

Geographic Object Based Image Analysis aplicada a dados Sentinel 2 MSI

Cristiano Louriceira Martins

**Dissertação de Mestrado em Gestão do Território: Área de
Especialização em Detecção Remota e Sistemas de Informação
Geográfica**

Versão corrigida e melhorada após defesa pública

Março, 2021

Dissertação apresentada para o cumprimento dos requisitos necessários à obtenção do grau de Mestre em Gestão do Território, na área de especialização em Detecção Remota e Sistemas de Informação Geográfica, realizada sob orientação científica do Professor Doutor José António Tenedório e Coorientação da Professora Doutora Rossana Estanqueiro.

DECLARAÇÕES

Declaro que esta Tese é o resultado da minha investigação pessoal e independente. O seu conteúdo é original e todas as fontes consultadas estão devidamente mencionadas no texto, nas notas e na bibliografia.

O Candidato

Luís Tiago Martins

Lisboa, 5 de janeiro de 2021

Declaro que esta Tese se encontra em condições de ser apreciada pelo júri designado.

O Orientador

João António Taveira

Lisboa, 5 de janeiro de 2021

Declaro que esta Tese se encontra em condições de ser apreciada pelo júri designado.

O Coorientador

Roseana F. G. G. G.

Lisboa, 5 de janeiro de 2021

À minha família e amigos.

AGRADECIMENTOS

Em primeiro lugar quero agradecer aos meus orientadores, Professor Doutor José António Tenedório e Professora Doutora Rossana Estanqueiro, por todo o suporte dado na realização desta dissertação, bem como por me terem introduzido tão bem à Deteção Remota ao ponto de ter decidido escrever uma tese neste domínio do conhecimento.

Aos meus pais e irmão, Carlos Manuel da Branca Martins, Lina Maria Simões Louriceira Martins e Daniel Louriceira Martins, o meu agradecimento vai além do apoio dado durante a escrita desta dissertação, mas a toda uma vida de dedicação e luta pelo meu futuro.

Por fim, quero deixar um grande obrigado aos meus amigos, que sempre se mantiveram ao meu lado; dos quais devo um agradecimento académico ao José Neto, Rafael Rei e Carlos Álvaro, pelos conselhos, esclarecimentos e auxílio técnico.

Geographic Object Based Image Analysis aplicada a dados Sentinel 2 MSI

Cristiano Louriceira Martins

RESUMO

Geographic Object-Based Image Analysis aplicada a dados Sentinel 2 MSI

O método de classificação ao objeto – *Geographic Object-Based Image Analysis (GEOBIA)* serviu para classificar, com recurso a dados Sentinel 2 MSI, os tipos de uso e ocupação de solo no município de Almada. Para isso foi utilizado um método de classificação supervisionado ao objeto sem recurso a classificadores estatísticos automáticos e a qualidade do mapeamento final, foi aferida pelo cálculo das seguintes métricas de precisão temática: precisão global, percentagem de erro, precisão no produtor, precisão no utilizador, erro de comissão e erro de omissão.

Foram considerados como satisfatórios os resultados que apresentassem uma precisão global $\geq 80\%$, e por tema uma precisão no utilizador e produtor igualmente $\geq 80\%$. A precisão global foi 81%, a percentagem de erro 19% e os temas que cumpriram os requisitos de precisão foram: 11 Tecido urbano (92%; 90%), 12 Indústria, comércio e transportes (81%; 96%), 141 Espaços verdes urbanos (93%; 95%) e a classe “331 Praias, dunas e areais” com a precisão de utilizador e produtor de 79% e 87%, foi incluída na lista, por ter em falta apenas 1% de precisão no utilizador, mas ter o seu processo classificativo passível de ser automatizado.

PALAVRAS-CHAVE: Detecção remota, Classificação supervisionada ao objeto, Automatização, Tipos de Uso e Ocupação de Solo, Precisão temática.

ABSTRACT

Geographic Object-Based Image Analysis applied to Sentinel 2 MSI data

The object classification method, Geographic Object-Based Image Analysis (GEOBIA) served to classify, using Sentinel 2 MSI data, the types of land use and occupation in the municipality of Almada. For this, a supervised object classification method was used without the use of automatic statistical classifiers and the quality of the final mapping was assessed by calculating the following thematic precision metrics: global precision, percentage of error, precision in the producer, precision in the user, commission error and omission error.

Results with global precision $\geq 80\%$ were considered satisfactory, and by theme, precision in the user and producer equally $\geq 80\%$. The overall accuracy was 81%, the error percentage 19% and the topics that met the precision requirements were: 11 Urban fabric (92%; 90%), 12 Industry, commerce and transport (81%; 96%), 141 Urban green spaces (93%; 95%) and the class "331 Beaches, dunes and sands" with user and producer precision of 79% and 87%, was included in the list, as only 1% of accuracy is missing in the user, but have its classification process capable of being automated.

Keywords: Remote detection, Supervised object classification, Automation, Types of Use and Land Occupation, Thematic precision.

Índice

INTRODUÇÃO.....	1
CAPÍTULO I - DETEÇÃO REMOTA	4
1.1 CONCEITOS FUNDAMENTAIS	4
1.2 RECOLHA DE DADOS	6
1.3 CARACTERÍSTICAS DOS SATÉLITES	8
1.3.1 Órbita.....	9
1.3.2 Sensores passivos e ativos.....	11
1.3.3 Tipos de resolução.....	11
1.3.4 Níveis de processamento de dados.....	12
1.4 UTILIDADE DOS DADOS DE OBSERVAÇÃO TERRESTRE.....	12
CAPÍTULO II - CARTAS DE USO E OCUPAÇÃO DE SOLO	18
2.1 DETEÇÃO REMOTA APLICADA À PRODUÇÃO DE CARTOGRAFIA DE USO E OCUPAÇÃO DO SOLO	18
2.2 O COPERNICUS E O CORINE	19
2.2.1 Programa CORINE.....	20
2.3 DIREÇÃO GERAL DO TERRITÓRIO E A COS	21
CAPÍTULO III - CLASSIFICAÇÃO DIGITAL DE IMAGEM	23
3.1 ANÁLISE DIGITAL DE IMAGEM E MÉTODOS CLASSIFICATIVOS.....	23
3.2 CLASSIFICAÇÃO DE IMAGEM	25
3.2.1 Classificação supervisionada	25
3.2.2 Classificação não supervisionada	26
3.2.3 Classificação híbrida	27
3.3 PRECISÃO TEMÁTICA E MATRIZ DE ERRO.....	28
CAPÍTULO IV - GEOGRAPHIC OBJECT-BASED IMAGE ANALYSIS (GEOBIA)	30

4.1	DO QUE SE TRATA?	30
4.2	GEOBIA ENQUANTO “INTELIGÊNCIA GEOGRÁFICA” E NÃO “INTELIGÊNCIA GEOESPACIAL”	30
4.3	GEOBIA EM ANÁLISE DIGITAL DE IMAGEM	32
4.4	SEGMENTAÇÃO E CLASSIFICAÇÃO DE DADOS OBTIDOS POR DETECÇÃO REMOTA: A BASE DA ALGORITMIA ECOGNITION	33
4.4.1	Segmentação	34
4.4.2	Classificação.....	36
CAPÍTULO V -METODOLOGIA E MATERIAIS		38
5.1	METODOLOGIA	38
5.2	ÁREA DE ESTUDO	38
5.3	AQUISIÇÃO DE DADOS	39
5.4	SOBRE O SENTINEL-2 MSI	39
5.5	NOMENCLATURA CLC E COS	41
5.6	MÉTODOS E TÉCNICAS UTILIZADAS	45
CAPÍTULO VI -PROCEDIMENTOS.....		47
6.1	PROCEDIMENTOS DE SEGMENTAÇÃO E CLASSIFICAÇÃO	47
6.2	OPERACIONALIZAÇÃO DA EXTRAÇÃO DE CLASSES.....	49
6.3	MATRIZ DE ERRO E PRECISÃO TEMÁTICA.....	80
6.3.1	Harmonização entre legenda COS e CLC	80
6.3.2	Matriz de erro.....	85
6.4	CÁLCULOS DE EXATIDÃO TEMÁTICA.....	86
6.4.1	Precisão global e Percentagem de erro.....	86
6.4.3	Erro de Omissão e Erro de Comissão	87
6.4.5	Precisão no Produtor e Precisão no Utilizador.....	87

6.4.6 Reajuste na precisão.....	88
CAPÍTULO VII -RESULTADOS E CONSIDERAÇÕES FINAIS	91
REFERÊNCIAS BIBLIOGRÁFICAS.....	95
ÍNDICE DE FIGURAS.....	98
ÍNDICE DE FLUXOGRAMAS	103
ÍNDICE DE QUADROS	103
ÍNDICE DE TABELAS.....	103
ÍNDICE DE MAPAS.....	103
ANEXOS.....	104
ANEXO A: Algumas das definições para detecção remota.....	104
ANEXOS B e C - MATRIZ DE ERRO E PRECISÃO TEMÁTICA ENTRE CLASSIFICAÇÃO DE UTILIZADOR E CLC (2018):.....	105

INTRODUÇÃO

Na produção cartográfica tentasse representar o território ou camadas do mesmo, da forma mais fiel possível á realidade e neste processo a produção cartográfica vem beneficiando de um suporte tecnológico cada vez mais preparados para captar, armazenar, processar e transformar dados, através de um melhor *hardware* e *software*. Prova disso mesmo são os computadores que utilizamos em nossas casas, que junto às novas plataformas e instrumentos que captam os dados terrestres, incrementaram maior celeridade e profundidade aos estudos¹ pertencentes aos domínios das ciências da terra.

No estudo da superfície terrestre por via da detecção remota, são necessários dados ou imagens que sirvam de objeto de estudo, contudo o acesso a estes pode ser dificultado pelo seu custo monetário, cingindo o seu contacto a estudantes, profissionais ou instituições. E neste sentido a existência de dados abertos, com destaque para os dados disponibilizados pelo programa *Landsat* e missões *Sentinel*, em consonância com o acesso a *software* livre, como o QGIS ou SNAP, tornaram os estudos pertencentes aos domínios das ciências da terra acessíveis ao publico em geral; como resultado, o reconhecimento da informação espacial, enquanto objeto de valor, vem beneficiando da inclusão de entusiastas das Tecnologias ou Sistemas de Informação Geográfica e da Detecção Remota. Ainda dentro deste capítulo do reconhecimento da informação espacial, merecem também destaque aos documentos de gestão publica que recorrem a esta ciência como método auxiliar; um exemplo disto mesmo é o Plano Diretor Municipal (PDM), que evidência tanto para os decisores políticos como para os cidadãos o seu valor, ao apoiar a governação camarária em tarefas como: localização dos serviços de apoio á população, gestão das rotas de autocarros, distribuição e localização de caixotes do lixo, monitoramento dos tipos de usos e ocupação de solo, caracterização topográfica, estudos ambientais (composição florestal, qualidade do ar, risco de cheias...), entre outros.

¹ Serve como exemplo a introdução de *drones* para a captação de fotografias áreas verticais ou o lançamento de novos satélites, como é o recente exemplo do Sentinel-6, que permitem alargar o escopo de dados disponíveis para o estudo da terra.

Percebendo tudo o que foi dito até agora, a formação específica para tratar informação espacial, como por exemplo em Detecção Remota ou nas Tecnologias e Sistemas de Informação Geográfica, é cada vez mais necessária, pois permite desenvolver em harmonia com a componente mais teórica e metodológica, modelos de análise espacial, essenciais em áreas como a gestão do território². E do leque de conhecimentos que compõem estas áreas do conhecimento, especialmente para a correta gestão do território, servem como indispensáveis as cartas de uso e ocupação de solo, pois estas possibilitam medir, entre outros: expansão de áreas artificializadas, desmatamentos, monitorização dos recursos hídricos....

Neste sentido, para o monitoramento dos tipos de uso e ocupação de solo, Portugal Continental na produção de cartografia temática, conta com duas cartografias de uso e ocupação de solo, a Carta de Uso e Ocupação do Solo (COS) e a CORINE Land Cover (CLC), sendo a primeira inspirada na segunda, contudo têm escalas de classificação temática e legendas distintas, sendo a CLC, uma cartografia de referência europeia e a COS uma cartografia exclusivamente nacional. E é na compreensão das duas classificações de solo, CLC e COS que surgiu a presente dissertação com o título "*Geographic Object Based Image Analysis aplicada a dados Sentinel 2 MSI*", onde o intuito base é aplicar um método de classificação e análise de dados, fundamentado em *Geographic Object-Based Image Analysis (GEOBIA)* para identificar os tipos de uso e ocupação do solo para o município de Almada, de acordo com a nomenclatura da legenda CORINE Land Cover (CLC).

Pretende-se aferir se, no processo de classificação de uma carta de usos e ocupação do solo (CLC), existem procedimentos que possam ser automatizados com o objetivo de encurtar o tempo de produção e subjetividade do técnico analista. Para o efeito serão utilizados dados Sentinel-2 MSI como forma de testar a viabilidade das técnicas GEOBIA e no final deverá resultar um mapa de ocupação e uso do solo para o concelho de Almada de acordo com a nomenclatura CLC, sendo a sua qualidade avaliada por métricas de precisão.

² Fonte: https://www.fcsh.unl.pt/cursos/mestrado_em_gestao_do_territorio/

A corrente dissertação está estruturada em 7 capítulos, considerando designadamente: o primeiro capítulo, apresenta os conceitos fundamentais em deteção remota, essenciais para iniciar qualquer trabalho de investigação neste domínio técnico-científico. Nesses conceitos insere-se a definição de Deteção Remota, as características da radiação eletromagnética, a recolha dos dados e suas características; o segundo centra-se no contributo que a deteção remota oferece no mapeamento dos tipos de uso e ocupação de solo, tendo por base as nomenclaturas da legenda CLC e COS (2018), por serem as duas principais cartografias aplicadas em Portugal Continental, como exemplos onde aplicação na produção deste tipo de cartas e é ainda feita uma breve síntese sobre no que consiste o programa Copérnicos, que incuba o programa CORINE; o terceiro capítulo sintetiza os métodos classificativos existentes em deteção remota e mostra como aferir a qualidade do mapeamento produzido. Nos métodos de classificação de imagem está a classificação supervisionada, classificação não supervisionada e a classificação híbrida, bem como o método de aferir as métricas de exatidão temática; no quarto capítulo aborda-se o que é *Geographic Object-based Image Analysis* (GEOBIA) e é dado a conhecer o *software* de referência neste tipo abordagem. Percebesse GEOBIA enquanto método de classificação híbrido e de que maneira o *software eCognition Developer* permite operacionalizar este tipo de abordagem classificativa; o quinto capítulo integra a metodologia e materiais utilizados, desde a área de estudo escolhida, os critérios para obtenção dos dados, o satélite que proveu os dados e ainda os principais métodos e técnicas utilizadas nos procedimentos classificativos; o capítulo VI apresenta os procedimentos de classificação temática executados em *software* e são analisados os resultados obtidos através de métricas de exatidão temática obtidas a partir de matrizes de erro; por fim, no capítulo VII discutem-se os resultados e fazem-se as considerações finais, de acordo com os objetivos propostos.

CAPÍTULO I - DETEÇÃO REMOTA

1.1 CONCEITOS FUNDAMENTAIS

Deteção remota é a ciência que procura obter informação de um objeto sem contacto físico ou mecânico, para isso existe sempre um sensor alojado numa plataforma terrestre, aérea ou espaciais, apto a captar e processar vários tipos de energia; desde energia eletromagnética, ondas sísmicas, ondas sonoras ou força gravitacional, sendo a captação e processamento de energia eletromagnética³ aquela que para esta dissertação servirá de base para todo o processo investigativo. Entendendo isto, percebemos que atos como tirar uma fotografia, configura um exemplo de deteção remota, pois existe uma plataforma, que é a própria estrutura da câmara bem como o utilizador da mesma, e um sensor, que capta a radiação eletromagnética (REM) emitida e transmitida pelos objetos a nossa volta. Porém no universo de sensores aptos a captar e processar este tipo de energia, a oferta dos mesmos varia muito de acordo com os objetivos, detalhe e frequência dos dados.

O planeta Terra e a atmosfera atuam em muitos casos de forma sinérgica, formando um sistema que pode ter as suas características medidas do espaço, desde pressão atmosférica, deslocamento de massas de ar, entrada e saídas de energia... Nestas dinâmicas a emissão de energia solar (REM) ao atingir a superfície terrestre é refletida, transmitida e absorvida⁴, e os satélites com os seus sensores ou instrumentos calibrados para detetar comprimentos de onda ao longo do espectro eletromagnético⁵,

³ Existem diversas definições para Deteção Remota, como tal a definição apresentada não pretende substituir ou invalidar qualquer uma das restantes. O Anexo A contém outras definições existentes.

⁴ De acordo com Tenedório, J. A. (2017), da energia (REM) incidente (E_i) na superfície da terra, esta pode ser refletida (E_r), transmitida (E_t) ou absorvida (E_a). Contudo o somatório desta energia em todas as suas formas de propagação é sempre igual a 1. Importa lembrar o 1º Princípio da termodinâmica que nos diz que toda a energia se conserva e não se perde.

- REM (Radiação eletromagnética); E_i (energia incidente); E_r (energia refletida); E_t (energia transmitida); E_a (energia absorvida)

O cálculo da energia radiante incidente é dado pelo seguinte cálculo: $E_i(\lambda) = E_r(\lambda) + E_t(\lambda) + E_a(\lambda) = 1$

⁵ Denomina-se espectro eletromagnético as regiões espectrais da REM. Toda matéria a uma temperatura superior ao zero absoluto (0o K ou -273o C) emite radiação eletromagnética, como resultado de suas oscilações atômicas e moleculares (Kuchler, Jupp, Daniel, & Bour, 1986).

conseguem captar esta energia radiante da superfície terrestre e fornecer informações aos utilizadores (Meneses & Almeida, 2012). (Figura 2 e Figura 3)




Figura 1 - Direção de propagação da radiação eletromagnética na forma de uma onda, em função das oscilações. Fonte: Meneses & Almeida (2012).

Intervalo Espectral	Comprimento de Onda
Raios cósmicos	0,01 A°
Raios gama	0,01 – 0,1 A°
Raios X	0,1 – 10 A°
Ultravioleta	100nm – 0,38µm
Visível	0,38 – 0,76 µm
Infravermelho próximo	0,76 – 1,2 µm
Infravermelho de ondas curtas	1,2 – 3,0 µm
Infravermelho médio	3,0 – 5,0 µm
Infravermelho termal	5,0 µm – 1 mm
Micro-ondas	1 mm – 100 cm
Rádio	1 m – 10 km
Áudio	10 – 100 km
Corrente alternada	> 100 km

Obs: A° = 10⁻¹⁰ m; nm = 10⁻⁹ m; µm = 10⁻⁶ m

Figura 2 - Divisão do espectro eletromagnético. Fonte: Meneses & Almeida (2012).

Comprimento de onda (µm)	Cor da luz refletida
0,380 – 0,455	Violeta
0,455 – 0,482	Azul
0,482 – 0,487	azul – esverdeado
0,487 – 0,493	azul – verde
0,493 – 0,498	verde – azulado
0,498 – 0,530	Verde
0,530 – 0,559	verde-amarelado
0,559 – 0,571	amarelo-verde
0,571 – 0,576	amarelo-esverdeado
0,576 – 0,580	Amarelo
0,580 – 0,587	laranja-amarelado
0,587 – 0,597	Laranja
0,597 – 0,617	laranja-avermelhado
0,617 – 0,760	Vermelho

Figura 3 - Divisões dos comprimentos de ondas das cores da região do visível. Fonte: Meneses & Almeida (2012).

A REM interage com a superfície terrestre e cada matéria transmite e absorve de forma particular os comprimentos de onda REM e este é o motivo pelo qual é possível associar diferentes comprimentos de onda a materiais ou matérias distintas; comprimentos estes, denominados como assinatura espectral (Figura 4) (Lal & Nizeyimana, 2005). Por exemplo: a vegetação saudável absorve os comprimentos de onda azuis e vermelhos, mas reflete os verdes e infravermelhos. E como o ser humano não consegue ver a radiação infravermelha, fica explicado o porquê de vermos a vegetação saudável com a cor verde; outro exemplo disto mesmo é a água, onde os comprimentos de onda no visível (verde e vermelho) e do infravermelho próximo são os mais absorvidos, explicando o porquê desta se apresentar com tons de azul ou azul-esverdeado ou no caso de ter sedimentação com maior brilho.




Figura 4 - Assinaturas espectrais de água, vegetação e solo.
Fonte: Lal & Nizeyimana (2005)

1.2 RECOLHA DE DADOS

Os dados são recolhidos a partir dos sensores que se encontram num dos seguintes tipos de plataformas: terrestres, aéreas ou espaciais. Dando como exemplo de plataformas terrestres, temos as escadas, topos de edifícios, guindastes...; como exemplos de plataformas aéreas existem, aeronaves, helicópteros, balões, veículos aéreos não tripulados, ou qualquer outra plataforma que se situe na troposfera ou estratosfera⁶; e no espaço a deteção remota é comumente conduzida a partir de satélites que orbitam a terra. De qualquer das formas os sensores estão alojados nas plataformas a receber a energia radiante (REM), que vai ser convertida em níveis digitais

⁶ Fonte: https://www.nasa.gov/mission_pages/sunearth/science/atmosphere-layers2.html

(ND) de acordo com a sua assinatura espectral. A título de exemplo a captação de REM por satélites, e porque esta dissertação utiliza dados provenientes deste tipo de plataforma, começa quando a radiação solar atravessa a atmosfera e atinge a superfície terrestre, causando radiação solar incidente, da qual alguma dessa radiação vai ser refletida e transmitida, interagindo com a atmosfera até chegar aos satélites, que estão equipados para detetar este tipo de energia.

A leitura da REM, permite compreender a superfície terrestre de acordo com a assinatura espectral de cada matéria. Por exemplo, a vegetação reflete certos comprimentos de onda da energia solar incidente para o satélite (Figura 4) e mudanças nas ondas refletidas podem indicar alguma alteração nos tipos de cobertura de solo. No caso da água, que reflete radiação principalmente no espectro azul-verde, mudanças na sua assinatura espectral podem fornecer dados relativos aos níveis de água, existência ou não de algas... Nas áreas de cultivo e solo a descoberto, alterações podem também ser detetadas, ajudando a identificar em que momento se encontra o ciclo de uma colheita. E por último nas áreas pavimentadas e com edifícios, que se destacam dos meios naturais por emitirem ondas “com um aspeto mais brilhante”, é possível quantificar o desenvolvimento ou expansão de áreas artificializadas. Tudo isto configura exemplos onde o satélite deteta energia solar, emitida e transmitida pela terra, onde o que varia é apenas a assinatura espectral da energia captada, processamento da mesma e exposição de acordo com as características próprias de cada satélite (órbita, fonte de energia (espectro solar e terrestre), características e aplicação⁷).

Como forma de sintetizar as etapas que precedem à transformação da energia REM em informação auxiliar ao utilizador, está exposto na Figura 5 o percurso ou etapas que a mesma percorre, desde o momento em que é emitida pelo sol, atinge a superfície terrestre e é captada pelos sensores, permitindo a sua transformação em dados aptos a auxiliar a nossa compreensão dos recursos, materiais e matérias em investigação.

⁷ Fonte: <https://arset.gsfc.nasa.gov/webinars/fundamentals-remote-sensing>

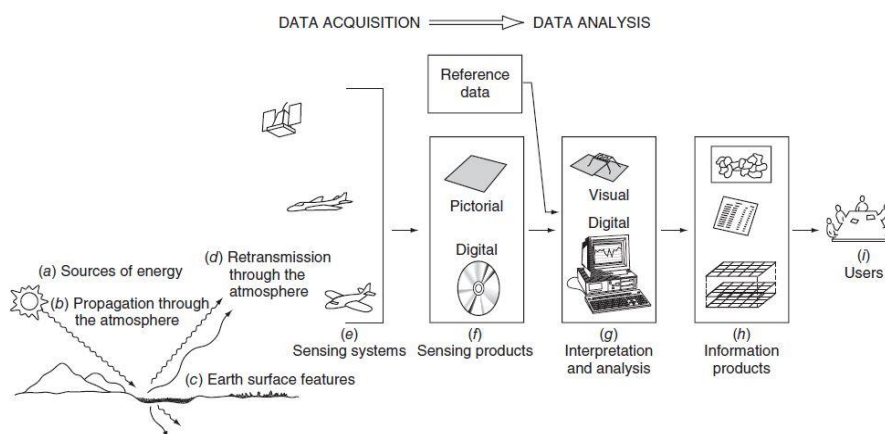


Figura 5 – Detecção remota de recursos terrestres. Fonte: Thomas M. Lillesand, Ralph W. Kiefer (2015)

De uma forma geral o processamento remoto da REM está envolvido em duas fases: primeiro na recolha de dados e em seguida na sua análise. A aquisição de dados começa com uma fonte de energia, normalmente solar **(a)**, que se propaga pela atmosfera **(b)**, interage com a superfície terrestre **(c)**, é retransmitida através da atmosfera **(d)** e é captada por sensores terrestres (escadas, topos de edifício...), aéreos (helicópteros/drones) e/ou espaciais (satélites) **(e)**, daí resultam dados sensoriais em formato pictórico (papel ou analógico) e/ou digital **(f)**.

Percebe-se então que os sensores registam ou medem as variações no modo como a matéria à superfície terrestre reflete e emite REM. Já o processo de análise e interpretação dos dados **(g)**, envolve examinar os dados (vetoriais ou *raster*) com recurso a dispositivos de visualização e interpretação dos dados provenientes dos sensores. Estas informações são então compiladas **(h)**, normalmente sob a forma de mapas, tabelas ou dados em formato digital que podem ser combinados com outras “camadas” de informações em sistema de informações geográficas (SIG). Finalmente, as informações são apresentadas aos utilizadores **(i)**, como forma de auxiliar os processos de tomada de decisão (Thomas M. Lillesand, Ralph W. Kiefer, 2015).

1.3 CARACTERÍSTICAS DOS SATÉLITES

As características dos satélites diferem de acordo com a órbita, fonte de energia (espectro solar e terrestre), tipos de sensores, nível de processamento dos dados, resolução e aplicações.

1.3.1 Órbita

Órbita é o caminho curva de um objeto no espaço (como uma estrela, planeta, lua, asteroide ou nave espacial) em torno de um objeto (terra ou sol). Quando um satélite é transportado por um *rocket* e é largado no espaço, recebe um “empurrão” dos motores, iniciando a sua órbita a volta da terra, que é mantida graças a força da gravidade (Figura 6), da mesma forma que a lua é mantida à volta da terra e a terra à volta do sol. Os satélites podem seguir três tipos de órbita, à volta da terra (órbita terrestre), do sol (órbita solar) ou no caso de terem outro planeta como destino (ex: Marte, ou Júpiter - órbita interplanetária). Mas pensando apenas nas órbitas terrestres, existem os seguintes tipos de órbita⁸: Órbita Geostacionária (GEO), Órbita Baixa (LEO), Órbita Média (MEO), Órbita polar e órbitas solares síncronas (SSO) e a Órbita de transferência e órbita de transferência geostacionária (GTO)⁹.




Figura 6 - Satélite a atingir a órbita. Fonte: https://www.esa.int/Enabling_Support/Space_Transportation/Types_of_orbits

Na Órbita Geostacionária (GEO), o(s) satélite(s) circulam sob a linha do equador de Oeste para Este a uma altitude de 35.786km e completam a sua órbita em 23 horas, 56 minutos e 4 segundos - viajando exatamente à mesma velocidade que a rotação do planeta Terra. Isso faz com que pareçam “estacionários”, numa posição fixa. Os satélites com este tipo de órbita permitem múltiplas observações diárias e por estarem muito distantes do planeta são necessários poucos satélites, desde que mantenham um

⁸ Nomenclatura oficial dos tipos de órbitas, não traduzidas: *Geostationary orbit (GEO)*, *Low Earth orbit (LEO)*, *Medium Earth orbit (MEO)*, *Polar orbit and Sun-synchronous orbit (SSO)*, *Transfer orbits and geostationary transfer orbit (GTO)*.

