

UNIVERSIDADE DE LISBOA  
FACULDADE DE CIÊNCIAS  
DEPARTAMENTO DE CIÊNCIAS DA TERRA E ENERGIA



## **Processamento de Dados LiDAR para gerar Conjuntos de Dados Geográficos para apoio à Produção da COS**

Miguel Miranda Barreira Domingues

**Mestrado em Engenharia Geoespacial**

Trabalho de Projeto orientado por:  
Professora Doutora Ana Cristina Navarro Ferreira  
Doutor Pedro José Santos da Costa Benevides

Parte da pesquisa desenvolvida no presente trabalho enquadra-se na Bolsa de Investigação no âmbito das atividades da Direção-Geral do Território relacionadas com a monitorização da ocupação do solo (1/SMOS/2024).

## Agradecimentos

À minha família deixo o meu agradecimento mais sentido. Estiveram na origem de todo este percurso, apoiando-me em cada etapa, desde os primeiros anos de escola até à conclusão deste mestrado. Para além do esforço e do investimento na minha formação, deram-me os valores, a segurança e o ambiente familiar de que precisava para crescer e ir mais longe. Muito do que consigo alcançar, e da pessoa em que me tornei, é reflexo deles.

Aos meus amigos, que estiveram sempre presentes nos momentos certos, seja nas pausas, nas conversas ou no riso, deixo um agradecimento profundo. Tornaram tudo mais leve e ajudaram-me a manter o equilíbrio durante esta etapa exigente.

À Faculdade de Ciências da Universidade de Lisboa e aos seus docentes, que acompanharam e enriqueceram o meu percurso académico, deixo o meu sincero agradecimento. À Carolina Brito, ao Vasco Veiga, ao Tiago Ferreira e ao Paulo Carvalho, bem como a todos os colegas que conheci ao longo destes anos, obrigado por tornarem este caminho mais significativo.

À Direção-Geral do Território, agradeço por todos os ensinamentos nas áreas de cartografia de uso e ocupação do solo. Ao professor Mário Caetano, pela oportunidade de experienciar o trabalho numa entidade de referência como a DGT, ao Francisco Moreira, por todos os concelhos e ajudas a solucionar os problemas, por fim, aos meus colegas António Sequeira, Bernardo Santos, Gonçalo Reis, Henrique Santos, João Fernandes, Pedro Santos, Rita Pereira, Rita Soares, Sérgio Soares e Simão Alves, como os restantes colegas, agradeço pela disponibilidade, apoio e companheirismo.

Quero agradecer de forma especial, e com grande ênfase, aos meus dois orientadores à Professora Ana Navarro e Pedro Benevides, que, de formas diferentes, tiveram um contributo determinante para o desenvolvimento deste trabalho. Agradeço pela orientação rigorosa, pela confiança e pela disponibilidade constante para esclarecer dúvidas e pelo apoio ao longo de todo o processo.

À Matilde, agradeço por tudo, pela paciência, pela compreensão das ausências, pela força que me deste nos momentos em que duvidei, e por acreditares em mim mesmo quando eu já não conseguia. Foste o meu porto seguro durante todo este processo.

E, finalmente, agradeço a mim próprio. Pela resiliência, pela disciplina, por não ter desistido quando tudo parecia difícil, e por ter encontrado força mesmo nos dias em que o cansaço falava mais alto.

A todos, o meu mais profundo obrigado.

## Resumo

O uso de dados LiDAR (*Light Detection and Ranging*) para gerar conjuntos de dados geográficos para a produção e atualização da Carta de Uso e Ocupação do Solo (COS) tornou-se indispensável. A informação tridimensional que os dados oferecem permite ultrapassar as limitações das metodologias tradicionais de fotointerpretação de ortofotos, possibilitando a identificação de alterações no território com mais rapidez e precisão. O objetivo central deste trabalho consistiu em desenvolver um fluxo de processamento de dados LiDAR capaz de detetar automaticamente elementos-chave da paisagem, como manchas florestais, culturas permanentes e edifícios, integrando-os como camadas auxiliares na elaboração da COS. Para esse fim, foram extraídos produtos derivados da nuvem de pontos do LiDAR, incluindo modelos digitais de terreno e de altura (*Canopy Height Model*), os quais se aplicaram algoritmos de segmentação de árvores e copas, e foram efetuadas análises espaciais destinadas a identificar as feições pretendidas. Os resultados foram depois cruzados com a ortofotografia multiespectral para validação temática. A abordagem demonstrou elevada eficácia, distinguindo manchas florestais em mosaicos agroflorestais, identificando pomares, vinhas e olivais pelo padrão geométrico regular e detetando edifícios com maior detalhe e atualidade do que a cartografia existente. A comparação com a COS2023 revelou que mais de 94% da área edificada identificada a partir do LiDAR coincide com o tecido urbano já mapeado, evidenciando simultaneamente novas construções e expansões urbanas ainda não cartografadas. O trabalho comprova as vantagens da integração de dados LiDAR na atualização cartográfica. A informação tridimensional permite acelerar os ciclos de revisão da COS, melhorar a precisão temática e espacial do produto e apoiar a tomada de decisão com os dados mais atuais. Este contributo estabelece o caminho para um sistema de alerta geográfico capaz de sinalizar mudanças significativas na ocupação do solo, reforçando a capacidade da Direção-Geral do Território (DGT) para monitorizar o território de forma mais eficiente.

Palavras-chave: LiDAR, Carta de Uso e Ocupação do Solo (COS), Detecção Remota, Classificação do Solo, Cartografia Temática

## Abstract

The use of LiDAR (Light Detection and Ranging) data to generate geographic datasets for the production and updating of the Land Use and Land Cover Map (COS) has become indispensable. The three-dimensional information offered by the data makes enables overcoming the limitations of traditional orthophoto photointerpretation methodologies, allowing the identification of territorial changes more quickly and accurately. The main objective of this work consisted of developing a LiDAR data processing workflow that automatically detects key landscape elements, such as forest patches, permanent crops, and buildings, and integrates them as auxiliary layers in the preparation of the COS. To this end, products derived from the LiDAR point cloud, including digital terrain and height models (*Canopy Height Model*), to which tree and canopy segmentation algorithms were applied, and spatial analyses aimed at identifying the desired features were performed. The results were then cross-referenced with multispectral orthophotography for thematic validation. The approach demonstrated high effectiveness, in distinguishing forest patches in agroforestry mosaics, identifying orchards, vineyards, and olive groves by their regular geometric pattern, and detecting buildings with greater detail and up-to-dateness than existing cartography. Comparison with the COS2023 revealed that more than 94% of the built-up area identified from the LiDAR data coincides with the already mapped urban fabric, while simultaneously evidencing new constructions and urban expansions. The work proves the advantages of integrating LiDAR data into cartographic updating. The three-dimensional information accelerates the COS reviewing cycles, improves the thematic and spatial accuracy of the product, and supports decision-making with the most up-to-data. This contribution paves the way for a geographic alert system capable of signalling significant changes in land occupation, strengthening the capacity of the Direção-Geral do Território (DGT) to monitor the territory more efficiently.

KeyWords: LiDAR, Land Use and Land Cover Map, Remote Sensing, Land Cover Classification, Thematic Mapping

## Lista de abreviaturas, siglas e acrónimos

3DEP – 3D Elevation Program  
AEA – Agência Europeia do Ambiente (*European Environment Agency*, EEA)  
ALS – Airborn Laser Scanning  
ASPRS – *The American Society for Photogrammetry & Remote Sensing*  
CCC – Conselho Coordenador de Cartografia  
CE – Comissão Europeia  
CHM – *Canopy Height Model* (Modelo de Altura do Coberto)  
CNGIFR – Comissão Nacional de Gestão Integrada de Fogos Rurais  
CNN – Redes Neurais Convolucionais  
CNT – Comissão Nacional do Território  
CORINE Land Cover – *Coordination of Information On The Environment*  
COS – Carta de Uso e Ocupação do Solo  
COSc – Carta de Ocupação do Solo Conjuntural  
COScid – Carta de Uso e Ocupação do Solo para o Cidadão  
CO-SNIG – Conselho de Orientação do Sistema Nacional de Informação Geográfica  
COSvgi – Visualizador de Informação Geográfica Voluntária  
DGT – Direção-Geral do Território  
ESA – Agência Espacial Europeia (*European Space Agency*)  
FCT – Fundação para a Ciência e Tecnologia  
FCUL – Faculdade de Ciências da Universidade de Lisboa  
FI PNPT – Fórum Intersetorial do Programa Nacional da Política de Ordenamento do Território  
GNSS – *Global Navigation Satellite System*  
GPS – Sistema de Posicionamento Global  
GT SNIG Local – Grupo de Trabalho CO-SNIG com entidades municipais e intermunicipais  
HA – Hectare  
I&D – Investigação e Desenvolvimento  
IA – Inteligência Artificial  
IFN – Inventário Florestal Nacional  
IGOT – Instituto de Geografia e Ordenamento do Território  
IMU – Unidade de medição inercial  
ISA – Instituto Superior de Agronomia  
ITS – Individual Tree Segmentation  
LiDAR – Light Detection and Ranging  
LMF – *Local Maximum Filter* (Filtro de Máximo Local)  
MDS – Modelo Digital de Superfície  
MDT – Modelo Digital de Terreno  
MIAEV – Mapas Intra-Anuais do Estado da Vegetação  
nDSM – Modelo de Superfície normalizado  
NIR – Infravermelho próximo  
PAC – Política Agrícola Comum  
PRR – Plano de Recuperação e Resiliência  
RJAAR – Regime Jurídico das Arbonizações e Rearborizações  
SIP – Sistema de Identificação Parcelar  
SMOS – Sistema de Monitorização da Ocupação do Solo

