida), e incluindo 4 categorias de seca, desde seca moderada a seca excecional.

Dos indicadores de seca utilizados, encontram-se a precipitação, fluxo de correntes, níveis nos reservatórios, temperatura e evapotranspiração, humidade do solo, saúde da vegetação, condições para incêndios, relatórios locais de condições de seca feitos por entidades externas, e relatórios individuais por mais de 400 contribuidores.

Capítulo 3.

Metodologia

3.1. *Google Earth Engine – “A planetary-scale platform for Earth science data & analysis”*

Para este estudo, a ferramenta usada para visualizar e examinar os dados foi o **Earth Engine**, a plataforma da Google que consiste num catálogo de dados, na ordem dos multi-petabyte, que estão ecolocalizados com o serviço de computação paralela (Noel Gorelick, 2016). Este serviço contém várias bibliotecas de diferentes tipos de dados, e permite o processamento desses dados nos seus próprios servidores, garantindo assim dois aspetos que são relevantes para o trabalho em deteção remota – a visualização de dados em grande quantidade, e o processamento desses dados com muito maior celeridade que teríamos a processar localmente. Ambos são possíveis graças ao processamento (dos dados) paralelo e em servidor (Noel Gorelick, 2016) sem ser necessária para esse efeito a aquisição de um grande volume de dados e respetivo armazenamento local, o que é sempre um aspeto chave a ter em conta no início de um projeto.

O acesso ao *Google Earth Engine* (GEE) pode ser feito através do *browser*, onde funciona com base numa interface para aplicação de programação (API – *Application Programming Interface*). Em alternativa, pode também funcionar com base num ambiente de desenvolvimento interativo (IDE). A versão usada para este estudo – a API – recorre a linguagem de programação *JavaScript*, e disponibiliza uma biblioteca de operadores que auxiliam o utilizador a gerir, processar e analisar os dados disponibilizados pela biblioteca pública de dados.

3.1.1. Regras na utilização

O catálogo de dados disponibilizado para utilização livre inclui vários *datasets* geoespaciais, incluindo observações satélite, imagens aéreas nos espectros ótico e não-ótico, variáveis ambientais, dados climáticos, meteorológicos, florestais, de cobertura de solo, topográficos, e até socioeconómicos.

Todos os dados são pré-processados e disponibilizados na forma “pronto-a-usar”, de forma a permitir acesso eficiente e remover barreiras associadas à gestão de dados, tornando assim a plataforma acessível a utilizadores até iniciantes na deteção remota. O modelo geral que o GEE utiliza consiste de um modelo simples, generalista, em que os pixéis de uma

banda individual devem ser homogêneos entre diferentes tipos de dados, bem como em resolução e em projeção. As bibliotecas presentes no GEE foram todas pré-processadas, como já foi mencionado, de forma a facilitar tanto o acesso como o próprio processamento dos produtos. Todas as imagens são recortadas em quadrados 256 x 256, na projeção e resolução originais (Noel Gorelick, 2016), de forma a preservar os dados, mas assumindo o melhor compromisso entre facilitar ao utilizador uma quantidade de dados eficazmente, sem ao mesmo tempo desperdiçar tempo e espaço de servidor. Cada imagem tem ainda associada a localização, hora de aquisição, e condições sobre as quais a imagem pode ser processada.

As imagens adquiridas por cada sensor são agrupadas e chamadas de “coleções”, o que permite ao utilizador filtrar, identificar e obter rapidamente os dados pretendidos. Os parâmetros a serem filtrados podem ser temporais, espaciais, e tão minuciosos como a escolha de cobertura de nuvens em dada percentagem, datas específicas ou zonas específicas – como foi exemplo neste estudo, em que se escolheu, por exemplo, de todos os produtos TRMM disponíveis, apenas trabalhar com os que fossem na zona da península ibérica, dentro do período de estudo. Para as imagens *Landsat*, foram filtradas as imagens adquiridas na zona de estudo, no período indicado, e também com cobertura de nuvens reduzida.

O utilizador é livre de aceder a esses dados, e até de integrar os seus mesmos dados e processá-los através da plataforma, apesar de haver restrições para o volume de dados, diretamente associadas às restrições comuns a outras aplicações mais comumente utilizadas (como, por exemplo, o *Google Drive*).




Figura 2 - Exemplo da Interface do Google Earth Engine

A versão API do GEE (Figura 2) é uma plataforma *web* em ambiente de desenvolvimento interativo, construída sobre a base que é o catálogo e servidor que constituem o sistema. O utilizador pode aceder ao GEE através da página <https://earthengine.google.com>, e aceder à interface de utilizador, bem como a tutoriais, guias, exemplos de funcionamento e de código: tudo desde o básico, incluindo fundamentos da linguagem de programação utilizada, passando pelo uso da biblioteca de funções disponíveis ao utilizador, a guias completos sobre o funcionamento geral do GEE, e cada conjunto de dados é acompanhado por um manual sobre os mesmos. A plataforma é, assim, acessível tanto a iniciantes no domínio da programação, quanto a iniciantes no âmbito da deteção remota, permitindo ao utilizador evoluir e progredir na plataforma até ao seu objetivo final com relativa facilidade.

A plataforma em si, como vista na figura 2, é o ambiente de trabalho principal para o utilizador: nela, encontram-se as bibliotecas de dados através da barra de procura (topo, centro); os *scripts* do utilizador são acessíveis diretamente, clicando em cada ficheiro (*scripts*, à esquerda). Documentação sobre as funções disponíveis está disponível (ainda no menu à esquerda, segunda opção) e os dados que o utilizador escolha incluir na sua plataforma como apoio ao seu trabalho estão também no menu à esquerda, como opção final.

O *workplace* para cada código é visível no centro do ecrã, onde é possível gerar um *link* direto para partilhar o código com outros utilizadores, guardar o ficheiro, correr o código, e pará-lo no ponto em que estiver (*reset*). Ao correr um *script*, é possível ao utilizador interagir com os dados usando a opção *Inspector*, que permite clicar em qualquer ponto do mapa, e os dados do píxel escolhido apareceriam – incluindo os valores das bandas nessa zona, coordenadas geográficas, ou qualquer outra informação associada ao que foi projetado no mapa.

Num script GEE, muitas das operações tomam lugar no lado do utilizador (*browser*), enquanto que outras são executadas nos próprios servidores da *Google*. Um dos desafios ao elaborar o código surgiu precisamente dessa distinção, uma vez que operações que ocorram do lado do utilizador são distintas das que ocorrem em servidor, e cruzá-las não é recomendado.

Isto acontece porque objetos GEE (normalmente antecidos pelo prefixo “*ee*”) são trabalhados exclusivamente em servidor, enquanto que outras variáveis JavaScript são interpretadas apenas a nível de utilizador (*browser*). Desta forma, operações que daríamos como recorrentes ao elaborar código, como por exemplo recorrer a iterações para percorrer os dados a estudar, quando a trabalhar no GEE não são aconselhadas, pois conduzem a resultados errados.

Para contornar esse problema, operadores como o *Map*, *Reduce*, *Median*, são os recomendados. Todos eles tornam as coleções de imagens, ou outros objetos de servidor, em objetos de utilizador, permitindo assim, ao longo do código, separar essas faces distintas.

Redutores espaciais e temporais

No *Earth Engine*, os redutores são usados para agregar os vários conjuntos de dados no tempo, espaço, ou outra estrutura que o utilizador escolha. Esta classe pode incluir regressão linear, ou elementos estatísticos, como histogramas. A *Google* fornece um diagrama que explica como funciona um redutor quando aplicado sobre uma coleção (Figura 3):




Figura 3 - Funcionamento do método Reducer (Fonte: Google Earth Engine for Everyone, Google)

3.1.2. Os prós e contras do GEE

Como ferramenta, o *Google Earth Engine* traz várias vantagens para os seus utilizadores. Os vários *petabytes* de dados que o GEE disponibiliza estão fundidos numa única localização, dispensando ao utilizador recorrer a diferentes localizações para os diferentes tipos de dados que o seu trabalho possa requerer. Adicionalmente, todos esses dados estão armazenados nos seus próprios servidores, dispensando assim ao utilizador o uso do seu próprio espaço de armazenamento. Por fim, o poder computacional do GEE permite que um milhão de horas de CPU sejam calculáveis em dias (Noel Gorelick, 2016), ao

dividir os dados em grelhas independentes, que são armazenadas em agrupamentos e calculando os dados através de centenas de CPUs.

Além disso, a interface gráfica é intuitiva para não-programadores, e fácil de utilizar para qualquer utilizador independentemente dos seus conhecimentos em programação ou detecção remota. A interface visual é acompanhada de exemplos, listagem de funções, documentação, e oferece informações detalhadas dos dados e a forma como estes possam ser manipulados. Além disso, é possível criar tarefas e proceder ao *download* de resultados assim que estes sejam obtidos.

No entanto, esta interface não permite uma exploração completa do GEE, por impor restrições a certas ações e não permitir mapear funções a nível de píxel. Apesar de um utilizador sem conhecimentos de programação poder utilizar a plataforma, está também limitado ao seu conhecimento para poder explorar a plataforma convenientemente, e é necessário conhecer a forma como os objetos e funções GEE funcionam para ser possível trabalhar em prol dos objetivos a atingir. A programação em paralelo em servidor, nesse sentido, limita em alguma extensão as funcionalidades, na medida em que um utilizador experiente na elaboração de códigos para processamento de dados de detecção remota precisa adaptar-se a esta forma de processamento e, portanto, de programar, para poder atingir os seus objetivos.

3.2. A Deteção Remota e o estudo de seca

Neste trabalho, são usadas técnicas de deteção remota para estudar o fenómeno da seca; isto é, quais os fatores que mais predominantemente influenciam e/ou são influenciados por este fenómeno: a precipitação, a vegetação, e o solo.