⁹Fonte: https://www.esa.int/Enabling_Support/Space_Transportation/Types_of_orbits

espaçamento igual entre si, para fornecer uma cobertura quase total do planeta, embora cada satélite, de forma individual, tenha a sua observação restringida à mesma área.

A Órbita Baixa (LEO) tem como sugere o nome, a sua órbita relativamente próxima da terra, aproximadamente entre os 160 km e os 1000 km de distância. Como comparação, um voo comercial encontra-se a aproximadamente 14 km de altitude, é por isso possível dizer que a órbita LEO, ainda que mais próxima, é 10 vezes mais distante que à de um voo comercial. Os satélites que seguem esta órbita, não cumprem sempre a mesma rota como os satélites GEO, eles podem inclinar as suas rotas e delinear mais e novas rotas e por este motivo os satélites LEO são bastante utilizados. Um satélite nesta órbita, demora aproximadamente, 90 minutos a circundar a terra.

A Órbita Média (MEO) situa-se entre a órbita GEO e LEO. Assemelha-se a LEO por ter a flexibilidade de modificar a sua rota e tem muitas aplicações, contudo é muito utilizada por satélites de navegação como o Sistema Europeu de Navegação (Galileo).

Na órbita polar e órbitas solares síncronas (SSO) os satélites geralmente têm uma rota de Norte a Sul, passando junto aos polos¹⁰ e são considerados de LEO por estarem em baixas altitudes, entre os 200 km e 1000 km. As órbitas solares síncronas (SSO) encontram-se a uma altitude de 600 km a 800 km e são um caso particular de órbita polar, porque se manterem numa posição “fixa” em relação ao sol; o que significa que o satélite que esteja a cumprir esta órbita cruza todos os locais precisamente à mesma hora local.

Por último a órbita de transferência e órbita de transferência geoestacionária (GTO) é um tipo específico de órbita que têm como função viabilizar as transferências de satélites para outras órbitas. Para uma melhor compreensão e a título de exemplo: para se atingir a órbita GEO, normalmente um *rocket* larga um satélite numa zona denominada de órbita de transferência geoestacionária (GTO), onde são ativados motores embutidos no satélite que o transporta à GEO, onde os motores dão mais um “empurrão” para que o satélite permanecer nessa órbita (Figura 7).

¹⁰ Até uma inclinação de 20 a 30 graus, em relação aos polos, é considerado órbita polar.

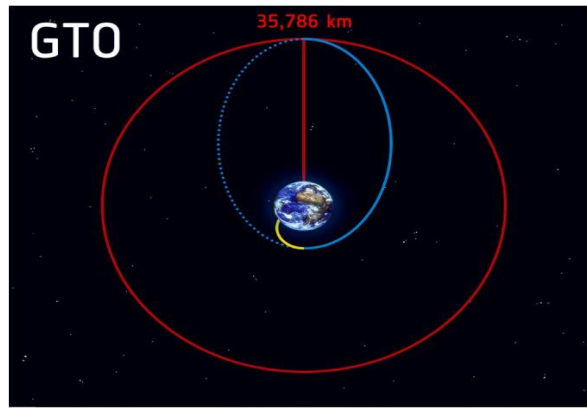


Figura 7 - Lançamento do *rocket* (linha amarela), começo da órbita de transferência (linha azul) quando o rocket solta o satélite no espaço e esta caminha para a órbita geoestacionária (linha vermelha). Fonte: https://www.esa.int/Enabling_Support/Space_Transp

1.3.2 Sensores passivos e ativos

Os satélites podem ter dois tipos de sensores para recolher dados da terra, os passivos e os ativos. Os sensores passivos dependem de mudanças na gravidade (ex: *GRACE Follow-On*) ou da radiação refletida e transmitida pela Terra (ex: *Landsat* ou *Sentinel*) e os sensores ativos enviam ondas de radiação e medem ou avaliam o seu retorno (ex: Radar, Sonar ou LIDAR). Estes últimos mostram-se especialmente eficientes em momentos de nebulosidade, céu encoberto ou de noite.

1.3.3 Tipos de resolução

A resolução depende muito da órbita do satélite (distância a que se encontra da superfície terrestre) e das características do sensor. Existem quatro tipos de resolução: a espacial, temporal, espectral e radiométrica: a resolução espacial corresponde à área ocupada por pixel na imagem, e geralmente quanto maior a resolução espacial, menor é a área coberta por pixel (vice-versa); a resolução temporal diz respeito ao período de revisita de um satélite à mesma área e ângulo de captura; a resolução espectral descreve a capacidade de um sensor ou instrumento detetar comprimentos de onda, ou seja, quanto maior for a capacidade para detetar intervalos de onda, maior é a sua resolução espectral; a resolução radiométrica descreve a capacidade de um sensor discriminar e representar diferenças de energia e quanto maior a resolução radiométrica, mais sensível é o sensor a pequenas diferenças de energia. As medidas de energia são

quantificadas ou codificadas pelos sensores em níveis digitais (ND ou DN – *Digital Numbers*) que variam entre os 6, 8, 10 ou 12 “bits” (2^6 , 2^8 , 2^{11} , 2^{12}), que correspondem em ND, como: 6 bits = 64 ND (Landsat MSS), 8 bits = 256 ND (Landsat TM), 10 bits = 1024 ND (AVHRR) e 12 bits = 4096 ND (MODIS, MISR, Sentinel-2 MSI);

1.3.4 Níveis de processamento de dados

Os produtos dos dados podem ser encontrados na sua forma mais bruta ou em formatos e parâmetros mais úteis ou processados. Por exemplo, todos produtos de dados da NASA *Earth Observing System Data and Information System* (EOSDIS) são processados a vários níveis, desde o nível 0 ao nível 4¹¹. Os produtos do nível 0 correspondem aos dados brutos, contudo nos níveis mais altos, os dados estão convertidos em parâmetros e formatos mais prestáveis para os utilizadores. Por exemplo, o satélite utilizado nesta dissertação, Sentinel-2 MSI da Agência Espacial Europeia (ESA), tem os seus produtos dos dados a variar entre os níveis 0 e 2 (Nível -0, Nível-1A, Nível -1B, Nível-1C e Nível-2A), sendo apenas os níveis, 1C e 2A, disponibilizados ao público. No Nível 1C os dados contêm a orto retificação dos mesmos, registo espacial, referência global ao nível do sub-pixel e cálculo da refletância ao nível do topo da atmosfera [*Top-Of-Atmosphere* (TOA)] e no Nível 2A o processamento dos dados tem como principal produto a imagem orto retificada no nível baixo da atmosfera [*Bottom-Of-Atmosphere* (BOA)].

1.4 UTILIDADE DOS DADOS DE OBSERVAÇÃO TERRESTRE

Os dados de observação terrestre, permitem captar momentos da superfície terrestre com mais ou menos detalhes, de acordo com as suas características. Estes dados podem servir diversas funções, tanto no uso individual de um cidadão que pretende estudar ou conhecer com mais detalhe a sua propriedade; produção cartográfica para fins governamentais; monitoramento do planeta em que vivemos.... Como os dados de observação terrestre têm um vasto conjunto de aplicações, serão elucidadas apenas algumas das suas utilidades.

¹¹ Fonte: <https://earthdata.nasa.gov/collaborate/open-data-services-and-software/data-information-policy/data-levels>

A título de exemplo, quando pensamos em estudar áreas como propriedades individuais, terrenos agrícolas ou produzir cartografia de referência para o território (como as cartas à escala de 1: 10 000 (Figura 8)), a utilização de dados de observação terrestre de alta resolução espacial (< 5m), permitem extrair informações como perfis topográficos, identificar linhas de escoamento de águas, delinear estruturas de transporte e abastecimento, edifícios, construções, cercaduras, vedações.... Contudo a utilização de dados de alta resolução espacial merecem uma ressalva, pois oferecem algumas barreiras ao utilizador, desde o seu fornecimento, que não é aberto (World view, Quickbird, Ikonos...) ou necessitam de alguém especializado na captação de imagens aéreas, por exemplo com *drones*, sem esquecer que utilizar diferentes tipos de dados ou sensores, como imagens multi/hiperespectrais ou tecnologia LIDAR (*Light Detection And Ranging*), podem levar a tempos de processamento elevados pelo tamanho dos dados bem como requerem um vasto conhecimento técnico no seu tratamento.

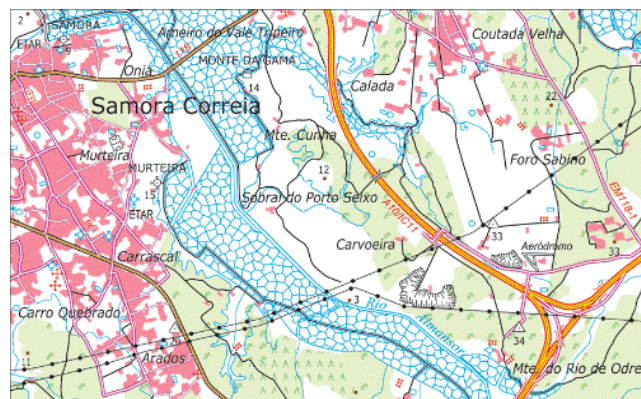


Figura 8 - Extrato de cartografia a escala 1: 10 000. Fonte: <https://www.dgterritorio.gov.pt/cartografia/cartografia-topografica/scn10k>

Quando não se tem por objetivo identificar ou estudar objetos que exigem uma alta precisão espacial, como cercas, rede elétrica, linhas de escoamento de água... a utilização de dados com este tipo de resolução pode representar um desperdício de recursos financeiros, existindo á disposição dados abertos com uma boa resolução espacial como é o caso do Sentinel-2 MSI que nas bandas 2 (Red), 3 (Green), B4 (Blue) e B8 (NIR) oferece uma resolução espacial de 10m, com excelente cobertura global para

as áreas cobertas por solo¹² (Figura 9), propiciando formas de estudo sem custos monetários, que aliado a *software* GIS aberto, como o SNAP ou QGIS, a investigação ou estudo de um território fica dependente apenas das capacidades técnicas do utilizador. No entanto para atividades como vectorização de cartografia de referência ou atividades como agricultura de precisão, a necessidade de dados de alta precisão é necessária.

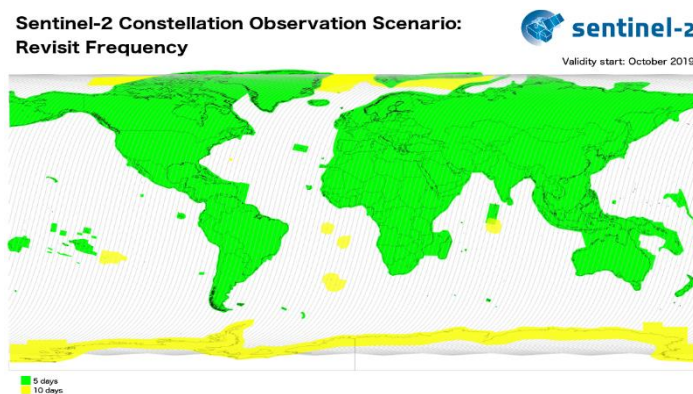


Figura 9 - Cobertura e resolução temporal para os dados Sentinel 2-MSI. Fonte: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/revisit-coverage>

Por fim, os dados de observação terrestre podem servir outras funções, além do uso individual e apoio a produção de cartografia de cobertura de solo. Em deteção remota os satélites viabilizam, por exemplo o monitoramento contínuo do nosso planeta, essencial para estudar os territórios não habitados, como desertos ou florestas¹³; permitem ainda observar as áreas com incêndios ativos (Figura 10); avaliar a qualidade do ar e acompanhar a deslocamentos de massas de ar poluídas (Figura 11 e Figura 12); monitorar os recursos hídricos á superfície (Figura 13), avaliando os riscos de cheia e secas; também possível aferir o impacto das alterações climáticas na subida dos níveis do oceano (Figura 14) e seus efeitos na agricultura (Figura 15); entre outras preocupações que como o controlo de desflorestação ou na identificação de vetores de transmissão de doenças.¹⁴

¹² Fonte: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/revisit-coverage>

¹³ Fonte: <https://arset.gsfc.nasa.gov/webinars/fundamentals-remote-sensing>

¹⁴ Fonte: <https://arset.gsfc.nasa.gov/webinars/fundamentals-remote-sensing>

Na figura abaixo (Figura 10) podemos ter um exemplo em como os satélites podem auxiliar o monitoramento de incêndios.

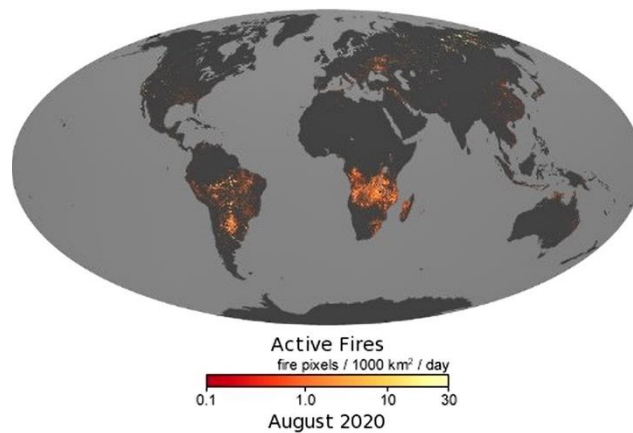


Figura 10 - Satélite Terra: Incêndios ativos no mês de agosto em 2020. Fonte: https://earthobservatory.nasa.gov/global-maps/MOD14A1_M_FIRE

Na próxima figura é demonstrada a utilidade dos mesmos na avaliação da qualidade do ar (Figura 11), como por exemplo, no fornecimento de dados relativos à concentração de partículas cancerígenas.

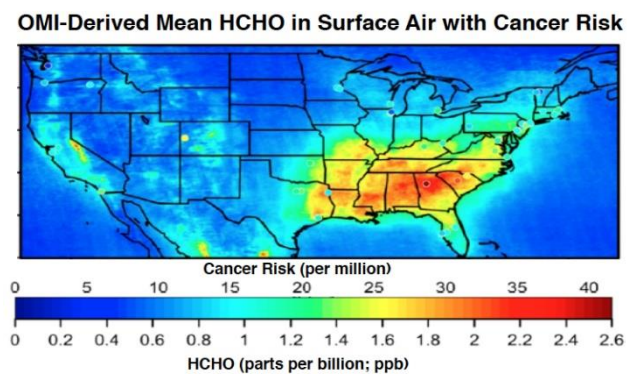


Figura 11 - Satélite Aura: Concentrações médias anuais de HCHO no ar e risco de cancro. Fonte: <https://aura.gsfc.nasa.gov/science/feature-201711a.html>

Também no monitoramento das deslocções de CO₂ pela atmosfera, podem ser utilizados dados provenientes de satélites espaciais (Figura 12).




Figura 12 – Satélite OCO-2: Anomalias de CO2 na atmosfera. Fonte: <https://earthobservatory.nasa.gov/images/89117/satellite-detects-human-contribution-to-atmospheric-co2>

No próximo exemplo é demonstramos como os dados orbitais, contribuem para monitorizar a quantidade de água presente á superfície do solo (Figura 13), ajudando a prever períodos e zonas de seca.

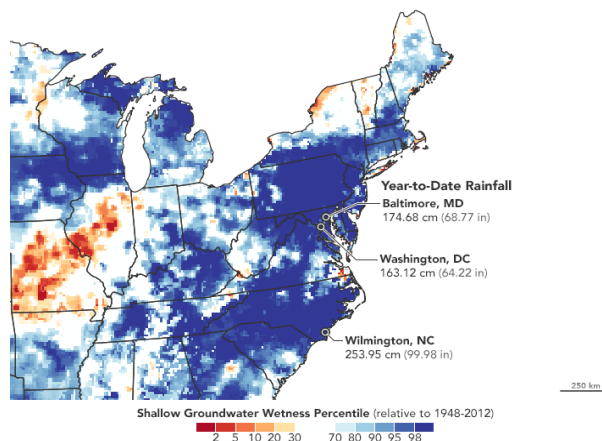


Figura 13 - Satélite GRACE-FO: Lençóis de água á superfície. Fonte: <https://earthobservatory.nasa.gov/images/144417/soggy%202018%20for%20the%20eastern%20us>

Mais um bom exemplo, para demonstrar as várias funções e aplicações dos dados obtidos a partir de satélites, é a observação dos fenómenos de *El niño* (Figura 14), que nos permite compreender de que forma o aquecimento global está a afetar as correntes oceânicas.

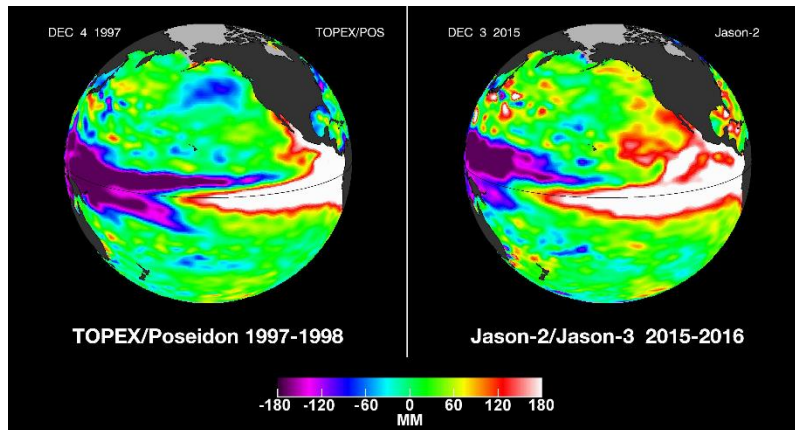


Figura 14 - Satélite Jason-2 e Jason-3: El Niño: 1997-1998 vs. 2015-2016.
 Fonte: <https://sealevel.jpl.nasa.gov/data/el-nino-la-nina-watch-and-pdo/el-nino-2015/>

Por último, como exemplo na aplicação de dados orbitais, está o monitoramento da quantidade de água contida no solo (Figura 15), isto permite, entre outras coisas perceber o impacto das alterações climáticas ao nível regional e local, bem como prover aos órgãos de gestão e planeamento do território uma estimativa de como a atividade agrícola poder ser afetada por esses mesmos efeitos.

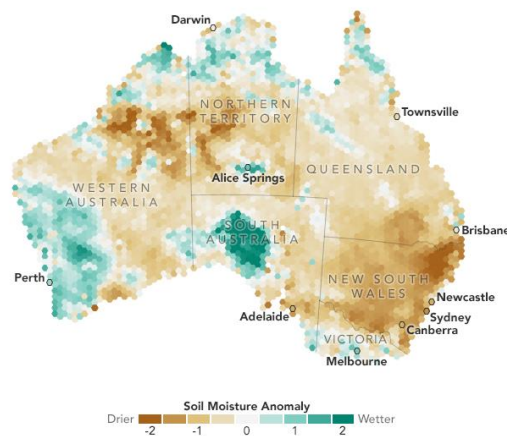


Figura 15 - Satélite SMAP: Água contida no solo. Fonte: <https://earthobservatory.nasa.gov/images/92583/a%20mid%20winter%20drought%20in%20australia>

CAPÍTULO II - CARTAS DE USO E OCUPAÇÃO DE SOLO

2.1 DETEÇÃO REMOTA APLICADA À PRODUÇÃO DE CARTOGRAFIA DE USO E OCUPAÇÃO DO SOLO

“A cartografia de ocupação/uso do solo tem um papel fundamental no ordenamento do território e na monitorização ambiental, e a sua aplicação tem vindo a ser alargada ao planeamento ambiental, político, económico e social. Este tipo de produto cartográfico retrata um momento temporal específico e constitui uma ferramenta imprescindível no panorama atual para entidades públicas e privadas dos mais diversos setores. Com recurso a este tipo de cartografia, pode-se avaliar a extensão, a distribuição e a relação espacial de classes de ocupação/uso do solo, identificar locais próprios para certas atividades e planear o presente e o futuro de uma forma fundamentada. Simultaneamente, a cartografia de ocupação/uso do solo serve de base para a produção de informação mais complexa sobre outros temas (e.g. erosão do solo, impermeabilização, emissões de gases com efeito de estufa).”

(Caetano, Igreja, & Filipe, 2018)

Desde 1858, quando foram captadas as primeiras fotografias aéreas pelo balonista francês, Félix Nadar, a tecnologia de aquisição e processamento de imagens adquiridas remotamente, progrediu rapidamente para imagens de alta resolução, multiespectrais, hiperespectrais e sistemas térmicos de imagem (Thomas M. Lillesand, Ralph W. Kiefer, 2015). A utilidade da deteção remota, não se circunscreve apenas a uma área do conhecimento, contudo, no que tange as atividades onde esta ciência pode contribuir de forma direta e com fins de apoio civil, destacam-se: mapeamento dos tipos de uso e ocupação de solo, monitoramento de florestas, planeamento regional e urbano, apoio arqueológico, monitoramento de recursos hídricos, aplicações agrícolas, avaliações ambientais, avaliação de relevo...

Na produção de mapas que descrevam os tipos de uso e ocupação de solo as informações relativas a este tipo de mapeamento são importantes para planear e modelar atividades, bem como entender o sistema terrestre a diferentes escalas. Os termos “uso” e “ocupação” não significam exatamente o mesmo, o termo “uso” indica

o tipo de atividade humana associada a uma área geográfica (Ex: habitação residencial ou empresarial; área de caça ou área protegida...) e o termo “ocupação” indica a denominação do material ou objeto que compõem o solo (Ex: lago, árvore, estrada, construção...). Posto isto, como forma de proceder ao tratamento dos tipos de uso e ocupação solo, a ciência geográfica beneficia de duas áreas complementares, a deteção remota e os sistemas de informação geográfica ou tecnologias de informação geográfica (SIG/TIG).

A ocupação do solo pode ser detetada por imagens aéreas e de satélites, contudo o uso de solo pode requer informações adicionais. O ser humano tende a apropriar-se de áreas para atividades recreativas (caçar, pescar, praticar desporto...), nas imagens aéreas é possível reconhecer, a título de exemplo, uma floresta, mas dificilmente se decifra a sua utilização para fim recreativos, como a caça. Por isso a utilização de imagens provenientes de deteção remota, beneficia da sua articulação com os SIG/TIG¹⁵ (Sistemas de Informação Geográfica/Tecnologias da Informação Geográfica). Esta informação suplementar é necessária para delimitar parques, áreas protegidas, limites administrativos, de entre outros, considerando que só o recurso a imagens remotas seria insuficiente para se poder identificar.

2.2 O COPERNICUS E O CORINE

A *European Environment Agency* (EEA) é um órgão da União Europeia (UE) que tem o papel apoiar a UE no desenvolvimento e implementação de medidas ambientais. Para isto, a UE delegou orçamentos à EEA para o programa de observação da terrestre *Copernicus* (EEA, 1995). *Copernicus* é o principal programa de monitoramento da UE, que conta com uma frota de satélites *Sentinel* e sensores terrestres, que recolhem e processam dados que contribuem para seis áreas temáticas (solo, marinha, atmosfera, alterações climáticas, gestão de imergências e segurança) e contribui em missões

¹⁵ De acordo com Julião (2016) “Os SIG/TIG são dois conceitos que detém um lato conjunto de definições. Mas grosso modo, SIG corresponde a um conjunto de procedimentos e suporte para recolher, armazenar, pesquisar, analisar, representar e visualizar dados geográficos representados por: pontos, linhas, polígonos e volumes. E TIG corresponde a todos os tipos de “instrumentos” que lidam com informação geográfica (satélites, CAD, GPS, Desktop Mapping...) tanto na fase de aquisição, integração, análise e visualização de dados.”

conjuntas, com seis serviços operacionais geridos pela Comissão Europeia (CE) nas áreas de mercado interno, indústria, empreendedorismo e *SMEs (small business)* (DG GROW)¹⁶. O programa *Copernicus* contém ainda produtos similares de cobertura global e pan-europeus (Figura 16). Os produtos pan-europeus estão em constante evolução e atualização e os produtos de cobertura global são produzidos pelo *Joint Research Centre*¹⁷.

Portfolio category	Product name	Individual products
Systematic Biophysical Monitoring	Snow and Ice*	Fractional Snow Cover (FSC) Permanent Snow Line River/Lake Ice
	High Resolution Phenology*	Various phenological indicators and seasonal trajectories
Land Cover & Land Use Mapping	Corine Land Cover (CLC)	LCLU status and change
	Corine Land Cover plus (CLC+)*	CLC-backbone CLC-core CLC+ instance CLC – legacy
	High Resolution Layers	Imperviousness Forest Grassland Wetness & Water Small Woody Features
Thematic Hotspot Mapping	Urban Atlas	LCLU status and change
	Riparian Zones	LCLU status and change
	Natura 2000	LCLU status and change
	Coastal Zones*	LCLU status and change
Reference Data	EU-DEM	EU-DEM Slope Aspect Hillshade
	EU-Hydro	Rivers (centreline and outline) Inland waters Coastline Drainage network
	Image Mosaics	Very High Resolution (VHR) High Resolution (HR)
Ground Motion Service*		

* = in preparation

Figura 16 - Produtos e serviços "Copernicus Land Monitoring Service". Fonte: (EEA, 2018)

Os produtos exclusivos de monitoramento do solo (*Copernicus Land Monitoring Service*) providenciam informação geográfica sobre a cobertura de solo com uma ampla gama de utilidades (monitoramento biofísico, mapeamento de ocupação e uso de solo, mapeamento temático de *hotspot's*, dados de referência; movimentos do solo) (EEA 2018) e é entre estes produtos de monitoramento do solo que estão os produtos *CORINE (Co-ordination of Information on the Environment)*.

2.2.1 Programa CORINE

Entre 1985 e 1990, a Comissão Europeia implementou o Programa CORINE e durante este período, foram criados sistemas para avaliar o ambiente na Europa bem como acordadas metodologias e nomenclaturas ao nível da UE. Foram utilizadas

¹⁶ <https://land.copernicus.eu/global/about>

¹⁷ *Joint Research Centre* é a comissão que presta serviços de inteligência, conhecimento e emprega cientistas como forma de fornecer pareceres científicos independentes para a UE.

imagens de satélite para classificar o tipo de cobertura do solo e em 1990 foi publicado o primeiro projeto *CORINE Land Cover* (CLC1990). Atualmente o *CORINE Land Cover* conta com uma legenda de 44 classes no seu nível mais desagregado e um inventário de cinco publicações na europa (Figura 17) com uma unidade mínima cartográfica (UMC) de 25 ha.

Nome	Ano	
	Início	Conclusão
CLC1990	1986	1999
CLC2000	2001	2006
CLC2006	2007	2010
CLC2012	2013	2015
CLC2018	2017	2018

Figura 17 - Inventário CLC

Nota: O inventário CORINE Land Cover só passou a integrar o programa Copernicus após a CLC2012 estar concluída.

A CLC2018, quinto do inventário, teve como provedor elementar de imagens para classificação de cobertura de solo, o Sentinel-2 (primeiro satélite europeu dedicado ao monitoramento do solo) recorrendo a imagens Landsat-8 para preenchimentos de lacunas. Os processos classificativos suportam-se na análise visual de imagem (fotointerpretação) por computador, enquanto método classificativo dominante, mas outras soluções (como por exemplo abordagens *bottom-up*) começam a surgir (Büttner, Kosztra, Soukup, Sousa, & Langanke, 2017).