SNIG – Sistema Nacional de Informação Geográfica  
TIN – *Trianguled Irregular Network* (Redes Triangulares Irregulares)  
UAV – Veículo Aéreo não tripulado (VANT)  
UC – Universidade de Coimbra  
UMC – Unidade Mínima Cartográfica  
viSMOS – Visualizador SMOS

# ÍNDICE

Agradecimentos.....	II
Resumo.....	III
Abstract .....	IV
Lista de abreviaturas, siglas e acrónimos .....	V
Índice de figuras .....	VIII
Índice de tabelas .....	IX
1 Introdução.....	1
1.1 Contextualização do Problema .....	1
1.2 Objetivos .....	4
1.3 Estrutura da Tese .....	5
2 Sistema de Monitorização da Ocupação do Solo .....	6
2.1 Produtos do SMOS.....	7
2.1.1 Cartografia de Base .....	7
2.1.2 Cartografia de Uso e Ocupação do Solo.....	8
2.2 Visualizadores .....	10
3 LiDAR.....	12
3.1 Componentes e Funcionamento .....	13
4 Revisão de Literatura.....	18
5 Área de Estudo .....	23
5.1 Área de Estudo .....	23
5.2 Especificações dos Dados Utilizados .....	25
6 Metodologia.....	28
6.1 Processamento dos dados LiDAR .....	28
6.2 Manchas Florestais .....	30
6.3 Culturas Permanentes .....	32
6.4 Detecção de Edifícios.....	33
6.4.1 Expansão urbana da COS a partir de dados LiDAR.....	34
7 Resultados .....	35
7.1 Apresentação e Contextualização dos Produtos derivados do LiDAR.....	35
7.2 Manchas Florestais .....	38
7.3 Culturas Permanentes .....	41
7.3.1 Identificação da Densidade dos Pomares e Olivais .....	47

7.4	Deteção de Edifícios.....	59
8	Conclusão.....	68
	Referências Bibliográficas .....	70
	Anexo 1 .....	75

## Índice de figuras

Figura 2.1.	Categorias de Produtos do SMOS. Adaptado de: DGT, 2022. ....	7
Figura 3.1.	Elementos constituintes de LiDAR ALS. Fonte: Mandlburguer, 2024). ....	14
Figura 3.2.	Princípio em que se baseia o sistema LiDAR. Fonte: Li,R.,2024.....	15
Figura 3.3.	Ilustração dos múltiplos ecos dos impulsos laser LiDAR. Fonte: Yan, W. et al.,2015. ....	15
Figura 5.1.	Enquadramento da área de estudo (Bloco 3A) na visão global dos blocos de Levantamento LiDAR e detalhe do respetivo enquadramento nas NUTS III.....	23
Figura 5.2.	Ocupação do Solo no Bloco 3A (megaclasses da COS). Fonte de Dados: SNIG – COS2023. ....	24
Figura 6.1.	Fluxo de processamento de dados LiDAR para obter o MDT, o CHM, os topos das árvores (Treetops) e as copas das árvores (Crowns).....	28
Figura 6.2.	Delimitação dos sub-blocos no Bloco 3A.....	30
Figura 7.1.	Modelo Digital do Terreno (MDT) do Bloco 3A.....	35
Figura 7.2.	Canopy Height Model (CHM) do Bloco 3A.....	36
Figura 7.3.	Conjugação dos diferentes produtos derivados do LiDAR para auxílio à produção da COS. ....	37
Figura 7.4.	Exemplos de segmentação de Treetops e de Crowns sobre o CHM.....	38
Figura 7.5.	Deteção correta das manchas florestais. ....	39
Figura 7.6.	Exemplo do limiar de floresta a ser marcado.....	40
Figura 7.7.	Classificação de falso positivo em contexto de presença de clareiras. ....	40
Figura 7.8 .	Identificação correta de vinhas com delimitação da COS sobre ortofotografia em falsa cor (à esquerda) e validação estrutural por meio do CHM com identificação dos Treetops a partir de dados LiDAR (à direita). ....	42
Figura 7.9.	Identificação correta de pomares, com delimitação da COS sobre ortofotografia em falsa cor (à esquerda) e validação estrutural por meio do CHM com identificação dos Treetops a partir de dados LiDAR (à direita). ....	43
Figura 7.10.	Identificação correta dos Olivais com delimitação da COS sobre ortofotografia em falsa cor (à esquerda) e validação estrutural por meio do CHM com identificação dos Treetops a partir de dados LiDAR (à direita). ....	44
Figura 7.11.	Identificação incorreta da metodologia com delimitação da COS sobre ortofotografia em falsa cor (à esquerda) e validação estrutural por meio do CHM com identificação dos Treetops a partir de dados LiDAR (à direita). ....	45
Figura 7.12.	Identificação incorreta da metodologia (em culturas permanentes) com delimitação da COS sobre ortofotografia em falsa cor (à esquerda) e validação estrutural por meio do CHM com identificação dos Treetops a partir de dados LiDAR (à direita).....	46

Figura 7.13. Área suplementar de análise (Bloco 1N, sub-bloco 1N4).....	48
Figura 7.14. Estatísticas dos pomares de baixa densidade. ....	50
Figura 7.15. Exemplos de classificação "Sem dados".....	50
Figura 7.16. Estatísticas de classificação na combinação de variáveis para pomares de baixa densidade. ....	51
Figura 7.17. Estatísticas de classificação dos pomares de alta densidade. ....	52
Figura 7.18. Estatísticas da combinação das duas variáveis na classificação dos pomares de alta densidade. ....	52
Figura 7.19. Estatísticas de classificação dos olivais de baixa densidade. ....	53
Figura 7.20. Classificação correta da densidade dos pomares e olivais. ....	56
Figura 7.21. Classificação incorreta da densidade dos pomares e olivais. ....	58
Figura 7.22. Classificação do LiDAR numa sub-área do sub-bloco 3A5. ....	59
Figura 7.23. Análise entre COS e LiDAR em edifícios. ....	60
Figura 7.24. Alertas para o tecido edificado não identificado na COS. ....	62
Figura 7.25. Classificação incorreta de alertas para o tecido edificado ....	63
Figura 7.26. Exemplos de edifícios identificados pelo LiDAR fora do tecido urbano da COS2023. ...	65
Figura 7.27. Exemplos de edifícios identificados pelo LiDAR.....	66
Figura 7.28. LiDAR vs. MBF.....	67

## Índice de tabelas

Tabela 2.1. Características dos Produtos da Cartografia de Base. Adaptado de: DGT, 2022. ....	8
Tabela 2.2. Características dos Produtos da Cartografia de Uso e Ocupação do Solo. Adaptado de: DGT, 2025.....	10
Tabela 3.1. Resumo das aplicações informáticas (softwares) de visualização LiDAR, com tipo, exemplos e principais usos em validação. ....	17
Tabela 5.1. Representação de cada ocupação na globalidade do Bloco 3A. ....	25
Tabela 5.2. Classificação dos pontos derivados da nuvem de pontos do levantamento LiDAR (padrão LAS 1.4). Adaptado de: (DGT, n.d.).....	26
Tabela 5.3. Atributos de cada ponto LiDAR. ....	26
Tabela 5.4. Características da Carta de Uso e Ocupação do Solo (COS) 2023. Adaptado de: (DGT, 2025a).....	27
Tabela 6.1. Características da Workstation DGT-759.....	28
Tabela 6.2. Etapas de processamento para detetar manchas florestais nas paisagens agropastoris com os dados LiDAR. ....	31
Tabela 6.3. Etapas de processamento de deteção de pomares com os dados LiDAR. ....	32
Tabela 6.4. Metodologia da deteção de edifícios. ....	33
Tabela 6.5. Metodologia para criação de alertas para os edifícios. ....	34
Tabela 7.1. Parâmetros para a classificação da densidade das culturas permanentes com base no manual de fotointerpretação. ....	47
Tabela 7.2. Síntese dos valores da análise dos edifícios. ....	61
Tabela 7.3. Cruzamento dos edifícios LiDAR fora do tecido urbano com a COS2023.....	64



# 1 Introdução

## 1.1 Contextualização do Problema

A ocupação e o uso do solo são dimensões fundamentais para compreender como os territórios se organizam, se transformam e se relacionam com os sistemas socioecológicos. O modo como as diferentes classes de uso do solo se distribuem no espaço tem implicações diretas no equilíbrio ambiental, na sustentabilidade dos recursos e na qualidade de vida das populações. Os mapas de uso e ocupação do solo são, por isso, ferramentas essenciais para a caracterização sistemática do território e para o suporte à tomada de decisão em múltiplos domínios. (Foody, 2002; Wulder et al., 2012).

Do ponto de vista científico, a cartografia de uso do solo assume-se como um eixo principal da investigação em ciências da Terra, mas também como base transversal a diferentes áreas aplicadas. Os dados de cobertura do solo sustentam os modelos de alteração climática, os sistemas de contabilidade de carbono, as avaliações de biodiversidade e as ferramentas de gestão hídrica (Foley et al., 2005; Turner et al., 2007). Em paralelo, a nível social, estes mapas suportam políticas públicas estruturantes, como a definição de perímetros urbanos, a delimitação de áreas protegidas e a atribuição de apoios ao setor agrícola. A importância global da cartografia de uso do solo apresenta uma dupla função, sendo simultaneamente um produto rigoroso e uma base de apoio à tomada de decisões estratégicas com impacto direto na sociedade e na economia.