Um dos conceitos básicos da deteção remota é a radiação eletromagnética, sendo crucial compreender a sua interação no espaço com elementos como a vegetação, os corpos de água, e até a atmosfera, uma vez que a radiação recebida pelo sensor sofre alterações específicas e características desses elementos (Campbell & Wynne, 2011).




Figura 4 - Interações da energia com a superfície da Terra e a atmosfera (Fonte: (Tempfli, Kerle, Huurneman, & Janseen, 2001))

Da radiação eletromagnética, convém mencionar que várias formas de interação ocorrem entre o emissor, a superfície e o próprio sensor. Antes que a energia do Sol atinja a superfície da terra, três interações ocorrem na atmosfera: a energia emitida pode, ainda na atmosfera, sofrer absorção, emissão ou reflexão.

Uma vez ultrapassada a atmosfera, a energia transmitida pode ser refletida ou absorvida pelo material à superfície; Se refletida pelo material, a energia refletida pode uma vez mais sofrer reflexão ou absorção na atmosfera antes de atingir o sensor (Campbell & Wynne, 2011), (Tempfli, Kerle, Huurneman, & Janseen, 2001).

A partir da superfície, também existe a possibilidade de haver energia emitida (térmica). Essa pode também sofrer absorção na atmosfera, ou atingir o sensor.

Por último, a radiação dispersa na atmosfera ou até emissões atmosféricas são também formas segundo as quais o sensor pode captar energia.




Figura 5 - Exemplificação dos comprimentos de onda associados a diferentes objetos. Fonte: Geo.University

Assim sendo, é possível distinguir o tipo de um objeto pela assinatura do comprimento de onda refletido e lido pelo sensor; as folhas da vegetação têm características distintas que se traduzem na energia que refletem, incluindo até a orientação e estrutura de uma folha. A quantidade de energia refletida de um comprimento de onda em particular depende do pigmento da folha – de forma análoga, também podemos distinguir os diferentes tipos de minerais presentes no solo, consoante os diferentes comprimentos de onda que são refletidos (Tempfli, Kerle, Huurneman, & Janseen, 2001).

Outro fator essencial na deteção remota é a resolução, e podem ser consideradas diferentes resoluções: espectral, espacial, temporal e radiométrica. A resolução espectral representa a sensibilidade do sensor à radiação, sendo definida pelo número e largura de bandas correspondentes a determinados intervalos de radiação eletromagnética. A resolução espacial pode ser definida como a menor medida entre dois objetos distintos identificáveis ou, mais simplesmente, pela cobertura da área de um pixel no terreno observado. A resolução temporal refere-se à periodicidade a que o sensor recolhe imagens de local ou ao período orbital do satélite a bordo do qual está instalado o sensor (Jensen, 2000). Por fim, a resolução radiométrica define a precisão das medidas do sensor num dado canal, sendo dada pelo número de níveis de cinza (ou DN, "*digital number*") utilizados para se compor a imagem. Normalmente este número de valores está relacionado com a representação informática da medida (número de bits).

3.2.1. Estudo da precipitação

A precipitação é um processo irregular, de mudanças constantes quer na sua forma, quer intensidade, enquanto atravessa uma determinada área. O estudo da precipitação sobre uma superfície é de grande importância, não apenas para estudos de seca, mas nas áreas da meteorologia, agricultura, climatologia, hidrologia, e tantas outras áreas científicas.

É importante entender esta variável e a sua representação temporal e espacial, mas é também uma variável difícil de monitorizar em grande escala – a construção de estações meteorológicas nas últimas décadas veio aumentar a capacidade de monitorização, em tempo real, a nível local, mas a distribuição destas nem sempre é uniforme e a cobertura nem sempre é total. Nesse sentido, o surgir dos satélites meteorológicos trouxe uma grande vantagem e evolução para o estudo da precipitação.

Hoje em dia, existe um número crescente de produtos que permitem o estudo da precipitação e estão disponíveis quase em tempo real a partir de diferentes fontes, sensores e formatos, todos eles com diferentes características, custos, definição e resolução espacial.

Os produtos derivados de satélites oferecem a vantagem de providenciarem dados com cobertura de maiores áreas, dando uma alternativa eficaz para estudos que cubram áreas extensas de tal forma que não existam dados de estações em terra que ofereçam dados suficientes para cobrir a zona de estudo por completo. No caso deste estudo, foram usados os produtos TRMM e CHIRPS, em que o segundo combina os dados do primeiro com dados em terra, de forma a se obter uma melhor resolução, e dados mais fidedignos, por combinar dados recolhidos em terra e dados espaciais, que garantem uma cobertura total, de forma contínua.

3.2.2. Estudo da vegetação: NDVI (*Normalized Difference Vegetation Index*)

A vegetação ocupa aproximadamente 70% da superfície dos continentes (Jensen, 2000), fazendo desta um dos mais importantes ecossistemas do nosso planeta. Entender as variações nas diferentes espécies de vegetação, os seus padrões de comportamento, e alterações nos seus ciclos de crescimento são alguns dos fatores que, uma vez compreendidos, nos permitem ter uma visão mais clara sobre as características de uma área, seja sobre a biodiversidade, geologia, até ao estudo das suas variações climáticas.

Através da deteção remota podemos estudar a vegetação sobre áreas extensas, mas para isso devemos primeiro entender as características da vegetação e com que tipo de dados devemos trabalhar para obter informações sobre esses parâmetros.

A clorofila presente numa típica folha de vegetação saudável tem tendência a absorver a radiação na zona do vermelho (400 – 700 nm), e a sua estrutura celular reflete na zona do infravermelho próximo, entre os 700 – 1200 nm. Uma folha saudável tende a absorver a energia radiada muito eficazmente nos comprimentos de onda do azul e do vermelho do espectro, no qual a luz incidente é requerida para a fotossíntese. Já no infravermelho próximo, se as plantas absorvessem nesse comprimento de onda, comprometeriam a sua estrutura por aquecerem demasiado, pelo que a vegetação adaptou-se e simplesmente reflete ou transmitem essa energia (Jensen, 2000).

Quão mais saudável seja a vegetação, maior a sua atividade fotossintética, e por conseguinte maior a absorção solar: assim sendo, há uma relação direta entre o vigor da vegetação e a absorção e emissão nas bandas do azul e do vermelho por parte da planta.

O índice de NDVI é calculado pela expressão:

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

Os valores de NDVI variam entre – 1 e + 1, dos quais aplicamos os valores nesse intervalo para definir a natureza do ponto. A classificação dos diferentes intervalos do NDVI, abaixo descritas, são meramente indicativas;

- Oceanos, Lagos, Rios → [-1 < NDVI < -0.5]
- Rochas, Areia, Neve → [-0.1 < NDVI < 0.1]
- Arbustos, Relvados, Vegetação Rasteira → [0.2 < NDVI < 0.4]
- Florestas tropicais ou temperadas → [NDVI > 0.5]

Os valores de NDVI são usados para a descrição de cobertura de solo em território continental e classificação de vegetação (J.P. Tarpley, 1984), bem como a monitorização de precipitação e de seca, atuando como uma ferramenta na determinação do estado de seca no território e/ou de previsão do potencial de seca vir ou não a estabelecer-se.

3.2.1. Estudo da vegetação: NDMI (*Normalized Difference Moisture Index*)

O índice NDMI (*Normalized Difference Moisture Index*), apesar de menos conhecido e usado que o NDVI, é útil pela sua maior sensibilidade à água nas regiões em que a absorção da água é menos influenciada por efeitos atmosféricos (Wilson & Sader, 2002).

Assim sendo, o NDMI é um bom indicador de presença de humidade no solo e vegetação, graças a recorrer às bandas do infravermelho médio, em lugar do vermelho como ao calcular o NDVI.

$$NDMI = \frac{NIR - MID}{NIR + MID}$$

Como já foi mencionado, o uso do infravermelho próximo deve-se à sua sensibilidade para refletância da clorofila presente as folhas; o uso do infravermelho intermédio traz a este índice maior sensibilidade à absorção de humidade das folhas.

O estudo do NDMI pode introduzir novas formas de esclarecimento no estudo da vegetação, particularmente no âmbito de estudos sobre seca, e definir dessa forma um indicador de seca mais preciso. Por o estudo da vegetação através do NDVI, por si só, não ser um indicador preciso de qualquer forma de seca (em particular na distinção de seca agrícola de seca hidrológica, se alguma destas ocorra), considerou-se trazer o índice de humidade para este estudo. Espera-se com isso conseguir ver que influência o comportamento da precipitação tem na saúde da vegetação ou no seu crescimento, caso sejam distinguíveis períodos de seca meteorológica no estudo da precipitação, e, por conseguinte, estabelecer se é possível que, perante períodos de seca meteorológica, haja um comportamento distinto na vegetação durante e após esses períodos, de tal forma que consigamos estabelecer a ocorrência de seca hidrológica e/ou agrícola.

3.3. Sensores

3.3.1. TRMM (*Tropical Rainfall Measuring Mission*)

A missão TRMM (*Tropical Rainfall Measuring Mission*) é uma missão conjunta da NASA/NASDA com uma órbita equatorial de baixa inclinação. O satélite a tem a bordo cinco sensores, e foi lançado em Agosto de 1997, numa órbita circular, uma altitude de 350 km e inclinação de 35° em relação ao Equador. O satélite leva 91 minutos a completar uma órbita em torno da Terra, permitindo a cobertura dos trópicos e a extração de dados de precipitação num período de 24 horas (16 órbitas). O tempo de retorno do satélite TRMM é de cerca de 15 horas.

O satélite TRMM tem a bordo três instrumentos principais de medição – o *TMM Microwave Imager* (TMI), que fornece informação da precipitação, conteúdo de água líquida numa nuvem, gelo, intensidade da precipitação, e tipos de precipitação; o *Visible Infrared Scanner* (VIRS), que fornece observações de cobertura de nuvens em alta resolução, tipos de nuvens, e máximo de temperatura das nuvens. Por fim, o *Precipitation Radar* (PR), mede a distribuição tridimensional da precipitação. Tem ainda a bordo os sensores *Light Imaging Sensor* (LIS), que deteta e localiza trovões sobre as regiões tropicais do globo, e o *Cloud and Earth's Radiant Energy System* (CERES), que mede a energia no topo da atmosfera, bem como estima os níveis de energia a nível da atmosfera e da superfície da Terra.