2.3 DIREÇÃO GERAL DO TERRITÓRIO E A COS

A Direção Geral do Território (DGT) integra em si, desde outubro de 2012, a Direção-Geral de Ordenamento do Território e Desenvolvimento Urbano e o Instituto Geográfico Português e em 2013 entra em funcionamento o novo Portal do Ordenamento do Território, do Urbanismo e da Informação Geográfica. É ainda responsável por um conjunto de plataformas e infraestruturas de dados espaciais como o Sistema Nacional de Informação Territorial (SNIT), o Sistema Nacional de Informação

Geográfica (SNIG) e o Sistema de Administração do Recurso Litoral (SIARL)¹⁸. De acordo com a própria Direção Geral do Território (DGT) *“A DGT é o organismo público nacional ao qual incumbe prosseguir as políticas públicas de ordenamento do território e de urbanismo, no respeito pelos fins, princípios gerais e objetivos consagrados na respetiva Lei de Bases... promover e apoiar as boas práticas de gestão territorial... bem como a criação e manutenção das bases de dados geográficos de referência... e ainda a manutenção da rede geodésica nacional e a produção de cartografia nacional de referência”*¹⁹.

A DGT é ainda o organismo nacional encarregue pela elaboração de duas cartografias de uso e ocupação do solo para Portugal Continental: Carta de Uso e Ocupação do Solo (COS) e CORINE Land Cover (CLC). A COS é uma cartografia inspirada na CLC que na sua versão mais recente COS2018, atualiza a COS2015 com mais 35 classes, mas que na sua atualização foram detetados erros na COS2015, que iram ser corrigidos e darão lugar à COS2015v2.0, que posteriormente serão propagadas para as COS anteriores (COS1995, COS2007 e COS2010), criando também versões atualizadas²⁰ (Direção-Geral do Território, 2019).

¹⁸ http://www.dgterritorio.pt/a_dgt/

¹⁹ http://www.dgterritorio.pt/a_dgt/natureza_e_missao/

²⁰ http://www.dgterritorio.pt/dados_abertos/cos/

CAPÍTULO III - CLASSIFICAÇÃO DIGITAL DE IMAGEM

3.1 ANÁLISE DIGITAL DE IMAGEM E MÉTODOS CLASSIFICATIVOS

A análise Digital de Imagem (*Digital Image Analysis* - ADI) consiste em tratar a imagem em formato digital, recorrendo ao computador. Esta manipulação acontece em uma, ou mais, de sete categorias: processamento de imagem; realce de imagem (*Image enhancement*), classificação de imagem, análise de mudança no tempo, fusão de dados e integração em Sistemas de Informação Geográfica (SIG), análise hiperespectral e(ou) multiespectral e modelação biofísica (Thomas M. Lillesand, Ralph W. Kiefer, 2015).

O processamento de imagem diz respeito aos procedimentos destinados a corrigir distorções, imprecisões ou degradação nos dados. Tem por objetivo manter os dados o mais fiel possível à realidade para os procedimentos posteriores. Esta categoria também recebe frequentemente a denominação de “pré-processamento”; o realce de imagem destina-se a realçar dados específicos para procedimentos seguintes, como manipulação de contraste (*level slicing* e *contrast stretching*), manipulação de características espaciais (*spatial filtering*, *convolution*, *edge enhancement*, e *Fourier analysis*) ou realce que envolvam diversas bandas (*spectral ratioing*, *principal and canonical components*, *vegetation components*, e *intensity–hue–saturation color space transformations*); na classificação de imagens o objetivo é interpretar e identificar elementos ou componentes na imagem através de métodos quantitativos. Normalmente são analisadas várias bandas de dados, com recurso a ferramentas que diferem no tratamento estatístico para decidirem a classe ou tema a que pertence cada pixel. Quando a decisão assenta exclusivamente sob informação espectral, o processo de classificação é entendido como *spectral pattern recognition* e quando a decisão leva em conta a geometria, tamanho e padrões nos dados, estes procedimentos de classificação são entendidos como *spatial pattern recognition*. Existem ainda as classificações híbridas que utilizam informação espectral e espacial; a análise de mudança no tempo é bastante utilizada em projetos que comparam duas ou mais imagem da mesma área em diferentes momentos para avaliar a quantidade de mudança e sua natureza; a fusão de dados e integração em SIG destina-se a combinar diferentes tipos de dados (Ex: *raster* ou *vetorial*) para a mesma área geográfica e normalmente esta

fusão de dados com representação no espaço é processada em ambiente SIG; no tópico de análise análise hiperespectral e(ou) multiespectral não existem procedimentos específicos, associados a uma destas tipologias de uma imagem, pois os procedimentos dependem da finalidade ou objetivo do utilizador. O que importa perceber nesta categoria é que praticamente todos os princípios de processamento de imagem em imagens multiespectrais podem ser estendidos diretamente à análise de dados hiperespectrais. No entanto existem procedimentos específicos para os dados hiperespectrais que pela sua natureza e volume são específicos para os dados hiperespectrais; por fim a modelação biofísica relaciona de forma quantitativa, dados obtidos em deteção remota que tenham uma relação com os fenómenos biofísicos (Ex: estimar o rendimento de culturas, concentração de poluição ou profundidade da água) (Thomas M. Lillesand, Ralph W. Kiefer, 2015).

A subdivisão apresentada acima para ADI, serve apenas como “mapa geral” de procedimentos utilizados. Não significa que não se possa misturar e/ou intercalar diferentes categorias no tratamento dos dados (por exemplo: o processamento de dados pode auxiliar os procedimentos de classificação de solo, e esta mesma classificação pode necessitar de integrar outros tipos de dados para aferir o seu uso, como por exemplo, a funcionalidade de um edifício) ou que a mesma operação não possa estar enquadrada em mais de uma categoria (por exemplo: procedimentos de realce, podem ser considerados apenas procedimentos de realce, mas este mesmo procedimento pode ser utilizado para melhorar a precisão da classificação). Isto significa que na prática, as fronteiras definidas acima não são inflexíveis e como tal, cada categoria deve ser percebida como parte de um “mapa geral” de procedimentos (Thomas M. Lillesand, Ralph W. Kiefer, 2015).

Na presente dissertação, é aplicado um método classificativo por objeto, que utiliza reconhecimento espectral e geométrico, ou seja, híbrido. Por este motivo, das “categorias” de ADI, será aprofundado o tópico “Classificação de imagem” bem como será percebido como se pode avaliar a qualidade de mapeamento de uma imagem, no capítulo “Matriz de erro e precisão temática”.

3.2 CLASSIFICAÇÃO DE IMAGEM

De maneira geral existem, três modelos de reconhecimento de características em imagem, com vista à classificação. O primeiro modelo de reconhecimento, *spectral pattern recognition*, incorpora-se na família de métodos classificativos que utilizam exclusivamente informação espectral para associar, pixéis a classes. O segundo modelo, *spatial pattern recognition*, é bastante diferente, por não incluir informação espectral, mas sim, a relação espacial dos pixéis de acordo com a sua vizinhança. Normalmente classificadores espaciais utilizam textura, proximidade de pixéis, área, forma, direção, repetição e contexto. O terceiro e último modelo, designado de híbrido, é uma combinação de aspetos espectrais e espaciais que é onde se insere a abordagem classificativa por objeto (GEOBIA), pois faz uso tanto de informação espectral como espacial, contudo, importa referir que não existe um método ou abordagem certa ou errada, tudo depende das características ou tipo de dados disponíveis, recursos computacionais disponíveis e o objetivo da classificação. Existindo por isso, um vasto leque de métodos classificativos, que se dividem, pela sua abordagem ao pixel e ao objeto. Normalmente os métodos mais utilizados, encontram-se ao nível do pixel, com tratamento estatístico espectral; são eles os métodos classificativos “supervisionados” e “não supervisionados”, porem existem outros métodos que fazem um uso híbrido e interpretativo²¹.

Em seguida detalharei as principais características referentes às classificações supervisionada e não supervisionada. E como esta dissertação recorre a um método classificativo orientado ao objeto, será dedicada uma explicação mais pormenorizada à este método classificativo (GEOBIA).

3.2.1 Classificação supervisionada

Nos classificadores supervisionados, o utilizador escolhe o classificador ou algoritmo computacional, bem como a descrição das classes através de uma seleção consciente de amostras (*training areas/ region of interest (ROI)*) que servem de referência para os restantes pixéis, que serão classificados por semelhança. Ou seja, a

²¹ Ex: *Artificial Neural Networks*

classificação supervisionada pode ser entendida como um processo onde o utilizador seleciona pixéis dos quais conhece a identidade para classificar pixéis dos quais não conhece a identidade. As vantagens dos classificadores supervisionados em relação aos não supervisionados decorrem do momento de seleção de amostras; primeiro o utilizador tem como controlar o número de classes a serem extraídas para uma determinada área; segundo, a seleção das amostras na classificação supervisionada está localizada em áreas específicas, conhecidas pelo utilizador; terceiro, o utilizador não terá problemas em compatibilizar as categorias espectrais que existam na imagem com temas específicos para o mapa, pois em princípio, a seleção de amostras já terá tido em consideração os temas, pré definidos, a serem classificados; quarto, é possível detetar deficiências na classificação, analisando as amostras, contudo é preciso ter em mente que, ter uma boa seleção de áreas de treino não é sinónimo de uma classificação de qualidade. Olhando para as desvantagens e limitações dos classificadores supervisionados, existem várias, a primeira deriva dos utilizadores imporem uma estrutura de classificação nos dados, inerente ao classificador, que não vai operar por classes “naturais” (*Nota: os classificadores não supervisionados operam por classes “naturais”*) e isso pode ser um constrangimento para classificar diferentes áreas e em diferentes momentos com os mesmos critérios; a segunda, é o nível de detalhe por categoria ou tema, isto porque e a título de exemplo, para uma área florestal, podem existir áreas de floresta mais jovem, mais densa... e se o utilizador tiver por objetivo distinções pormenorizadas por classe, a precisão pode ser baixa; terceira, as amostras selecionadas podem não representar a imagem como um todo, se esta for extensa, complexa e inacessível. Em quarto lugar, a seleção cuidada e consciente de amostras pode ser demorada, cara e aborrecida. Por último, a classificação supervisionada pode não ser capaz de reconhecer e representar os temas não representados nas amostras, possivelmente por não serem conhecidos pelo analista ou por ocuparem áreas muito pequenas (James B. Campbell, 2011).

3.2.2 Classificação não supervisionada

Nos classificadores não supervisionados, o processo de classificação difere dos classificadores supervisionados, por não serem selecionadas amostras (*training areas/region of interest (ROI)*) de forma manual. O utilizador escolhe um classificador ou

algoritmo computacional, que agrupa em *clusters* os pixéis da imagem e aos quais é atribuída normalmente uma denominação própria de acordo com a legenda pretendida. Ou seja, a classificação não supervisionada pode ser entendida como a identificação de grupos naturais ou estruturas contidas nos dados. As vantagens dos classificadores não supervisionados, relativos aos classificadores supervisionados decorrem em primeiro lugar, da não necessidade de conhecimentos específicos sob a área em estudo, contudo, ainda que não seja necessário conhecimento específico, deve-se possuir algum tipo de conhecimento da área, como forma de interpretar o resultado da classificação. A segunda vantagem está na minimização do erro humano, pois o utilizador no máximo define o número de classes a serem extraídas e pode impor algumas restrições que balizem a distinção ou uniformidade de grupos. Por último existe o reconhecimento de classes, independente da sua extensão, pois na classificação supervisionada as classes que se circunscrevem a pequenas áreas e sem se repetirem em diferentes pontos da imagem podem passar despercebidas. As desvantagens e limitações dos classificadores não supervisionados resultam dos próprios agrupamentos ou *clusters* “naturais”, que podem não se coadunar com as classes de interesse do utilizador e com isto existir a dificuldade de combinar as classes espectrais extraídas com a nomenclatura pretendida. Outra limitação prende-se com a reduzida influência na classificação, que é uma condição antagónica às classificações supervisionadas. Por fim, existe o problema da sazonalidade espectral, onde para diferentes datas existem propriedades espectrais que se alteram, tornando a relação entre temas e informação espectral instável e consequentemente as definições inseridas em um classificador, para uma classificação, não podem ser padronizadas para outras imagens em diferentes momentos (James B. CampBell, 2011).

3.2.3 Classificação híbrida

Nos classificadores supervisionados e não supervisionados a principal diferença está na (não)seleção de áreas de treino. Estes tipos de abordagens mostram-se úteis em classificar áreas onde a variação espectral garante uma boa precisão e são, portanto, classificadores que levam o reconhecimento espectral como o único elemento no processo classificativo. Os modelos híbridos, reconhecem a informação espectral e espacial, não significando isto que a informação espectral não seja a unidade

fundamental de informação; apenas elementos adicionais, como o contexto, forma, área e textura são adicionados à equação para auxiliar e automatizar processos classificativos (Ex: na distinção de uma área urbana horizontal e vertical, onde a textura é variável determinante); e é nesta categoria que insere a GEOBIA.

3.3 PRECISÃO TEMÁTICA E MATRIZ DE ERRO

Uma classificação raramente é perfeita, seja pela seleção de amostras, seja pela fraca estratégia classificativa. A precisão temática serve para avaliar os temas ou classes mapeados (classificação de utilizador) em comparação com a real ocupação e uso de solo num determinado momento (classificação de referência) (Gupta, 2017). Valores altos de precisão temática indicam uma qualidade elevada no mapeamento e vice-versa. Como método que compare a classificação do utilizador com a classificação de referência, serve a criação de uma matriz de erro. A matriz de erro consiste numa grelha, onde no *eixo Y* estão representados os temas pertencentes a classificação de referência e no *eixo X* estão representadas as classes temáticas referentes ao utilizador. Nesta matriz as células têm representadas unidades de classe (ex: número de pixéis ou área) e uma vez gerada a matriz de erro o utilizador pode calcular e ter acesso as métricas de controlo de qualidade, como a precisão global, percentagem de erro; erro de omissão, erros de comissão; precisão no produtor e precisão no utilizador²² (Figura 18) (Ross S. Lunetta, 2004). A precisão global mostra a percentagem da classificação do utilizados que corresponde a classificação de referência, o seu valor varia entre 0 e 1 (0% e 100%), sendo que valores mais elevados representam maior precisão classificativa; a percentagem de erro representa o total de área incorretamente classificada pelo utilizador; o erro de omissão representa, por tema, as áreas ou pixéis incorretamente classificados de forma passiva e que deveriam integrar a classe; o erros de comissão diz respeito, por tema, as áreas ou pixéis incorretamente classificados de forma ativa pelo utilizador e que não deveriam integrar a classe; a precisão no produtor compara, por classe, as áreas corretamente classificadas e o seu peso representativo no mapa de referência; por último a precisão no utilizador compara, por classe, as áreas corretamente classificadas e o seu peso representativo no mapa de utilizador.

²² Fonte: http://gis.humboldt.edu/OLM/Courses/GSP_216_Online/lesson6-2/metrics.html

		Reference Data				Row total	Land Cover Categories
		D	C	AG	SB		
Classified Data	D	63	4	22	24	113	D = deciduous
	C	6	79	8	8	101	C = conifer
	AG	0	11	85	11	107	AG = agriculture
	SB	4	7	3	89	103	SB = shrub
Column total		73	101	118	132	424	OVERALL ACCURACY = (63 + 79 + 85 + 89)/424 = 316/424 = 75%

PRODUCER S ACCURACY		USER S ACCURACY	
D = 63/73 = 86%		D = 63/113 = 56%	
C = 79/101 = 78%		C = 79/101 = 78%	
AG = 85/118 = 72%		AG = 85/107 = 79%	
SB = 89/132 = 67%		SB = 89/103 = 86%	

Figura 18 - Exemplo de matriz de erro. Fonte: Ross S. Lunetta (2004).

A matriz de erro é um método universalmente aceite na avaliação de qualidade temática. É interessante perceber que a matriz acima representada, é do tipo *site-specific assessment* (avaliação temática tendo em consideração a localização áreas temáticas), que foi uma evolução das avaliações *non-site-specific accuracy assessment* (leva em conta a avaliação global, sem considerar a localização espacial dos temas). Este foi um importante avanço, pois numa comparação entre uma classificação de referência e duas classificações levadas a cabo por diferentes classificadores ou utilizadores, numa avaliação *non-site-specific*, a avaliação ao levar apenas em conta a área ou pixéis extraídos em relação a classificação de referência, não aponta qual a real precisão temática, pois não demonstra no espaço se existe concordância entre as classificações de utilizador e a classificação de referência, por exemplo, supondo que uma classificação de referência tenha identificado para o tema “Floresta” = 10ha, e para o mesmo tema o “Classificador ou utilizador A” tenha identificado 10ha e o “Classificador ou utilizador B” tenha identificado 9ha, supostamente pelo a abordagem *non-site-specific accuracy assessment* a maior precisão global pertence ao “Classificador ou utilizador A”, contudo se 5 desses hectares, não obtiverem concordância geográfica e o “Classificador ou utilizador B” tiver os 9ha em concordância geográfica, a sua precisão passa a ser superior. Com isto a abordagem *site-specific assessment* demonstra o porquê de ser um importante avanço na avaliação do mapeamento (Congalton & Green, 2019).

CAPÍTULO IV - GEOGRAPHIC OBJECT-BASED IMAGE ANALYSIS (GEOBIA)

4.1 DO QUE SE TRATA?

Os termos OBIA e GEOBIA, são a abreviatura para *Object-based Image Analysis* (Análise de Imagens Baseada em Objetos) e *Geographic Object-Based Image Analysis* (Análise de Imagens Baseada em Objetos Geográficos). Esta é a área de estudo em detecção de remota que estuda fenômenos, através da segmentação e análise de objetos em imagem ou invés de pixéis. Este tipo de abordagem pode ser considerado um aprimoramento na classificação de imagens, pixel por pixel, onde se combinam vários parâmetros de análise para determinar, por exemplo, diferentes tipos de cobertura de solo (estradas, edifícios, vegetação, superfícies aquáticas...). Neste tipo de classificação podem ser cruzados vários tipos de dados como: Radiométricos, DEM, DSM, LiDAR...; avaliar similaridades geométricas, contexto, cor e textura. Sendo no final possível atribuir diferentes importâncias ou pesos a cada uma das características e *layer* para obter uma classificação (Chen, Weng, Hay, & He, 2018).

Em GEOBIA o objeto de estudo é a superfície terrestre e neste estudo o que realmente se almeja é usar os dados de observação da terra para delinear e explorar a diferentes escalas as relações espaciais dos objetos e com informações auxiliares, enquanto modeladoras desses mesmos objetos geográficos e adquirir novos *insight* do planeta e suas funções. Posto isto, e tendo em conta o objetivo de estudo descrito acima, podemos dizer que o termo que melhor descreve o significado de GEOBIA é o de “Inteligência Geográfica”.(Blaschke, Thomas; Lang, Stefan; Hay, 2008)

4.2 GEOBIA ENQUANTO “INTELIGÊNCIA GEOGRÁFICA” E NÃO “INTELIGÊNCIA GEOESPACIAL”

Para evitar confusões, importa distinguir dois termos, o de “inteligência geográfica” e o de “inteligência geoespacial” que por serem parecidos, podem incorretamente ser associados de forma igual a GEOBIA. A inteligência geoespacial (GEOINT) é de acordo com Governo dos Estados Unidos em *U.S. Code Title 10, §467*

(GPO, 2006)²³: *“A Inteligência Geoespacial é conhecimento acionável, um processo e uma profissão. É a capacidade para descrever, compreender e interpretar para antecipar o impacto nos humanos, de um evento ou ação, num contexto espaço-tempo. É igualmente, a capacidade para identificar, recolher, armazenar e manipular dados para criar conhecimento geoespacial por intermédio de pensamento crítico, de raciocínio geoespacial e de técnicas analíticas. Por fim, é a capacidade de expor o conhecimento numa forma apropriada ao ambiente de tomada de decisão”.*

A GEOBIA tem por base o estudo da superfície da terra, que é um sistema complexo, e pode ser representado por vários objetos, a diferentes escalas e em diversos tipos de dados, onde cada um deles pode mudar de acordo com a escala de interpretação. Posto isto e recuperando o enquadramento anteriormente dado a GEOBIA, como inteligência geográfica, esta recorre os dados de observação terrestre para delinear e explorar a diferentes escalas as relações espaciais entre objetos devidamente definidos, em conjunto com informações auxiliares enquanto modeladoras destes objetos geográficos, como forma de adquirir novos insight do planeta e suas funções.

É possível dizer que o que caracteriza “inteligência geoespacial” e “inteligência geográfica”, é no primeiro caso a coordenação e capacidade de processar e interligar um leque de diferentes áreas de estudo (Figura 19), de forma repetida, transparente e ainda a serem representadas espacialmente (Doty, 2005). Enquanto a inteligência geográfica, onde a GEOBIA se insere, lida com o desafio de delinear e explorar a diferentes escalas a relação espacial de objetos em imagens, como forma de entender o sistema e/ou padrões terrestres.

²³ Fonte: <https://www.e-education.psu.edu/geointmooc/node/1989>

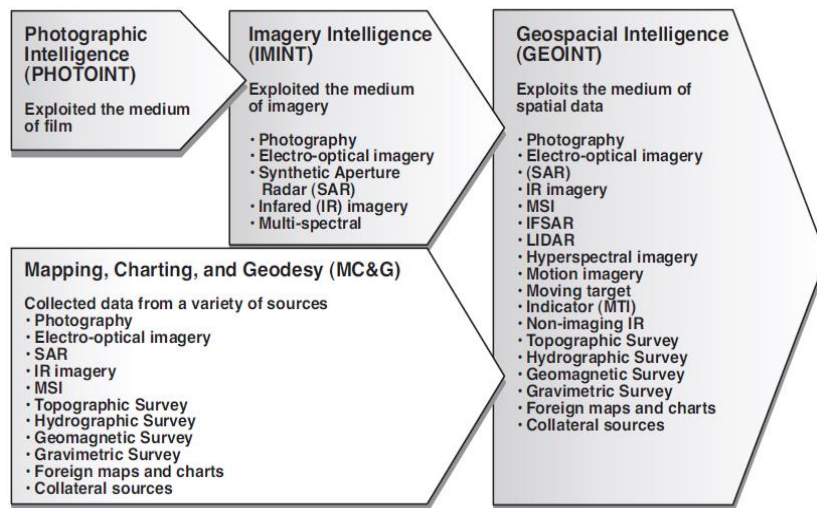


Figura 19 - A fundação e evolução da Inteligência Geoespacial. Fonte: Doty, (2005)

4.3 GEOBIA EM ANÁLISE DIGITAL DE IMAGEM

Relembrando, existem dois modelos de reconhecimento de características em imagem, o reconhecimento espectral e espacial, onde a sua articulação num modelo híbrido é onde se insere a GEOBIA. Existem algoritmos que servem o propósito de avaliar e classificar imagens, que podem ser do tipo supervisionado ou não supervisionado, porém, quando se processam formas de reconhecimento espectral e espacial no mesmo processo classificativo, o método classificativo também se denomina como híbrido. Nos procedimentos de classificação ao nível do pixel, como visto anteriormente, recorre-se exclusivamente a algoritmos que avaliam a informação espectral, expressa em níveis digitais (ND). Já nos procedimentos de classificação orientada ao objeto, existem dois momentos chave: em primeiro lugar a segmentação de objetos e depois a classificação dos mesmos, onde o objetivo é classificar uma imagem, tendo por base um conjunto de áreas homogêneas que sejam constituídas por mais de um pixel²⁴.

A escala é um elemento fundamental, na segmentação de objetos. A título de exemplo, numa floresta, a uma escala de segmentação mais fina, podem ser identificadas árvores de forma individual; numa escala intermédia podem ser segmentados objetos que representem diferentes culturas ou porções de árvores; e a

²⁴ – “An image object is a group of pixels in a map”. (Trimble Germany, 2014b)

uma grande escala, a segmentação pode gerar objetos que representem florestas. Nos procedimentos o utilizador define os critérios que controlam a homogeneidade dos objetos. Um critério chave é o *scale parameter* (tolerância a diferentes ND), que determina a dimensão dos objetos e varia de acordo com a legenda e a resolução espacial dos dados. Estas regiões geradas na segmentação são os objetos, a que se refere o método classificativo por “objetos”. Como os objetos são formados por muitos píxeis, contem diversos indicadores e características que só são possíveis encontrar e avaliar neste tipo de abordagem, desde as suas características intrínsecas (textura, forma, valor espectral, desvio padrão) até outras características de relação espacial (proximidade, contiguidade e contexto) (Figura 20). A classificação por objeto, preserva ainda uma relação de parentalidade “*parent-child*” entre os objetos, que facilita o monitoramento no uso do solo (exemplo, se uma área homogénea, em datas posteriores apresentar novos recortes, pode-se estabelecer uma relação “*parent-child*” a ser confirmada por uma análise posterior) (Thomas M. Lillesand, Ralph W. Kiefer, 2015). A segunda parte do processo é a classificação, que pode acontecer com o uso de procedimentos convencionais, como classificação por *nearest-neighbor* ou *fuzzy*; ou atribuindo a cada objeto, ou pequenas malhas dos mesmos um tema ou classe, através da identificação de características singulares, que os possam associar a um dos temas na legenda que se pretenda atingir.




Figura 20 - Estrutura tradicional de trabalho em GEOBIA. Fonte: Chen, Weng, Hay, & He (2018)

4.4 SEGMENTAÇÃO E CLASSIFICAÇÃO DE DADOS OBTIDOS POR DETECÇÃO REMOTA: A BASE DA ALGORITMIA ECOGNITION

O *software* de referência para aplicar técnicas de classificação por objeto é o *eCognition*, mais especificamente o *eCognition Developer* que conta com um vasto leque

de ferramentas para os processos de segmentação e classificação, permitindo testar e comparar os métodos e ferramentas que mais se adequem ao objetivo do utilizador. Como *eCognition Developer* foi o *software* utilizado nesta dissertação, será feita uma revisão das suas potencialidades enquanto auxiliar no processo classificativo ao objeto.

4.4.1 Segmentação

Geralmente, o termo segmentação significa subdividir entidades, como objetos, em porções menores. No *eCognition Developer*, o termo é utilizado de forma diferente: segmentação é qualquer operação que cria objetos ou altera a morfologia dos objetos existentes de acordo com critérios específicos. Isso significa, que como segmentação, estão incluídas operações de subdivisão, junção (*merging*) ou remodelagem (*reshaping*). Neste sentido o *eCognition Developer* na segmentação dos dados segue uma de duas lógicas: 1) *Top-down Segmentation*; 2) *Bottom-up segmentation*. A lógica *Top-down Segmentation* significa dividir objetos em objetos menores e *Bottom-up segmentation* significa unir objetos para criar objetos maiores (Trimble Germany, 2014b).