A nível internacional, a produção de mapas de uso do solo tem sido uma prioridade constante. Têm surgido iniciativas como o *CORINE Land Cover (Coordination of Information on the Environment)*, promovida pela Agência Europeia do Ambiente (*European Environment Agency*, EEA) desde os anos 90, ou programas mais recentes como o *GlobeLand30* e o *Dynamic World*, que destacam a relevância para produtos harmonizados e comparáveis em diferentes escalas (Büttner et al., 2012; Gong et al., 2013; Brown et al., 2022). Estes projetos destacam a necessidade de atualização periódica e de metodologias consistentes, para garantir que a informação territorial acompanha a velocidade de transformação do espaço geográfico. Com a intensificação de processos como a urbanização, a expansão agrícola e os impactos das alterações climáticas, a necessidade de cartografia fiável e atualizada é cada vez mais importante.

A produção cartográfica tem evoluído de forma consistente, em paralelo com os avanços tecnológicos, tanto ao nível dos sensores de observação da Terra instalados em satélite como das inovações metodológicas. Desde o início dos anos 2000, a utilização de dados de deteção remota consolidou-se como a principal fonte de informação para a elaboração de mapas de ocupação do solo. Diferentes sensores têm sido amplamente utilizados, como óticos, multiespectrais e hiperespectrais, oferecendo vantagens em termos de cobertura espacial e temporal. Contudo, apresentam algumas limitações, como a dependência das condições atmosféricas, a sua incapacidade de penetrar na vegetação densa e a dificuldade de distinguir classes estruturalmente semelhantes com base apenas em assinaturas espectrais (Lu et al., 2007).

Foi neste contexto que tecnologias complementares, como o LiDAR (*Light Detection and Ranging*), ganharam relevância. O LiDAR é um sensor ativo que, por meio da emissão de pulsos laser, gera nuvens de pontos tridimensionais capazes de representar com grande detalhe a estrutura da superfície terrestre e dos objetos nele presentes. Ao contrário dos sensores passivos, o LiDAR não depende da iluminação solar nem das condições atmosféricas, sendo que a capacidade de atravessar o

dossel florestal até ao solo, o torna particularmente eficaz na caracterização de ecossistemas complexos (Mallet et al., 2009; Hyyppä et al., 2012).

A integração de dados LiDAR nos fluxos de trabalho de cartografia temática permite superar algumas das limitações mais críticas dos métodos convencionais. Os sensores 3D, como LiDAR e fotogrametria UAV<sup>1</sup> (Veículo Aéreo Não Tripulado, VANT), possibilitam a estimação da altura, volume e biomassa com grande precisão em zonas florestais; a distinção entre edifícios, vias e vegetação com elevado detalhe em áreas urbanas; e a monitorização tridimensional de culturas e o apoio à agricultura de precisão em áreas agrícolas (Dalponte et al., 2008; Niemeyer et al., 2014; Bendig et al., 2015). Em todos estes casos, o grande destaque é a capacidade de captar a dimensão estrutural do território, complementado a informação espectral. Desta forma é preciso compreender as diferenças entre os dados LiDAR e os de satélite, bem como as respetivas limitações e vantagens de cada um.

Primeiramente, o LiDAR, especialmente na sua versão de captação aérea ALS (*Airborne Laser Scanning*), apresenta custos de aquisição muito elevados. Este fator acaba por limitar a sua utilização frequente e extensiva, sobretudo em grandes áreas nacionais. Por outro lado, os dados de satélite, como os recolhidos pelo Sentinel-2 (S2), que nos fornece imagens com áreas de cerca de 100 km x 100 km a cada cinco dias, a um custo muito menor (*Copernicus, n.d.*). No entanto, essa cobertura frequente e o custo mais acessível tornam os dados de satélites ideais para a monitorização de grandes regiões, apesar de algumas limitações. Outra limitação importante do LiDAR é a respetiva resolução temporal. Para obter dados atualizados, muitas vezes é necessário realizar campanhas dispendiosas, o que reduz a frequência com que se pode adquirir novas informações. Assim, enquanto o satélite consegue monitorizar uma área de forma regular e automática, o LiDAR, é dispendioso e com menor frequência. Por outro lado, o LiDAR destaca-se pela resolução espacial, que depende da densidade de pontos registados por metro quadrado. Quanto maior a densidade de pontos, maior a capacidade de captar detalhes extremamente finos do terreno e da vegetação. No âmbito do PRR, a DGT promoveu o primeiro levantamento LiDAR de cobertura nacional, realizado entre 2024 e o início de 2025, com densidade média de 10 pontos por metro quadrado. Estes dados têm vindo a ser explorados para a produção de modelos digitais do terreno de elevada resolução, essenciais para o planeamento e a gestão territorial, no contexto do investimento dedicado ao Cadastro da Propriedade Rústica e à Monitorização da Ocupação do Solo.

Por fim, é importante mencionar que os dados de LiDAR referidos correspondem ao modo ALS. Este método consiste na utilização de VANT's ou aviões equipados com *scanners laser* que emitem pulsos de luz para o solo e recolhem os ecos de volta, criando uma nuvem de pontos extremamente detalhada. Esta tecnologia permite obter informações tridimensionais do terreno com uma precisão muito elevada, fundamental para estudos que exigem uma análise de detalhes topográficos e de vegetação.

A relevância científica e social da cartografia de ocupação do solo está ligada à capacidade de atualização frequente e de fiabilidade temática. Contudo, é precisamente neste ponto que se coloca um dos maiores desafios. Embora os produtos de referência se mantenham com elevada importância, os seus ciclos de atualização prolongados contrastam com a rapidez das transformações territoriais. Esta defasagem temporal entre a realidade e a cartografia pode comprometer a sua utilidade como instrumento de apoio à decisão em tempo útil. No caso português, a Carta de Uso e Ocupação do Solo

---

<sup>1</sup> *Unmanned Aerial Vehicle (UAV)*

(COS), produzida pela DGT, é o instrumento de referência para a cartografia temática. A COS é disponibilizada em diferentes edições, constituindo uma série de grande relevância para investigadores, técnicos e decisores. O produto tem múltiplas funções, desde apoiar a elaboração de planos de ordenamento, subsidiar a monitorização ambiental, servir de base para a definição de políticas agrícolas, por exemplo, com a PAC (Política Agrícola Comum), bem como, permitir o acompanhamento da evolução do território ao longo do tempo (Sequeira, A. et al., 2022; DGT, 2020).

A produção da COS baseia-se numa metodologia tradicional de fotointerpretação de imagens aéreas ortorretificadas, complementada com informação auxiliar. Esta abordagem acaba por assegurar uma elevada precisão temática, mas é intensiva em termos de tempo, custos e recursos humanos especializados. O ciclo de atualização tem sido, em média, de três a cinco anos, o que significa que as versões disponíveis refletem um retrato desatualizado face à realidade. Esta limitação pode ser problemática em contextos de rápida transformação, como incêndios florestais de grande dimensão, que têm sido anualmente uma constante em Portugal, na expansão urbana acelerada ou nas alterações abruptas nas práticas agrícolas. A desfase temporal entre a realidade territorial e a sua representação cartográfica tem implicações práticas, pelo que é necessário acelerar os processos de atualização da COS, sendo esta uma prioridade identificada pela própria DGT e reconhecida pela comunidade científica.

Apesar dos esforços desenvolvidos da DGT para garantir a continuidade da produção da COS, os desafios metodológicos e operacionais persistem. Em primeiro lugar, os longos ciclos de atualização, dependentes de processos manuais de fotointerpretação, tornam difícil capturar a dinâmica do território português. Em segundo lugar, os custos financeiros e logísticos limitam a possibilidade de revisões mais frequentes, dado o esforço necessário na aquisição de imagens, na mobilização de técnicos e na validação de campo. Por fim, a dependência da interpretação humana introduz subjetividade e dificulta a reprodutibilidade, gerando variações na classificação entre diferentes operadores ou ciclos de atualização. Estes constrangimentos têm levado a comunidade científica e os organismos responsáveis a testar alternativas complementares que possam acelerar a atualização e aumentar a eficiência da COS. Entre as propostas destacam-se metodologias de classificação automática ou semiautomática com recurso a algoritmos de aprendizagem automática, a integração de dados multissensoriais de satélite e, mais recentemente, o aproveitamento de tecnologias ativas como o LiDAR. Tais metodologias têm sido aplicadas pelo Sistema de Monitorização da Ocupação do Solo (SMOS) para, desta forma, contribuir para a melhoria dos métodos de produção da COS. O desafio é conjugar o rigor temático que caracteriza a COS com métodos inovadores que ofereçam maior rapidez e escalabilidade, sem comprometer a fiabilidade exigida a um produto oficial de referência.