Figura 6 - Ilustração do TRMM e a sua instrumentação: TMI, VIRS, PR, LIS e CERES (Fonte: NASA, página de apresentação do sistema TRMM, Junho de 2018)

Para melhorar a qualidade dos dados TRMM e de modo a melhorar os algoritmos, os produtos são constantemente reprocessados, à medida que a nova informação é adquirida. (Gómez, 2007).

Os dados TRMM usados são provenientes do algoritmo 3B42, versão 6, que tem uma resolução temporal de 3 horas e resolução espacial de 0.25° por 0.25°, com cobertura global entre os 50° Sul e os 50° Norte de latitude e entre os 180° Este e 180° Oeste de longitude.

Este produto é baseado em análise de precipitação por multi-satélites (Gómez, 2007), e tem como propósito produzir dados de precipitação adquiridos, combinando os dados dos sensores TRMM com os dados de outros satélites (GPI, GP CP e SSMM). O produto 3B42 V6 é a combinação das estimativas de precipitação medidas por sensores de micro-ondas, calibradas e combinadas. Essas estimativas são calibradas também por observações a partir de satélites geoestacionários de temperatura, medida por infravermelho térmico. O produto

final, 3B42, consiste nessa combinação final, escalada para dados mensais, e é expresso em mm por hora.

3.3.2. CHIRPS (*Climate Hazards Group InfraRed Precipitation with Station data*)

Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS) é um *dataset* de dados de precipitação com mais de 30 anos, desde 1981 até ao presente, com cobertura *quasi-global* (50°S – 50°N). O produto foi criado numa colaboração entre a USGS (U.S. Geological Survey) e o EROS (*Earth Resources Observation and Science*), de forma a fornecer dados de precipitação com vista a análise de séries temporais e monitorização sazonal de seca, uma vez que estimativas derivadas de dados satélite ofereciam médias espaciais que podiam diferir da realidade quando associadas a mudanças no terreno. Por outro lado, estações meteorológicas em terra não garantem uma cobertura uniforme a monitorização da precipitação em áreas extensas (Funk, et al., 2015).

O produto CHIRPS é obtido interpolando imagens de satélite, mais concretamente do produto TRMM, com dados *in-situ* de estações meteorológicas em terra. Este trabalho usou os dados CHIRPS para estudar o máximo mensal, sazonal e anual da precipitação sobre a península ibérica. Essa decisão foi tomada uma vez que o produto CHIRPS oferece a cobertura que os dados TRMM oferecem para uma zona de estudo vasta como é a Península Ibérica, ao passo que os dados das estações meteorológicas oferecem uma melhor resolução.

Os dados de precipitação são expressos em mm/pentad, em que pentad é definido tal que os primeiros 5 pentad do mês são de 5 dias cada, e o último pentad do mês vai do dia 26 até ao último dia do mês. O valor mínimo é 0 mm/pentad e o máximo 1072.43 mm/pentad.

3.3.1. Landsat 5 e Landsat 8

Nos estudos de vegetação e solo, foram usados os dados dos satélites Landsat, que são parte do programa Landsat da NASA e que, entre eles, fornecem produtos desde 1984 até 2018. Apesar de o satélite Landsat 5 ter sido desativado entre 2012 e 2013, com os dados do Landsat 8 foi possível ter a continuidade temporal necessária para este estudo.

Apesar de se ter ponderado o uso do Landsat 7 neste estudo, essa hipótese foi descartada devido às falhas nos produtos provenientes desse satélite. Tal deveu-se à falha ocorrida em 2003 a bordo do Landsat 7 (Página da USGS - Landsat 7, 2018) com o seu *Scan Line Corrector* (SLC), que compensava o movimento do satélite.

As imagens dos satélites *Landsat 5* e *Landsat 8* permitem ter cobertura da Terra a cada 16 dias. A bordo do Landsat 5, estão presentes os sensores *Multispectral Scanner* (MSS), com quatro bandas espectrais – Bandas 4 a 7 – e o *Thematic Mapper* (TM), com sete bandas espectrais – Bandas 1 a 7. No *Google Earth Engine* as informações das bandas são apresentadas conforme apresentado na tabela 2. A banda 6, do infravermelho térmico, tem resolução de 30 metros depois de ter sido reamostrada de 60 metros.

Tabela 1 - Bandas do Landsat 5. Fonte: USGS

Banda	Resolução	Comprimento de onda
B1 – Azul	30 m	0.45 - 0.52 μm
B2 - Verde	30 m	0.52 - 0.60 μm
B3 – Vermelho	30 m	0.63 - 0.69 μm
B4 – Infravermelho	30 m	0.76 - 0.90 μm
B5 – Infravermelho de ondas curtas	30 m	1.55 - 1.75 μm
B6 – Infravermelho térmico 1.	30 m	10.40 - 12.50 μm
B7 – Infravermelho de ondas curtas 2	30 m	2.08 - 2.35 μm
BQA (QA Bitmask)	Quality Assessment (QA)	

Já a bordo do *Landsat 8*, dois instrumentos estão presentes: o *Operational Land Imager* (OLI) e o *Thermal Infrared Sensor* (TIRS).

As bandas espectrais a bordo do sensor OLI têm duas bandas adicionais em relação aos anteriores instrumentos *Landsat*: a banda 1, no canal do azul escuro do visível, designado especificamente para investigação em zonas costeiras, recursos hídricos e estudos de aerossóis, e um novo canal de infravermelho de onda curta, na banda 9.

O instrumento TIRS capta duas bandas espectrais para o comprimento de onda antes coberto por uma única banda nos sensores TM e ETM+, os seus antecessores.

As imagens Landsat 8 consistem, então, de nove bandas espectrais com:

- Resolução espacial de 30 metros para as bandas 1 a 7 e 9;
- A resolução da banda 8 (pancromática) é de 15 metros.;
- As bandas térmicas 10 e 11 são úteis a providenciar temperaturas à superfície mais precisas, e são recolhidas com 100 metros;
- O produto normalmente tem 170 km (norte-sul) por 183 km (este-oeste).

Tabela 2 - Bandas do Landsat 8. Fonte: USGS

Banda	Resolução	Comprimento de onda
B1 – Aerossol costeiro	30 m	0.43 - 0.45 μm
B2 - Azul	30 m	0.45 - 0.51 μm
B3 – Verde	30 m	0.53 - 0.59 μm
B4 – Vermelho	30 m	0.64 - 0.67 μm
B5 – Infravermelho	30 m	0.85 - 0.88 μm
B6 – Infravermelho de ondas curtas 1.	30 m	1.57 - 1.65 μm
B7 – Infravermelho de ondas curtas 2	30 m	2.11 - 2.29 μm
B8 – Pancromática	15 m	0.52 – 0.90 μm
B9 – Cirrus	15 m	1.36 – 1.38 μm
B10 – Infravermelho térmico 1	30 m	10.60 – 11.19 μm
B11 – Infravermelho térmico 2	30 m	11.50 – 12.51 μm

Dados utilizados

Nome: Landsat 5 TM Collection 1 Tier 1 calibrated top-of-atmosphere (TOA) reflectance

ID no GEE: LANDSAT/LT05/C01/T1_TOA

Nome: Landsat 8 Collection 1 Tier 1 and Real-Time data calibrated top-of-atmosphere (TOA) reflectance.

ID no GEE: LANDSAT/LC08/C01/T1_RT_TOA

Nota: Coeficientes de calibração são extraíveis dos metadados do produto

3.4. Área de estudo

A zona de estudo para esta dissertação é a Península Ibérica. Esta localiza-se a sudoeste da Europa; e é rodeada pelo Mar Mediterrâneo e pelo Oceano Atlântico e é a segunda maior península do continente, com aproximadamente 580.000 km². Está ligada ao continente europeu pela zona nordeste, sendo que a fronteira é formada pelos Pirenéus, e compreende os países de Portugal, Espanha e Andorra, uma pequena fração do território francês e o território britânico de Gibraltar.

Num estudo de seca, é importante conhecer as características do terreno e ter estas em conta quando considerando os resultados dos fatores que neste estudo vão ser analisados, nomeadamente a precipitação, vegetação e humidade do solo. É natural que, pela natureza distinta das regiões na península ibérica, mesmo que sob condições semelhantes de precipitação ou temperatura, se obtenham comportamentos diferentes, e vice-versa – menor precipitação cumulativa ou média em determinadas regiões não quer necessariamente dizer que essa mesma estará sujeita a um cenário de seca, mais ou menos do que uma região que tenha precipitação cumulativa e/ou média superior.

É portanto necessário ter em conta dois fatores, que são a ocupação do território e as zonas climáticas da região de estudo; o primeiro pelas razões enunciadas, e o segundo porque se deverá ter em conta, ao analisar a precipitação e temperatura, que existe um comportamento distinto e característico associado às diferentes zonas climáticas que abrangem a península, uma vez que nas zonas em que os climas são secos, é de esperar menor precipitação em determinadas épocas do ano em relação a zonas temperadas e zonas frias, como se irá elaborar a seguir.

Por outro lado, é também importante realçar a importância de um estudo de seca em território nacional, como já foi mencionado, pelas consequências que esta forma de desastre natural traz quando se abate sobre uma região.