A segmentação é gerada a partir de algoritmos, que podem atuar ao nível do pixel e ao nível do objeto, quando uma imagem é segmentada, por não conter objetos previamente identificados, obriga a uma primeira segmentação ao nível do pixel e só em seguida, caso o utilizador considere necessário, são segmentados novos objetos a partir dos objetos previamente segmentados, o que significa que o mesmo algoritmo utilizado na primeira fase de segmentação, ao nível do pixel, pode ser utilizado novamente mais tarde ao nível do objeto. A escolha do algoritmo de segmentação pode variar de acordo com o(s) objeto(s) alvo, a título de exemplo, nesta dissertação foram testados três algoritmos de segmentação: o *Multiresolution Segmentation*, *Quadtree-Based Segmentation* e *Segmentation by Reshaping Algorithms*. Destes algoritmos o *Quadtree-Based Segmentation* segue uma lógica *Top-down* e o *Multiresolution Segmentation* e o *Segmentation by Reshaping Algorithms* seguem uma lógica *Bottom-up*. A lógica na escolha destes algoritmos teve, no caso do *Quadtree-Based Segmentation* a noção de que o município de Almada é predominantemente urbano, e com esta informação se deduzir que áreas de ocupação humana (ex: zonas habitacionais) apresentem formatos retangulares ou quadrados e por este algoritmo segmentar a imagem em quadrados de diferentes dimensões (de acordo com o nível de homogeneidade), se posicionar como

um potencial algoritmo de segmentação a ser utilizado²⁵. A escolha do *Multiresolution Segmentation* aconteceu por este não apresentar limitações geométricas na sua segmentação e ter como único critério de segmentação a homogeneidade de objetos ou pixels vizinhos. Por últimos a escolha do *Segmentation by Reshaping Algorithms* surge pela viabilidade em remodelar e harmonizar o formato dos objetos (ex: suavizar arestas), bem como permitir expandir ou retrair a área de uma classe, através de operações de *grow*, *shrink* e *merge*. Na Figura 21 esta representada a diferença entre uma segmentação a partir dos algoritmos de *Quadtree-Based Segmentation* e *Multiresolution Segmentation* e na Figura 22 alguns exemplos de como o uso de ferramentas de remodelagem, podem atuar nos objetos.



Figura 21 - Algoritmos de segmentação, Quadtree-Based Segmentation e Multiresolution Segmentation. Fonte: Trimble Germany, 2014.

²⁵ Apesar de testado, o algoritmo *Quadtree-Based Segmentation* não foi utilizado, por não se ter mostrados eficaz na segmentação de dados Sentinel 2 MSI. A sua ineficácia deveu-se à necessidade de uma maior resolução espacial.

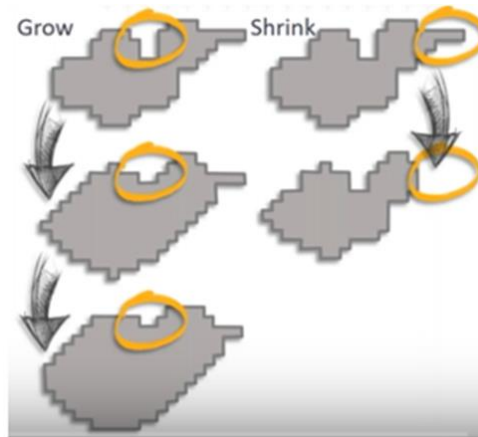


Figura 22 - Uso de ferramentas de remodelagem em objetos. Fonte: eCognition Webinar: Image Object Refinement Techniques.

4.4.2 Classificação

A classificação baseada em objetos recorre tradicionalmente a valores espectrais, geometria, contexto, textura e cor, após segmentações não supervisionadas (Chen et al., 2018). As características dos objetos no *eCognition Developer* podem ser lidas pós processo de segmentação e diversos tipos de classificadores podem ser aplicados, desde os mais simples algoritmos de classificação como o “*Assign Class*” onde são determinados limiares (*threshold*) para determinar a que classe ou tema de imagem um objeto pertence, até aos mais avançados como “*Membership Functions for Classification*” que permite definir a afinidade de um objeto a um tema de acordo com as características que compõem uma classe, usando uma lógica *fuzzy*. Para além dos classificadores mais “básicos”, outras opções surgem com a aplicação de classificadores supervisionados baseados em valores estatísticos, como o classificador de *Bayes*; *KNN* (*K Nearest Neighbor*); *SVM* (*Support Vector Machine*); *Decision Tree* ou *Random Trees*.(Ma et al., 2017; Trimble Germany, 2014b). Todos estes classificadores são executados após a segmentação. Nos classificadores mais simples o utilizador tem o poder de controlar o processo classificativo “passo a passo”, onde cada tema tem de forma supervisionada um *script* (conjunto de operações estruturadas e personalizadas de acordo com o tipo de dados e legenda em vista), já os classificadores supervisionados baseados em valores estatísticos têm implícita a associação de objetos a classes de

forma automatizada, sem ser necessária a extração personalizada objeto a objeto pelo utilizador.

A opção de classificação para dissertação foi de classificação supervisionada ao objeto, sem recurso a classificadores estatísticos, ou seja, foi organizada uma sequência de procedimentos, onde foram atribuídas classes aos objetos de acordo com características detetadas e atribuídas pelo utilizador.

CAPÍTULO V -METODOLOGIA E MATERIAIS

5.1 METODOLOGIA

A abordagem metodológica recorre a um método de classificação e análise de dados orbitais baseado em *Geographic Object-Based Image Analysis* (GEOBIA) para automatizar alguns processos na produção de uma carta de uso e ocupação do solo para o município de Almada, com base na nomenclatura da CORINE Land Cover (CLC). O material que suportou a experimentação dos métodos e técnicas foram os dados orbitais, de acesso livre, disponibilizados através da plataforma de dados abertos da Agência Espacial Europeia (ESA), *Copernicus Open Access Hub* bem como o principal *software* utilizado: *eCognition Developer 9.0*, *ArcMap 10.6* e *SNAP*.

5.2 ÁREA DE ESTUDO

A área geográfica escolhida para experimentação de técnicas de GEOBIA é o concelho de Almada (Figura 23). Esta escolha decorre do facto de constituir uma área geográfica muito diversificada do ponto de vista do uso do solo, apesar da extensa e dominante ocupação urbana. A experimentação do método é tão mais rica quanto maior for a diversificação de uso do solo referida, na medida em que garante, também, o teste às medições de estado de superfície (índices de vegetação e de água, por exemplo).

O território de Almada integra 11 freguesias com uma área total de 71 km² e situa-se na margem esquerda do rio Tejo, fazendo fronteira com o concelho do Seixal a Este e com o concelho de Sesimbra a Sul²⁶.



Figura 23 - Enquadramento da área de estudo.

²⁶ <http://www.m-almada.pt/xportal/xmain?xid=cmav2>

5.3 AQUISIÇÃO DE DADOS

Os dados utilizados foram extraídos com recurso à plataforma de dados abertos da Agência Espacial Europeia (ESA), a partir dos mais recentes registos do satélite Sentinel-2 MSI, que podem ser descarregados de forma livre e gratuita, estando permanentemente em atualização. Os dados foram descarregados da *Copernicus Open Access Hub* e os critérios que suportaram a decisão na obtenção dos mesmos, foram: (a) a data, que deve ser a mais recente possível e (b) a cobertura de nuvens, que deve ser equivalente a 0%. Para cumprir estes parâmetros foi utilizado o *software* SNAP e à data da pesquisa (11 de outubro de 2019) os dados Sentinel-2 MSI, para a área do município de Almada que cumpriram os critérios descritos acima são “S2B_MSIL1C_20191010T113319_N0208_R080_T29SMC_20191010T132921.SAFE”

Quando é descarregada a imagem de Sentinel-2 MSI, esta encontra-se estruturada numa matriz de colunas e linhas, onde nas suas interseções se encontra o pixel, como unidade mínima portadora de informação, o valor radiométrico ou nível digital. E relembrando, a abordagem a objetos (GEOBIA) mede não apenas a informação expressa em níveis digitais (ND), mas também, a forma, contexto e textura. Sendo necessário definir critérios que agrupem os pixels que partilhem as mesmas características e assim gerar os agrupamentos denominados como objetos de imagem – “*An image object is a group of pixels in a map*”. (Trimble Germany, 2014b)

5.4 SOBRE O SENTINEL-2 MSI

Sentinel-2 é o nome da missão dentro do programa GMES (*Global Monitoring for Environment and Security*), implementado em conjunto pela EC (*European Commission*) e ESA (*European Space Agency*) para observação da terra (com dados sobre vegetação, cobertura do solo e da água, além de fornecer correções nos dados de absorção e distorção atmosférica).²⁷ O Sentinel-2 é composto por dois satélites, Sentinel-2A e Sentinel-2B (S2A e S2B), o primeiro foi lançado a 23 de Junho de 2015 e o segundo a 07 de março de 2017 e encontram-se a uma altitude de 786 km, equipados com instrumentos de MSI (*Multi-Spectral Instrument*), a resolução temporal combinada dos

²⁷<https://directory.eoportal.org/web/eoportal/satellite-missions/c-missions/copernicus-sentinel-2#sensors>

satélites é de 5 dias, mas de cada satélite individualmente é de 10^{28} (ESA, 2015). Os produtos oferecidos pelo Sentinel-2 MSI aos utilizadores estão divididos em dois níveis, “Level-1C; Level-2A”. O nível 1C inclui correções radiométricas e geométricas, ortorectificação e registo espacial num sistema de referência global com precisão ao sub-pixel. O nível 2A, fornece imagens de refletância *Bottom Of Atmosphere* (BOA) derivadas dos produtos associados ao nível-1C. Portanto, cada produto de nível-2A é composto de 100 km² de azulejos em geometria cartográfica (projeção UTM / WGS84). (SUHET, 2013)

O MSI é um telescópio do tipo *Three Mirror Anastigmat* (TMA) com uma lente de 150 mm que captura numa sequência linear imagens na dimensão de 290 km de FOV (*Field of View*) e representa a informação numa resolução radiométrica de 12 bits, ou seja, a energia radiante da terra é codificada em 4096 DN (*Digital Numbers*) por 13 bandas espectrais, 10 delas dentro do espectro do visível/infravermelho próximo (VNIR) e 3 dentro do infravermelho médio (SWIR). A energia radiante da terra, quando chega ao sensor é separada (*split*) através de um divisor dicróico (Figura 25), que vai separar a energia VNIR e SWIR em direções diferentes e por fim a filtragem espectral nas diferentes bandas espectrais VNIR e SWIR é garantida por filtros próprios para esse efeito (Figura 24) (Cazaubiel, Chorvalli, & Miesch, 2017). Por fim, as bandas espectrais geradas têm características próprias quanto à resolução espacial, comprimento de onda e largura de banda espectral (Quadro 1) e encontram-se distribuídas no espectro do visível (VIS), próximo infravermelho (NIR) e infravermelho médio (SWIR) (Figura 26) (ESA, 2015).




Figura 25 - Telescópio do tipo Three-Mirror Anastigmatic (TMA). Fonte: Cazaubiel, Chorvalli, & Miesch (2017)



Figura 24 - Filtros espectrais para VNIR e SWIR. Fonte: Cazaubiel, Chorvalli, & Miesch (2017)

²⁸ <https://earth.esa.int/web/guest/missions/esa-operational-eo-missions/sentinel-2>

		Sentinel-2				
Banda espectral	Número de bandas	S2A		S2B		Resolução espacial (m)
		Comprimento de onda central (nm)	Largura de Banda (nm)	Comprimento de onda central (nm)	Largura de Banda (nm)	
Coastal/Aerosol	1	443.9	27	442.3	45	60
Blue	2	496.6	98	492.1	98	10
Green	3	560.0	45	559	46	10
Red	4	664.5	38	665	39	10
Red edge	5	703.9	19	703.8	20	20
Red edge	6	740.2	18	739.1	18	20
Red edge	7	782.5	28	779.7	28	20
NIR	8	835.1	145	833	133	10
Red edge	8a	864.8	33	864	32	20
Water Vapor	9	945.0	26	943.2	27	60
Cirrus	10	1373.5	75	1376.9	76	60
SWIR 1	11	1613.7	143	1610.4	141	20
SWIR 2	12	2202.4	242	2185.7	238	20

Quadro 1- Características espectrais e espaciais do Sentinel-2 MSI.




Figura 26 - Bandas espectrais do Sentinel-2 MSI e resolução espacial. Fonte: ESA (2015)

5.5 NOMENCLATURA CLC E COS

No terceiro capítulo desta dissertação está explicado no que consistem as cartas CLC e COS. A legenda CLC (Quadro 2) vai servir para classificar os tipos de uso e ocupação de solo do município de Almada e a legenda COS (Quadro 3 e Quadro 4) irá ser adaptada à legenda CLC, para elaborar uma matriz de erro. A escolha da adaptação deve-se ao facto da legenda COS ser inspirada na legenda CLC, com a vantagem de ter uma unidade mínima cartográfica (UMC) de 1ha e a legenda CLC ter uma UMC de 25ha. Os detalhes

de como foi feita a adaptação seguem-se no capítulo “7.3 PRODUÇÃO DA “MATRIZ DE ERRO”.

Nível 1	Nível 2	Nível 3
1 Territórios artificializados	1.1 Tecido urbano	1.1.1 Tecido urbano contínuo 1.1.2 Tecido urbano descontínuo
	1.2 Indústria, comércio e transportes	1.2.1 Indústria, comércio e equipamentos gerais 1.2.2 Redes viárias e ferroviárias e espaços associados 1.2.3 Áreas portuárias 1.2.4 Aeroportos e aeródromos
	1.3 Áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção	1.3.1 Áreas de extração de inertes 1.3.2 Áreas de deposição de resíduos 1.3.3 Áreas em construção
	1.4 Espaços verdes urbanos, equipamentos desportivos, culturais e de lazer, e zonas históricas	1.4.1 Espaços verdes urbanos 1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas
2 Áreas agrícolas e agroflorestais	2.1 Culturas temporárias	2.1.1 Culturas temporárias de sequeiro 2.1.2 Culturas temporárias de regadio 2.1.3 Arrozaís
	2.2 Culturas permanentes	2.2.1 Vinhas 2.2.2 Pomares 2.2.3 Olivais
	2.3 Pastagens permanentes	2.3.1 Pastagens permanentes
	2.4 Áreas agrícolas heterogéneas	2.4.1 Culturas temporárias e/ou pastagens associadas a culturas permanentes 2.4.2 Sistemas culturais e parcelares complexos 2.4.3 Agricultura com espaços naturais e semi-naturais 2.4.4 Sistemas agro-florestais (SAF)
3 Florestas e meios naturais e semi-naturais	3.1 Florestas	3.1.1 Florestas de folhosas 3.1.2 Florestas de resinosas 3.1.3 Florestas mistas
	3.2 Florestas abertas e vegetação arbustiva e herbácea	3.2.1 Vegetação herbácea natural 3.2.2 Matos 3.2.3 Vegetação esclerófita 3.2.4 Florestas abertas, cortes e novas plantações
	3.3 Zonas descobertas e com pouca vegetação	3.3.1 Praias, dunas e areais 3.3.2 Rocha nua 3.3.3 Vegetação esparsa 3.3.4 Áreas ardidas 3.3.5 Glaciares e neve permanente
4 Zonas húmidas	4.1 Zonas húmidas interiores	4.1.1 Paúis 4.1.2 Turfeiras
	4.2 Zonas húmidas litorais	4.2.1 Sapais 4.2.2 Salinas e aquicultura litoral 4.2.3 Zonas entre-marés
5 Corpos de água	5.1 Águas interiores	5.1.1 Cursos de água 5.1.2 Planos de água
	5.2 Águas marinhas e costeiras	5.2.1 Lagoas costeiras 5.2.2 Desembocaduras fluviais 5.2.3 Oceano

Quadro 2 - Legenda CORINE Land Cover. Fonte: Direção Geral do Território (2010); Fonte: copernicus.eu

Nível 1	Nível 2	Nível 3
1 Territórios artificializados	1.1 Tecido urbano	1.1.1 Tecido edificado contínuo
		1.1.2 Tecido edificado descontínuo
		1.1.3 Espaços vazios em tecido edificado
	1.2 Indústria, comércio e instalações agrícolas	1.2.1 Indústria
		1.2.2 Comércio
		1.2.3 Instalações agrícolas
	1.3 Infraestruturas	1.3.1 Infraestruturas de produção de energia
	1.4 Transportes	1.3.2 Infraestruturas de águas e tratamento de resíduos
1.4.1 Redes viárias e ferroviárias e espaços associados		
1.4.2 Áreas portuárias		
1.5 Áreas de extração de inertes, áreas de deposição de resíduos e estaleiros de construção	1.4.3 Aeroportos e aeródromos	
	1.5.1 Áreas de extração de inertes	
	1.5.2 Áreas de deposição de resíduos	
1.6 Equipamentos deposição de resíduos e estaleiros de construção	1.5.3 Áreas em construção	
	1.6.1 Equipamentos desportivos	
	1.6.2 Equipamentos de lazer e parques de campismo	
	1.6.3 Equipamentos culturais	
	1.6.4 Cemitérios	
1.7 Parques e jardins	1.6.5 Outros equipamentos e instalações turísticas	
	1.7.1 Parques e jardins	
2 Agricultura	2.1 Culturas temporárias	2.1.1 Culturas temporárias de sequeiro e regadio e arrozais
	2.2 Culturas permanentes	2.2.1 Vinhas
		2.2.2 Pomares
		2.2.3 Olivais
2.3 Áreas agrícolas heterogéneas	2.3.1 Culturas temporárias e/ou pastagens melhoradas associadas a culturas permanentes	
	2.3.2 Mosaicos culturais e parcelares complexos	
	2.3.3 Agricultura com espaços naturais e seminaturais	
2.4 Agricultura protegida e viveiros	2.4.1 Agricultura protegida e viveiros	
3.Pastagens	3.1 Pastagens	3.1.1 Pastagens melhoradas
4.Superfícies agrofloretais (SAF)	4.1 Superfícies agrofloretais (SAF)	3.1.2 Pastagens espontâneas
		4.1.1 Superfícies agrofloretais (SAF)
5.Florestas	5.1 Florestas	5.1.1 Florestas de folhosas
		5.1.2 Florestas de resinosas
6.Matos	6.1 Matos	6.1.1 Matos
7. Espaços descobertos ou com pouca vegetação	7.1 Espaços descobertos ou com pouca vegetação	7.1.1 Praias, dunas e areais
		7.1.2 Rocha nua
		7.1.3 Vegetação esparsa
8.Zonas húmidas	8.1 Zonas húmidas	8.1.1 Zonas húmidas interiores
		8.1.2 Zonas húmidas litorais
9.Massas de água superficiais	9.1 Massas de água interiores	9.1.1 Cursos de água
		9.1.2 Planos de água
	9.2 Aquicultura	9.2.1 Aquicultura
	9.3 Massas de água de transição e costeiras	9.3.1 Salinas
		9.3.2 Lagoas costeiras
9.3.3 Desembocaduras fluviais		
		9.3.4 Oceano

Quadro 3 – 1º parte da Legenda da Carta de Uso e Ocupação do Solo (COS). Fonte: Direção-Geral do Território (2019)

Nível 4

1.1.1.1 Tecido edificado contínuo predominantemente vertical
1.1.1.2 Tecido edificado contínuo predominantemente horizontal
1.1.2.1 Tecido edificado descontínuo
1.1.2.2 Tecido edificado descontínuo esparso
1.1.3.1 Áreas de estacionamento e logradouros
1.1.3.2 Espaços vazios sem construção
1.2.1.1 Indústria
1.2.2.1 Comércio
1.2.3.1 Instalações agrícolas
1.3.1.1 Infraestruturas de produção de energia renovável
1.3.1.2 Infraestruturas de produção de energia não renovável
1.3.2.1 Infraestruturas para captação, tratamento e abastecimento de águas para consumo
1.3.2.2 Infraestruturas de tratamento de resíduos e águas residuais
1.4.1.1 Rede viária e espaços associados
1.4.1.2 Rede ferroviária e espaços associados
1.4.2.1 Terminais portuários de mar e de rio
1.4.2.2 Estaleiros navais e docas secas
1.4.2.3 Marinas e docas pesca
1.4.3.1 Aeroportos
1.4.3.2 Aeródromos
1.5.1.1 Minas a céu aberto
1.5.1.2 Pedreiras
1.5.2.1 Aterros
1.5.2.2 Lixeiras e Sucatas
1.5.3.1 Áreas em construção
1.6.1.1 Campos de golfe
1.6.1.2 Instalações desportivas
1.6.2.1 Parques de campismo
1.6.2.2 Equipamentos de lazer
1.6.3.1 Equipamentos culturais
1.6.4.1 Cemitérios
1.6.5.1 Outros equipamentos e instalações turísticas
1.7.1.1 Parques e jardins
2.1.1.1 Culturas temporárias de sequeiro e regadio
2.1.1.2 Arrozaís
2.2.1.1 Vinhas
2.2.2.1 Pomares
2.2.3.1 Olivais
2.3.1.1 Culturas temporárias e/ou pastagens melhoradas associadas a vinha
2.3.1.2 Culturas temporárias e/ou pastagens melhoradas associadas a pomar
2.3.1.3 Culturas temporárias e/ou pastagens melhoradas associadas a olival
2.3.2.1 Mosaicos culturais e parcelares complexos
2.3.3.1 Agricultura com espaços naturais e seminaturais
2.4.1.1 Agricultura protegida e viveiros
3.1.1.1 Pastagens melhoradas
3.1.2.1 Pastagens espontâneas
4.1.1.1 SAF de sobreiro
4.1.1.2 SAF de azinheira
4.1.1.3 SAF de outros carvalhos
4.1.1.4 SAF de pinheiro manso
4.1.1.5 SAF de outras espécies
4.1.1.6 SAF de sobreiro com azinheira
4.1.1.7 SAF de outras misturas
5.1.1.1 Florestas de sobreiro
5.1.1.2 Florestas de azinheira
5.1.1.3 Florestas de outros carvalhos
5.1.1.4 Florestas de castanheiro
5.1.1.5 Florestas de eucalipto
5.1.1.6 Florestas de espécies invasoras
5.1.1.7 Florestas de outras folhosas
5.1.2.1 Florestas de pinheiro bravo
5.1.2.2 Florestas de pinheiro manso
5.1.2.3 Florestas de outras resinosas
6.1.1.1 Matos
7.1.1.1 Praias, dunas e areais interiores
7.1.1.2 Praias, dunas e areais costeiros
7.1.2.1 Rocha nua
7.1.3.1 Vegetação esparsa
8.1.1.1 Paus
8.1.2.1 Sapais
8.1.2.2 Zonas entremarés
9.1.1.1 Cursos de água naturais
9.1.1.2 Cursos de água modificados ou artificializados
9.1.2.1 Lagos e lagoas interiores artificiais
9.1.2.2 Lagos e lagoas interiores naturais
9.1.2.3 Albufeiras de barragens
9.1.2.4 Albufeiras de represas ou de açudes
9.1.2.5 Charcas
9.2.1.1 Aquicultura
9.3.1.1 Salinas
9.3.2.1 Lagoas costeiras
9.3.3.1 Desembocaduras fluviais
9.3.4.1 Oceano

Quadro 4 - 2ª parte da Legenda da Carta de Uso e Ocupação do Solo (COS). Fonte: Direção-Geral do Território

5.6 MÉTODOS E TÉCNICAS UTILIZADAS

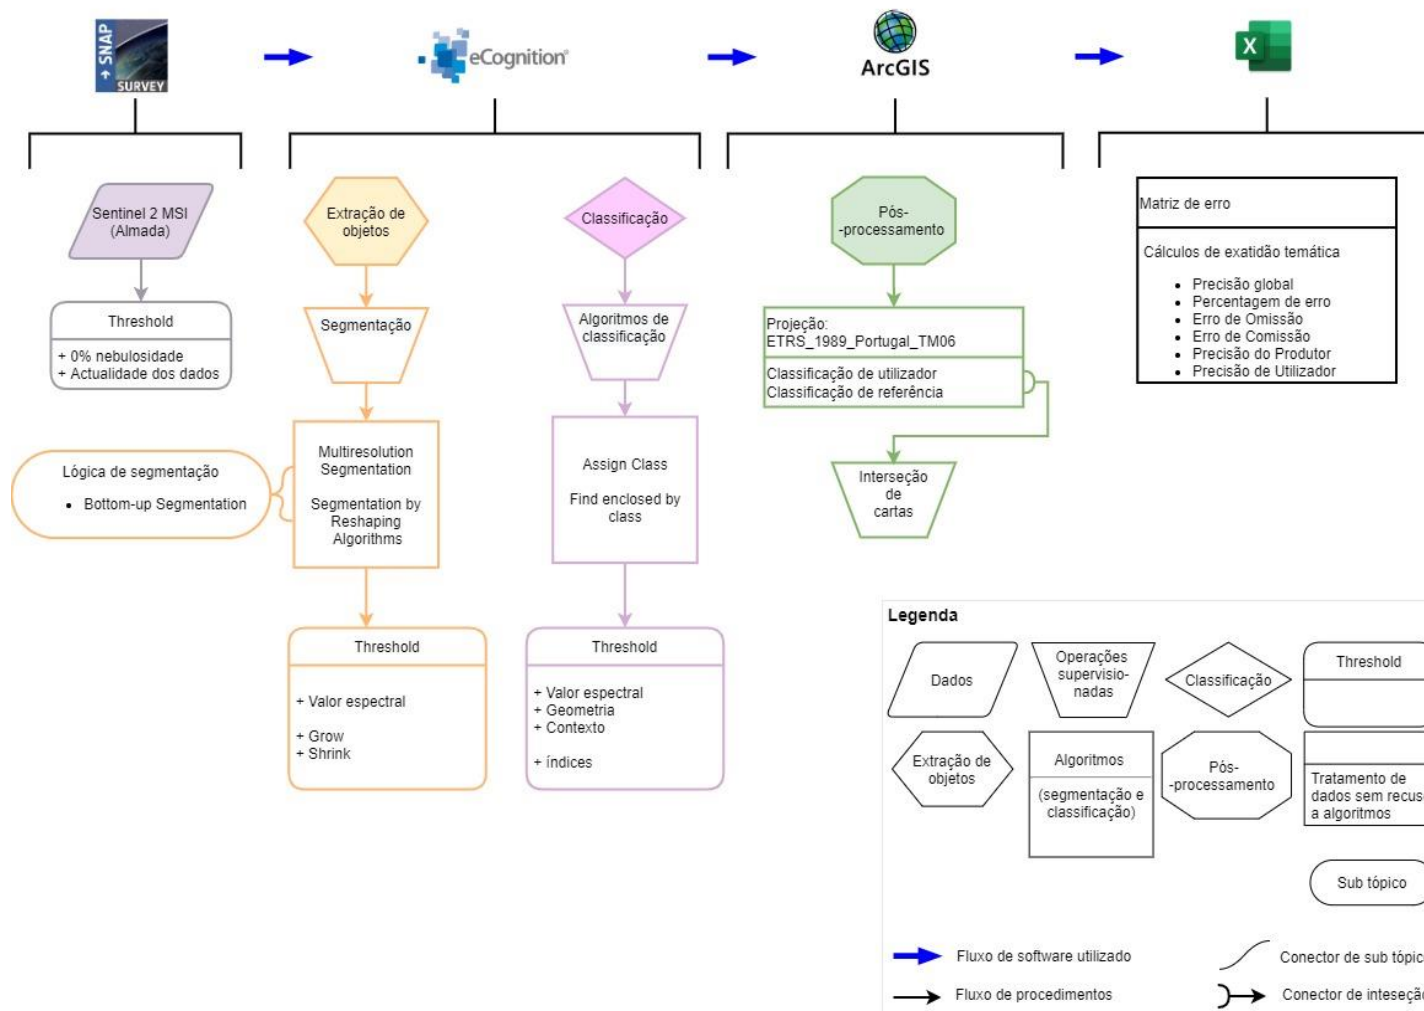
O método classificativo escolhido foi de classificação supervisionada ao objeto sem recurso a classificadores estatísticos automáticos, neste sentido foi elaborado um *script* ou conjunto de ordens como o objetivo de associar os objetos de imagem a temas da legenda CLC, de acordo com critérios definidos pelo utilizador.