É neste enquadramento que se insere a presente investigação, cujo objetivo central é explorar o potencial dos dados LiDAR como base para sistemas de alerta, que é a produção de informação auxiliar automática que identifica potenciais áreas de mudança para dar à produção. O pressuposto é que o LiDAR, ao captar diretamente a estrutura tridimensional do território, e ao identificar as características físicas com elevado detalhe e precisão, funcione como um mecanismo para caracterizar o terreno e a vegetação com elevado detalhe espacial na data de aquisição. Este método permite obter uma representação tridimensional precisa do terreno, incluindo detalhes que muitas vezes não são visíveis ou são difíceis de interpretar na cartografia tradicional ou em ortofotos 2D. Assim, o LiDAR fornece informações detalhadas sobre a estrutura do terreno, a altura das árvores, a densidade da vegetação e outras características do relevo, numa escala que pode chegar a poucos centímetros. Este nível de detalhe é especialmente útil para a caracterização atual do estado do terreno e da vegetação, permitindo uma

análise precisa do estado de ocupação e do uso do solo num momento específico. Além disso, os dados LiDAR podem servir de forma complementar na detecção de mudanças ao longo do tempo, ao serem comparados com cartografia de anos anteriores, ajudando a monitorizar alterações na cobertura vegetal, a evolução de áreas de floresta ou de mato, ou a degradação do solo.

A simples fotointerpretação pode não ser suficiente para identificar diferentes espécies de árvores, nem para distinguir de forma clara entre classes de floresta e mato. O LiDAR permite, diferenciar assim, espécies com base na altura e na densidade da vegetação, ou avaliar a altura das árvores com precisão.

A relevância científica desta investigação assenta na capacidade de o LiDAR colmatar lacunas metodológicas na produção de cartografia temática em Portugal, apoiando a modernização dos processos da DGT. Esta tecnologia encontra-se numa fase de consolidação operacional, sendo já explorada em sistemas de alerta que utilizam a informação tridimensional para detetar mudanças na vegetação, identificar novas áreas agrícolas e delimitar zonas edificadas. Assim, o trabalho contribui para integrar o potencial estrutural do LiDAR nos fluxos de produção da COS, melhorada a qualidade temática, a fiabilidade e do detalhe da informação geográfica.

Em resumo, os benefícios de um sistema de alerta baseado em dados LiDAR são evidentes. Em primeiro lugar, torna a atualização da COS mais eficiente, reduzindo o tempo de produção e, em segundo lugar, reforçar o suporte à decisão pública, disponibilizando dados mais atuais e fiáveis. Finalmente, o sistema tem potencial para reduzir custos a médio prazo, ao automatizar etapas do processo de monitorização que dependem de trabalho intensivo de recursos humanos. Esta investigação tem ainda a vantagem de alinhar-se com as tendências internacionais de inovação na monitorização territorial. Embora a presente tese não se centre em análises comparativas com outros países, é inegável que a modernização da COS, através da integração de dados LiDAR, acompanha o movimento global em direção a sistemas de cartografia mais dinâmicos e automatizados (*Büttner et al., 2012; Brown et al., 2022*). Nesse sentido, o trabalho contribui para que Portugal se posicione em linha com as melhores práticas, beneficiando de avanços científicos e tecnológicos já comprovados.

## 1.2 Objetivos

O objetivo central desta dissertação é desenvolver e validar um sistema de geração automática de alertas que apoie a produção e atualização da COS, identificando áreas que precisem de revisão ou reclassificação. Como objetivo complementar, foi desenvolvido e testado um fluxo de processamento de dados LiDAR, para criar conjuntos de dados geográficos que fornecem a base estrutural necessária à detecção desses alertas, integrando a informação tridimensional do território e acelerando os ciclos de atualização cartográfica.

Neste âmbito, o processamento foi orientado para três classes com relevância direta para a COS, que são:

- Manchas florestais: detetar manchas florestais, distinguindo-as de outras coberturas arbóreas;
- Pomares: explorar a regularidade espacial e a estrutural típicas destas culturas permanentes através de manchas ou padrões automáticos;
- Edifícios: fazer a sua delimitação automática com base na sua geometria e altura.

Estes processos visam demonstrar o potencial do LiDAR como fonte de dados para reforçar a consistência temática e reduzir o tempo de produção da COS, de modo a permitir uma atualização mais célere desta cartografia. Importa salientar que as abordagens de processamento LiDAR aqui utilizadas têm origem em métodos criados e aperfeiçoados internamente pela DGT

### 1.3 Estrutura da Tese

Esta tese encontra-se dividida em oito (8) capítulos estruturados da seguinte forma:

1. Introdução, onde se enquadra o tema e os objetivos do trabalho;
2. Sistema de Monitorização da Ocupação do Solo, que descreve a iniciativa SMOS, concebida e desenvolvida pela DGT, com o objetivo de produzir de forma contínua informação cartográfica de base e temática relativa ao uso e ocupação do solo em Portugal;
3. LiDAR, onde são abordados os princípios de funcionamento da tecnologia, os seus componentes e características técnicas;
4. Revisão de Literatura, onde são abordados os principais trabalhos e avanços na área descrito na literatura mais relevante;
5. Área de Estudo, explicando as suas características e importância;
6. Metodologia, onde se detalha os procedimentos e técnicas utilizadas para a produção de informação extraída dos dados LiDAR;
7. Resultados, onde se mostra os resultados obtidos e se efetua a respetiva análise;
8. Conclusão, onde são apresentados os principais contributos do trabalho e proposto os possíveis desenvolvimentos futuros.

## 2 Sistema de Monitorização da Ocupação do Solo

A DGT é um organismo central da Administração Pública, com responsabilidades na produção e disponibilização de informação geográfica oficial, assumindo um papel de relevo na modernização dos sistemas de observação do território. É neste contexto que surge o SMOS (DGT, 2022). A iniciativa SMOS enquadra-se na Reforma RE-r20, designado de “Reorganização do sistema de cadastro da propriedade rústica e do Sistema de Monitorização da Ocupação do Solo”, e é integrada na componente C08 que representa as «Florestas» no Plano de Recuperação e Resiliência (PRR), por sua vez é, igualmente associada ao investimento RE-C08-i02.01, designado de “Cadastro da Propriedade Rústica e Sistema de Monitorização da Ocupação do Solo: Sistema Nacional de Cadastro Predial”, como disposto no Despacho n.º 291/2023, de 6 de janeiro. Esta iniciativa representa uma solução para a constante exigência de governação do território, de monitorização ambiental e de ações de resiliência aos desafios ambientais.

Atendendo a este novo paradigma, a DGT apostou num investimento estratégico relacionado com o processamento de imagens e análise geoespacial. Tais projetos tiveram o apoio de entidades como a Comissão Europeia (CE), a Agência Espacial Europeia (*European Space Agency*, ESA) e a Fundação para a Ciência e Tecnologia (FCT), bem como o seu financiamento. Desta forma, a DGT capacitou-se para a produção de cartografia, aliando o seu conhecimento técnico a metodologias recentes, demonstrando o envolvimento entre a ciência de dados, a aprendizagem automática (*machine learning*) e os grandes volumes de dados (*Big Data*) (DGT, 2022).

O desenvolvimento do SMOS baseia-se num modelo de produção de informação contínuo e automatizado, com base em imagens de satélite do programa europeu *Copernicus*, com particularidade dos satélites Sentinel-2, com período de revisita de cinco dias em Portugal. Desta forma é possível uma cobertura sistemática e atualizada. Recentemente (durante 2024), foi realizado um levantamento de dados LiDAR baseado em ALS, abrangendo todo o Portugal Continental. Estes dados, aliados à aplicação de algoritmos de inteligência artificial (IA), permitiram à DGT produzir cartografia temática de uso e ocupação do solo com níveis de precisão e detalhe significativamente superiores aos métodos tradicionais. Esta abordagem representa uma transformação não apenas nos métodos convencionais, como a fotointerpretação, que muitas vezes se limita à interpretação visual e a uma escala de eficácia relativamente reduzida, mas também na capacidade de identificar dinâmicas territoriais. Assim, o uso de técnicas avançadas de processamento de dados e de análise automática favorece uma compreensão mais aprofundada e atualizada das mudanças no território (DGT, 2022).

O SMOS assenta também numa lógica de governação colaborativa e partilhada, o que permite a cedência de dados abertos e gratuitos de todos os produtos que desenvolve. Esta política de dados abertos permite a utilização destes dados por parte da Administração central e local, do setor científico e académico, das empresas e dos cidadãos, potenciando o valor da informação geoespacial (DGT, 2022). O SMOS permite responder a um vasto leque de necessidades, com a disseminação de um amplo conjunto de produtos e visualizadores para apoiar a formulação de políticas públicas. Trata-se de uma infraestrutura estratégica para um conhecimento melhorado do território, como forma de o tornar mais resiliente, constituindo-se como uma referência central para a administração pública territorial.

Importa ainda refletir sobre a articulação estratégica do SMOS com órgãos nacionais de política territorial e cartográfica, como a Comissão Nacional do Território (CNT), o Fórum Intersetorial do Programa Nacional da Política de Ordenamento do Território (FI PNPOT), a Comissão Nacional de

Gestão Integrada de Fogos Rurais (CNGIFR), o Conselho Coordenador de Cartografia (CCC), o Conselho de Orientação do Sistema Nacional de Informação Geográfica (CO-SNIG) e o Grupo de Trabalho CO-SNIG com entidades municipais e intermunicipais (GT SNIG Local), assegurando a integração da informação produzida nas políticas públicas.

Relativamente à componente de investigação e desenvolvimento (I&D), a DGT tem desenvolvido parcerias estratégicas com instituições académicas, como o Instituto Superior de Agronomia (ISA), o Instituto de Geografia e Ordenamento do Território (IGOT), a Faculdade de Ciências da Universidade de Lisboa (FCUL) e a Universidade de Coimbra (UC). Estas ligações têm permitido o desenvolvimento de métodos para a classificação e validação da ocupação do solo, consolidando a sua base científica e metodológica (DGT, 2025).