Nos casos de Portugal e Espanha, por exemplo, a percentagem de população empregada nos setores da agricultura, silvicultura e pesca ronda os 4.8% (Portugal) e os 4.1% (Espanha). Ambos os países dedicam-se à produção de trigo e de vinho nesses setores, e ambos têm áreas a rondar os 8% respetivamente dedicadas a agricultura biológica. Em 2015, Espanha detinha 27% do seu território como áreas protegidas pela sua diversidade, e Portugal 21% (Instituto Nacional de Estatística, 2016). Cenários de seca trazem consequências muitas vezes desastrosas para estes setores, e, quando se estendem por períodos prolongados, chegam a outros setores, como ao da energia.

3.4.1. Ocupação do terreno

O mapa de ocupação de solo, apresentado na Figura 7 - Mapa de ocupação de solo da Península Ibérica foi criado a partir de imagens MODIS, já preparadas com o produto *landcover*, com resolução de 500 metros, e mostra a ocupação do território na península no ano de 2015 (os últimos dados disponíveis no *Google Earth Engine*, a plataforma usada para este estudo), e podemos ver a verde escuro as zonas de vegetação densa, a laranja a vegetação rasteira, a amarelo zonas áridas e vermelho zonas urbanas; a verde-claro zonas húmidas e pantanosas, a azul corpos de água e finalmente, a branco, outros tipos de solo.



Figura 7 - Mapa de ocupação de solo da Península Ibérica

Os aspetos físicos do clima e vegetação na península são influenciados pela proximidade aos oceanos, especialmente nas regiões costeiras; as zonas áridas são extensas, sobretudo em Espanha, mas também a sul de Portugal.

Neste estudo, pretende-se prestar atenção a diferentes tipos de terreno, para verificar o seu comportamento quando sob condições de menor precipitação e, portanto, de potencial seca.

Segundo o relatório de Uso e Ocupação de Solo em Portugal Continental de 2010, cerca de 5% da ocupação do terreno é por terrenos artificializados; 35.0% são terrenos agrícolas; 8.8% agroflorestais; 34.6% são áreas florestais; 15.2% terrenos incultos, 0.2% são zonas húmidas e 1.2% corpos de água (Direção-Geral do Território (DGT), 2014).

Já em Espanha, a distribuição das principais classes de cobertura de solo é tal que 49.80% são zonas agrícolas, 47.10% zonas florestais e vegetação natural, bem como espaços abertos, e 2.10% superfícies artificiais. Finalmente, zonas húmidas e superfícies de água constituem 0.20% e 0.70% da cobertura de solo, respetivamente (Observatorio de la Sostenibilidad en España, 2006).

3.4.2. Clima na península ibérica

O atlas climático da península ibérica, desenvolvido pelo IPMA – Instituto Português do Mar e da Atmosfera, fornece a delimitação dos distintos tipos de clima da Península Ibérica utilizando a classificação climática de *Köppen*, que define os diferentes tipos de clima a partir dos valores médios mensais da precipitação e da temperatura, baseados principalmente na sua influência sobre a distribuição da vegetação e da atividade humana na região.




Figura 8 - Zonas climáticas segundo a escala de Köppen, em Portugal e Espanha. Fonte: Atlas Climático da Península Ibérica - IPMA

A delimitação dos climas áridos realiza-se em 3 intervalos diferentes, e baseia-se no regime anual de precipitação, onde a precipitação no Inverno é mais efetiva para o desenvolvimento da vegetação do que a época estival ao ser menor a evaporação. Identificam-se na Península Ibérica segundo o tipo B (climas secos) as regiões:

- **Deserto quente e deserto frio** – As províncias espanholas de Almeria, Múrcia e Alicante, no sudeste da Península, coincidem com os mínimos pluviométricos peninsulares
- **Estepe quente e fria** – O vale do Ebro, em Espanha, que se estende ao longo do seu lado sudeste, a Estremadura e Ilhas Balneares, e em Portugal, a região do Baixo Alentejo, no distrito de Beja.

Já como zonas de climas temperados (tipo C), em que a temperatura média do mês mais frio é compreendida entre os 0°C e os 18°C:

- **Temperado com verão seco e quente** – É a variedade climática que abrange uma maior extensão da península ibérica, ocupando 40% da sua superfície. Estende-se pela maior parte da metade sul e das regiões costeiras mediterrânicas, com exceção das zonas áridas da zona sudeste.
- **Temperado com verão seco e temperado** – Abrange a zona noroeste da península, assim como o litoral oeste de Portugal Continental e as zonas montanhosas do interior da península.
- **Temperado sem estação seca, com verão quente** – Zona nordeste da península, numa franja de altitude média que rodeia os Pirenéus.
- **Temprado sem estação seca, com verão temperado** – Ocorre na cordilheira da Cantábrica, parte da meseta norte e grande parte dos Pirenéus, com exceção das áreas de maior altitude.

As zonas de climas frios (tipo D), em que a temperatura média do mês mais frio é inferior a 0°C, e a temperatura média do mês mais quente é superior a 10°C, são:

- **Frio com verão seco e temperado ou verão seco e fresco** – Nas pequenas áreas das regiões montanhosas de maior altitude da Cordilheira Cantábrica, Sistema ibérico, Sistema Central e Serra Nevada
- **Frio sem estação seca e verão temperado ou verão fresco** – Regista-se este tipo de clima nas áreas de maior altitude dos Pirenéus e em algumas pequenas áreas de maior altitude da Cordilheira Cantábrica e do Sistema Ibérico.

Por fim, observa-se comportamento de clima polar, com temperaturas médias dos meses mais quentes sendo inferiores a 0°C, apenas em pequenas áreas de cotas mais elevadas dos Pirenéus Centrais.

Capítulo 4.

Análise dos resultados

4.1. Estudo da precipitação na Península Ibérica entre 1990 e 2017

Para o estudo da precipitação, estabeleceu-se, primeiro de tudo, a fronteira para este estudo – a península Ibérica.

Quando se importam os produtos de interesse para o estudo no GEE, obtêm-se inicialmente os dados completos: neste caso, ao se importarem os dados CHIRPS, obter-se-iam todos os dados desde 1 de Janeiro de 1981 até 2018, com cobertura quase global. Isso torna necessário seleccionar os dados, inclusivé limitá-los para a região de estudo.

Para esse efeito, foi criada inicialmente uma *shapefile* da Península Ibérica, que era importada para a conta particular do utilizador, mas, como foi mencionado anteriormente em 3.1.1., nas Regras de utilização, alguns conflitos podem surgir ao cruzar objetos locais com pedidos (cálculos) em servidor.

A alternativa foi usar as tabelas fornecidas pela *Google Tables*, onde as variáveis Portugal e Espanha estavam presentes, para importar esses objetos e criar a variável *table*, que define a região de estudo, a Península Ibérica.

Para esse efeito, foram seleccionadas as variáveis dos produtos que definiam Portugal e Espanha, respetivamente, através do comando *.filterMetadata()*, e posteriormente uniram-se estes pelo comando *.merge()*:

```
1. // Estabelecimento da fronteira do estudo (variável table)
2. var Portugal = ee.FeatureCollection('ft:1tdSwUL7MVpOauSgRzqVT0wdfy17KDbw-1d9omPw').filterMetadata('Country', 'equals', 'Portugal');
3. var Spain = ee.FeatureCollection('ft:1tdSwUL7MVpOauSgRzqVT0wdfy17KDbw-1d9omPw').filterMetadata('Country', 'equals', 'Spain');
4. var table = Portugal.merge(Spain);
```

O passo seguinte consistiu em importar os dados CHIRPS, sob o ID “UCSB-CHG/CHIRPS/PENTAD”, e filtrá-los para a região de estudo e para o período de estudo pretendido.

Foi seleccionado o parâmetro “*precipitation*”, de forma a limitar os dados apenas aos de precipitação, e subsequentemente foram aplicados os redutores de média, que como mencionado antes, também atua como redutor, para se reduzir os dados a uma só camada.

A camada final resultante traduziu-se na média da precipitação, em cada píxel, em *mm/pentad*, da região.

```
1.  var CHIRPS = ee.ImageCollection('UCSB-CHG/CHIRPS/PENTAD')
2.  .filterDate('1990-01-01', 2017-12-31')
3.  .select('precipitation');
4.
5.  var chrips_mean01 = CHIRPS.mean();
6.  var chrips_peninsula2010 = chrips_mean01.clip(table);
```

No tocante ao desempenho do GEE em si, o tempo de cálculo dos resultados foi de meros segundos – algo que não teria sido possível caso o trabalho tivesse sido feito com recursos próprios. A celeridade no cálculo dos resultados permite não apenas obter resultados quase instantâneos ao elaborar um script, mas também testar com maior à vontade novas abordagens na elaboração de um script, um maior à vontade a explorar os dados disponíveis na plataforma do GEE, algo que não seria possível se fosse necessário adquirir os dados e processá-los com um computador pessoal – ou pelo menos, não com a mesma rapidez.

4.1.1. Média anual de 2000 a 2017

Para o cálculo das médias anuais dos anos entre 2000 e 2017, foram selecionados os dados do ano respetivo e calculada a média de cada píxel da precipitação local, em mm/pentad. A classificação está dividida em 7 classes, identificando as diferentes intensidades na precipitação: a vermelho, zonas em que a precipitação foi mínima nesse ano; a laranja, amarelo-torrado, amarelo, azul claro, azul-céu e azul escuro, que identifica a precipitação máxima. Para definir o intervalo dessa escala, foram analisados os valores mínimos e máximos de cada ano, conforme apresentados na Tabela 3 - Mínimos e máximos dos mapas de precipitação média entre 2000 e 2017, e foi estabelecido um intervalo de 0 a 40, para as classes estabelecidas.

Tabela 3 - Mínimos e máximos dos mapas de precipitação média entre 2000 e 2017

Ano	Min	Max	Ano	Min	Max
2000	0.54	39.03	2009	0.58	34.14
2001	0.42	37.86	2010	0.77	34.91
2002	0.47	28.48	2011	0.54	26.76
2003	0.45	33.12	2012	0.33	29.18
2004	0.74	29.74	2013	0.50	38.82
2005	0.76	26.76	2014	0.560	38.92
2006	0.88	33.66	2015	0.52	28.69
2007	0.76	28.37	2016	0.68	34.40
2008	0.58	35.18	2017	0.47	28.48

Os resultados, apresentados na figura 9, mostram como os anos 2002, 2005 e 2015 a 2017 apresentaram precipitação média mais fraca, em particular na zona sudeste de Espanha.