As técnicas e procedimentos de segmentação e classificação foram executadas em software *eCognition Developer* (no sétimo capítulo estão descritos os procedimentos e critérios por tema) e para isso recorreu-se a dois algoritmos de segmentação de lógica *Bottom-up* (unir objetos para criar objetos maiores). Primeiro o algoritmo *Multiresolution Segmentation*, onde foram atribuídos pesos as bandas de imagem e determinada a tolerância de desvio padrão para formação de objetos²⁹, e no segundo algoritmo de segmentação, *Segmentation by Reshaping Algorithms*, foram incorporadas operações de remodelagem³⁰ como operações de aumento (*Grow*) para agregar objetos vizinhos contíguos. A classificação contou com o auxílio de dois classificadores, primeiro o *Assing Class*, que apesar de ser um classificador bastante simples, permite ao utilizador controlar “passo a passo” todo o processo classificativo, onde os *thresholds* inseridos devem considerar a legenda CLC no momento da escolha dos limiares espectrais, geometria, relações de vizinhança e índices, e o segundo classificador, *Find enclosed by class*, serviu para reclassificar ou classificar os objetos contidos em diferentes temas caso não cumpram a UMC = 25ha.

Como forma de sintetizar os procedimentos executados nesta dissertação desde a obtenção dos dados até à avaliação da qualidade temática para carta de tipos de uso e ocupação de solo produzida para o município de Almada; o Fluxograma 1 sintetiza em quatro momentos os procedimentos gerais envolvidos para a concretização desta investigação.

²⁹ Objetos maiores são gerados a partir de uma maior tolerância de desvio de padrão e objetos menores são gerados a partir de uma menor tolerância de desvio padrão. O parâmetro que controla esta tolerância de desvio padrão é o “Scale parameter”.

³⁰ É considerado pelo *eCognition Developer* que instrumentos de segmentação não são apenas aqueles que sub-dividem entidades em porções menores, mas também aqueles que alteram a morfologia dos objetos. (sub-divisão, *merging*, *reshaping*).



Fluxograma 1 -Procedimentos gerais executados.

CAPÍTULO VI -PROCEDIMENTOS

6.1 PROCEDIMENTOS DE SEGMENTAÇÃO E CLASSIFICAÇÃO

Em GEOBIA o processo que gera objetos é a segmentação e o principal algoritmo utilizado foi o *Multiresolution Segmentation*. Este algoritmo minimiza localmente a heterogeneidade média dos objetos de imagem para uma determinada resolução de objetos de imagem (Trimble Germany, 2014a). A heterogeneidade vai depender da manipulação direta do *Scale Parameter*³¹ (SP) e seus componentes de *Shape*³² e *Compactness*³³, contudo a manipulação destes 3 elementos influi na manipulação indireta de outros elementos que importa ter em atenção no momento de definir parâmetros (Figura 27).

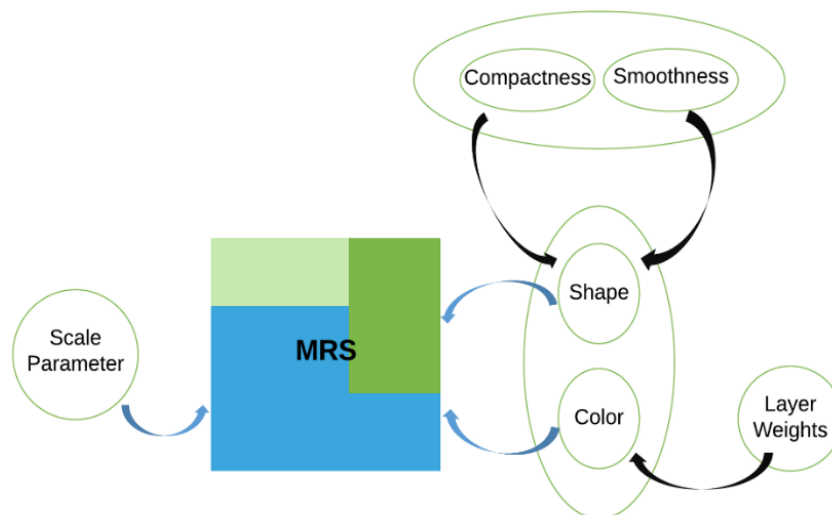


Figura 27 - Elementos que compõem o Multiresolution Segmentation (MRS).

³¹ **Scale Parameter** - Define o máximo do desvio padrão no critério de homogeneidade, que é próprio do processo de segmentação para gerar objetos. Logo quanto mais elevado for o valor do *Scale Parameter*, maiores iram ser os objetos gerados.

³² **Shape** - "*Shape*" é a combinação de dois critérios, *Color* (*digital number* ou valor espectral) e *Shape*. Estes dois somados dão sempre 1, portanto ao alterarmos o valor do "Shape", estamos indiretamente a modificar o peso do *Color* (ex: 0,5 indica uma igual influencia no objeto final do *Shape* e da *Color*, já 0.7, indica uma maior influencia do *Shape* do que de *Color*...). Nota: o valor mínimo e máximo varia entre 0.1 e 0.9.

³³ **Compactness** - "*Compactness*" reflete a distância média a que os pixéis constituintes de um objeto se encontram em relação aos outros, este critério contrabalança com o critério "*smoothness*", sendo a sua soma sempre igual a 1. A modificação deste valor vai influenciar a forma dos objetos gerados, seja enquanto objetos mais compactos ou com os limites mais suavizados. Nota: o valor mínimo e máximo varia entre 0.1 e 0.9.

A segmentação dos dados orbitais Sentinel 2-MSI foi dividida em dois momentos, o primeiro na composição dos primeiros objetos, a partir de pixels com vista à classificação do tema “1. Territórios artificializados”. Num segundo momento, outra nova segmentação, desta vez orientada aos objetos previamente gerados com vista a criar objetos que melhor delimitassem as áreas “3. Florestas e meios naturais e semi-naturais”. Posterior a estes dois processos de segmentação foi classificada a classe “5. Corpos de água” e toda a restante área que não se encaixasse nas classes de uso e ocupação de solo acima mencionadas seriam entendidas como “2 Áreas agrícolas e agroflorestais”.

Nota: A escolha para não atribuir uma segmentação específica que se circunscrevesse às áreas agrícolas e agroflorestais, resulta da imprecisão de segmentação e classificação, deste tema, em situações de fronteira com os territórios artificializados, contudo a aplicação de segmentação específica aos territórios artificializados mostrou-se mais precisa em situação de fronteiras com as áreas agrícolas e agroflorestais.

A classe de “4 Zonas húmidas” foi propositalmente não considerada neste início de atividade em software *eCognition* por na área de estudo (Almada) e com recurso a imagens de *Google Maps* não se identificar por análise visual este tipo de uso e ocupação de solo e pela classificação do tema “5. Corpos de água” já identificar as superfícies aquosas em toda a área em estudo.

Deve ser entendido que a extração das classes da CLC teve na sua lógica de segmentação, a produção de objetos com a maior escala possível respeitando a separação entre diferentes regiões; a classificação priorizou em primeiro lugar o nível 1 da legenda CLC, sem a criação de super objetos (junção dos objetos contíguos ou constituintes do mesmo tema); daí em diante foram classificadas as classes que se encaixassem no nível 3 da legenda CLC (objetos estes que já tinham uma nomenclatura de nível 1 atribuída) bem como gerado um super objeto para cada tema extraído do nível 3 da legenda; por fim foram classificados os objetos de nível 2 (correspondente às áreas onde não foi possível identificar a classe de uso e ocupação de solo no nível 3 de legenda) com a junção dos objetos constituintes e contíguos, por classe, num super objeto.

Relembrando que o algoritmo de segmentação *Multiresolution Segmentation* segue um logica *bottom-up*, isto significa que os objetos não podem ser fatiados em segmentações futuras, apenas agregados aos seus vizinhos. Justifica-se por isso, a opção de unir objetos somente quando se atinge uma classificação que se aproximasse o máximo possível do nível 3 da legenda CLC, pela noção que níveis inferiores da legenda são contidos pelos níveis superiores e por isso mesmo a criação de super objetos na sua fase inicial de segmentação (nível 1 da nomenclatura da CLC), impossibilitaria futuramente a extração de sub-objetos (Nível 2; Nível 3).

6.2 OPERACIONALIZAÇÃO DA EXTRAÇÃO DE CLASSES

A operacionalização de extração de classes foi desenvolvida no software *eCognition Developer 9.0*. Para uma maior celeridade no processamento dos dados foi selecionado um *Subset* (Figura 28) que restringisse os procedimentos de extração à área mais próxima do município de Almada, para então se iniciar a extração das classes, que foi desenvolvida inteiramente na janela de *Process Tree* (Figura 29).




Figura 28 - Subset ajustado ao município de Almada.

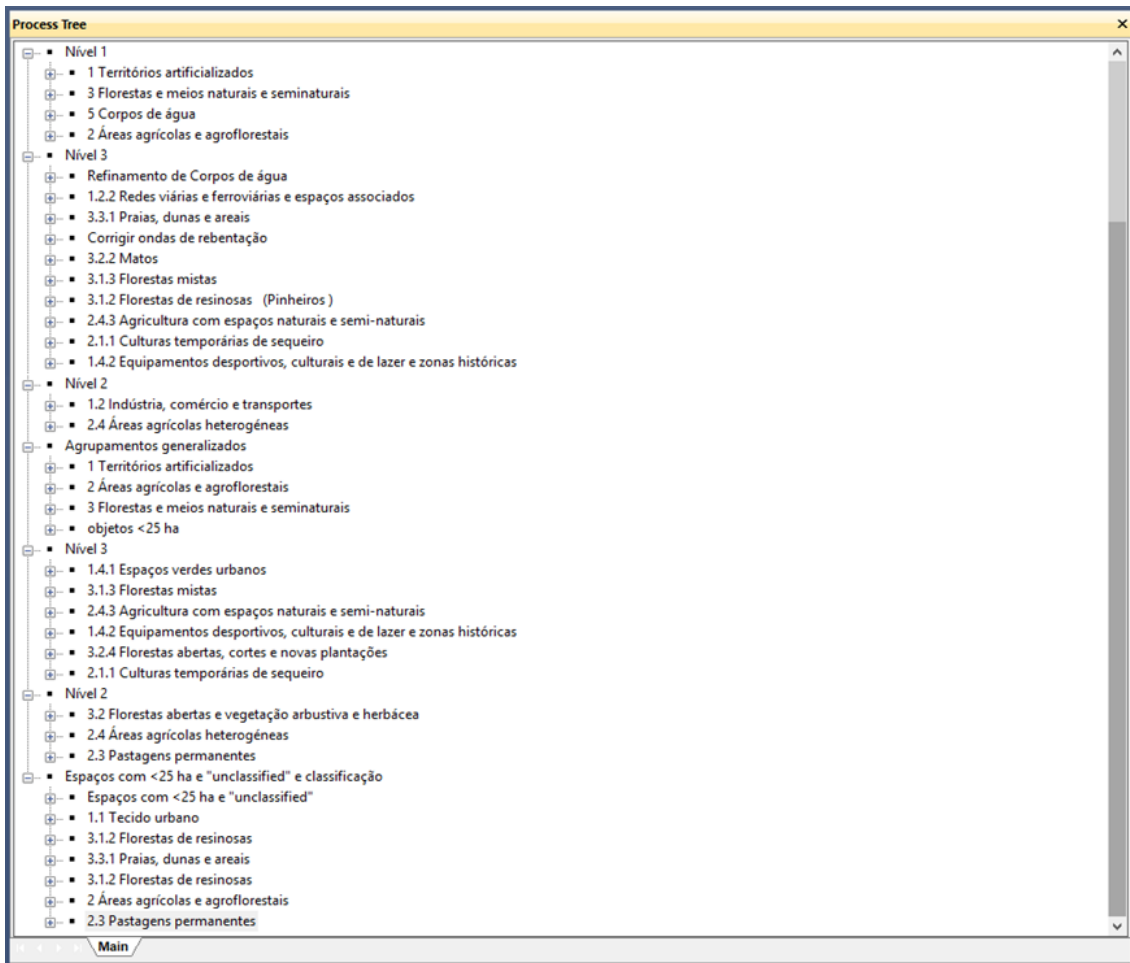


Figura 29 - Fluxo de classes extraídas em software eCognition.

De acordo com o *Processe Tree*, a primeira ordem de segmentação teve o objetivo de gerar os objetos que melhor circunscrevessem os “1. Territórios artificializados” e para isso foi dado um peso as *layers Red = 8, Green = 1 e Blue = 1*. O valor excessivamente elevado da *layer Red* deve-se a tentativa que melhorar a segmentação em situações de fronteira das áreas artificializadas com as “2. Áreas agrícolas e agroflorestais” (Figura 30), tendo em conta que os valores de *Mean Red* se demonstram mais efetivos na extração de áreas construídas (Ex: terrenos para construção, solo a descoberto e vegetação mista) (Li et al., 2018). Apesar que tendo em conta a nomenclatura CLC, para uma distinção clara entre territórios artificializados e áreas agrícolas e agroflorestais não foi encontrada uma solução ótima na classificação das *áreas artificializadas* sem confusão com as *superfícies agrícolas e agroflorestais*.



Figura 30 - Peso da layer Red na segmentação de objetos em zona de fronteira de territórios artificializados e áreas agrícolas e agroflorestais.

Mais a diante será explicado que apesar do peso da banda do vermelho ser propositalmente exagerado o indicador que melhor circunscreveu as áreas artificializadas foi o *standard deviation* para a banda *Red*.

O *Scale Parameter (SP)* escolhido foi de 80, apesar de apresentar bons resultados entre 80 e o 120³⁴. A escolha do SP 80 ao invés de SP 120, deveu-se ao facto de o

³⁴ Valores estes que se mantém próximos do SP de referencia para imagens Sentinel-2 MSI na extração de parcelas agrícolas, que variam entre os 90 e 110 (Yang, Mansaray, Huang, & Wang, 2019).

algoritmo de segmentação *Multiresolution Segmentation* seguir uma lógica de *Bottom-up segmentation* e após uma segmentação com um determinado SP, a(s) segmentação(es) subsequentes, não efetuarem alterações na morfologia dos objetos se os valores de SP forem inferiores, apenas se iguais ou superiores. Por fim o *Shape* foi de 0.1, o que significa que o peso da *Color* teve uma ponderação de 0.9 e o *Compactness* foi de 0.3, o que denota que o *Smoothness* teve uma ponderação de 0.7.

Concluído o processo de segmentação foi analisado de forma visual os indicadores que melhor se ajustavam à classificação de territórios artificializados. Feita à análise, rapidamente se pode concluir que o desafio consistia em classificar as *áreas artificializadas* com o menor nível de confusão com às *áreas de solo a descoberto (agricultura de sequeiro e pastagens)*, e a pesar de não ter sido encontrado um indicador que fosse suficientemente satisfatório, aquele que melhor se adequou foi o *standard deviation* para a banda *Red* entre os valores de ≥ 210 e ≤ 410 (Figura 31).

Atente-se que neste momento, de classificação dos temas de nível 1 da nomenclatura CLC, a classificação do tema “1. Território artificializado” irá assumir o nome de “1.1. Tecido urbano”. Esta alteração acontece, pôr em fases mais avançadas do projeto se ter concluído que a totalidade da área classificada como “1. Território artificializado” corresponder a “1.1. Tecido urbano” e como o *software eCognition* não permite a renomeação da totalidade dos objetos que compõem um tema, caso este tenha sido utilizado como *threshold* em alguma operação anterior (o que aconteceu!), houve a necessidade de renomear o tema desde o primeiro procedimento como forma de manter os procedimentos de classificação das restantes classes intactos.



Figura 31 - Classificação de “1.1 tecido urbano” para objetos com Stand.Dev ≥ 210 e ≤ 410 .

Feita a classificação identificou-se *tecido urbano* na área de praia (na zona de rebentação de ondas). Como forma de correção, o tema “1.1 tecido urbano” deve perder a sua contiguidade para as superfícies de “3.3.1 Praias, dunas e areais” com forma de facilitar o processo de correção. Para isso foi determinado que o *tecido urbano* com um *Length/Width* ≥ 4 (Figura 32) seria entendido como *unclassified*. Desta forma os objetos longilíneos, associados a *praias e* rebentação de ondas, perderam a classificação de “1.1 tecido urbano” (Figura 33), para então em procedimentos futuros, serem encaixados nas suas devidas classes. E com isto procura-se melhorar o processo classificativo, diminuindo generalizações na classificação³⁵.




Figura 32 - Tecido Urbano incorretamente classificado em praia.



Figura 33 - Resultado da remoção de tecido urbano em praia.

³⁵ Entenda-se “generalizações na classificação” a todas as classificações que decorrem sem um levantamento de campo, e que por isso, contêm inevitavelmente generalizações e imprecisões.

De seguida foi efetuado o último processo de segmentação para o nível 1 da legenda CLC, com a classificação do tema “3. Florestas e meios naturais e semi-naturais”.

Recorreu-se novamente ao algoritmo de segmentação *Multiresolution Segmentation* como os seguintes parâmetros para as áreas *unclassified*: com um peso para as *layers Red = 1, Green = 1, Blue = 1, NIR = 4, SP = 80, Shape = 0.1* e *Compactness = 0.3* (Figura 34).

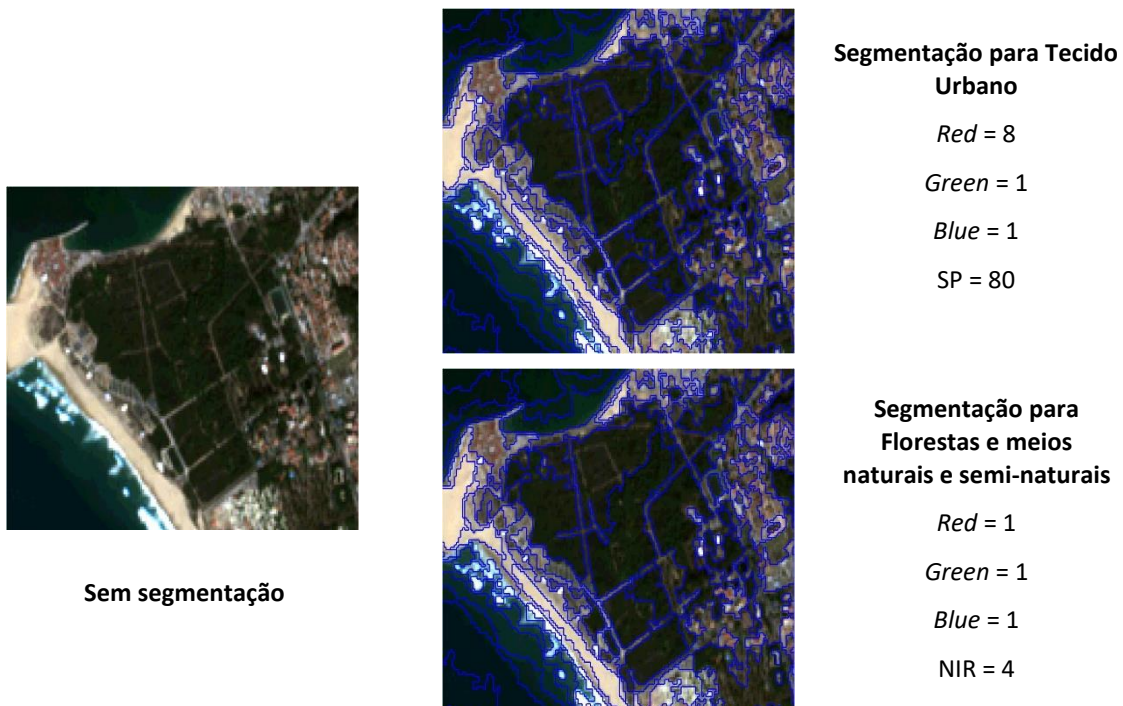


Figura 34 – Diferença na segmentação com vista a extração de “3. Florestas e meios naturais e semi-naturais” e a segmentação com vista o “1.1 tecido urbano”, mantendo o SP = 80.

Na classificação foi aplicado um índice que ajudasse a discriminar as “3. Florestas e meios naturais e semi-naturais” das “2. Áreas agrícolas e agroflorestais”. Foram testados três índices: o *Normalized Difference Vegetation Index (NDVI)*³⁶, *Soil Adjusted*

³⁶ **NDVI** = (NIR - R) / (NIR + R). O NDVI mede numa escala de -1 e 1 a diferença entre as bandas NIR e R. Quanto maior for diferença entre os valores de NIR e R, maior é a presença de clorofila. Este indicador em superfície de água é sempre inferior a 0. (Rissini, Kawakami, & Genú, 2015)

Vegetation Index (SAVI)³⁷ e Wide Dynamic Range Vegetation Index (WDRVI)³⁸ (Figura 35).




Figura 35 - Teste de índices para classificação de “3. Florestas e meios naturais e semi-naturais”

O índice escolhido foi o WDRVI. E assim todas as áreas com um WDRVI entre ≥ 0.5 e ≤ 0 foram classificadas como “3. Florestas e meios naturais e semi-naturais” (Figura 36)

³⁷ **SAVI** = $((\text{NIR} - \text{R}) / (\text{NIR} + \text{R} + \text{L})) * (1 + \text{L})$. O SAVI tem por objetivo melhorar o NDVI por levar em consideração a composição/cobertura do solo, se a cobertura de solo for 100% composta por vegetação o $\text{L} = 1$. O valor de L pode ir de 0 a 1 (Xue & Su, 2017). O valor utilizado foi de 0.35.

³⁸ **WDRVI** = $(\alpha * \text{NIR} - \text{R}) / (\alpha * \text{NIR} + \text{R})$. O WDRVI é semelhante ao NDVI, sendo mais indicado para realçar as áreas com maior índice de biomassa (*Leaf area index* > 2). O valor de 0.20 parece ser o indicado para α e por isso mesmo foi o valor adotado (Henebry, Viña, & Gitelson, 2004).




Figura 36 - Classificação de “3. Florestas e meios naturais e semi-naturais”.

A classificação de “5. Corpos de água” resultou da aplicação do *threshold* de $NDVI < 0$ para as áreas *unclassified* (Figura 38). Em sequência as restantes áreas *unclassified*, por exclusão de partes, foram consideradas como “2. Áreas agrícolas e agroflorestais” (Figura 37).




Figura 38 - Classificação de “5. Corpos de água”.




Figura 37 - Classificação de “2. Áreas agrícolas e agroflorestais”.

Feitas as classificações de nível superior (nível 1), procurar-se-á extrair classes no seu nível mais inferior (nível 3).

Antes de iniciar esta nova etapa do processo, foram corrigidas algumas “manchas” de “5. Corpos de água” que se encontravam, pontualmente, espalhadas pelo solo de Almada. Para isso foi realizada uma operação de *merge* para a classe “5. Corpos de água” como forma de unificar todos os objetos contíguos dessa mesma classe para em seguida ordenar, com o classificador *assign class* que todos os corpos de água com

uma área inferior a 25ha³⁹ e que tocassem a classe “1.1. Tecidos urbanos” fossem reclassificados igualmente como “1.1. Tecidos urbanos” e o mesmo foi feito com pigmentos que tocassem as classes “2. Áreas agrícolas e agroflorestais” e “3. Florestas e meios naturais e semi-naturais” (Figura 39).




Figura 39 - Reclassificação dos pigmentos de "5. Corpos de água".

O próximo passo consistiu na extração da classe “1.2.2 Redes viárias e ferroviárias e espaços associados”. Para isso foram classificados os objetos que fossem longilíneos e que tocassem a classe “1 Territórios artificializados” com as seguintes condições *Length/Width* ≥ 3 e *Rel. Border to 1 Territórios artificializados* > 0 . Por fim foram reclassificados desta última operação os objetos com um NDVI ≥ 0.4 para “3 Florestas e meios naturais e seminaturais”, terminando assim a classificação do tema “1.2.2 Redes viárias e ferroviárias e espaços associados” (Figura 40).

³⁹ A unidade mínima cartográfica (UMC) para a CLA é de 25 hectares.



Figura 40 - Objetos candidatos á classe (azul) e objetos classificados (vermelho).

Devido a incorreta classificação por parte das “1.2.2 Redes viárias e ferroviárias e espaços associados” na área de praia, o próximo procedimento passou por reclassificar esta área de praia.

Por a praia ter um aspeto longilíneo e que fazer fronteira com a classe “5 Corpos de água”, os critérios para reclassificar a classe “1.2.2 Redes viárias e ferroviárias e espaços associados” em “3.3.1 Praias, dunas e areais” foram os seguintes: *Class filter = 1.2.2 Redes viárias e ferroviárias e espaços associados, Length/Width ≥ 10 e Rel. Border to 5 Corpos de água > 0* . Foram detetados alguns “pigmentos” com área inferior a 25ha dentro da classe “3.3.1 Praias, dunas e areais” e que deveriam, por isso mesmo, serem reclassificados (Figura 41). Para isso foram executadas duas operações, a primeira de remodelagem com a ferramenta *pixel-based object resizing*, onde foram aplicados 2 *loops* de *growing* à classe “3.3.1 Praias, dunas e areais” no sentido⁴⁰ *X direction only positive*. Por fim foi executada uma correção para os objetos contidos na classe alvo “3.3.1 Praias, dunas e areais” que não cumprissem a UMC de 25ha, com recurso a ferramenta *find enclosed by image object* “(Figura 42).

⁴⁰ O *pixel-based object resizing* permite que o crescimento de uma classe em 2 eixos: X positivo/negativo e Y positivo/negativo.




Figura 41 - Limites irregulares e classes contidas.




Figura 42 - Suavização de limites e reclassificação de classes contidas em "3.3.1 Praias, dunas e areais".

Como se pode observar nas figuras imediatamente acima ainda existe imprecisão na classificação, na zona de rebentação, que são entendidas como "1.1 Tecido urbano". Para corrigir esta situação foram considerados como "5 Corpos de água" os objetos de "1.1 Tecido urbano" que tocassem as classes "5 Corpos de água" e "3.3.1 Praias, dunas e areais" e para eliminar possíveis pigmentos, os objetos cercados ou *enclosed* pela classe "5 Corpos de água" com menos de 25ha foram classificados como "5 Corpos de água" (Figura 43).




Figura 43 - Correção de ondas de rebentação.

A próxima classe extraída foi "3.2.2 Matos". Nesta classificação foram considerados os objetos pertencentes ao tema "3 Florestas e meios naturais e seminaturais" com *Rel. Border to 3.3.1 Praias, dunas e areais* > 0 com um valor de *WDRVI* ≤ -0.3 . Com esta primeira classificação, os procedimentos seguintes tiveram objetivo classificar os objetos contíguos ao tema "3.2.2 Matos" que a ele pertencessem, pela ferramenta de *pixel-based object resizing*; reclassificando os objetos contidos que não

cumprissem a UMC = 25ha pela ferramenta *find enclosed by image object* e por fim gerando um super objeto com a ferramenta *merge* (Figura 44).




Figura 44 - Classificação do tema "3.2.2 Matos".

A próxima classe a ser extraída foi "3.1.3 Florestas mistas". Para ela foram classificados, os objetos pertencente a classificação de "3 Florestas e meios naturais e seminaturais" com o valor de $WDRVI \geq -0.24$ (Figura 46) a uma distância de mais de 6 km de "3.2.2 Matos" (Figura 45).




Figura 46 - Objetos com $WDRVI \geq -0.24$.




Figura 45 - Distancia >6 km de "3.2.2 Matos".

Isolados os objetos alvo (Figura 48), mais uma vez se foram executados procedimentos de *pixel-based object resizing* para objetos vizinhos que se encaixasse na classe, com recurso a ferramenta *find enclosed by image object* foram reclassificados os objetos contidos e por fim foram unidos/*merge* os objetos contíguos da classe "3.1.3 Florestas mistas" em um super objeto (Figura 47).



Figura 48 - Objetos isolados.




Figura 47 - Classificação de "3.1.3 Florestas mistas".