## 2.1 Produtos do SMOS

Para disponibilização da informação geoespacial a iniciativa SMOS tem um sistema constituído por nove produtos distintos subdivididos em três grandes grupos, aos quais pertencem: a cartografia de base, a cartografia de uso e ocupação do solo e outros produtos cartográficos específicos, conforme plasmado na Figura 2.1. Esta distribuição baseia-se em critérios técnicos claros, incluindo especificações, objetivos, fontes de dados e metodologias de produção (DGT, 2022). Todos estes produtos constituem instrumentos de elevada relevância e têm uma aplicabilidade transversal em diversos domínios estratégicos, tendo em vista o desenvolvimento sustentável do território nacional. Esta versatilidade e fiabilidade dos produtos do SMOS torna-os ainda mais valiosos para as entidades da Administração Pública, setor privado, comunidade científica e cidadãos em geral, visto que promovem uma visão integrada sobre o uso e ocupação do solo, refletindo as dinâmicas territoriais (DGT, 2022). Alguns desses exemplos é a comparação entre dois anos da Carta de Uso e Ocupação do Solo Conjuntural (COSc) para perceber a evolução de uma determinada classe, como também monitorizar uma zona de floresta através dos Mapas Intra-Anuais do Estado da Vegetação (MIAEV).

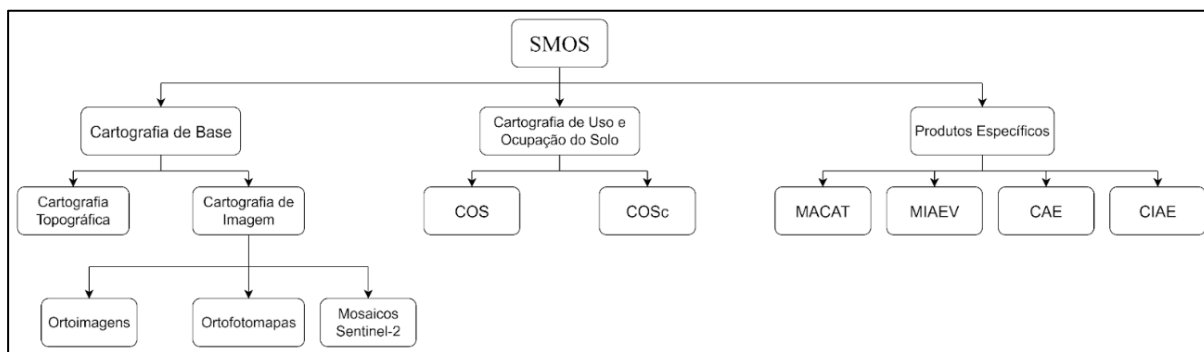


Figura 2.1. Categorias de Produtos do SMOS. Adaptado de: DGT, 2022.

### 2.1.1 Cartografia de Base

A cartografia de base agrega dois tipos de informação geográfica: a cartografia topográfica e a cartografia de imagem. Estes produtos desempenham um papel estruturante dado que servem de base para a produção dos restantes produtos do sistema. A cartografia de imagem inclui um conjunto de produtos, nomeadamente: ortoimagens, ortofotomapas e os mosaicos de imagens Sentinel-2, com diversas resoluções espaciais. Como apresentado na Tabela 2.1, os produtos estão em formato matricial, com composições de cor verdadeira e de falsa cor, o que permite uma análise detalhada do território (DGT, 2025).

Tabela 2.1. Características dos Produtos da Cartografia de Base. Adaptado de: DGT, 2022.

	<b>Ortoimagens (OrtoSat)</b>	<b>Ortofotomapas</b>	<b>Mosaicos Sentinel-2</b>
<b>Formato</b>	Matricial ( <i>Raster</i> )	Matricial ( <i>Raster</i> )	Matricial ( <i>Raster</i> )
<b>Unidade Mínima Cartografia</b>	30 cm	25 cm a 1 m	10 m
<b>Periodicidade</b>	Anual	Campanhas anuais	Mensal
<b>Edições Produzidas</b>	2023	1995, 2004-2006, 2007, 2010, 2012, 2015, 2018, 2021	2017-presente

Neste contexto da produção cartográfica, é importante realçar que existem diferentes tipos de coberturas ortofotográficas, produzidas a partir de voos fotogramétricos que resultam em ortoimagens e ortofotomapas. As ortoimagens (OrtoSat) correspondem a imagens obtidas por satélite de alta resolução, corrigidas geometricamente para eliminar distorções e garantir que cada píxel está corretamente posicionado em termos geoespaciais. Já os ortofotos são produzidas a partir de fotografias aéreas captadas por avião ou VANT, igualmente ortorretificadas, mas com maior detalhe espacial e precisão métrica, sendo frequentemente utilizadas como base cartográfica de referência. A DGT tem produzido ao longo das últimas décadas várias coberturas nacionais de ortofotografias, geralmente com periodicidade de alguns anos, sendo as mais recentes de grande relevância para a produção de cartografia temática oficial, existem 9 (Tabela 2.1). Estas coberturas têm evoluído em termos de resolução espacial, acompanhando os avanços tecnológicos da aquisição aérea e permitindo um detalhe cada vez maior na caracterização do território.

No entanto, a atualização destas ortofotografias é pontual e anual (por campanha), o que limita a sua utilização em contextos que exigem acompanhamento contínuo da dinâmica territorial. É desta forma que se destaca a utilidade das imagens de satélite, em particular os mosaicos Sentinel-2, que podem ser atualizados em base mensal, disponibilizados no âmbito do programa *Copernicus*. Embora apresentem uma resolução espacial bastante inferior à das ortofotografias (10 metros em algumas bandas), oferecem uma resolução temporal muito superior, com revisitas frequentes que permitem acompanhar alterações na ocupação e no uso do solo (*Copernicus, n.d.*). Esta cadência torna os dados Sentinel-2 fundamentais para a atualização e a monitorização contínua, funcionando como base para a produção da cartografia de uso e ocupação do solo de Portugal Continental. Assim, enquanto as ortofotografias fornecem a precisão geométrica e o detalhe espacial necessários para a validação e referência cartográfica, os mosaicos Sentinel-2 complementam esse trabalho, garantindo uma cobertura temporal que permite detetar e caracterizar mudanças no território de forma mais sistemática.

### 2.1.2 Cartografia de Uso e Ocupação do Solo

A cartografia de uso e ocupação do solo da DGT integra dois produtos (Tabela 2.2), considerados de referência nacional, desde logo a Carta de Uso e Ocupação do Solo (COS), que é a cartografia temática de referência nacional, bem como, a Carta de Ocupação do Solo Conjuntural

(COSc). Estes dois produtos complementam-se, tanto na forma, como na finalidade, o que possibilita uma análise detalhada, contínua e evolutiva.

A COS constitui a cartografia temática oficial de referência nacional, representando um mapeamento vetorial detalhado das diferentes classes de uso e ocupação do solo. Esta carta caracteriza unidades homogêneas de ocupação do solo, organizadas em 9 (nove) megaclasses e estruturadas em quatro níveis hierárquicos com um total de 93 (noventa e três) classes temáticas, com uma unidade mínima cartográfica de 1 ha. Cada polígono é classificado de acordo com uma nomenclatura padronizada, assegurando consistência temática e comparabilidade entre edições. Esta informação encontra-se disponível de forma aberta e gratuita através do Sistema Nacional de Informação Geográfica (SNIG), o que permite a qualquer utilizador visualizar e descarregar os dados. (DGT, 2020)

A primeira edição da COS remonta à década de 1990, e desde então a DGT produziu sucessivas versões que refletem as dinâmicas do território. A Série 1 da COS inclui as edições de 1995, 2007, 2010, 2015 e 2018, tendo esta últimas introduzido refinamento significativo da legenda, passando de 48 para 83 classes no nível mais detalhado, correspondendo a um acréscimo de 35 classes face à versão anterior (DGT, 2020). Este aumento de detalhe melhorou a precisão temática, embora tenha criado algumas descontinuidades face as versões precedentes. Para garantir consistência espacial e temática nas análises multitemporais, a DGT realizou uma atualização retrospectiva das edições anteriores (1995-2015), harmonizando-as segundo a nova nomenclatura. Até ao final deste processo, é recomendada cautela na comparação entre as versões (DGT, 2020).

Com avanço tecnológico e a necessidade de maior coerência temática, a DGT iniciou a Série 2 da COS, inaugurada com a COS2023. Esta nova série introduz as novas especificações técnicas e uma legenda revista, refletindo melhorias metodologias e maior detalhe temático. A Série 2 integra, até ao momento, a COS2018 (versão 3, ajustada à nova legenda) e a COS2023 (versão 1). As cartas dentro de cada série são comparáveis entre si, mas as Séries 1 e 2 não são diretamente compatíveis, devido as diferenças de especificações e nomenclaturas (DGT, 2025). A manutenção da Série 1 continua, contudo, a ser relevante pelo seu valor histórico e pela sua importância para análises de longo prazo, enquanto a Série 2 representa uma nova fase, com processos de produção mais eficientes e alinhados com a estratégia do SMOS. A produção da COS tem evoluído paralelamente aos avanços tecnológicos. Tradicionalmente, baseava-se na fotointerpretação manual de ortofotografias aéreas, um processo moroso entre a aquisição das imagens e a disponibilização do mapa final. Atualmente, a sua cartografia tornou-se semiautomática e, conseqüentemente, mais rápida, graças à integração de novos métodos e ferramentas digitais. A COS2018, por exemplo, foi produzida em nove meses, sendo disponibilizada no ano seguinte à aquisição das ortofotografias, que representa um marco importante (DGT, 2020). No estratégia da iniciativa SMOS, o objetivo é apresentar informação de ocupação do solo de forma regular através de processos mais eficientes, que diminuem o tempo entre a deteção das mudanças no terreno e a atualização cartográfica (DGT, 2025).