A zona norte de Portugal continental apresenta constantemente precipitação média superior às restantes regiões da península, contando, no entanto, com episódios de menor precipitação nos anos de 2002, 2004, 2005, 2011, 2012 e novamente para os anos de 2015 e 2017.

As zonas centro e sul de Portugal continental apresentam precipitação em geral baixa, com os anos de 2005 e 2015 com os extremos de precipitação mínima no período estudado.

Os anos de 2000, 2010 e 2013 foram os casos cuja média anual apresentou melhores resultados, com cenários de precipitação dentro do esperado em toda a península.




Figura 9 - Mapas da precipitação média anual entre 2000 e 2017

4.1.2. Acumulação anual de precipitação entre 2000 e 2017

Para a acumulação de precipitação anual entre os anos entre 2000 e 2017, foram selecionados os dados CHIRPS de cada ano para criar cada nova camada, e calculada a precipitação acumulada ao longo desse ano.

A Tabela 4 - Mínimos e máximos dos mapas de precipitação acumulada entre 2000 e 2017, abaixo, mostra os valores mínimos e máximos da precipitação ao longo da península, valores que foram considerados ao atribuir as classificações e estabelecer o gradiente de cores a atribuir aos mapas. A classificação foi atribuída para os valores de 30 a 2500 (mm/pentad), e nas figuras da imagem 10 estão representados os mapas com a distribuição anual de precipitação, com classificação entre esses valores.

Tabela 4 - Mínimos e máximos dos mapas de precipitação acumulada entre 2000 e 2017

Ano	Min	Max	Ano	Min	Max
2000	39.21	2810.27	2009	42.12	2458.20
2001	30.35	2726.07	2010	55.72	2513.92
2002	34.11	2050.76	2011	38.94	1927.16
2003	32.97	2385.09	2012	23.72	2101.37
2004	53.99	2141.34	2013	35.71	2795.32
2005	55.25	1927.02	2014	42.96	2802.27
2006	63.89	2423.86	2015	37.08	2066.07
2007	55.01	2043.21	2016	48.62	2477.38
2008	42.14	2533.14	2017	34.11	2050.76

Os resultados, na Figura 10 - Mapas de precipitação total anual entre 2000 e 2017, mostram novamente os anos 2002, 2005 e 2015 e 2017 como os anos em que a precipitação total anual foi em geral fraca quando comparada com os restantes anos.

A análise da precipitação acumulada foi considerada para ser possível distinguir episódios esporádicos de precipitação mais intensa durante o ano, que eventualmente não seriam detetáveis com uma análise da média da precipitação anual.

Com este estudo, é possível ver na zona norte da península, com precipitação média em geral superior à do resto da região de estudo, os anos em que a precipitação total tenha declinado em relação a outros anos, como são os casos em 2002, 2004, 2007, 2011, 2012, 2015 e 2017. Apesar de esses valores serem superiores aos valores nas zonas de Espanha central ou até sul de Portugal continental, a zona climática em questão seria, por definição, de esperar que a precipitação fosse superior à que foi sentida nesses anos.




Figura 10 - Mapas de precipitação total anual entre 2000 e 2017

4.1.3. Anomalias de 2000 a 2017

Para o cálculo das anomalias na precipitação, escolheu-se fazer a média geral dos dados entre 1990 e 2017, e comparar a média anual de cada ano entre 2000 e 2017 com essa mesma média geral. Pretende-se com as anomalias mostrar o desvio de cada ano em relação à média dos últimos 30 anos (aproximadamente), sendo que foram criados mapas anuais das anomalias, com classificação das anomalias de tal forma que os pontos a azul indicam precipitação anual superior à média, e vermelho, que indicam que a precipitação anual é inferior à média. A média de 30 anos como base de comparação é, em geral, o mínimo aconselhado para estudos de anomalias na precipitação, e normalmente é também aconselhado que os estudos sejam sobre médias de 3 meses, 6 meses, 9 meses e 12 meses; optou-se no entanto, neste estudo, por apenas fazer o estudo da média de 12 meses.

Para estabelecer o intervalo de classificação adequado, observaram-se os mínimos e máximos das anomalias de cada ano, apresentados na tabela abaixo.

Tabela 5 - Mínimos e máximos dos mapas de anomalias de precipitação anual entre 2000 e 2017

Ano	Min	Max	Ano	Min	Max
2000	-10.28	4.73	2009	-5.92	3.67
2001	-9.15	5.25	2010	-14.57	0.98
2002	-2.95	7.87	2011	-4.97	7.42
2003	-6.90	2.47	2012	-5.06	9.05
2004	-3.23	11.52	2013	-11.01	3.15
2005	-2.23	10.10	2014	-11.98	3.71
2006	-7.70	3.70	2015	-2.06	10.69
2007	-3.85	7.33	2016	-6.80	4.48
2008	-6.57	4.78	2017	-2.95	7.87

O cálculo das anomalias é, talvez, o que fornece resultados mais intuitivos para a análise, senão mesmo mais úteis. Por considerar um maior intervalo de tempo como base de comparação em relação a cada ano, estes resultados fornecem uma ideia mais clara do quanto a precipitação em cada ano diverge dessa média, ao contrário dos dois estudos anteriores, os quais consideram apenas a precipitação média anual ou total anual, respetivamente, como forma de análise.

Esta abordagem é próxima ao estudo do índice de precipitação utilizado pelo IPMA, apenas não contando com o uso do desvio padrão no seu cálculo.

Na figura 11, observam-se então as anomalias da precipitação média de cada ano em relação à média geral desde 1990 até 2017.

Destacam-se, como nos estudos anteriores, os anos de 2002, 2004, 2005, 2012, 2015 e 2017 como os anos em que a precipitação foi tal que se podem considerar esses cenários de seca nas regiões a vermelho.

Curiosamente, o ano de 2008 evidencia um contraste entre os dois países: Portugal continental apresenta uma anomalia de precipitação, abaixo da média, que é contrária ao que se vê em Espanha, em que a precipitação foi acima do habitual, apesar de, em ambos os casos, a diferença não ser grande.

Os anos de 2004 e 2005 destacam-se em particular pela severidade na zona norte de Portugal, confirmando-se o relatado na literatura, pela qual sabemos terem ocorrido situações de seca extrema nessa região. De igual forma, 2015 apresenta anomalia séria na região norte e em algumas regiões sul entre Portugal e Espanha.

No entanto, o ano 2016, relatado na literatura como um ano de seca, em todos os estudos aparenta normalidade, ao contrário do que se sabe ser realidade.




Figura 11 - Anomalias de precipitação entre 2000 e 2017. A azul, os desvios em que a precipitação anual foi acima da média; a vermelho, os valores da precipitação abaixo da média; a amarelo, os valores em que a precipitação não difere da média. Média calculada entre 1990 e 2017

4.1.4. Estudo da precipitação anual – séries temporais

Para concluir o estudo da precipitação nas épocas entre 1990 e 2017, apresenta-se agora um estudo da série temporal à escala da região de estudo. Numa primeira observação, são mais perceptíveis os picos na precipitação ao longo da série, que indicam períodos de precipitação mais intensa; mas também é possível discernir períodos em que a precipitação tem menor intensidade e frequência, algo mais importante a identificar para este estudo.




Figura 12 - Série temporal entre 01 de Janeiro de 1990 e 31 de Dezembro 2017, usando dados CHIRPS, para a região de estudo

Para uma compreensão detalhada do comportamento da precipitação ao longo do tempo de estudo, em particular entre os últimos 18 anos, 2000 e 2017, foram feitos os gráficos da precipitação ao longo do ano, para cada ano. Dado o comportamento da série temporal ser semelhante independentemente de zonas escolhidas em particular, escolheu-se fazer uma média geral da precipitação para cada dia do ano sobre a região de estudo, para elaborar uma série temporal anual. Os gráficos produzidos foram representados conforme a exemplificação do gráfico produzido para 2000, visível na figura 13:




Figura 13 - Precipitação (mm/pentad) ao longo do ano 2000 (a azul) e média geral (laranja)

Na figura 13, representada acima, está representada a precipitação ao longo de 2000. Os primeiros meses do ano, normalmente caracterizados por precipitação intensa, apresentam fraca precipitação. Dado o longo período com precipitação abaixo dos 10 mm a

cada 5 dias, entre Janeiro e Março, é considerável que se possa ter corrido risco de seca, apesar de os meses seguintes entre Abril e Junho terem compensado com precipitação estável e perto dos 30 mm/pentad. Os meses seguintes, entre Julho e Setembro, até meados de Outubro, apesar de constatarem precipitação baixa, é de considerar normal por serem meses de verão e ser portanto esperada baixa taxa de precipitação.

Os meses restantes apresentam precipitação abundante e constante, apenas registando-se no período de começo de Novembro valores pouco abaixo dos 20 mm/pentad.

Já no ano de 2001 não existem episódios de precipitação abaixo do considerado normal, apesar de o período de precipitação abaixo dos 15 mm/pentad ser mais prolongado por se iniciar na segunda quinzena de Maio, e se prolongar até Outubro. Pondera-se que tal poderá eventualmente ter causado um declínio, não grave, na saúde da vegetação. No entanto, a precipitação ao longo de 2002, mostra que este ano é marcado por precipitação abaixo dos 30 mm/pentad ao longo do ano inteiro. Apesar de, como foi dito, ser esperada baixa precipitação durante os meses de verão, os restantes meses são marcados por precipitação anormalmente baixa, que não compensa o suficiente pelos meses já por si de fraca pluviosidade.