Segue-se a classificação de "3.1.2 Florestas de resinosas". Para esta classe e para a maioria das classes que se seguem, o processo de classificação assemelha ao da classe anterior: Identificar o limiar de um índice que se aplique à classe a extrair, em seguida realizam-se operações da remodelagem (no caso de *growing*), reclassificam-se os objetos com >25ha (que não cumprem a UMC) que se encontrem contidos pela a classe alvo e no final unem-se todos os objetos do tema alvo em um super objeto.

O valor do índice que se aplicou para identificar a "3.1.2 Florestas de resinosas" foi o *WDRVI* ≥ -0.20 para os objetos da classe "3 Florestas e meios naturais e seminaturais" (Figura 49), foi executada uma ordem de *merge* para todos os objetos contíguos da classe alvo com forma de gerar um único objeto (super objeto) e a partir daqui deram-se os processos de *pixel-based object resizing* para anexar os objetos vizinhos que se encaixasse na classe alvo e por fim foi executada a ferramenta *find enclosed by image object* para reclassificar objetos contidos na classe "3.1.2 Florestas de resinosas" com menos de 25ha, gerado um novo super objeto.




Figura 49 - $WDRVI \geq -0.20$ para "3.1.2 Florestas de resinosas".

A única particularidade na classificação temática desta classe foi a execução de um novo processo de classificação para os objetos que se encontra-se a uma distancia de 6.5km da classe até então extraída ("3.1.2 Florestas de resinosas") com um $WDRVI \geq -0.30$, com o objetivo de classificar como floresta resinosa (Figura 51), a mancha verde imediatamente a norte (Figura 50).




Figura 51 - Mancha verde alvo de classificação para "3.1.2 Florestas de resinosas".




Figura 50 - Classificação da classe "3.1.2 Florestas de resinosas".

Segue-se a extração da classe "2.4.3 Agricultura com espaços naturais e seminaturais". A classe descrita encontra-se localizada na área assinalada a norte do município e na sua extração foram considerados os objetos classificados como "3 Florestas e meios naturais e seminaturais" que tocassem a classe "5 Corpos de água" (Figura 52).




Figura 52 - Área alvo de classificação.

Selecionados a primeira amostra de objetos, sucederam-se os mesmos procedimentos anteriores de remodelagem, *growing* (apenas com a classe alvo “3 Florestas e meios naturais e seminaturais”). Por fim reclassificam-se os objetos que se encontrem rodeados pela classe “2.4.3 Agricultura com espaços naturais e seminaturais” com área inferior a 25ha e no final uniu-se todos os objetos da mesma classe em um super objeto (Figura 53).




Figura 53 - Classificação da classe “2.4.3 Agricultura com espaços naturais e semi-naturais”.

A próxima classe a ser extraída foi a de “2.3 Pastagens permanentes”⁴¹. Os processos mantiveram-se semelhantes. Para extrair a primeira amostra foi utilizado dois

⁴¹ Está classe de nível 2 está representada no seguimento da extração de classes de nível 3, por inicialmente ter sido considerado o resultado da extração como “2.1.1 Culturas temporárias de sequeiro”. Contudo no final do projeto foi detetada a incorreta classificação do tema e alterada a sua denominação.

thresholds destinados à classe “2 Áreas agrícolas e agroflorestais”; *Distance to 3.1.3 Florestas mistas* $\leq 5\text{km}$ e *Distance to 2.4.3 Agricultura com espaços naturais e semi-naturais* $\leq 1.6\text{km}$ (Figura 54). Os objetos rodeados pela classe alvo com uma área inferior a 25ha, foram reclassificados pela ferramenta *find enclosed by image object* (Figura 55).




Figura 54 - Thresholds para classificação inicial.



Figura 55 - Classificação inicial para "2.3 Pastagens permanentes".

Para terminar, foi determinado que todos os objetos no raio de 2.6km pertencentes a classe “2 Áreas agrícolas e agroflorestais” fossem classificados como “2.3 Pastagens permanentes” e unidos num super objeto (Figura 56).



Figura 56 - Classificação final para "2.3 Pastagens permanentes".

Segue-se a classe “1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas”. Com recurso a imagens de *Google maps*, foi possível detetar um parque de golfe, que foi classificado como “1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas” (Figura 57).



Figura 57 - Área alvo de classificação.

Foi utilizado como *thresholds* para classificar a primeira amostra de objetos o $WDRVI \geq -0.25$ e $Distance\ to\ 2.4.3\ Agricultura\ com\ espaços\ naturais\ e\ semi-naturais \geq 10.6km$ (Figura 58).




Figura 58 - Thresholds para classificação inicial.

Em seguida foram realizados processos de *pixel-based object resizing* para anexar os objetos vizinhos que se encaixasse na classe, recorrendo-se a ferramenta *find enclosed by image object* para reclassificar objetos contidos. Por fim, foi executada a ordem de *merge*, para unir os objetos contíguos da classe “1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas” em um super objeto (Figura 59).




Figura 59 - Classificação final para "1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas".

A próxima classe a ser extraída foi "1.2 Indústria, comércio e transportes" (Figura 60).




Figura 60 - Área alvo de classificação.

Para extrair a primeira amostra de objetos, foram classificados dos objetos da classe "3 Florestas e meios naturais e seminaturais" aqueles que cumprissem as condições de área inferior a 25ha e se encontrassem a uma *Distance to 3.3.1 Praias, dunas e areais* $\geq 7.9\text{km}$ (Figura 62). Para em seguida serem realizadas operações de *pixel-based object resizing* para objetos vizinhos que se encaixasse na classe, *find enclosed by image object* para reclassificar objetos contidos inferiores a 25ha e *merge* para unir os objetos contíguos da classe em um super objeto (Figura 61).




Figura 62 - Thresholds para classificação inicial.




Figura 61 - Classificação final para "1.2 Indústria, comércio e transportes".

Segue-se a extração da classe "2.4 Áreas agrícolas heterogêneas" que não teve o resultado esperado. Isto porque, tal como é possível verificar na Figura 63, a classificação de nível 1, predominante na área alvo é maioritariamente do tipo "1.1 Territórios artificializados" e "3 Florestas e meios naturais e seminaturais" e pouco de "2 Áreas agrícolas e agroflorestais" que é a classe onde se insere a classe alvo "2.4.3 Agricultura com espaços naturais e semi-naturais". Acresce ainda que a expansão de objetos que são realizados pela ferramenta de remodelagem de objetos *pixel-based object resizing* seguem o sentido do eixo X e Y (que não é a inclinação em que a área da classe alvo se encontra). Estas condicionantes impediram que a extração da classe "2.4 Áreas agrícolas heterogêneas" fosse concluída da forma desejada.



Figura 63 - Localização da classe "2.4 Áreas agrícolas heterogêneas".

Nesta classificação foram considerados como “2.4 Áreas agrícolas heterogêneas” os objetos da classe “3 Florestas e meios naturais e seminaturais” com menos de 25ha e que tocassem a área de mato *Rel. Border to 3.2.2 Matos*. De seguida foram dadas ordens maioritariamente de *growing* alternadamente entre: *Y direction only positive* e *X direction only positive* da classe alvo para os objetos com menos de 25ha. Por fim com a ferramenta *find enclosed by image object* foram reclassificados os objetos contidos na classe alvo, com área inferior a 25ha, e unidos em um super objeto (Figura 64).




Figura 64 - Classificação final para “2.4 Áreas agrícolas heterogêneas”.

Até ao momento todos os temas classificados estão localizados junto aos limites do município, como tal o interior de Almada, não mereceu ainda atenção na sua classificação temática (Figura 65). Por análise visual e com recurso a imagens de *Google Maps*, conclui-se que dos objetos por classificar o território artificializado é representado na sua totalidade pelo tema “1.1 Tecido urbano”, sendo assim possível gerar um super objeto para esta classe. Os temas “3 Florestas e meios naturais e seminaturais” e “2 Áreas agrícolas e agroflorestais”, apesar de não apresentarem a mesma grandeza de ocupação que o “1.1 Tecido urbano”, formam de forma geral áreas contiguas superiores a UMC de 25ha, tornado possível criar super objetos para estas duas classes, formando pequenas “ilhas” rodeadas pela classe “1.1 Tecido urbano”, que serão posteriormente analisadas caso não cumpram a UMC.




Figura 65 – Área alvo pré-simplificação.

Para gerar os super objetos para os três temas referidos acima, foi repetida a seguinte operação para cada uma das classes, individualmente: seleção de uma classe, 1º - “1.1 Tecido urbano”, 2º - “3 Florestas e meios naturais e seminaturais” e 3º - “2 Áreas agrícolas e agroflorestais” e com o operador merge region, foram unidos cada um dos três temas, formando três novos super objetos.

Apos serem gerados os super objetos, foram selecionados estes mesmos três super objetos e desclassificados as partes que não cumprissem a UMC de 25ha, para em procedimentos posteriores serem reclassificado de acordo com a sua vizinhança.

Na reclassificação dos objetos que não atingiram a UMC e se encontrassem rodeados ou contidos por uma única classe, a ferramenta find enclosed by image object serviu para reclassificar esse objeto de acordo com o objeto que o envolvia. Nos casos em que o objeto que não atingisse a UMC se encontrassem rodeados por mais de uma classe a sua atribuição seguiu a seguinte ordem de preferência: se nos seus objetos vizinhos se encontrasse o tema “1 Territórios artificializados”, a sua atribuição deveria ter esta mesma classe como preferência; no caso de se encontrar rodeado pelos temas “2 Áreas agrícolas e agroflorestais” e “3 Florestas e meios naturais e seminaturais”, a preferência deveria ser dada para a classe “2 Áreas agrícolas e agroflorestais”.

Terminando assim a classificação dos temas localizados no interior do município de Almada, ou que não tocassem os seus limites (Figura 66).




Figura 66 - Área alvo pós-simplificação.

Neste momento foram gerados três novos super objetos, com classes de nível 1 e de nível 2, como tal os passos seguintes seguem igualmente a logica de extrair primeiro as classes de nível 3 e depois de nível 2.

A próxima classe a ser extraída foi “1.4.1 Espaços verdes urbanos” (Figura 67). Para a sua classificação foi considerado para a classe “3 Florestas e meios naturais e seminaturais” os objetos que tocassem a classe “1.2.2 Redes viárias e ferroviárias e espaços associados” com $WDRVI \geq -0.32$ (Figura 68).



Figura 67 - Localização da classe “1.4.1 Espaços verdes urbanos”.



Figura 68 - Classificação final para “1.4.1 Espaços verdes urbanos”.

Segue a classe “3.1.3 Florestas mistas”. Para a sua classificação foi considerado para a classe “3 Florestas e meios naturais e seminaturais” os objetos que tocassem a classe “1.2.2 Redes viárias e ferroviárias e espaços associados” com *Area < 58ha* (Figura 69).



Figura 69 - Classificação final para “3.1.3 Florestas mistas”.

O próximo tema classificado foi “2.4.3 Agricultura com espaços naturais e seminaturais”. Para a sua classificação foi considerado para a classe “3 Florestas e meios naturais e seminaturais” os objetos que tocassem as classes “1.2.2 Redes viárias e ferroviárias e espaços associados” e “3.1.3 Florestas mistas” (Figura 70) e foi ainda reajustada a sua classificação no norte do município (Figura 71).



Figura 70 - Classificação final para “2.4.3 Agricultura com espaços naturais e semi-naturais”.



Figura 71 - Aumento da extensão da classe “2.4.3 Agricultura com espaços naturais e semi-naturais” a norte do município.

A próxima classe extraída foi “1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas” (Figura 72) que com recurso a imagens de *Google Maps* foi possível aferir que se trata de uma área de campismo. Para a sua classificação foi considerado para a classe “3 Florestas e meios naturais e seminaturais” os objetos que tocassem as classes “2 Áreas agrícolas e agroflorestais” e “3.1.3 Florestas mistas”. Foi ainda utilizado o *find enclosed by image object* para reclassificar as classes contidas com área inferior a 25ha no tema “1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas” (Figura 73).



Figura 72 - Localização da classe "1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas".




Figura 73 - Classificação final para "1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas".

A classe seguinte a ser extraída foi "3.2.4 Florestas abertas, cortes e novas plantações" (Figura 75), que conta com três áreas assinaladas. Para a classificação da área mais a norte do município foi considerado para a classe "3 Florestas e meios naturais e seminaturais" os objetos que tocassem o tema "2.3 Pastagens permanentes" e *Distance to Florestas mistas* $\leq 1.5km$. Para as áreas assinaladas a sul foram considerados os objetos da classe "3 Florestas e meios naturais e seminaturais" com *Distance to Florestas abertas, cortes e novas plantações* $\leq 2.5km$ e que tocassem a classe "3.1.2 Florestas de resinosas. Foi por fim realizada uma operação de *find enclosed*

by *image object* para classes contidas em “3.2.4 Florestas abertas, cortes e novas plantações” com área inferior a 25ha (Figura 74).



Figura 75 - Localização das áreas para a classe “3.2.4 Florestas abertas, cortes e novas plantações”.




Figura 74 - Classificação final para “3.2.4 Florestas abertas, cortes e novas plantações”.

Na classe que se segue “2.1.1 Culturas temporárias de sequeiro” (Figura 76), importa deixar explícito que o resultado da extração não é o desejado, pelos motivos de imprecisão na distinção dos objetos das classes “2 Áreas agrícolas e agroflorestais” e “1 Territórios artificializados”.




Figura 76 - Localização da classe "2.1.1 Culturas temporárias de sequeiro".

Posto isto, as condições utilizadas foram, num primeiro momento, para a classe "2 Áreas agrícolas e agroflorestais" os objetos que tivessem um *Rel. Border to 2 Áreas agrícolas e agroflorestais* ≥ 0.56 , *Rel. Border to 2 Áreas agrícolas e agroflorestais* ≤ 0.57 e num segundo momento para a classe "3 Florestas e meios naturais e seminaturais" os objetos que cumprissem as condições de *Distance to Espaços verdes urbanos* < 2.6 km e *Rel. Border to Culturas temporárias de sequeiro* > 0 . No final de cada um destes momentos foi executada uma ordem de *find enclosed by image object* para os objetos contidos no tema "2.1.1 Culturas temporárias de sequeiro" com < 25 ha e para terminar foi gerado um super objeto para esta classe (Figura 77).

Classificação inicial

Classificação Final



Figura 77 – Classificação final para "2.1.1 Culturas temporárias de sequeiro".

Extraídas as classes dos níveis 3 serão extraídas as classes de nível 2, a começar por “3.2 Florestas abertas e vegetação arbustiva e herbácea”. Para a sua classificação foi considerado para a classe “3 Florestas e meios naturais e seminaturais” os objetos que tocassem a classe “1.2.2 Redes viárias e ferroviárias e espaços associados” com *Area > 72ha* (Figura 78).



Figura 78 - Classificação final para “3.2 Florestas abertas e vegetação arbustiva e herbácea”.

Segue-se a classificação da classe “2.4 Áreas agrícolas heterogêneas”. Para a sua classificação foi considerado para a classe “3 Florestas e meios naturais e seminaturais” aqueles objetos que se encontrassem a uma *Distance to Espaços verdes urbanos* entre $\geq 1.1km$ e $\leq 1.2km$ (Figura 79).




Figura 79 - Classificação final para “2.4 Áreas agrícolas heterogêneas”.

A próxima classe a ser extraída foi “2.3 Pastagens permanentes”. Para a sua classificação foi considerado para a classe “3 Florestas e meios naturais e seminaturais”

os objetos que se encontrassem a uma *Distance to Culturas temporárias de sequeiro* < 1.001km e *Area* >=25ha (Figura 80).




Figura 80 - Classificação final para “2.3 Pastagens permanentes”.

Segue a última fase de procedimentos em *software eCognition*, onde serão classificados como “*Unclassified*” os objetos <25ha para em seguida serem incorporados por análise visual a algum tema de fronteira. Para finalizar, serão formados super objetos para as classes que não tenham sido anteriormente alvo desta operação.

Os objetos “*Unclassified*” com área superior a 25ha foram, com recurso à ferramenta de *assign class*, classificados de forma individualizada, de acordo com a sua vizinhança (Figura 81). E por análise visual o mesmo processo que se deu para os restantes objetos que não cumpriam a UMC = 25ha (Figura 82).



Figura 81 - Exemplo objetos <25ha que unidos cumprem a UCM e foram reclassificados.




Figura 82 - Exemplo de classificação para "Unclassified " onde se verifica uma área <25ha.















Fica dado por terminado a execução dos procedimentos em *eCognition Developer*. Para restringir a classificação apenas à área de estudo, município de Almada, foi realizada uma operação de *Clip* em *software ArcMap 10.6*, pelos limites administrativos da CAOP 2019⁴² para o município de Almada (Mapa 1).

Fica assim concluída a produção de um mapa de ocupação e uso do solo para o concelho de Almada, de acordo com a nomenclatura da CLC aplicando técnicas de GEOBIA.

⁴² "A Carta Administrativa Oficial de Portugal (CAOP) regista o estado da delimitação e demarcação das circunscrições administrativas do País". Fonte: http://www.dgterritorio.pt/cartografia_e_geodesia/cartografia/carta_administrativa_oficial_de_portugal_caop/




Legenda CLC

-  1.1 Tecido urbano
-  1.2 Indústria, comércio e transportes
-  1.2.2 Redes viárias e ferroviárias e espaços associados
-  1.4.1 Espaços verdes urbanos
-  1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas
-  2.1.1 Culturas temporárias de sequeiro
-  2.3 Pastagens permanentes
-  2.4 Áreas agrícolas heterogéneas
-  2.4.3 Agricultura com espaços naturais e semi-naturais
-  3 Florestas e meios naturais e seminaturais
-  3.1.2 Florestas de resinosas
-  3.1.3 Florestas mistas
-  3.2 Florestas abertas e vegetação arbustiva e herbácea
-  3.2.2 Matos
-  3.2.4 Florestas abertas, cortes e novas plantações
-  3.3.1 Praias, dunas e areais
-  5 Corpos de água

Limites Administrativos Oficiais de Portugal

 CAOP

0 3 km



Mapa 1 - Ocupação e uso do solo para o concelho de Almada, de acordo com a nomenclatura CLC.

6.3 MATRIZ DE ERRO E PRECISÃO TEMÁTICA

Nos procedimentos em software *eCognition Developer* foram classificados os temas de acordo com a nomenclatura da *CORINE Land Cover*, com recurso a dados Sentinel-2 MSI. Para avaliar a qualidade do mapeamento serve a matriz de erro, que compara, por interceção, dois mapas com legendas idênticas. Um dos mapas composto pelos temas cartografados pelo utilizador e o segundo mapa providenciado por uma fonte de referência.

A DGT conta com duas cartografias temáticas de uso e ocupação do solo para Portugal Continental: Carta de Uso e Ocupação do Solo (COS) e *CORINE Land Cover* (CLC). A COS tem como unidade mínima cartográfica (UMC) de 1ha e a CLC de 25ha.

A matriz de erro contou com a última cartografia CLC e COS disponibilizada pela plataforma de dados abertos *Copernicus Open Access Hub* e Direção Geral Território, ambas do ano de 2018.

6.3.1 Harmonização entre legenda COS e CLC

Os dados Sentinel2-MSI têm uma resolução espacial de 100m² (bandas: 2, 3, 4 e 8) por pixel, ou seja, são necessários 1 000 pixéis (10 000m²) para igual a UMC de 1ha da COS e são necessários 25 000 pixéis (250 000m²) para igualar a UMC de 25ha da CLC. É assim possível a partir de dados Sentinel2-MSI elaborar uma legenda CLC que seja comparável à legenda COS, se esta for adaptada na sua nomenclatura, até porque a nomenclatura COS inspira-se na nomenclatura CLC, com a vantagem de que a legenda COS tem uma escala mais fina de classificação e é elaborada por profissionais que conhecem o território. Estas condições possibilitam que a legenda COS, que é inspirada na legenda CLC, seja uma melhor opção de cartografia de referência ao invés de uma cartografia CLC, que ainda que seja elaborada por equipas nacionais a sua UMC não permite uma classificação tão detalhada e com uma probabilidade de erro tão baixa, na representação da realidade⁴³.

⁴³ A legenda COS apresenta uma probabilidade de erro na representação da realidade menor que a legenda CLC porque, a validação de áreas pequenas (UMC = 1ha) obriga a uma validação mais constante do terreno. Logo o peso, do erro, de uma classificação incorreta com UMC = 1ha, não representa à partida, o mesmo peso de uma classificação incorreta com UMC = 25ha.

Para comparar legendas CLC e COS, existem dois critérios que têm de ser atendidos: o primeiro é a adaptação da legenda COS à legenda CLC; o segundo é inclusão na precisão global do erro de comissão composto pelas áreas com <25ha. O segundo critério acontece porque quando se processa uma classificação atendendo à legenda CLC, com UMC de 25ha, não se deve incorrer no erro de considerar os temas com áreas inferiores a 25ha da classificação de referência, classificados de forma incorreta, como erro de classificação. Porque o critério classificativo adotado no mapeamento dos temas, pelo utilizador, não teve em conta a UMC igual a 1ha, mas sim de 25ha.

A adaptação da legenda COS à legenda CLC, foi executada apenas para os temas circunscritos a área do município de Almada. A adaptação passou por dois procedimentos: 1) Adaptar os temas da legenda COS aos temas CLC extraídos pelo utilizador; 2) Em caso de incompatibilidade entre temas COS e os temas CLC extraídos pelo utilizador, deve-se encontrar na nomenclatura CLC o tema adequado para adaptação da legenda. A Figura 83 mostra os temas CLC extraídos pelo utilizador e em seguida o Quadro 5 mostra a renomeação das classes COS, para a mesma área, de acordo com a legenda CLC. A coluna de temas à esquerda representa os temas COS originais e a coluna à direita representa a adaptação ou renomeação dos temas. Estão marcados a vermelho os temas que não obtiveram par com algum dos temas extraídos pelo utilizador e foram compatibilizados com outro tema da nomenclatura CLC. Finalmente o Mapa 2 representa espacialmente a adaptação de nomenclatura COS 2018 à CLC⁴⁴ no município de Almada.

⁴⁴ O elevado número de classes a representar no mapa COS 2018 torna pouco perceptível a correspondência dos temas mapeados à legenda. Para auxiliar à interpretação, de uma forma geral, as manchas com tons de vermelho, magenta e laranja (representam os “1 Territórios artificializados”), a amarelo (“2 Áreas agrícolas e agroflorestais”), a verde (“3 Florestas e meios naturais e semi- naturais”) e os tons de azul (“5 Corpos de água”). Contudo o mais importante é perceber a redução do número de elementos da legenda COS para CLC.

Temas CLC extraídos pelo utilizador

- 1.1 Tecido urbano
- 1.2 Indústria, comércio e transportes
 - 1.2.2 Redes viárias e ferroviárias e espaços associados
- 1.4.1 Espaços verdes urbanos
- 1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas
- 2.1.1 Culturas temporárias de sequeiro
- 2.3 Pastagens permanentes
- 2.4 Áreas agrícolas heterogéneas
 - 2.4.3 Agricultura com espaços naturais e semi-naturais
- 3 Florestas e meios naturais e seminaturais
 - 3.1.2 Florestas de resinosas
 - 3.1.3 Florestas mistas
 - 3.2 Florestas abertas e vegetação arbustiva e herbácea
 - 3.2.2 Matos
 - 3.2.4 Florestas abertas, cortes e novas plantações
 - 3.3.1 Praias, dunas e areais
- 5 Corpos de água

Figura 83 - Temas CLC extraídos pelo utilizador para o município de Almada.

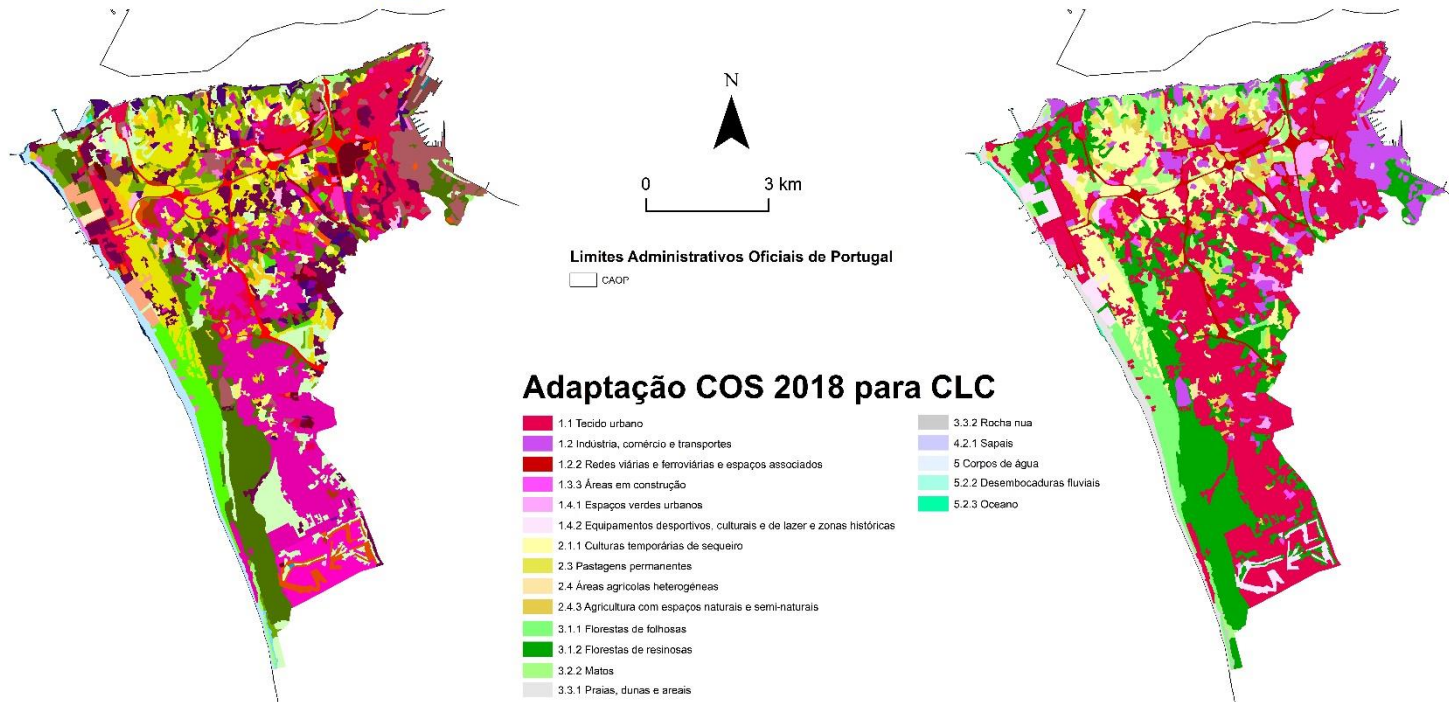
Temas COS2018 no município de Almada	Adaptação COS à legenda CLC
1.1.1.1 Tecido edificado contínuo predominantemente vertical	1.1 Tecido urbano
1.1.1.2 Tecido edificado contínuo predominantemente horizontal	1.1 Tecido urbano
1.1.2.1 Tecido edificado descontínuo	1.1 Tecido urbano
1.1.2.2 Tecido edificado descontínuo esparso	1.1 Tecido urbano
1.1.3.1 Áreas de estacionamento e logradouros	1.1 Tecido urbano
1.1.3.2 Espaços vazios sem construção	1.1 Tecido urbano
1.2.1.1 Indústria	1.2 Indústria, comércio e transportes
1.2.2.1 Comércio	1.2 Indústria, comércio e transportes
1.3.1.1 Infraestruturas de produção de energia renovável	1.1 Tecido urbano
1.3.1.2 Infraestruturas de produção de energia não renovável	1.1 Tecido urbano
1.4.1.1 Rede viária e espaços associados	1.2.2 Redes viárias e ferroviárias e espaços associados
1.4.1.2 Rede ferroviária e espaços associados	1.2.2 Redes viárias e ferroviárias e espaços associados
1.4.2.1 Terminais portuários de mar e de rio	1.2 Indústria, comércio e transportes
1.4.2.2 Estaleiros navais e docas secas	1.2 Indústria, comércio e transportes
1.5.2.1 Aterros	1.1 Tecido urbano
1.5.3.1 Áreas em construção	1.3.3 Áreas em construção
1.6.1.1 Campos de golfe	1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas
1.6.1.2 Instalações desportivas	1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas
1.6.2.1 Parques de campismo	1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas
1.6.2.2 Equipamentos de lazer	1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas
1.6.3.1 Equipamentos culturais	1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas
1.6.4.1 Cemitérios	1.1 Tecido urbano
1.6.5.1 Outros equipamentos e instalações turísticas	1.2 Indústria, comércio e transportes
1.7.1.1 Parques e jardins	1.4.1 Espaços verdes urbanos
2.1.1.1 Culturas temporárias de sequeiro e regadio	2.1.1 Culturas temporárias de sequeiro
2.2.2.1 Pomares	2.4 Áreas agrícolas heterogéneas
2.2.3.1 Olivais	2.4 Áreas agrícolas heterogéneas
2.3.2.1 Mosaicos culturais e parcelares complexos	2.4.3 Agricultura com espaços naturais e semi-naturais
2.3.3.1 Agricultura com espaços naturais e seminaturais	2.4.3 Agricultura com espaços naturais e semi-naturais
3.1.1.1 Pastagens melhoradas	2.3 Pastagens permanentes
3.1.2.1 Pastagens espontâneas	2.3 Pastagens permanentes
5.1.1.1 Florestas de sobreiro	3.1.1 Florestas de folhosas
5.1.1.2 Florestas de azinheira	3.1.1 Florestas de folhosas
5.1.1.5 Florestas de eucalipto	3.1.1 Florestas de folhosas
5.1.1.6 Florestas de espécies invasoras	3.1.1 Florestas de folhosas
5.1.1.7 Florestas de outras folhosas	3.1.1 Florestas de folhosas
5.1.2.1 Florestas de pinheiro bravo	3.1.2 Florestas de resinosas
5.1.2.2 Florestas de pinheiro manso	3.1.2 Florestas de resinosas
6.1.1.1 Matos	3.2.2 Matos
7.1.1.2 Praias, dunas e areais costeiros	3.3.1 Praias, dunas e areais
7.1.2.1 Rocha nua	3.3.2 Rocha nua
8.1.2.1 Sapais	4.2.1 Sapais
9.1.2.1 Lagos e lagoas interiores artificiais	5.2.1 Lagos e lagoas interiores artificiais
9.3.3.1 Desembocaduras fluviais	5.2.2 Desembocaduras fluviais
9.3.4.1 Oceano	5.2.3 Oceano

* Estão marcados a vermelho os temas COS 2018 para o município de Almada que na sua adaptação para a legenda CLC não obtiveram par com algum dos temas extraídos pelo utilizador, na sua classificação final, e que por isso mesmo tiveram a sua adaptação compatibilizada por outro tema presente na nomenclatura CLC (tema esse não identificado pelo utilizador!).