Não obstante o já exposto, a COSc apresenta uma abordagem mais dinâmica e direcionada para a atualidade, sendo produzida desde 2018. Este é um produto matricial composto por 15 classes temáticas, fornece um mapa preciso da ocupação do solo para um ano específico. A sua metodologia baseia-se na classificação automática de imagens Sentinel-2, complementada com dados auxiliares, recorrendo a algoritmos de inteligência artificial com técnicas de aprendizagem automática e a integração de conhecimento pericial (DGT, 2022; DGT, 2025).

Tabela 2.2. Características dos Produtos da Cartografia de Uso e Ocupação do Solo. Adaptado de: DGT, 2025.

	<b>COS - Carta de Uso e Ocupação do Solo</b>	<b>COSc - Carta de Ocupação do Solo Conjuntural</b>
<b>Dados de Base</b>	Ortofotos	Imagens Sentinel-2
<b>Metodologia de Base</b>	Manual	Automático
<b>Formato</b>	Vetorial (Polígonos)	Matricial ( <i>Raster</i> )
<b>Unidade Mínima Cartografia</b>	1 hectare (ha)	10 m
<b>Nomenclatura (Nº de classes)</b>	93 classes	15
<b>Periodicidade</b>	3 a 5 anos	Anual
<b>Edições Produzidas</b>	1995, 2007, 2010, 2015, 2018 e 2023	2018, 2020, 2021, 2022, 2023, 2024 e 2025

Em termos gerais, a COS é considerada a carta de referência, produzida em edições discretas, com recurso à fotointerpretação e à vectorização, privilegiando o detalhe, a geometria e a consistência temática para análises estruturais. Já a COSc segue um modelo regular de atualização, assente em séries temporais e métodos automáticos e semiautomáticos, oferecendo uma maior resolução temporal para detetar mudanças e apoiar a monitorização. Em suma, a COS é um produto de alta fiabilidade espacial, com ciclos de atualização espaçados, enquanto a COSc privilegia a dinâmica temporal, com atualizações frequentes e deteção rápida de alterações (DGT, 2022a)

## 2.2 Visualizadores

O SMOS apresenta um conjunto de visualizadores interativos na sua plataforma de WebSIG, fazendo parte destes: o visualizador SMOS (viSMOS), a Carta de Usos e Ocupação do Solo para o Cidadão (COScid) e o visualizador de Informação Geográfica Voluntária (COSvgi). Estes visualizadores permitem a exploração, a análise e a participação cívica da informação geográfica disponibilizada, possibilitando a consulta de diferentes tipos de produtos, a sua comparação temática e temporal, o acesso a informação estatística detalhada e a contribuição de informação geográfica voluntária, de modo a reforçar a qualidade e atualização dos dados disponíveis (DGT, 2025).

O viSMOS agrega todos os produtos desenvolvidos pela SMOS, permitindo uma visualização integrada e interativa. Possibilita desta forma uma análise dinâmica da ocupação do solo, a identificação de mudanças sazonais e estruturais, evidenciando a evolução do território nacional ao longo do tempo de forma fácil e intuitiva, não sendo necessários grandes conhecimentos em Sistemas de Informação Geográfica (DGT, 2022; DGT, 2025). O COScid apresenta uma lógica diferente, focando-se em garantir uma proximidade e acessibilidade a qualquer cidadão, independentemente do seu conhecimento técnico, para consultar a COS. O visualizador integra diversas funcionalidades, como observar tendências temporais, aceder a estatísticas temáticas e consultar gráficos e tabelas explicativas. Assim, garante-se que a informação geográfica é útil e compreensível e ainda mais acessível do que o viSMOS, permitindo análises estatísticas gerais da COS ao nível das unidades administrativas (NUTSII, NUTSIII, concelhos e freguesias)(DGT, 2022; DGT, 2025). Compete, por fim, dizer que o COSvgi é um visualizador de participação colaborativo que permite que cidadãos e especialistas apresentem propostas de correção ou

melhoria da COS e da COSc. Podem apresentar-se novas classificações da cartografia, ou até mesmo propor o redesenho através das ferramentas, propondo uma correção de geometria e desta forma, ajudar a corrigir as inconsistências e assim melhorar a cartografia (*DGT, 2022; DGT, 2025*). Concluiu-se, portanto, que estes três visualizadores reforçam o compromisso de transparência, acessibilidade e inovação, por meio de um sistema moderno e eficaz de observação e monitorização do território.

### 3 LiDAR

LiDAR é o acrónimo de *Light Detection and Ranging*, que se refere a uma tecnologia de deteção remota ativa de emissão de energia sob a forma de pulsos laser para medir distâncias. O princípio de funcionamento do LiDAR é semelhante ao do radar (ondas rádio) ou do sonar (ondas sonoras), emitindo energia em direção aos objetos e analisando o sinal de retorno para, desta forma, determinar a posição e distâncias desses objetos (IBM,2023). A diferença é que, no LiDAR, a energia emitida pelo feixe laser permite medições muito mais rápidas, com precisão e alta resolução espacial. De forma simples, o LiDAR emite uma série de pulsos laser e regista o tempo que cada pulso demora a regressar após ter sido refletido pelo alvo. Dado que a velocidade da luz é conhecida e é constante, consegue-se calcular com rigor a distância percorrida pelo pulso, bem como a distância até cada objeto. Um dos resultados desta técnica é obter um conjunto elevado de distâncias que, quando georreferenciadas, formam uma nuvem de pontos tridimensionais representativa das superfícies do terreno e dos objetos sobre ele (IBM,2023).

Os dados LiDAR permitem criar tanto mapas topográficos, com elevado detalhe (modelo digital de terreno), como modelos 3D dinâmicos de cidades ou florestas. Esta tecnologia tem ganhado ênfase ao longo do tempo em diversas áreas de aplicação, graças à sua capacidade de mapear em 3D com elevada precisão e até substituir os métodos tradicionais de fotogrametria, morosos e menos precisos. Também na área florestal, o LiDAR se tem revelado uma ferramenta essencial, permitindo obter as alturas das copas das árvores e a estrutura da vegetação e do relevo do terreno mesmo sob vegetação densa, algo bastante importante na produção dos inventários florestais nacionais. Nos estudos costeiros e ambientais, os sistemas LiDAR permitem medir batimetria em águas pouco profundas recorrendo a laser verde, que penetra a coluna de água e possibilita mapear rios e zonas costeiras com detalhe. A versatilidade da tecnologia estende-se ao espaço, existindo LiDAR espaciais instalados em satélites e sondas, usados para mapear a topografia de planetas e da Lua (NASA, n.d.). Um exemplo recente é o helicóptero *Ingenuity*, em Marte (NASA, n.d.), cuja navegação contou com um altímetro laser (LiDAR de feixe único) para medir a altura ao solo durante os voos. (Szafarczyk et al., 2023; Kinzel et al., 2013; Sun, 2016; Trawny et al., 2022)

Os sistemas LiDAR classificam-se, de modo geral, em duas principais categorias de acordo com a plataforma em que são instalados, o LiDAR ALS e o LiDAR terrestre. O LiDAR ALS envolve sensores montados em aeronaves tripuladas, como o caso de avião ou helicóptero, ou não tripuladas, como os VANTs que efetuam varreduras a laser em extensas áreas. Esta modalidade é amplamente focada em mapear o terreno em grande escala, cobrindo centenas de quilómetros em pouco tempo. Com o LiDAR aéreo obtêm-se modelos digitais do terreno com elevada resolução e inventaria-se a ocupação do solo em regiões extensas. Em Portugal, a cobertura LiDAR foi realizada por avião, em que foi definida como prioridade a obtenção de um novo modelo altimétrico de elevado detalhe (DGT, 2025). O LiDAR terrestre pode operar a partir de dispositivos fixos, como tripés ou outro tipo de estrutura, ou móvel, como um automóvel. Esta categoria de LiDAR é utilizada para levantamentos mais localizados, como edifícios, monumentos ou estradas, onde se pretendem precisões milimétricas (IBM,2023).

Com esta elevada resolução é possível captar detalhes mais específicos, o que é particularmente útil em contextos urbanos onde a exatidão é essencial. Além destes usos, esta tecnologia é de grande importância em levantamentos de parcelas florestais, permitindo analisar a estrutura da vegetação e caracterizar diferentes espécies de árvores. A capacidade de distinguir

variações na altura, na forma das copas e na densidade da vegetação torna o LiDAR uma ferramenta fundamental tanto para a investigação florestal como para a gestão sustentável dos recursos naturais.