O ano de 2003, por seu turno, é igualmente marcado por precipitação abaixo dos 30 mm/pentad como em 2002, durante o seu primeiro trimestre, mas nos meses de outono e inverno a precipitação sobe uma vez mais, eventualmente descendo para valores mínimos nos finais de dezembro, predominantemente abaixo dos 10 mm/pentad.

Esse valor baixo na intensidade da precipitação, e na época de inverno, é considerado anormal, e pela sua extensão no ano de 2004, marca o início de um período de seca, por os períodos de precipitação durante 2004 serem intermitentes, e abaixo dos 30 mm/pentad durante os meses de inverno e primavera, até aos períodos baixos de um verão também seco. Outubro é também marcado por valores muito baixos de precipitação, só se registando valores em novembro.

A situação prolonga-se em 2005 e 2006, registando-se períodos de fraca precipitação, e de baixa duração.

Estes períodos de baixa precipitação, constantemente abaixo dos 30 mm/pentad, coincidem com os registos de seca em Portugal e em Espanha, com zonas como Porto e Beja afetadas durante períodos que se vieram a estender entre 10 e 33 meses, respetivamente.

Em 2007, apesar de a intensidade da precipitação não ter subido em relação aos anos anteriores, registaram-se períodos mais longos na precipitação, e um período de baixa precipitação associada ao verão mais curto.

Já em 2008, registou-se um inverno com precipitações abaixo dos 25 mm/pentad durante o outono, mas precipitação intensa durante o final da primavera, entre abril e finais de junho.

A precipitação fraca no inverno de 2008 prolongou-se até um período de chuva intensa e prolongada em fevereiro de 2009. No entanto, os seguintes meses são marcados por um período longo de pouca precipitação, até ao final do ano, altura em que valores de precipitação ultrapassam até os registos dos anos anteriores.

O ano de 2010 foi relativamente normal em termos de precipitação, quer na sua distribuição, quer em média mensal. Com precipitação menor nos meses de verão, entre julho e finais de setembro, o padrão anual verificou-se comum em relação à média dos últimos anos, e superior à maioria dos anos em estudo.

De igual forma, o ano de 2011 também apresentou ter a precipitação conforme o esperado, em média a rondar os 30 mm/pentad mensalmente, apenas se vendo os meses de fevereiro e abril com menor precipitação em relação ao normal, e o período de menor precipitação associado ao verão a ter-se estendido até meados de outubro. No entanto, períodos de precipitação intensa a seguir essas fases de menor precipitação poderão ter compensado, não sendo de esperar um declínio na saúde da vegetação nesses períodos.

Todavia, o ano de 2012 apresenta longos períodos com défice de precipitação, entre os meses de janeiro e finais de abril, e novamente apresentando um período de menor precipitação durante e após o verão, que se estendeu até finais de outubro, com precipitação posteriormente nunca acima dos 30 mm/pentad.

Os anos de 2013 e 2014, no entanto, apresentaram períodos em que a precipitação chegou aos 40 mm/pentad, no começo do ano, e até superiores em abril, podendo a precipitação ter compensado a falta desta no ano anterior de 2012. Cenários de seca que possam ter surgido no período de 2012 foram por isso colmatados pela sequente precipitação durante os dois anos seguintes.

Apesar de no ano de 2014 a precipitação se ter mantido em média nos 30 mm/pentad nos meses de maior precipitação, os períodos em que ocorreu precipitação foram longos, sobretudo nos primeiros meses do ano.

O ano de 2015, no entanto, é marcado globalmente por precipitação fraca, abaixo dos 20 mm/pentad, tornando-se comparável apenas ao ano de 2005, e fazendo deste ano, em termos de precipitação, um dos com maior gravidade neste estudo.

O ano de 2016 apresentou períodos de precipitação e comportamento normal no início do ano e até maio; no entanto, a precipitação mínima a partir de junho, apenas com um intervalo pequeno de precipitação em novembro, a seguir ao ano de 2015, que já havia sido marcado por períodos de precipitação fraca, fez com que o ano de 2016 fosse marcado por seca.

Em suma, a análise da precipitação recorrendo ao produto CHIRPS permitiu identificar períodos de seca meteorológica, sendo que a análise dos resultados obtidos foi confirmada pelo que foi relatado na literatura (Pires, Silva, & Mendes, 2010) e pelo IPMA (Instituto Português do Mar e da Atmosfera, 2018).

4.2. Estudo da vegetação

4.2.1. Análise da vegetação entre 2000 e 2017 com índice NDVI

Na análise da vegetação, pretende-se em primeiro lugar calcular o índice de NDVI e a sua variação anual entre 2000 e 2017, de forma análoga ao que foi anteriormente feito no estudo da precipitação. No entanto, nesta fase do estudo, já se tem em conta o conhecimento adquirido no estudo da precipitação, em que foram apuradas as fases de seca meteorológica. Pretende-se, assim, verificar se é possível identificar períodos de seca, na forma de seca agrícola, em particular.

Para a elaboração deste estudo, foi elaborado um *script* no GEE para calcular e extrair o índice de vegetação, NDVI. Para esse efeito, foram selecionados os produtos para as zonas de estudo, provenientes dos satélites Landsat 5 e Landsat 8.

Assim sendo, foram criadas funções para o cálculo do índice NDVI para os produtos do Landsat 5 e do Landsat 8. Cada função foi aplicada à coleção dos produtos de cada satélite, filtrada para as datas de interesse, selecionando apenas produtos com cobertura de nuvens abaixo dos 22%. Isso significa que, por exemplo do total de produtos do Landsat 8 disponíveis, foram selecionados todos os produtos cuja cobertura de nuvens fosse abaixo dos 22%, e que se apresentasse no período entre 01 de Janeiro de 2013 e 31 de Dezembro de 2017. Para cada um desses produtos foi calculado o índice pela função “NDVI_L8”, e criada a banda “NDVI”.

Tal cálculo é feito conforme abaixo:

```
1. var NDVI_L5 = function(image) {
2.   var ndvi = image.normalizedDifference(['B4', 'B3']);
3.   image = image.addBands(ndvi.rename('NDVI'));
4.   return (image);
5. };
6. // LANDSAT 5 available through: Jan 1, 1984 - May 5, 2012
7. var NDVI1 = ee.ImageCollection('LANDSAT/LT05/C01/T1_TOA')
8.   .filter(ee.Filter.lessThanOrEqualTo('CLOUD_COVER_LAND', 22))
9.   .filterDate('1990-01-01', '2011-12-31')
10.  .map(NDVI_L5);
11.
12. var NDVI_L8 = function(image) {
13.   var ndvi = image.normalizedDifference(['B5', 'B4']);
14.   image = image.addBands(ndvi.rename('NDVI'));
15.   return (image);
16. };
17.
18. // LANDSAT 8 available through: Apr 11, 2013 - Aug 31, 2018
19. var NDVI2 = ee.ImageCollection('LANDSAT/LC08/C01/T1_RT_TOA')
20.   .filter(ee.Filter.lessThanOrEqualTo('CLOUD_COVER_LAND', 22))
21.   .filterDate('2013-01-01', '2017-12-31')
22.   .map(NDVI_L8);
```

Tal permitiu a criação de uma banda extra em cada produto, chamada “NDVI”, cujo cálculo foi feito pela função `.normalizedDifference()`, já integrada na biblioteca de funções disponibilizada pelo GEE. No caso do Landsat 8, foram utilizadas as bandas B4 e B5, respetivamente o infravermelho e o vermelho, ao passo que para o Landsat 5, foram usadas as bandas B4 e B3, que correspondiam igualmente ao infravermelho e vermelho.

De forma análoga ao estudo da precipitação, foi posteriormente à implementação desta nova banda feita uma redução às fronteiras da região de estudo, e aplicada a função `.mean`, que calcula a média, ao nível de cada píxel, de cada uma das bandas do produto, para o período selecionado – neste caso, fizeram-se mosaicos da média anual, neste caso em particular do NDVI.

Como se pretendiam calcular anomalias anuais da vegetação, para elaborar um mapa da média do NDVI entre 1990 e 2017, utilizou-se o já citado método de *merge*, como usado para unir as coleções “Portugal” e “Espanha” para definir a reunião de estudo, para unir as coleções do Landsat 5 e do Landsat 8. Foi selecionada apenas a banda “NDVI” de forma a descartar as restantes e assim poupar tempo de processamento, e aplicar o mesmo processo acima descrito no cálculo da média geral dos dois produtos:

```
1. // Merges two collections into one. The result has all the elements that were i
   n either collection.
2. var average = (NDVI1.select('NDVI')).merge(NDVI2.select('NDVI'));
3. var average_total = average.mean().clip(table);
```

Assim, foi obtida uma média geral entre os anos 1990 e 2017 do NDVI para a região de estudo, que foi usada no cálculo da anomalia para cada ano, entre 2000 e 2017, do NDVI. A anomalia expressa-se de tal forma que, do valor da média do ano de estudo em questão, se subtrai o valor da média, entre 1990 e 2017. Por se combinarem os produtos de duas coleções, e como só haviam dados disponíveis até 2011 por parte do Landsat 5 e a partir de 2013 por parte do Landsat 8, não foi possível obter dados para o ano de 2012, que será omitido nos estudos.

Para o NDVI considera-se que as anomalias variam entre -0.5 e 0.5, em que os valores negativos expressam uma vegetação de menor saúde, ou inexistente, em relação à média, e os valores positivos expressam uma vegetação mais saudável e/ou viçosa que na média.




Figura 14 - Anomalias da média anual do NDVI em relação à média do NDVI entre 1991 e 2017, calculadas a partir de produtos Landsat 5 e 8

Decidiu-se neste ponto optar por um estudo sazonal da evolução da vegetação, uma vez que observar a média anual não passaria, possivelmente, uma ideia tão clara do estado da vegetação em cada ano.