Quadro 5 - Adaptação dos temas COS a temas CLC.

COS 2018

 1.1.1.1 Tecido edificado contínuo predominantemente vertical	 1.4.2.2 Estaleiros navais e docas secas	 2.2.3.1 Olivais	 7.1.1.2 Praias, dunas e areais costeiros
 1.1.1.2 Tecido edificado contínuo predominantemente horizontal	 1.5.2.1 Aterros	 2.3.2.1 Mosaicos culturais e parcelares complexos	 7.1.2.1 Rocha nua
 1.1.2.1 Tecido edificado descontínuo	 1.5.3.1 Áreas em construção	 2.3.3.1 Agricultura com espaços naturais e seminaturais	 8.1.2.1 Sapais
 1.1.2.2 Tecido edificado descontínuo esperso	 1.6.1.1 Campos de golfe	 3.1.1.1 Pastagens melhoradas	 9.1.2.1 Lagos e lagoas interiores artificiais
 1.1.3.1 Áreas de estacionamento e logradouros	 1.6.1.2 Instalações desportivas	 3.1.2.1 Pastagens espontâneas	 9.3.3.1 Desembocaduras fluviais
 1.1.3.2 Espaços vazios sem construção	 1.6.2.1 Parques de campismo	 5.1.1.1 Florestas de sobreiro	 9.3.4.1 Oceano
 1.2.1.1 Indústria	 1.6.2.2 Equipamentos de lazer	 5.1.1.2 Florestas de azinheira	
 1.2.2.1 Comércio	 1.6.3.1 Equipamentos culturais	 5.1.1.5 Florestas de eucalipto	
 1.3.1.1 Infraestruturas de produção de energia renovável	 1.6.4.1 Cemitérios	 5.1.1.6 Florestas de espécies invasoras	
 1.3.1.2 Infraestruturas de produção de energia não renovável	 1.6.5.1 Outros equipamentos e instalações turísticas	 5.1.1.7 Florestas de outras folhosas	
 1.4.1.1 Rede viária e espaços associados	 1.7.1.1 Parques e jardins	 5.1.2.1 Florestas de pinheiro bravo	
 1.4.1.2 Rede ferroviária e espaços associados	 2.1.1.1 Culturas temporárias de sequeiro e regadio	 5.1.2.2 Florestas de pinheiro manso	
 1.4.2.1 Terminais portuários de mar e de rio	 2.2.2.1 Pomares	 6.1.1.1 Matos	



Mapa 2 - Adaptação da legenda COS 2018 para CLC no município de Almada.

6.3.2 Matriz de erro

Com a adaptação da legenda COS à legenda CLC, foi executado um procedimento de *Intersect*, em software *ArcMap*, para os dois mapas e calculado em hectares o valor da interseção entre classes, para produzir através de uma tabela de dupla entrada, em software *Excel*, a matriz de erro (Quadro 6).

Matriz de erro (área em ha)		Classes da classificação "COS (2018)"																		Área total (ha)	Índice de ocupação do solo (%)	
		11	12	122	133	141	142	211	23	24	243	311	312	322	331	332	421	5	522			523
Classes da classificação e Cognition 2019	Classes CORINE Land Cover	11	2078	247	115	36	62	82	164	46	19	108	16	281	87	14	2	0			3358	48,0
	12	18	200	1		2	3					1	6	62	4			0			298	4,3
	122	13	1	41	0	2	1	6	1	0	1	1	13	4							85	1,2
	141	0		3		35	2					4		1							46	0,7
	142	209	6	2	0	1	114							80	1	0			1		416	5,9
	211	61	3	17				69	9			9		13	9						190	2,7
	23	55	11	10	3			15	153	28	0	14	1	10	50						349	5,0
	24	22	2	13	1			1	75	5		16	18	4	17						174	2,5
	243	31	34	15		2	3	69	37	5	35	31	74	114	0				0		450	6,4
	3	0										0	2								2	0,0
	312	57	3					1	2	7	0	0	50	561	12	2	6				703	10,0
	313	4	0	2		0	1	3	2	1		9	84	32	1						138	2,0
	32	6	0	3					24			6	26	10							76	1,1
	322	5	0				2	14				151	3		11						186	2,7
	324	50	0	6	10		10	33	25		16	3	103	18							273	3,9
	331	21		1		1	2		0			37	11	4	134	0					218	3,1
5	1	23	0							0	0	0	2	2				5	3	38	0,5	
Área total (ha)	2631	531	227	50	106	237	589	184	25	205	331	1329	364	164	7	2	1	6	10	7001		
Ocupação do Solo (%)	37,6	7,6	3,2	0,7	1,5	3,4	8,4	2,6	0,4	2,9	4,7	19,0	5,2	2,3	0,1	0,0	0,0	0,1	0,1			

Quadro 6 - Matriz de erro. Classificação *eCognition* (2019) e COS (2018)

Para perceber o peso que as áreas que não cumprem a UMC e se encontram incorretamente classificadas, foi produzida uma outra matriz de erro específica para este fim (Quadro 7), onde foram selecionados os polígonos com área <25ha da carta COS e intercetados com a carta CLC e assim se poder quantificar o erro decorrente da aplicação de diferentes unidades mínimas de cartográficas.

A precisão global será reajustada apenas com o valor da área incorretamente classificada no erro de comissão constituído por áreas <25ha, por este ser o erro que aponta a área incorretamente classificadas de forma ativa pelo utilizador.

Matriz de erro (objetos <25ha)		Classes da classificação "COS (2018)"																		Área total (ha)	Índice de ocupação do solo (%)
		11	12	122	133	141	142	211	23	24	243	311	312	322	331	332	421	5	522		
Classes da classificação eCognition 2019	11	659	239	21	36	58	54	93	44	19	108	16	233	79	9		2	0		1671	51,1
	12	7	21	1		2	3					1	6	15	4			0		61	1,9
	122	6	1	3	0	1	1	6	1	0	1	1	10	4						36	1,1
	141	0					2					4	1							7	0,2
	142	29	6		0	1	48		1				64	1				1		152	4,6
	211	61	3	0				46	9		9		13	9						150	4,6
	23	54	11		3		15	70	28	0	14	1	3	26						224	6,9
	24	22	2	3	1		1	34	5		16		2	17						102	3,1
	243	24	34	6		2	3	54	37	5	35	31	38	93	0				0	362	11,1
	3											0	2							2	0,1
	312	22	3					2	7	0	0	14	62	12		6				130	4,0
	313	3	0			0	1	3	2	1		9	26	2						47	1,4
	32	2	0						1			6	26	10						46	1,4
	322	5	0				2	11					2							21	0,6
	324	38	0		10		9	21	25		16	2	54	18						194	5,9
	331	21		1		1	0		0			4	1	4		0			7	39	1,2
5	1	11	0								0	0	0	0	0		5	3	22	0,7	
Área total (ha)	954	332	35	50	65	139	341	159	25	205	91	554	280	10	7	2	1	6	10	3267	
Ocupação do solo (%)	29,2	10,2	1,1	1,5	2,0	4,3	10,4	4,9	0,8	6,3	2,8	17,0	8,6	0,3	0,2	0,1	0,0	0,2	0,3		
Imprecisão na Omissão devido a polígonos com <25ha	295	312	32	50	65	91	295	131	25	170	91	492	280	10	7	2	1	6	10	2364	

Quadro 7 - Matriz de erro para áreas <25ha. Classificação eCognition (2019) e COS (2018)

6.4 CÁLCULOS DE EXATIDÃO TEMÁTICA

A avaliação de exatidão temática conta com o cálculo de seis métricas⁴⁵: Precisão global, Percentagem de erro, Erro de Omissão, Erro de Comissão, Precisão no Produtor, Precisão no Utilizador. Os cálculos de exatidão temática foram obtidos a partir da “Matriz de erro. Classificação eCognition (2019) e COS (2018)” (Quadro 6) e todas as métricas de precisão temática têm os valores expressos numa escala de 0 (0%) a 1 (100%).

6.4.1 Precisão global e Percentagem de erro

A precisão global apresenta um valor de 0,47 e a percentagem de erro apresenta um valor de 0,53.

⁴⁵ O significado da cada uma das métricas pode ser lida no capítulo “4.6 PRECISÃO TEMÁTICA E MATRIZ DE ERRO”.

6.4.3 Erro de Omissão e Erro de Comissão

A Tabela 1 reporta os erros de omissão e comissão.

Erros de Omissão	Tipos de erro		
		Erro de comissão	
11 Tecido urbano	0,21	11 Tecido urbano	0,38
12 Indústria, comércio e transportes	0,62	12 Indústria, comércio e transportes	0,33
122 Redes viárias e ferroviárias e espaços associados	0,82	122 Redes viárias e ferroviárias e espaços associados	0,52
133 Áreas em construção	1,00		
141 Espaços verdes urbanos	0,67	141 Espaços verdes urbanos	0,23
142 Equipamentos desportivos, culturais e de lazer e zonas históricas	0,52	142 Equipamentos desportivos, culturais e de lazer e zonas históricas	0,73
211 Culturas temporárias de sequeiro	0,88	211 Culturas temporárias de sequeiro	0,63
23 Pastagens permanentes	0,85	23 Pastagens permanentes	0,92
24 Áreas agrícolas heterogêneas	1,00	24 Áreas agrícolas heterogêneas	1,00
243 Agricultura com espaços naturais e semi-naturais	0,83	243 Agricultura com espaços naturais e semi-naturais	0,92
		3 Florestas e meios naturais e seminaturais	1,00
311 Florestas de folhosas	1,00		
312 Florestas de resinosas	1,00	312 Florestas de resinosas	0,20
		313 Florestas mistas	1,00
		32 Florestas abertas e vegetação arbustiva e herbácea	1,00
322 Matos	1,00	322 Matos	1,00
		324 Florestas abertas, cortes e novas plantações	1,00
331 Praias, dunas e areais	0,18	331 Praias, dunas e areais	0,39
332 Rocha nua	1,00		
421 Sapais	1,00		
5 Corpos de água	1,00	5 Corpos de água	1,00
522 Desembocaduras fluviais	1,00		
523 Oceano	1,00		

Tabela 1 - Tipos de erro: omissão e comissão

6.4.5 Precisão no Produtor e Precisão no Utilizador

A Tabela 2 reporta a precisão no produtor e utilizador.

Precisão no produtor	Tipos de erro		
		Precisão no utilizador	
11 Tecido urbano	0,79	11 Tecido urbano	0,62
12 Indústria, comércio e transportes	0,38	12 Indústria, comércio e transportes	0,67
122 Redes viárias e ferroviárias e espaços associados	0,18	122 Redes viárias e ferroviárias e espaços associados	0,48
133 Áreas em construção			
141 Espaços verdes urbanos	0,33	141 Espaços verdes urbanos	0,77
142 Equipamentos desportivos, culturais e de lazer e zonas históricas	0,48	142 Equipamentos desportivos, culturais e de lazer e zonas históricas	0,27
211 Culturas temporárias de sequeiro	0,12	211 Culturas temporárias de sequeiro	0,37
23 Pastagens permanentes	0,15	23 Pastagens permanentes	0,08
24 Áreas agrícolas heterogêneas		24 Áreas agrícolas heterogêneas	
243 Agricultura com espaços naturais e semi-naturais	0,17	243 Agricultura com espaços naturais e semi-naturais	0,08
		3 Florestas e meios naturais e seminaturais	
311 Florestas de folhosas			
312 Florestas de resinosas	0,42	312 Florestas de resinosas	0,80
		313 Florestas mistas	
		32 Florestas abertas e vegetação arbustiva e herbácea	
322 Matos		322 Matos	
		324 Florestas abertas, cortes e novas plantações	
331 Praias, dunas e areais	0,82	331 Praias, dunas e areais	0,61
332 Rocha nua			
421 Sapais			
5 Corpos de água	0,00	5 Corpos de água	
522 Desembocaduras fluviais			
523 Oceano			

Tabela 2 - Tipos de precisão: produtor e utilizador.

6.4.6 Reajuste na precisão

No capítulo “7.3.1 Harmonização entre legenda COS e CLC” é explicado que pelas diferentes UMC associadas às legendas COS e CLC é necessário desconsiderar as áreas <25ha que se encontrem em erro de comissão e corrigir o valor da precisão global. A matriz de erro representada no Quadro 7 mostra a distribuição das áreas inferiores a 25 hectares na carta COS 2018 em relação à classificação CLC de utilizador, viabilizado os reajustes de precisão global, precisão de utilizador e precisão de produtor.

Na Tabela 3 está representado o somatório dos polígonos com área <25ha, que compõem o erro de comissão e omissão. O somatório do erro de comissão permite obter a área incorretamente classificada pelo utilizador em polígonos inferiores a 25ha, devido a diferença de UMC nas cartas COS (1ha) e CLC (25ha) e corrigir as métricas de avaliação temática.

A correção da precisão global foi calculada pela seguinte fórmula:

$$\text{Precisão global corrigida} = \frac{\sum \text{Erro de comissão} < 25\text{ha}}{\text{Área total do município de Almada}} + \text{Precisão global} \Leftrightarrow \\ \Leftrightarrow \frac{2364,3}{7001} + 0,47 = 0,81$$

A precisão global corrigida passa então de 0,47 para 0,8 e mesmo procedimento serve para o ajuste da precisão no produtor e no utilizador (Tabela 4). O ajuste é dado pelas seguintes formulas:

$$\text{Reajuste de precisão no Utilizador} = (1 - \text{Precisão no Utilizador}) * \\ \text{Imprecisão causada no tema por áreas} < 25\text{ha no Utilizador} + \text{Precisão de Utilizador}$$

$$\text{Reajuste de precisão no Produtor} = (1 - \text{Precisão no Produtor}) * \\ \text{Imprecisão causada no tema por áreas} < 25\text{ha no Produtor} + \text{Precisão no Produtor}$$

Ex: Reajuste de precisão no produtor e utilizador para o tema “11 Tecido Urbano”:

$$\text{Reajuste.produtor} = (1 - 0,79) * 0,53 + 0,79 = 0,90$$

$$\text{Reajuste.utilizador} = (1 - 0,62) * 0,79 + 0,62 = 0,92$$

Imprecisão provocada por diferentes UMC (1ha e 25ha)	Matriz de erro		COS 2018 (áreas <25ha)		Imprecisão provocada por UMC <25	
	Σ (ha) erro de Comissão	Σ (ha) erro de Omissão	Σ Polígonos em erro de Comissão <25ha	Σ Polígonos em erro de Omissão <25ha	Relação entre erro de Comissão causado por áreas <25ha e erro de Comissão total da classe	Relação entre erro de Omissão causado por áreas <25ha e erro de Omissão total da classe
11 Tecido urbano	1280	553	1012	295	0,79	0,53
12 Indústria, comércio e transportes	98	331	40	312	0,41	0,94
122 Redes viárias e ferroviárias e espaços associados	44	186	33	32	0,75	0,17
133 Áreas em construção		50		50		1,00
141 Espaços verdes urbanos	11	71	7	65	0,69	0,92
142 Equipamentos desportivos, culturais e de lazer e zonas históricas	302	123	104	91	0,34	0,74
211 Culturas temporárias de sequeiro	120	520	104	295	0,86	0,57
23 Pastagens permanentes	321	157	196	131	0,61	0,84
24 Áreas agrícolas heterogéneas	174	25	102	25	0,59	1,00
243 Agricultura com espaços naturais e semi-naturais	415	170	327	170	0,79	1,00
3 Florestas e meios naturais e seminaturais	2		2		1,00	
311 Florestas de folhosas		331		91		0,27
312 Florestas de resinosas	142	768	67	492	0,48	0,64
313 Florestas mistas	138		47		0,34	
32 Florestas abertas e vegetação arbustiva e herbácea	76		46		0,61	
322 Matos	186	364	21	280	0,11	0,77
324 Florestas abertas, cortes e novas plantações	273		194		0,71	
331 Praias, dunas e areais	84	30	39	10	0,47	0,32
332 Rocha nua		7		7		1,00
421 Sapais		2		2		1,00
5 Corpos de água	38	1	22	1	0,57	1,00
522 Desembocaduras fluviais		6		6		1,00
523 Oceano		10		10		1,00
Acumulado	3705	3705	2364	2364		
Precisão global corrigida	0,8					
Percentagem de erro corrigida	0,2					

Tabela 3 - Imprecisão provocada por diferentes UMC (1ha e 25ha).

Precisão de utilizador		Utilizador Ajustado	Precisão do produtor		Produtor Ajustado
11 Tecido urbano	0,62	0,92	11 Tecido urbano	0,79	0,90
12 Indústria, comércio e transportes	0,67	0,81	12 Indústria, comércio e transportes	0,38	0,96
122 Redes viárias e ferroviárias e espaços associados	0,48	0,87	122 Redes viárias e ferroviárias e espaços associados	0,18	0,32
			133 Áreas em construção		1,00
141 Espaços verdes urbanos	0,77	0,93	141 Espaços verdes urbanos	0,33	0,95
142 Equipamentos desportivos, culturais e de lazer e zonas históricas	0,27	0,52	142 Equipamentos desportivos, culturais e de lazer e zonas históricas	0,48	0,86
211 Culturas temporárias de sequeiro	0,37	0,91	211 Culturas temporárias de sequeiro	0,12	0,62
23 Pastagens permanentes	0,08	0,64	23 Pastagens permanentes	0,15	0,86
24 Áreas agrícolas heterogéneas		0,59	24 Áreas agrícolas heterogéneas		1,00
243 Agricultura com espaços naturais e semi-naturais	0,08	0,80	243 Agricultura com espaços naturais e semi-naturais	0,17	1,00
3 Florestas e meios naturais e seminaturais		1,00			
			311 Florestas de folhosas		0,27
312 Florestas de resinosas	0,80	0,89	312 Florestas de resinosas	0,42	0,79
313 Florestas mistas		0,34			
32 Florestas abertas e vegetação arbustiva e herbácea		0,61			
322 Matos		0,11	322 Matos		0,77
324 Florestas abertas, cortes e novas plantações		0,71			
331 Praias, dunas e areais	0,61	0,79	331 Praias, dunas e areais	0,82	0,87
			332 Rocha nua		1,00
			421 Sapais		1,00
5 Corpos de água		0,57	5 Corpos de água	0,00	1,00
			522 Desembocaduras fluviais		1,00
			523 Oceano		1,00

Tabela 4 - Valor de precisão de utilizador e produtor ajustados.

CAPÍTULO VII -RESULTADOS E CONSIDERAÇÕES FINAIS

O método classificativo ao objeto pela legenda CLC e sua avaliação qualitativa tendo como referência a legenda da carta COS 2018 para o município de Almada, tem de ter em conta nas suas considerações finais a UMC (pré e pós reajuste) da CLC e COS 2018, para correta contabilização das áreas corretamente e incorretamente classificadas. Por isso, devem ser analisados os resultados tendo em consideração dois momentos: 1º análise da precisão sem a contabilização do erro associado a áreas com <25ha; 2º análise da precisão tendo em conta o erro associado a áreas com <25ha. Lembrando que no segundo momento, deve-se ao facto de a classificação do utilizador, ter obedecido aos critérios de UMC = 25ha impostos pela legenda CLC, que diferem da UMC = 1ha referentes a carta COS 2018.

A matriz de erro permite obter as métricas de exatidão temática (precisão global, percentagem de erro, erro de omissão, erro de comissão, precisão no produtor e precisão no utilizador). No primeiro momento de análise, isto é, desconsiderando o erro associado a área com <25ha, a precisão global foi de 47%, que é um resultado insatisfatório; com a exclusão das áreas incorretamente classificadas com dimensão <25ha, a precisão global situou-se nos 81%, que já pode ser considerado uma precisão aceitável. E serão considerados aceitáveis, valores de precisão iguais ou superiores a 80%.

Sem considerar o ajuste às áreas incorretamente classificadas <25ha, a precisão aceitável de 80%, ao nível do tema foi detetada duas vezes, uma na precisão no produtor e outra na precisão no utilizador. Na precisão no produtor, a classe “331 Praias, dunas e areais” apresentou uma precisão de 82% e na precisão no utilizador a classe “312 Florestas de resinosas” apresentou uma precisão de 80%. Considerando o ajuste que deve ser efetuado, de atenuar da imprecisão as áreas incorretamente classificadas inferiores a 25ha (Tabela 4), os temas que simultaneamente obtiveram tanto uma exatidão temática mínima de 80% na precisão de produtor e na precisão no utilizador foram os seguintes: “11 Tecido urbano” (92%; 90%); “12 Indústria, comércio e transportes” (81%; 96%); “141 Espaços verdes urbanos (93%; 95%)” e “243 Agricultura com espaços naturais e semi-naturais” (80%; 100%). Excecionalmente a classe “331

Praias, dunas e areais” irá ser incluída nas classes que cumprem a precisão simultânea de 80% entre precisão no utilizador e produtor por dois motivos: o primeiro é o facto da sua precisão no utilizador se encontrar apenas a 1 ponto percentual dos 80% (79%) e a sua precisão de produtor se situar nos 87%, o segundo motivo deriva de neste tema as técnicas de GEOBIA apresentarem indícios de possibilidade de automatizar a sua classificação.

Percebendo as classes que atingiram valores de precisão em níveis aceitáveis, importa perceber como as técnicas GEOBIA, enquanto abordagem híbrida (reconhecimento espectral e geométrico) aplicadas na classificação de dados orbitais Sentinel-2 MSI para o município de Almada permitiram automatizar procedimentos na produção de uma carta temática (tomando como exemplo a nomenclatura CLC), encurtando o tempo e subjetividade do processo classificativo. E sob este aspecto a conclusão é de que com dados Sentinel-2 MSI, ou seja, com uma imagem constituída por pixels de 100m², os procedimentos onde as técnicas de GEOBIA foram vantajosas na redução do tempo de análise visual e permitiram acelerar e automatizar procedimentos classificativos, nasceram da aplicação de limiares (*thresholds*) referentes à geometria (área e comprimento/largura), valor espectral e relações de vizinhança (fronteira) dos objetos. Limiares de área permitiram restringir as classificações apenas aos objetos que cumprissem a UMC exigida pela nomenclatura CLC, a relação comprimento/largura foi útil na distinção de temas com aspeto longilíneo (praias e rede viária), o valor espectral como unidade fundamental em deteção remota foi determinante para distinguir os temas no seu nível mais agregado (nível 1 e nível 2 “11 Tecido urbano”) e por último as questões de fronteira mostram-se especialmente adequadas para classificar as áreas de praia.

Contudo e para concluir, a aplicação de técnicas GEOBIA, com vista a automatização do processo classificativo, obteve uma resposta bastante satisfatória quando aplicados ao tema “331 Praias, dunas e areais” onde foi possível identificar um conjunto de procedimentos passíveis de serem replicados, e por isso mesmo automatizados. No capítulo “6.2 OPERACIONALIZAÇÃO DA EXTRAÇÃO DE CLASSES” a classificação do tema “331 Praias, dunas e areais” obedeceu aos seguintes critérios de classificação: *Class filter = 1.2.2 Redes viárias e ferroviárias e espaços associados,*

Length/Width ≥ 10 e *Rel. Border to 5 Corpos de água* > 0 . Isto significa que para o tema “122 Redes viárias e ferroviárias e espaços associados” os objetos longilíneos “*Length/Width* ≥ 10 ” que tocassem o oceano “*Rel. Border to 5 Corpos de água* > 0 ” deveriam ser classificados como 331 Praias, dunas e areais”.

É, portanto, possível perceber pelos procedimentos acima descritos que os dados Sentinel-2 MSI permitem identificar geometricamente, objetos com espectro longilíneos, que é o formato característico de areais/praias, onde se insere a classe “331 Praias, dunas e areais”. Deduzindo que todas as praias tocam o oceano, que por ser uma superfície aquosa é facilmente identificado com valores de NDVI negativos, é possível automatizar procedimentos de classificação automática para praias, na nomenclatura CLC “331 Praias, dunas e areais”. Para isso terá de ser montado um *script* (conjunto de procedimentos) que cumpra duas etapas: primeiro, marcar todos os objetos com aspeto longilíneo, como forma de identificar os objetos com o formato de areal ou praia, para em seguida serem identificados dos objetos anteriores, aqueles que tocam o oceano e serem classificados como “331 Praias, dunas e areais”.