### 3.1 Componentes e Funcionamento

Um sistema LiDAR é composto por componentes principais e auxiliares (Figura 3.1). Os principais são os essenciais para o funcionamento básico, os quais são:

- Fonte emissora de laser, que gera pulsos rápidos de luz, geralmente no espectro do infravermelho próximo (NIR);
- Sensor recetor, que deteta os pulsos refletidos nos objetos;
- Unidade de processamento, que calcula o tempo de viagem de cada pulso e converte os dados brutos numa nuvem de pontos tridimensional (Coordenadas X,Y e Z);

Relativamente aos auxiliares, estes vão garantir a precisão e qualidade, correspondendo a:

- Relógio de alta resolução, que garante a precisão temporal das medições;
- Recetor GPS (*Global Navigation Satellite System*, GNSS), que fornece a posição e altitude exata do sensor em cada momento;
- Unidade de medição inercial (IMU), que regista a orientação e movimentos da plataforma;
- Plataforma aérea, sendo o meio que transporta o sistema, avião, VANT, entre outros;
- Sistema de controlo e aquisição de dados, que sincroniza o laser, GPS e IMU, e regista a informação;
- Camara digital, que capta imagens RGB ou multiespectrais para enriquecer a nuvem de pontos;
- Aplicação informática (*software*) de processamento, que processa os dados recolhidos e gera produtos finais (nuvem de pontos georeferenciada);

Tudo em conjunto, assegura que o cálculo das distâncias é rigoroso e que a nuvem de pontos está georeferenciada em relação a um sistema de coordenadas no terreno (IBM,2023).




Figura 3.1. Elementos constituintes de LiDAR ALS. Fonte: Mandlburguer, 2024).

O funcionamento do LiDAR baseia-se no princípio do “tempo de voo” (*time-of-flight*), medindo o intervalo de tempo entre a emissão de um pulso laser e a recepção do seu eco de volta ao sensor (Figura 3.2). Na prática, o emissor laser dispara milhares de pulsos por segundo em diversas direções (*GISGeography, n.d.*), os quais se deslocam à velocidade da luz. Quando o feixe encontra um objeto, parte da sua energia é refletida de volta ao sensor. O sensor deteta o momento exato de recepção do eco e um circuito de cronometragem regista o tempo decorrido. Dado que a velocidade de propagação é conhecida, o cálculo da distância até ao objeto, é efetuado com base na seguinte fórmula (3.1):

$$d = c * (t/2) \quad (3.1)$$

em que  $d$  é a distância,  $c$  é a velocidade da luz e  $t/2$  é o tempo dividido porque o pulso faz um percurso de ida e volta, sendo necessário considerar só o tempo de ida (*IBM,2023*).

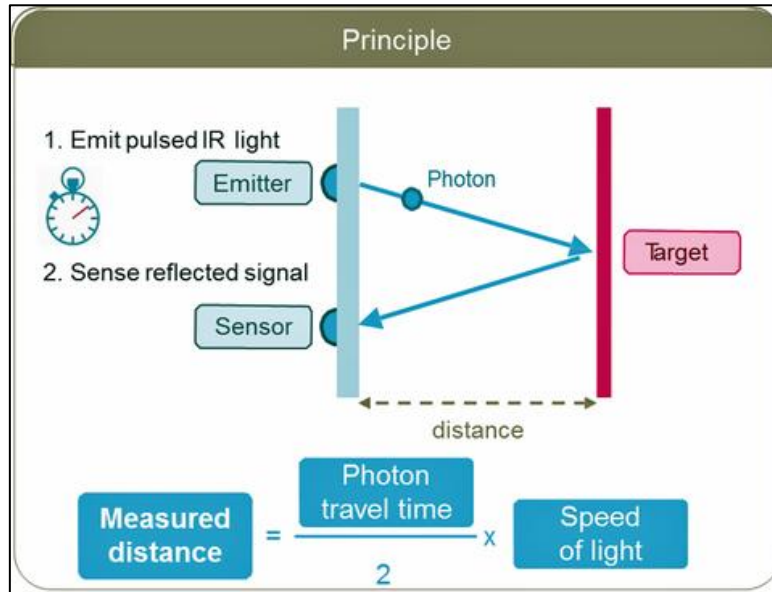


Figura 3.2. Princípio em que se baseia o sistema LiDAR. Fonte: Li,R.,2024.

Este processo repete-se sucessivamente enquanto o sistema está em operação, varrendo a área de estudo. A cadência é elevada no que se refere às emissões, o que faz com que se acumulem milhões de medições pontuais (IBM,2023). Cada medida corresponde a um ponto no espaço onde o pulso incidiu, com coordenadas derivadas dos ângulos de emissão, do tempo de retorno e da posição do sensor fornecida pelo GPS/IMU. O conjunto de todos estes pontos 3D constitui a nuvem de pontos LiDAR, que é uma representação discreta e densa da superfície terrestre. Um aspeto de destaque dos sensores LiDAR é a capacidade de registar múltiplos retornos de um mesmo pulso (Figura 3.3). Esta particularidade é útil para áreas com vegetação densa, dado que parte dos pulsos laser consegue penetrar pelos interstícios da cobertura florestal. Assim um pulso laser pode refletir, por exemplo, o topo das árvores (primeiro retorno), depois ramos ou vegetação intermediária (retornos intermédios) e o solo, caso atinja abertura suficiente até ao terreno (último retorno) (GISGeography, n.d.).




Figura 3.3. Ilustração dos múltiplos ecos dos impulsos laser LiDAR. Fonte: Yan, W. et al.,2015.

O sensor regista os ecos sucessivos, associados ao mesmo pulso. Desta forma, temos a informação da altura da estrutura vertical, desde a copa das árvores até ao solo, dado que o pulso atravessa várias camadas da vegetação (*GISGeography, n.d.*). Além do tempo de retorno, os sensores também medem a intensidade do sinal refletido. A intensidade do retorno varia conforme as características da superfície do objeto (material, cor, rugosidade). Essas diferenças de refletividade acrescentam uma dimensão radiométrica aos dados LiDAR, podendo ser posteriormente exploradas para distinguir os alvos. Verifica-se que as superfícies artificiais, edificadas ou pavimentadas, podem se destacar em imagens de intensidade LiDAR em comparação com as superfícies naturais, servindo de apoio às tarefas de classificação temática (*GISGeography, n.d.*).

Após a recolha, os dados passam por diversas etapas de processamento. São aplicados filtros para remover os pontos de ruído e, posteriormente, é aplicado algoritmos específicos para classificar os pontos da nuvem consoante a classe que representam, isto é, separar os pontos ao nível do solo daqueles que correspondem à vegetação ou a outras estruturas verticais. Este processo identifica de forma automática, diferentes elementos, como o terreno, edifícios, linhas de água e copas das árvores. A partir daí, podem ser gerados diferentes produtos cartográficos derivados, como um Modelo Digital de Superfície (MDS), um Modelo Digital de Terreno (MDT) e até modelos de altura das copas, calculados pela diferença entre o MDS e o MDT, originando um Modelo de Altura do Coberto (*Canopy Height Model, CHM*), entre outros produtos. Os dados LiDAR são normalmente convertidos para um formato padrão, LASer (LAS v.1.4), para facilitar a sua partilha e análise. Desta forma, com a nuvem de pontos devidamente georreferenciada e classificada, esta pode ser utilizada para visualização 3D ou ser integrada em sistema de informação geográfica para diversas aplicações (*IBM,2023 ; DGT, n.d.*).

Na visualização inicial, recorrem-se a operações básicas como coloração por atributos (altura ou intensidade, por exemplo) e análise de perfis verticais, que permitem confirmar se os valores registados são consistentes e se a classificação automática apresenta erros evidentes. Esta etapa funciona como controlo de qualidade inicial. É importante notar que a visualização foi limitada ao ambiente 2D devido à natureza da COS, que é também um produto cartográfico bidimensional. Contudo, as ferramentas de visualização mais específicas, que tiram partido da informação tridimensional do LiDAR, são abordadas em seguida.

Os três visualizadores mais populares para análise e visualização (Tabela 3.1): o *Quick Terrain Reader*, o *FugroViewer* e o *CloudCompare*. Todos permitem navegação 3D, colorir por atributos e fazer medições, mas diferem dependendo do foco principal. O *Quick Terrain Reader*, desenvolvido pela *Applied Imagery*, é um visualizador gratuito que, no entanto, é um componente do *software Quick Terrain Modeler*, que permite abrir ficheiros LAS/LAZ, de grande dimensão, de forma muito rápida e inspecionar os dados em poucos cliques. O *FugroViewer*, desenvolvido por *Fugro*, é um visualizador gratuito e independente, sendo um visualizador para a inspeção e a seleção com simbologia por atributos. Por fim, o *CloudCompare*, desenvolvido por *Daniel Girardeu-Montaut* é um visualizador de código aberto (também gratuito) que oferece funcionalidade avançadas para análise e comparação entre nuvens.

Além destes, o FUSION/LDV do *United States Forest Service (USGS)* é um ambiente de visualização integrado no ecossistema FUSION. Para fluxos reprodutíveis, recomenda-se ainda trabalhar em *R(4.1.1)* com o pacote *lidR (4.0.2)* (*Roussel & Auty, 2025*), que conjuga o processamento e visualização de nuvens, perfis e ficheiros matriciais derivados, dentro do *R*. Esses recursos também lista recursos como *LAStools* e *MCC-LIDAR* que são mais vocacionados para processamento e menciona

alternativas comerciais como LiDAR360, mas, para uma visualização e validação rápida dos dados ALS, o trio *Quick Terrain Reader*, *FugroViewer* e *CloudCompare* é o núcleo sugerido.

Tabela 3.1. Resumo das aplicações informáticas (softwares) de visualização LiDAR, com tipo, exemplos e principais usos em validação.