Para tal efeito, para obter os dados para cada estação de cada ano, foram selecionados apenas os dados para as épocas de cada estação do ano, entre 1990 e 2017, ou seja, por exemplo, para fazer a média de todas as primaveras, foram filtrados apenas os dados entre Abril e Junho. O procedimento foi análogo ao que foi acima mencionado no cálculo da média anual do NDVI e respetivas anomalias, com exceção de que a filtragem por datas passou a ser com base nos meses, pelo comando `.ee.Filter.calendarRange (início, fim, tipo intervalo)`.

```
1. var spring1 = NDVI1.filter(ee.Filter.calendarRange(3, 5, 'month'));
```

Foi, portanto, calculada a média global para cada estação do ano, em que a média das primaveras, verões, outonos e invernos entre 1990 a 2017 foi calculada e é agora visível nas figuras 15 a 18, respetivamente.



Figura 15 - Média do NDVI das primaveras entre 1990 e 2017 - sensores Landsat 5 e Landsat 8



Figura 16 Média do NDVI dos verões entre 1990 e 2017 - sensores Landsat 5 e Landsat 8



Figura 17 - Média do NDVI dos outonos entre 1990 e 2017 - sensores Landsat 5 e Landsat 8



Figura 18 - Média do NDVI dos invernos entre 1990 e 2017 - sensores Landsat 5 e Landsat 8

É visível a evolução da vegetação ao longo do ano; e apesar de essa evolução não influenciar as conclusões que se retiram ao analisar a evolução da vegetação anualmente, é também importante observar a vegetação em períodos de tempo menores que um ano, já que, na presença de seca meteorológica, o seu comportamento pode ser limitado aos meses após períodos de ausência de precipitação, mas antes de períodos de precipitação ocorrerem. Também entrou o fator de o volume de resultados a apresentar ser consideravelmente superior.

Nesse sentido, apesar de ter sido considerado produzir uma análise mensal da evolução do NDVI, uma análise sazonal produz efeitos muito semelhantes, uma vez que traduz de igual forma a evolução mensal, com maior condensação dos dados, por se condensarem 3 meses de evolução numa só época.

Decidiu-se, por isso, como já foi dito acima, fazer o estudo sazonal da vegetação, por se tratarem de vários anos de estudo. Por outro lado, foram selecionados 9 pontos na península ibérica (Figura 19 - Pontos selecionados para estudo das anomalias na saúde da vegetação através do NDVI) aos quais se analisaram a evolução da vegetação entre 2000 e 2017, ao longo das estações desses anos.



Figura 19 - Pontos selecionados para estudo das anomalias na saúde da vegetação através do NDVI

As regiões escolhidas foram:


1. Portimão – Terreno rasteiro (-8.493488° N , 37.141536 ° E)
2. Mértola – Campo de cultivo (-7.63202° N, 37.70907 ° E)
3. Constantina, Córdoba – Zona Florestal (-5.3752° N, 37.9063)
4. Turleque, Toledo – Zona árida (-3.57354° N, 39.67598 ° E)
5. Sertã – Zona Florestal (-8.11895° N, 39.80099 ° E)
6. Queijigal, Salamanca – Campos de Cultivo (-5.93938° N, 40.89747 ° E)
7. Porto – Campo de cultivo (-8.49945° N, 41.22035 ° E)
8. Lérida, Saragoça – Zona de cultivo (0.30096° N, 41.70212 ° E)

9. Embalse de la Cuerda del Pozo, Sória, Saragoça – Zona protegida (-2.69223° N, 41.85139° E)

Foram escolhidos predominantemente campos agrícolas, pela importância que seria estudar quão precisamente é possível identificar alturas de seca que ocorram nessas zonas. Zonas florestais ou terrenos em pousio ou abandonados foram também alvo para objeto de estudo quando se elaborou a tabela 6.

Na tabela, estão as épocas de cada ano, entre 2000 e 2017, e as anomalias nessas épocas de cada uma das regiões de estudo acima mencionadas.

Tabela 6 - Anomalias NDVI das quatro estações do ano entre os anos de 2000 e 2017, nas nove regiões de estudo selecionadas (Figura 19), em relação à média, calculada para os anos entre 1990 e 2017 (dados Landsat 5 e 8)



Da análise feita, as anomalias negativas – isto é, em que a vegetação se apresentava com saúde menor em relação à média, e que está representada a valores vermelhos na tabela 6, apresentam-se em quantidade considerável.

No entanto, os valores mais destacáveis são:

- Primavera de 2000, em Salamanca e Saragoça
- Primavera de 2002 em Salamanca
- Primavera de 2004, em Sória, Saragoça
- Primavera de 2005 em Sertã, Portimão e Mértola
- Outono de 2006 em Sertã
- Verão e Outono de 2008 em Lérida, Saragoça
- Inverno e primavera de 2009 na Sertã
- Primavera de 2009 em Salamanca
- Outono de 2010 no Porto, com aparente extensão a todo o ano de 2011
- Verão e Outono de 2011 em Lérida, Saragoça
- Primavera de 2013 em Lérida, Saragoça
- Primavera de 2014 em Lérida, Saragoça

Não há aparente correlação com as anomalias verificadas na precipitação, apesar de isso poder dever-se a vários fatores, muitos alheios ao estudo.

Sobretudo o facto de as anomalias durante os anos de 2015, 2016 e 2017 mostrarem que houve até um crescer da vegetação em relação à média leva a crer que o estudo, pelo menos nesta forma, não serviria como indicador de seca.

4.3. Estudo de humidade do solo

4.3.1. Análise da humidade do solo entre 2000 e 2017 com índice NDMI

Tanto o processo de análise como a metodologia, incluindo o código implementado, foram análogos ao que foi implementado com o índice de vegetação, o NDVI, na secção anterior.

Para o estudo da humidade presente no solo, portanto, foram usados os dados dos dois satélites Landsat 5 e Landsat 8, para obter dados para o período entre 1990 e 2017.




Figura 20 - Média do NDMI dos invernos entre 1990 e 2017 - sensores Landsat 5 e Landsat 8




Figura 21 - Média do NDMI das primaveras entre 1990 e 2017 - sensores Landsat 5 e Landsat 8




Figura 22 - Média do NDMI dos verões entre 1990 e 2017 - sensores Landsat 5 e Landsat 8



Figura 23 - Média do NDMI dos outonos entre 1990 e 2017 - sensores Landsat 5 e Landsat 8

Nas figuras 20 a 23 estão, então, representadas as médias de cada época do ano – inverno, primavera, verão e outono, respetivamente, calculadas com todos os dados entre 1990 e 2017 disponíveis para cada época. A escala de cor usada contém menos classes que a do NDVI, contando com apenas 7 classes.





Figura 24 - Anomalias da média anual do NDMI em relação à média do NDMI entre 1991 e 2017, calculadas a partir de produtos Landsat 5 e 8

O índice NDMI, tal como o NDVI, está compreendido entre os valores de -1 e 1, mas a escala é invertida – os valores negativos representam os valores em que a água está mais presente, até aos valores positivos que traduzem presença de menor quantidade de água.

A tabela produzida, também de forma análoga à produzida para o NDVI, mostra as anomalias para os mesmos períodos e para as mesmas zonas de estudo usadas na secção anterior. Apesar de a análise desta segunda tabela não se poder retirar informação adicional, e ser quase tão inconclusiva quanto a análise ao NDVI, denota-se um declínio na humidade presente no solo em todas as regiões no período entre 2015 e 2017, que era de esperar tanto pela análise da precipitação, como tendo em conta os relatórios dos institutos meteorológicos e pela literatura.

Tabela 7 - - Anomalias NDMI das quatro estações do ano entre os anos de 2000 e 2017, nas nove regiões de estudo seleccionadas (Figura 18), em relação à média, calculada para os anos entre 1990 e 2017 (dados Landsat 5 e 8)



4.3.2. Análise da aridez do solo entre 2013 e 2017 (Landsat 8)

Por último, introduz-se um estudo a nível de aridez de solo. Como solo seco está normalmente associado a temperaturas altas (Sholihah, et al., 2015) e considera-se que condições de seca estão associadas a níveis de temperaturas altas a par de baixos valores de NDVI (Sholihah, et al., 2015).

Sholihah (Sholihah, et al., 2015) comprovou com sucesso que um estudo de temperatura e do índice de vegetação, NDVI, em conjunto, serve como um forte indicador de seca, em particular seca agrícola.




Figura 25 - Índice de aridez médio calculado entre 2013 e 2017 (esquerda, topo), e médias anuais entre 2013 e 2017. Produtos Landsat 8

Nesta última abordagem, procura-se calcular a aridez de solo, com base no estudo inicial feito por Sholihah, mas considerando também a precipitação na região – o que conduz ao índice de aridez, que combina as temperaturas de solo com a quantidade de precipitação

- para produzir um índice de aridez ao nível do solo. O índice de aridez proposto por De Martonne, IA, considera a média anual da precipitação a dividir pelas temperaturas médias anuais.

No GEE, foram importados os mapas gerados no estudo da precipitação, em particular os referentes à precipitação média anual dos anos 2013 a 2017 (Figura 9). Para cada um desses anos, usando os produtos do Landsat 8, calculou-se a Temperatura do solo à superfície, usando a 1ª banda térmica do sensor, calculando-se a temperatura média anual para os anos 2013 a 2017.

Os mapas de aridez foram obtidos pela média da temperatura de cada ano, expressa em °C, dividida pela precipitação média anual, expressa em mm/pentad, e os resultados estão presentes na figura 25, em que valores mais baixos estão associados um rácio de maior precipitação para menores temperaturas (valores a verde), até às zonas mais áridas, em que a precipitação é menor e as temperaturas de maiores valores. Foi também calculado um mapa com a média geral, calculada com os dados entre 2013 e 2017 inclusive.