Em contexto de *software eCognition* o procedimento descrito acima é facilmente executado com recurso ao classificador *Assing Class*, contudo classificação pode ser refinada com a classificação dos objetos contidos na área de praia que não tenham sido classificados como tal e não cumpram a unidade mínima cartográfica (Ex. 25ha no caso da legenda CLC). Para isso a ferramenta *find enclosed by class* permite atribuir a todos os objetos com área inferior à UMC, e que se insiram na classe alvo (Ex. “331 Praias, dunas e areais”) a (re)classificação dos mesmos, ou então podem ser classificados os objetos rodeados a 100% pelo tema “331 Praias, dunas e areais” com área inferior à UMC, com recurso ao classificador *Assing Class*. Ainda em *softwear eCognition* e cumprindo as regras associadas à nomenclatura CLC, isto é, com UMC de 25ha, o conjunto de procedimentos a serem executados para classificar de forma automática o tema “331 Praias, dunas e areais” está representado na Figura 84.

Nota: Os procedimentos têm em conta os critérios específicos de segmentação apresentados no capítulo “CAPÍTULO VI -PROCEDIMENTOS”, principalmente o Scale parameter = 80 para o algoritmo de segmentação Multi-resolution Segmentation e a classificação prévia do tema que represente o oceano, no caso “5 Corpos de água”.

Script para classificação automática do tema “Praias, dunas e areais”

- **Passo 1** = Classificar objetos longilíneos que toquem o “Oceano”.
- **Passo 2** = Classificar os objetos contidos que tenham área inferior à UMC.

❑ **Passo 1:**

- Assing Class:
 - Class filter -> All
 - Thresholds -> Length/Width >=10 / Rel. Border to 5 Corpos de água > 0
(Nota: Corpos de água ou classe que represente o oceano)
 - Use class -> “Praias, dunas e areais”
- Merge region:
 - Class filter -> “Praias, dunas e areais”
 - Fusion super objects -> Yes

❑ **Passo 2** (“Find enclosed by class” ou “Assing Class”)

2A) Find enclosed by class”:

- Class filter -> “Praias, dunas e areais”
- Thresholds -> Area (ha) < 25(ha)
- Use class -> “Praias, dunas e areais”

○ Merge region:

- Class filter -> “Praias, dunas e areais”
- Fusion super objects -> Yes

2B) Assing Class:

- Class filter -> All
- Thresholds -> Rel. Border to “Praias, dunas e areais” > 1 / Area (ha) < 25(ha)
- Use class -> “Praias, dunas e areais”

○ Merge region:

- Class filter -> “Praias, dunas e areais”
- Fusion super objects -> Yes

Figura 84 - Script para classificação automática do tema “Praias, dunas e areais”.

No primeiro passo é pedido para classificar os objetos que toquem o tema “5 Corpos de água” e apresentem um formato longilíneo, representando a classe “331 Praias, dunas e areais”. No segundo passo são considerados os objetos com área <25ha e que se encontrem contidos no tema “331 Praias, dunas e areais”, ou seja, que não cumprem a UMC = 25ha exigida pela nomenclatura CORINE Land Cover e que por isso mesmo devem ser entendidos como pertencentes a sua classe envolvente “331 Praias, dunas e areais”. O segundo passo pode ser executado dizendo ao *software* que os objetos contidos no tema “331 Praias, dunas e areais” e com área inferior a 25 hectares, são do tipo “331 Praias, dunas e areais” (**passo 2A**) ou então pode-se dizer ao *software* que os objetos fechados pelo tema “331 Praias, dunas e areais” (ou seja, contidos!) e que tenham uma área inferior a 25 hectares são do tipo “331 Praias, dunas e areais” (**passo 2B**). Na presente dissertação foi executada a opção 2A.

REFERÊNCIAS BIBLIOGRÁFICAS

- European Environment Agency (1995). *Copernicus Land Monitoring Services*. Retrieved from <http://land.copernicus.eu/>
- European Environment Agency (2018). *Copernicus Land Monitoring Services*. Retrieved from <http://land.copernicus.eu/>
- Blaschke, Thomas; Lang, Stefan; Hay, G. (2008). *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications*. Retrieved from <http://www.springer.com/gb/book/9783319142791>
- Büttner, G., Kosztra, B., Soukup, T., Sousa, A., & Langanke, T. (2017). *CLC2018 Technical Guidelines*. Retrieved from https://land.copernicus.eu/user-corner/technical-library/clc2018technicalguidelines_final.pdf
- Caetano, M., Igreja, C., & Filipe, M. (2018). *Carta de Uso e Ocupação do Solo de Portugal Continental para 2015*.
- Cazaubiel, V., Chorvalli, V., & Miesch, C. (2017). *The multispectral instrument of the Sentinel2 program*. 10566(October 2008), 95. <https://doi.org/10.1117/12.2308278>
- Chen, G., Weng, Q., Hay, G. J., & He, Y. (2018). Geographic object-based image analysis (GEOBIA): emerging trends and future opportunities. *GIScience and Remote Sensing*, 55(2), 159–182. <https://doi.org/10.1080/15481603.2018.1426092>
- Congalton, R. G., & Green, K. (2019). Assessing the Accuracy of Remotely Sensed Data. In *Assessing the Accuracy of Remotely Sensed Data*. <https://doi.org/10.1201/9780429052729>
- Direção-Geral do Território. (2019). *Especificações Técnicas da Carta de Uso e Ocupação do Solo (COS) de Portugal Continental para 2018*.
- Doty, J. M. (2005). Geospatial Intelligence: An Emerging Discipline in National Intelligence with an Important Security Assistance Role. *DISAM Journal of International Security Assistance Management*, 27(3), 1–14. Retrieved from <http://libpublic3.library.isu.edu/login?url=http://search.ebscohost.com/login.aspx?direct=true&db=a9h&AN=17531729&site=eds-live>

- ESA. (2015). *ESA's Optical High-Resolution Mission for GMES Operational Services* (K. Fletcher, Ed.). ESA Communications.
- Gupta, R. P. (2017). Remote sensing geology: Third edition. In *Remote Sensing Geology: Third Edition*. <https://doi.org/10.1007/978-3-662-55876-8>
- Henebry, G., Viña, A., & Gitelson, A. (2004). The wide dynamic range vegetation index and its potential utility for gap analysis. *Papers in Natural Resources*, 50–56. Retrieved from <http://digitalcommons.unl.edu/natrespapers/262/>
- JameS B. CampBell, R. h. W. (2011). *Introduction to Remote Sensing* (Fifth ed).
- Kuchler, D. A., Jupp, D. L. B., Daniel, D. B., & Bour, W. (1986). Coral reef remote sensing applications. In *Geocarto International* (Vol. 1). <https://doi.org/10.1080/10106048609354064>
- Lal, R., & Nizeyimana, E. (2005). Remote Sensing and GIS Integration. In *Encyclopedia of Soil Science, Second Edition*. <https://doi.org/10.1201/noe0849338304.ch309>
- Li, L., Zhou, H., Wen, Q., Chen, T., Guan, F., Ren, B., ... Wang, Z. (2018). Automatic extraction of urban built-up area based on object-oriented method and remote sensing data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42(3), 877–883. <https://doi.org/10.5194/isprs-archives-XLII-3-877-2018>
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P., & Liu, Y. (2017). A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130(June), 277–293. <https://doi.org/10.1016/j.isprsjprs.2017.06.001>
- Meneses, P. R., & Almeida, T. De. (2012). *Introdução ao Processamento de Imagens de Sensoriamento Remoto*.
- Rissini, A. L. L., Kawakami, J., & Genú, A. M. (2015). Índice De Vegetação Por Diferença Normalizada E Produtividade De Cultivares De Trigo Submetidas a Doses De Nitrogênio. *Revista Brasileira de Ciencia Do Solo*, 39(6), 1703–1713. <https://doi.org/10.1590/01000683rbcs20140686>
- Ross S. Lunetta, J. G. L. (2004). *Remote sensing and GIS accuracy assessment*. CRC Press.

SUHET. (2013). *L-2 User Handbook Sentinel-2 User Handbook*.
<https://doi.org/10.1021/ie51400a018>

Thomas M. Lillesand, Ralph W. Kiefer, J. W. C. (2015). Remote Sensing and Image Interpretation. In *Journal of Chemical Information and Modeling* (Seventh ed, Vol. 53). <https://doi.org/10.1017/CBO9781107415324.004>

Trimble Germany. (2014a). *eCognition Developer 9.0. Reference Book*.

Trimble Germany. (2014b). *eCognition Developer 9.0 User Guide*.

Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*, 2017. <https://doi.org/10.1155/2017/1353691>

Yang, L., Mansaray, L. R., Huang, J., & Wang, L. (2019). Optimal segmentation scale parameter, feature subset and classification algorithm for geographic object-based crop recognition using multisource satellite imagery. *Remote Sensing*, 11(5). <https://doi.org/10.3390/rs11050514>

Outras

Julião, R. P. (2015). Conteúdos lecionados na licenciatura de *Geografia e Planeamento Regional*, unidade curricular de “Sistemas de Informação Geográfica” do ano letivo 2015-2016.

Tenedório, J. A. (2017). Conteúdos lecionados no mestrado de *Gestão do Território com especialidade em Sistemas de Informação Geográfica e Deteção Remota*, unidade curricular de “Deteção Remota e Processamento Digital de Imagem” do ano letivo 2018-2019.

ÍNDICE DE FIGURAS

Figura 1 - Direção de propagação da radiação eletromagnética na forma de uma onda, em função das oscilações. Fonte: Meneses & Almeida (2012).	5
Figura 2 - Divisão do espectro eletromagnético. Fonte: Meneses & Almeida (2012).	5
Figura 3 - Divisões dos comprimentos de ondas das cores da região do visível. Fonte: Meneses & Almeida (2012).	5
Figura 4 - Assinaturas espectrais de água, vegetação e solo. Fonte: Lal & Nizeyimana (2005).....	6
Figura 5 – Detecção remota de recursos terrestres. Fonte: Thomas M. Lillesand, Ralph W. Kiefer(2015)	8
Figura 6 - Satélite a atingir a órbita. Fonte: https://www.esa.int/Enabling_Support/Space_Transportation/Types_of_orbits	9
Figura 7 - Lançamento do rocket (linha amarela), começo da órbita de transferência (linha azul) quando o rocket solta o satélite no espaço e esta caminha para a órbita geostacionária (linha vermelha). Fonte: https://www.esa.int/Enabling_Support/Space_Transporta	11
Figura 8 - Extrato de cartografia a escala 1: 10 000. Fonte: https://www.dgterritorio.gov.pt/cartografia/cartografia-topografica/scn10k	13
Figura 9 - Cobertura e resolução temporal para os dados Sentinel 2-MSI. Fonte: https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/revisit-coverage ...	14
Figura 10 - Satélite Terra: Incêndios ativos no mês de agosto em 2020. Fonte: https://earthobservatory.nasa.gov/global-maps/MOD14A1_M_FIRE	15
Figura 11 - Satélite Aura: Concentrações médias anuais de HCHO no ar e risco de cancro. Fonte: https://aura.gsfc.nasa.gov/science/feature-201711a.html	15
Figura 12 – Satélite OCO-2: Anomalias de CO2 na atmosfera. Fonte: https://earthobservatory.nasa.gov/images/89117/satellite-detects-human-contribution-to-atmospheric-co2	16

Figura 13 - Satélite GRACE-FO: Lençóis de água á superfície. Fonte: https://earthobservatory.nasa.gov/images/144417/soggy%202018%20for%20the%20eastern%20us	16
Figura 14 - Satélite Jason-2 e Jason-3: El Niño: 1997-1998 vs. 2015-2016. Fonte: https://sealevel.jpl.nasa.gov/data/el-nino-la-nina-watch-and-pdo/el-nino-2015/	17
Figura 15 - Satélite SMAP: Água contida no solo. Fonte: https://earthobservatory.nasa.gov/images/92583/a%20mid%20winter%20drought%20in%20australia	17
Figura 16 - Produtos e serviços "Copernicus Land Monitoring Service". Fonte: (EEA, 2018)	20
Figura 17 - Inventário CLC.....	21
Figura 18 - Exemplo de matriz de erro. Fonte: Ross S. Lunetta (2004).....	29
Figura 19 - A fundação e evolução da Inteligência Geoespacial. Fonte: Doty, (2005)...	32
Figura 20 - Estrutura tradicional de trabalho em GEOBIA. Fonte: Chen, Weng, Hay, & He (2018).....	33
Figura 21 - Algoritmos de segmentação, Quadtree-Based Segmentation e Multiresolution Segmentation. Fonte: Trimble Germany, 2014.....	35
Figura 22 - Uso de ferramentas de remodelagem em objetos. Fonte: eCognition Webinar: Image Object Refinement Techniques.	36
Figura 23 - Enquadramento da área de estudo.....	38
Figura 24 - Filtros espectrais para VNIR e SWIR. Fonte: Cazaubiel, Chorvalli, & Miesch (2017).....	40
Figura 25 - Telescópio do tipo Three-Mirror Anastigmatic (TMA). Fonte: Cazaubiel, Chorvalli, & Miesch (2017)	40
Figura 26 - Bandas espectrais do Sentinel-2 MSI e resolução espacial. Fonte: ESA (2015)	41
Figura 27 - Elementos que compõem o Multiresolution Segmentation (MRS).	47

Figura 28 - Subset ajustado ao município de Almada.	49
Figura 29 - Fluxo de classes extraídas em software eCognition.....	50
Figura 30 - Peso da layer Red na segmentação de objetos em zona de fronteira de territórios artificializados e áreas agrícolas e agroflorestais.....	51
Figura 31 - Classificação de “1.1 tecido urbano” para objetos com Stand.Dev ≥ 210 e ≤ 410	52
Figura 32 - Tecido Urbano incorretamente classificado em praia.	53
Figura 33 - Resultado da remoção de tecido urbano em praia.....	53
Figura 34 – Diferença na segmentação com vista a extração de “3. Florestas e meios naturais e semi-naturais” e a segmentação com vista o “1.1 tecido urbano”, mantendo o SP = 80.	54
Figura 35 - Teste de índices para classificação de “3. Florestas e meios naturais e semi-naturais”	55
Figura 36 - Classificação de “3. Florestas e meios naturais e semi-naturais”.	56
Figura 37 - Classificação de “2. Áreas agrícolas e agroflorestais”.	56
Figura 38 - Classificação de “5. Corpos de água”.	56
Figura 39 - Reclassificação dos pigmentos de "5. Corpos de água".....	57
Figura 40 - Objetos candidatos á classe (azul) e objetos classificados (vermelho).....	58
Figura 41 - Limites irregulares e classes contidas.	59
Figura 42 - Suavização de limites e reclassificação de classes contidas em “3.3.1 Praias, dunas e areais”.	59
Figura 43 - Correção de ondas de rebentação.	59
Figura 44 - Classificação do tema "3.2.2 Matos".....	60
Figura 45 - Distancia >6 km de "3.2.2 Matos".	60
Figura 46 - Objetos com WDRVI ≥ -0.24	60
Figura 47 - Classificação de “3.1.3 Florestas mistas”.	61

Figura 48 - Objetos isolados.	61
Figura 49 - WDRVI \geq -0.20 para "3.1.2 Florestas de resinosas".	62
Figura 50 - Classificação da classe "3.1.2 Florestas de resinosas".	62
Figura 51 - Mancha verde alvo de classificação para "3.1.2 Florestas de resinosas". ...	62
Figura 52 - Área alvo de classificação.	63
Figura 53 - Classificação da classe "2.4.3 Agricultura com espaços naturais e seminaturais".	63
Figura 54 - Thresholds para classificação inicial.	64
Figura 55 - Classificação inicial para "2.3 Pastagens permanentes ".	64
Figura 56 - Classificação final para "2.3 Pastagens permanentes".	64
Figura 57 - Área alvo de classificação.	65
Figura 58 - Thresholds para classificação inicial.	65
Figura 59 - Classificação final para "1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas".	66
Figura 60 - Área alvo de classificação.	66
Figura 61 - Classificação final para "1.2 Indústria, comércio e transportes".	67
Figura 62 - Thresholds para classificação inicial.	67
Figura 63 - Localização da classe "2.4 Áreas agrícolas heterogéneas ".	67
Figura 64 - Classificação final para "2.4 Áreas agrícolas heterogéneas"	68
Figura 65 – Área alvo pré-simplificação.	69
Figura 66 - Área alvo pós-simplificação.	70
Figura 67 - Localização da classe "1.4.1 Espaços verdes urbanos".	70
Figura 68 - Classificação final para "1.4.1 Espaços verdes urbanos".	71
Figura 69 - Classificação final para "3.1.3 Florestas mistas".	71

Figura 70 - Classificação final para “2.4.3 Agricultura com espaços naturais e semi-naturais”	72
Figura 71 - Aumento da extensão da classe “2.4.3 Agricultura com espaços naturais e semi-naturais” a norte do município.....	72
Figura 72 - Localização da classe “1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas”.....	73
Figura 73 - Classificação final para "1.4.2 Equipamentos desportivos, culturais e de lazer e zonas históricas"	73
Figura 74 - Classificação final para “3.2.4 Florestas abertas, cortes e novas plantações”.	74
Figura 75 - Localização das áreas para a classe “3.2.4 Florestas abertas, cortes e novas plantações”.....	74
Figura 76 - Localização da classe “2.1.1 Culturas temporárias de sequeiro”	75
Figura 77 – Classificação final para “2.1.1 Culturas temporárias de sequeiro”	75
Figura 78 - Classificação final para “3.2 Florestas abertas e vegetação arbustiva e herbácea”	76
Figura 79 - Classificação final para “2.4 Áreas agrícolas heterogéneas”.....	76
Figura 80 - Classificação final para “2.3 Pastagens permanentes”	77
Figura 81 - Exemplo objetos <25ha que unidos cumprem a UCM e foram reclassificados.	77
Figura 82 - Exemplo de classificação para "Unclassified " onde se verifica uma área <25ha.....	78
Figura 83 - Temas CLC extraídos pelo utilizador para o município de Almada.	82
Figura 84 - Script para classificação automática do tema “Praias, dunas e areais”	94

ÍNDICE DE FLUXOGRAMAS

Fluxograma 1 -Procedimentos gerais executados.....	46
--	----

ÍNDICE DE QUADROS

Quadro 1- Características espectrais e espaciais do Sentinel-2 MSI.....	41
Quadro 2 - Legenda CORINE Land Cover. Fonte: Direção Geral do Território (2010); Fonte: copernicus.eu	42
Quadro 3 – 1º parte da Legenda da Carta de Uso e Ocupação do Solo (COS). Fonte: Direção-Geral do Território (2019).....	43
Quadro 4 - 2º parte da Legenda da Carta de Uso e Ocupação do Solo (COS). Fonte: Direção-Geral do Território (2019).....	44
Quadro 5 - Adaptação dos temas COS a temas CLC.....	83
Quadro 6 - Matriz de erro. Classificação eCognition (2019) e COS (2018)	85
Quadro 7 - Matriz de erro para áreas <25ha. Classificação eCognition (2019) e COS (2018)	86

ÍNDICE DE TABELAS

Tabela 1 - Tipos de erro: omissão e comissão.....	87
Tabela 2 - Tipos de precisão: produtor e utilizador.	87
Tabela 3 - Imprecisão provocada por diferentes UMC (1ha e 25ha).	89
Tabela 4 - Valor de precisão de utilizador e produtor ajustados.	90

ÍNDICE DE MAPAS

Mapa 1 - Ocupação e uso do solo para o concelho de Almada, de acordo com a nomenclatura CLC.....	79
Mapa 2 - Adaptação da legenda COS 2018 para CLC no município de Almada.....	84

ANEXOS

ANEXO A: Algumas das definições para detecção remota

Remote sensing has been variously defined but basically it is the art or science of telling something about an object without touching it. (Fischer et al., 1976, p. 34)

Remote sensing is the acquisition of physical data of an object without touch or contact. (Lintz and Simonett, 1976, p. 1)

Imagery is acquired with a sensor other than (or in addition to) a conventional camera through which a scene is recorded, such as by electronic scanning, using radiations outside the normal visual range of the film and camera—microwave, radar, thermal, infrared, ultraviolet, as well as multispectral, special techniques are applied to process and interpret remote sensing imagery for the purpose of producing conventional maps, thematic maps, resources surveys, etc., in the fields of agriculture, archaeology, forestry, geography, geology, and others. (American Society of Photogrammetry)

Remote sensing is the observation of a target by a device separated from it by some distance. (Barrett and Curtis, 1976, p. 3)

The term “remote sensing” in its broadest sense merely means “reconnaissance at a distance.” (Colwell, 1966, p. 71)

Remote sensing, though not precisely defined, includes all methods of obtaining pictures or other forms of electromagnetic records of the Earth’s surface from a distance, and the treatment and processing of the picture data. . . . Remote sensing then in the widest sense is concerned with detecting and recording electromagnetic radiation from the target areas in the field of view of the sensor instrument. This radiation may have originated directly from separate components of the target area; it may be solar energy reflected from them; or it may be reflections of energy transmitted to the target area from the sensor itself. (White, 1977, pp. 1–2)

“Remote sensing” is the term currently used by a number of scientists for the study of remote objects (earth, lunar, and planetary surfaces and atmospheres, stellar and galactic phenomena, etc.) from great distances. Broadly defined . . . , remote sensing denotes the joint effects of employing modern sensors, data-processing equipment, information theory and processing methodology, communications theory and devices, space and airborne vehicles, and large-systems theory and practice for the purposes of carrying out aerial or space surveys of the earth’s surface. (National Academy of Sciences, 1970, p. 1)

Remote sensing is the science of deriving information about an object from measurements made at a distance from the object, i.e., without actually coming in contact with it. The quantity most frequently measured in present-day remote sensing systems is the electromagnetic energy emanating from objects of interest, and although there are other possibilities (e.g., seismic waves, sonic waves, and gravitational force), our attention . . . is focused upon systems which measure electromagnetic energy. (D. A. Landgrebe, quoted in Swain and Davis, 1978, p. 1)

Anexo A - Detecção Remota: Algumas definições. Fonte: (James B. CampBell, 2011)

ANEXOS B e C - MATRIZ DE ERRO E PRECISÃO TEMÁTICA ENTRE CLASSIFICAÇÃO DE UTILIZADOR E CLC (2018):

Para efeitos de dissertação, a classificação de referência que foi tida em conta é a COS 2018, contudo segue em anexo a matriz de erro (Anexo B) e os valores de precisão temática (Anexo C), entre a classificação efetuada em software *eCognition* (classificação de utilizador) e a classificação CLC de 2018, disponibilizada na plataforma de dados abertos *Copernicus* (classificação de referência).

		Classes da classificação "Copernicus (CLC) 2018"																		
Classes da classificação eCognition 2019	Matriz de erro (área em ha)	11	12	122	141	142	211	231	24	243	3	312	313	322	324	331	421	5	Área total (ha)	Índice de ocupação do solo
	Classes CORINE Land Cover	11	12	122	141	142	211	231	24	243	3	312	313	322	324	331	421	5		
11		2545	218	14	60	59	61	36	102	121	0	19	14	4	73	15		17	3358	48,0
12		36	261												0		0	1	298	4,3
122		31	10	21	1				2	11		1			8				85	1,2
141		0	0	4	41				0										46	0,7
142		124				272		2				17	1			0			416	5,9
211		84	1				81	2		23					1				190	2,7
23		58	7			0	87	148		25			0	25	0				349	5,0
24		5	20	4		0	11		128			3		3	0				174	2,5
243		25	56	20	16		11	34		273		6			2			7	450	6,4
3		0													2				2	0,0
312		81	4			0			1			552		23	32	10			703	10,0
313		9		4		1				28		23	67		6	0			138	2,0
32		19													57				76	1,1
322			0			4			13			3		155		11			186	2,7
324		80					15	22	18	27		21		1	90				273	3,9
331		17				3						3	0	36		155		4	218	3,1
5		1	16	0	0					1		0	0			2		17	38	0,5
Área total (ha)		3115	592	66	119	339	266	243	264	509	0	649	83	247	271	193	0	45	7001	
Ocupação do solo (%)		44,5	8,5	0,9	1,7	4,8	3,8	3,5	3,8	7,3	0,0	9,3	1,2	3,5	3,9	2,8	0,0	0,6		

Anexo B - Matriz de erro. Classificação eCognition (2019) e CLC (2018).

Métricas de precisão			
Precisão global	0,69	Percentagem de erro	0,31
Tipos de erro		Tipos de erro	
Erros de Omissão		Erro de comissão	
11 Tecido urbano	0,18	11 Tecido urbano	0,24
12 Indústria, comércio e transportes	0,56	12 Indústria, comércio e transportes	0,13
122 Redes viárias e ferroviárias e espaços associados	0,68	122 Redes viárias e ferroviárias e espaços associados	0,75
141 Espaços verdes urbanos	0,65	141 Espaços verdes urbanos	0,10
142 Equipamentos desportivos, culturais e de lazer e zonas históricas	0,20	142 Equipamentos desportivos, culturais e de lazer e zonas históricas	0,35
211 Culturas temporárias de sequeiro	0,70	211 Culturas temporárias de sequeiro	0,58
		23 Pastagens permanentes	0,58
231 Pastagens permanentes	0,39		
24 Áreas agrícolas heterogéneas	0,52	24 Áreas agrícolas heterogéneas	0,27
243 Agricultura com espaços naturais e semi-naturais	0,46	243 Agricultura com espaços naturais e semi-naturais	0,39
3 Florestas e meios naturais e seminaturais	1,00	3 Florestas e meios naturais e seminaturais	1,00
312 Florestas de resinosas	0,15	312 Florestas de resinosas	0,21
313 Florestas mistas	0,19	313 Florestas mistas	0,51
		32 Florestas abertas e vegetação arbustiva e herbácea	1,00
322 Matos	0,37	322 Matos	0,16
324 Florestas abertas, cortes e novas plantações	0,67	324 Florestas abertas, cortes e novas plantações	0,67
331 Praias, dunas e areais	0,20	331 Praias, dunas e areais	0,29
421 Sapais	1,00		
5 Corpos de água	0,63	5 Corpos de água	0,56
Tipos de precisão			
Precisão no produtor		Precisão no utilizador	
11 Tecido urbano	0,82	11 Tecido urbano	0,76
12 Indústria, comércio e transportes	0,44	12 Indústria, comércio e transportes	0,87
122 Redes viárias e ferroviárias e espaços associados	0,32	122 Redes viárias e ferroviárias e espaços associados	0,25
141 Espaços verdes urbanos	0,35	141 Espaços verdes urbanos	0,90
142 Equipamentos desportivos, culturais e de lazer e zonas históricas	0,80	142 Equipamentos desportivos, culturais e de lazer e zonas históricas	0,65
211 Culturas temporárias de sequeiro	0,30	211 Culturas temporárias de sequeiro	0,42
		23 Pastagens permanentes	0,42
231 Pastagens permanentes	0,61		
24 Áreas agrícolas heterogéneas	0,48	24 Áreas agrícolas heterogéneas	0,73
243 Agricultura com espaços naturais e semi-naturais	0,54	243 Agricultura com espaços naturais e semi-naturais	0,61
3 Florestas e meios naturais e seminaturais	0,00	3 Florestas e meios naturais e seminaturais	0,00
312 Florestas de resinosas	0,85	312 Florestas de resinosas	0,79
313 Florestas mistas	0,81	313 Florestas mistas	0,49
		32 Florestas abertas e vegetação arbustiva e herbácea	0,00
322 Matos	0,63	322 Matos	0,84
324 Florestas abertas, cortes e novas plantações	0,33	324 Florestas abertas, cortes e novas plantações	0,33
331 Praias, dunas e areais	0,80	331 Praias, dunas e areais	0,71
421 Sapais	0,00		
5 Corpos de água	0,37	5 Corpos de água	0,44

Anexo C - Métricas de precisão. Classificação eCognition (2019) e CLC (2018).