Figura 26 - Anomalias da aridez em relação à média, calculada entre 2013 e 2017

Os resultados revelam não apenas as zonas atingidas por seca meteorológica, agrícola e potencialmente hidrológica nos anos de estudo, como também a intensidade da seca estabelecida. Realce-se em particular que a zona árida de Espanha é mais comumente atingida. A seca que atingiu Portugal Continental durante 2015 é também visível, muito em particular na zona Sul, em que parece ter tido maior efeito, bem como na zona Este de

Espanha ao longo da sua costa – o cenário é semelhante, apesar de consideravelmente menor gravidade, em 2017.

Foram também calculadas as anomalias, conforme foi feito nos restantes casos de estudo (Figura 26), em que se observam cenários de aridez mais acentuada nos anos de 2013 e de 2015. No caso do ano de 2013, ocorrem cenários de aridez severa nas zonas já tipicamente secas, em particular em Espanha, mas com extensão ao sul de Portugal.

No caso de 2015, no entanto, estamos perante cenários de seca severa a sul de Portugal e nos extremos norte e sul a Este de Espanha.

Estes resultados coincidem com as conclusões retiradas do estudo da precipitação, em que os anos de 2013 e 2015 revelaram anomalias da precipitação nas mesmas zonas, no caso de 2013 sobretudo no período de 2012, prolongando-se até 2013, e nos casos de 2015 e até 2017, anomalias na precipitação durante esses anos conduziu à aridez do solo nesses mesmos períodos.

Capítulo 5.

Conclusões

Um fenómeno como o da seca pode ser estudado por vários ângulos. Nesta dissertação, procurou-se analisar os fatores mais comumente explorados, no estudo da seca, com recurso ao GEE.

Foram assim analisados dados de precipitação, com particular foco aos anos entre 2000 e 2017, de vegetação e de humidade de solo, com vista a verificar, sabendo a priori em que anos haviam já corrido seca, os anos e zonas em que se observa essa ocorrência.

O estudo da precipitação, em particular, permitiu a identificação as zonas e anos específicos em que seca havia ocorrido. Os dados CHIRPS trouxeram para o estudo resolução e precisão que não teria sido possível atingir ao usar apenas os dados TRMM.

Os estudos de vegetação e de humidade, em particular com o índice NDMI, não evidenciam resultados tão claros quanto os da precipitação, o que de certo modo era expectável, uma vez que a resposta da vegetação face a períodos de seca muitas vezes não é imediata ou linear. O comportamento da vegetação depende de muitos outros fatores que são externos ao uso de deteção remota, ou qualquer outra forma de análise; seja, por exemplo, pela ocorrência de incêndios nas zonas de estudo, por rega artificial ou intervenção humana a nível local, ou até mesmo pelo tipo de vegetação, o facto é que estes fatores intervêm nas observações feitas e, portanto, nos resultados obtidos.

Em futuras análises, deverá ser melhor começar por estudar as características individuais da vegetação em estudo, por exemplo com uma classificação dos diferentes tipos de vegetação observadas, antes de proceder à análise de como a seca meteorológica possa afetar a vegetação.

O índice de aridez, por seu turno, revelou ter potencial na análise do comportamento do solo perante cenários de seca meteorológica, e pode ser um fator a explorar em futuros projetos no mesmo âmbito desta dissertação.

Por último, algumas palavras em relação à ferramenta que permitiu um trabalho com esta extensão de dados para uma zona de estudo tão grande, o *Earth Engine*. Antes de ter sido possível iniciar a tese, e antes até mesmo de definir a sua temática, o GEE foi o primeiro desafio a tomar para tornar tudo o resto possível. A sua interface e os guias disponíveis tornam a introdução na aprendizagem de como o sistema funciona tão suave quanto se

poderia esperar, o que é extraordinário tendo em conta a complexidade do sistema por si só, mas mesmo no fim desta dissertação ainda dá para vislumbrar todo um mundo que há a explorar no potencial que o GEE representa.

Chegamos a um ponto em que temos vários anos de dados, com cobertura global, ou quase global. A possibilidade de partirmos da utilização dos nossos computadores pessoais para o uso dos servidores que o GEE nos oferece abre portas a darmos uso a todos esses dados com rapidez e eficiência, de tal forma que foi quase um desafio adicional conceber como condensar tanta informação numa dissertação, e foi verdadeiramente fascinante aprender e trabalhar nesta plataforma.

Sugere-se para trabalhos futuros, para melhor se compreender o que ocorre durante as diferentes fases de seca, que se façam modelos de evapotranspiração para analisar o solo e o seu comportamento quer em períodos de menor precipitação, quer em alturas de temperaturas anormalmente altas. Em particular nos estudos de temperatura de solo, o cruzamento das imagens térmicas tanto dos produtos MODIS como de Landsat são promissores para o uso quer no estudo da aridez do solo, quer na elaboração de estudos de evapotranspiração.

Em acréscimo, sugere-se que se usem técnicas de *machine learning* em trabalhos futuros como forma de deteção automática de zonas afetadas, sobretudo se o estudo considerar uma área tão vasta ou ainda superior à que foi estudada nesta dissertação. Nos últimos anos, machine learning tem vindo a ser aplicada nas geociências, e em particular em estudos de Deteção Remota (Lary, Alavi, Gandomi, & Walker, 2016), e, tal como o uso de uma ferramenta como o *Google Earth Engine* trouxe vantagens para este estudo, também o uso de novas técnicas vai trazer novas possibilidades para a forma como estudamos e usamos a enorme quantidade de informação que hoje temos disponível para estudar o nosso planeta.

Capítulo 6.

Bibliografia

-
-
- (1975). *Annual Report of the World Meteorological Organization*. World Meteorological Organization.
- Bordi, I. e. (2001). The analysis of the Standard Precipitation Index in the Mediterranean area: large scale patterns. *Annali di Geofisica*, 965 - 978.
- Campbell, J. B., & Wynne, R. H. (2011). *Introduction to Remote Sensing: Fifth Edition*. Guilford Press.
- Direção-Geral do Território (DGT). (2014). *Uso e Ocupação do Solo em Portugal Continental - Avaliação e Cenários Futuros*.
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., . . . Michaelsen., J. (2015). The climate hazards infrared precipitation with stations - a new environmental record for monitoring extremes. *Scientific Data* , 150066 .
- Gallagher, S. (6 de 10 de 2013). *How Google built a 52-terapixel time-lapse portrait of Earth*. Obtido de Ars Technica: <https://arstechnica.com/information-technology/2013/06/how-google-built-a-108-terapixel-time-lapse-portrait-of-earth/>
- Gómez, M. R. (2007). *Spatial and Temporal Rainfall Gauge Data Analysis and Comparison with TRMM Microwave Radiometer Surface Rainfall Retrievals*. Holanda: ITC.
- Google - Google Earth Engine API. (s.d.). *Developers' Guide - Introduction*. Obtido de Google Earth Engine API: <https://developers.google.com/earth-engine/>
- Instituto Nacional de Estatística. (2016). *Península Ibérica em números 2016*.
- Instituto Português do Mar e da Atmosfera. (23 de 07 de 2018). *IPMA: Índice PDSI - Resumo e introdução - Definição*. Obtido de Instituto Português do Mar e da Atmosfera: <http://www.ipma.pt/pt/oclima/observatorio.secas/spi/apresentacao/definicao/>
- IPCC, I. P. (2012). Managing the risks of extreme events and disasters to advance climate change adaption.
- J.P. Tarpley, S. R. (1984). Global vegetation indices from NOAA-7 meteorological satellite. *Journal of Climate and Applied Meteorology*, 491 - 494.

- Jensen, J. R. (2000). *Remote Sensing of the Environment - An Earth Resource Perspective*. University of South Carolina: Pearson Prentice Hall.
- Kademani, S. B. (2006). *A critical study of drought prone area programme in Karnataka a case study of Chitradurga district*. Kuvempu University.
- Lary, D. J., Alavi, A. H., Gandomi, A. H., & Walker, A. L. (2016). Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, Volume 7, Issue 1, January 2016, Pages 3-10.
- Ministério da Agricultura e Pesca, Alimentação e Meio Ambiente. (28 de 07 de 2018). Obtido de https://www.mapama.gob.es/app/publicaciones/rev_numero.asp?codrevista=SSR
- Noel Gorelick, M. H. (2016). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*.
- Observatorio de la Sostenibilidad en España. (2006). *Cambios de ocupación del suelo en España*.
- P.H. Herbst, D. B. (1966). A technique for the evaluation of Drought from Rainfall data. *Journal of Hydrology*, 264-272.
- Página da USGS - Landsat 7. (15 de 5 de 2018). *Landsat Missions*. Obtido de USGS - Science for a changing world: <https://landsat.usgs.gov/landsat-7>
- Pires, V. C., Silva, Á., & Mendes, L. (2010). *Riscos de Seca em Portugal Continental*. Coimbra: Associação Portuguesa de Riscos, Prevenção e Segurança.
- Pires, V. C., Silva, Á., & Mendes, L. (2010). *Riscos de secas em Portugal Continental*. Coimbra: Associação Portuguesa de Riscos, Prevenção e Segurança.
- Sholihah, R. I., Trisasongko, B. H., Shiddiq, D., Iman, L. O., KUSDARYANTO, S., Manijo, & Panuju, D. R. (2015). Identification of agricultural drought extent based on vegetation health indices of Landsat data: case of Subang and Karawang, Indonesia. *The 2nd International Symposium on LAPAN-IPB Satellite for Food Security and Environmental Monitoring 2015*. Elsevier.
- Tempfli, K., Kerle, N., Huurneman, G. C., & Janseen, L. L. (2001). *Principles of Remote Sensing*. Munich.
- Thiruvengadachari, S., & Gopalkrishna, H. (1993). An integrated PC environment for assessment of drought. *Int Journal Remote Sensing*.

- Wilhite, D., & Glantz, M. (1985). Understanding the Drought Phenomenon: The Role of Definitions. *Water International* 10(3), 111–120.
- Wilson, E. H., & Sader, S. A. (2002). Detection of forest harvest type using multiple dates of Landsat TM. *Remote Sensing of Environment*.