<b>Software</b>	<b>Tipo</b>	<b>Exemplo de visualização</b>	<b>Ponto forte ao usar</b>
<b>Quick Terrain Reader</b>	Visualizador 3D	Nuvem 3D; cores por altura/intensidade/classe; perfis; medições	Muito leve e rápido para inspeção de ALS e validação visual.
<b>FugroViewer</b>	Visualizador gratuito 3D	Nuvem 3D; simbologia por atributos; ROIs; perfis	Prático para abrir LAS/LAZ e fazer checks rápidos.
<b>CloudCompare</b>	Visualizador de código aberto 3D	Nuvem 3D; cortes/ secções; perfis; comparação	Ferramentas ricas para QA/QC e análise visual mais detalhada.
<b>FUSION/LDV</b>	Visualizador + Utilitários	Inspeção 3D; colorir por atributos; perfis	Integra com ferramentas FUSION; recomendado no curso (nota do LASzip).
<b>R + lidR</b>	Programação em R	Visualização de nuvens; perfis; rasters (MDT/MDS/CHM)	Fluxos reprodutíveis; juntar visualização ao processamento.

## 4 Revisão de Literatura

A tecnologia LiDAR emergiu no final do século XX como uma ferramenta revolucionária na cartografia, especialmente para gerar, de forma automática, modelos digitais de terreno de alta precisão (Ackermann, 1999). De estatuto experimental nos anos 70, com sistemas pioneiros da NASA, o LiDAR ALS foi consolidado na década de 90 como método independente para a obtenção de dados altimétricos de elevada precisão, reduzindo drasticamente a necessidade de intervenção humana na produção de MDTs. Ackermann (1999) notou que, em poucos anos, a varredura laser aérea se estabeleceu com sucesso em diversas aplicações cartográficas. Paralelamente, Wehr e Lohr (1999) introduziram de forma abrangente a tecnologia, onde se destacam os princípios de funcionamento e o potencial da varredura laser aérea para medir terrenos mesmo em áreas de florestas, graças à capacidade de múltiplos retornos do pulso laser. Esse potencial levou a uma rápida adoção do LiDAR por agências cartográficas nacionais no início do século XXI, revolucionando a aquisição topográfica tradicional.

Nas décadas de 2000 e 2010 observou-se um progresso notável tanto nos sensores LiDAR quanto nos métodos de processamento. Os sistemas tornaram-se mais leves e compactos, viabilizando o seu uso em VANTs e aumentando consideravelmente a densidade de pontos capturados (Mandlbürger, 2024). Por exemplo, os sensores atuais conseguem taxas de mais de 20 pontos por metro quadrado, o que permite obter produtos de terreno com resolução elevada. Além da geometria precisa e da capacidade de penetrar na vegetação, os sensores modernos também registam a intensidade do retorno, o que adiciona conteúdo radiométrico útil às análises semânticas dos pontos. Esta tecnologia foi inicialmente concebida para gerar modelos altimétricos, evoluindo para um recurso polivalente na cartografia, integrado gradualmente nos fluxos de produção de mapas topográficos nacionais (Mandlbürger, 2024) e abrindo caminho para aplicações mais diversas.

Com o amadurecimento do LiDAR, tornou-se vantajoso integrar dados LiDAR com dados espectrais, multiespectrais ou hiperespectrais para melhorar a qualidade da cartografia temática. Os dois tipos de sensores fornecem informações complementares. Enquanto o LiDAR oferece atributos geométricos tridimensionais, as imagens óticas fornecem informação espectral. Diversos estudos têm demonstrado que a fusão destas duas fontes de dados melhora significativamente a classificação do uso do solo, comparativamente ao uso isolado de cada uma (Dalponte et al., 2008; Antonarakis et al., 2008).

Uma das contribuições fundamentais do LiDAR para a cartografia temática é a capacidade de distinguir classes de ocupação do solo com base em características tridimensionais, o que é particularmente útil para diferenciar classes de vegetação, superfícies artificializadas e outras categorias com morfologia distinta. No caso da vegetação, os pulsos laser permitem estimar a altura da copa das árvores e a estrutura vertical da vegetação, dados essenciais para distinguir floresta de matos ou pastagens. Hyypä et al. (2008) mostraram que a tecnologia LiDAR se tornou o método padrão para extrair informação relevante para a produção de inventários florestais, como altura dominante das árvores, biomassa e volume, com elevada precisão, comparativamente aos métodos tradicionais de fotointerpretação. Os CHMs derivados do LiDAR permitem mapear a vegetação alta e baixa, em larga escala (Popescu et al., 2003). Zhao et al. (2022) reforçam que os atributos de altura extraídos do LiDAR discriminam a vegetação alta e baixa, conforme demonstrado nas experiências. Assim, as coberturas arbóreas podem ser separadas de matos rasteiros ou de culturas agrícolas apenas pelo critério de altura da vegetação. Este tipo de informação tridimensional supera as ambiguidades típicas das análises espectrais, como observado em campos agrícolas abandonados com vegetação herbácea que podem

apresentar uma assinatura espectral semelhante à de um prado ou de um mato baixo. Ainda assim, se existirem árvores jovens dispersas, o LiDAR deteta essas alturas pontuais, permitindo identificar a presença de estágios iniciais de arborização.

Entretanto, há classes particularmente difíceis de discriminar, mesmo com dados LiDAR. Estas correspondem à vegetação rasteira densa e a árvores jovens. Essas categorias podem ter alturas semelhantes no terreno, gerando confusões na classificação. *Kuras et al. (2021)* salientam esta limitação, que resulta do facto de a morfologia de árvores jovens e de matos altos causar, frequentemente, classificações erradas, dada a confusão entre arbustos e árvores altas. Para solucionar esta limitação, pode ser necessária uma fusão adicional de dados ou o uso de algoritmos de aprendizagem automática mais sofisticados capazes de aproveitar as variações da nuvem de pontos para diferenciar a estrutura das copas. Por exemplo, em áreas florestais complexas, a combinação de imagens hiperespectrais de alta resolução com dados LiDAR permitiu classificar espécies arbóreas com maior exatidão, tirando partido, simultaneamente, da diferença espectral entre diferentes tipos de folha e estrutura da copa (*Dalponte et al., 2008*). Também em áreas com vegetação esparsa ou pastagens, a inclusão da altura do LiDAR ajudou a separar formações vegetais espectralmente semelhantes (*Antonarakis et al., 2008*).

O LiDAR é igualmente importante em áreas urbanas para distinguir elementos construídos e classes urbanas complexas. A capacidade de extrair feições geométricas torna a varredura laser uma ferramenta fundamental para a deteção de construções (*Kuras et al., 2021*). Os autores referem que, em ambiente urbano, os algoritmos de classificação baseados em LiDAR tradicionalmente concentravam-se em identificar edifícios e vegetação alta, devido à elevada refletância e à forma plana dos telhados, aliadas à altitude acima do solo, facilitando a sua distinção nas nuvens de pontos. Estas técnicas clássicas para extrair edificações incluem a geração de MDSs e MDTs a partir do LiDAR e de modelos de altura normalizada (nDSM) que representa exclusivamente a altura dos objetos acima do solo, obtido ao subtrair o MDT com o MDS. As áreas com elevação positiva significativa e contornos definidos no nDSM indicam prováveis edifícios (*Yan et al., 2015*). De facto, abordagens com o DSM/nDSM derivado do LiDAR para detetar edifícios são comuns e eficazes (*Yan et al., 2015*). Além disso, o LiDAR fornece intensidades de retorno que podem ajudar a distinguir materiais urbanos (*Song et al., 2002*), embora com menor detalhe espectral do que imagens óticas.

Desta forma destaca outra distinção difícil de alcançar, que é a separação entre superfícies artificiais planas constituídas por materiais distintos. Isoladamente, o LiDAR identifica ambos como planos elevados em relação ao solo, mas não distingue com clareza a composição do material, enquanto a imagem multispectral distingue as superfícies pelo comportamento espectral. Assim, a abordagem de fusão de dados multisensor (hiperespectral e LiDAR), referida por *Kuras et al. (2021)* como HL-Fusion, é necessária para classificar corretamente nesses casos.

*Kuras et al. (2021)*, numa revisão sobre classificação urbana, destacam que os avanços tecnológicos nos sensores hiperespectrais e LiDAR abriram um novo caminho para a aplicação de algoritmos de aprendizagem automática para mapear cidades, visto que ambos os sistemas conseguem discriminar muitas estruturas e materiais urbanos significativos, os quais não seriam distinguíveis com apenas uma das fontes. O LiDAR, em particular, adiciona uma dimensão vertical que permite distinguir objetos de materiais idênticos, mas com alturas distintas, já os dados espectrais discriminam superfícies pelo material. Esta complementaridade supera as limitações dos sensores isolados, dado que a natureza ativa do LiDAR faz com que não dependa da iluminação solar, o que auxilia a correção de sombras em

imagens óticas quando usados em conjunto. Estudos recentes mostram que os métodos de fusão multisensor, frequentemente apoiados em aprendizagem profunda, conseguem tirar partido dessas características complementares para melhorar a eficácia da classificação da ocupação do solo (Li et al., 2025).

As técnicas avançadas de fusão, como a aprendizagem profunda multimodal, já demonstraram ganhos de desempenho com a inclusão de características espectrais e estruturais de cada sensor, distinguindo classes de terreno com maior precisão (Li et al., 2025; Zhu et al., 2017). Em síntese, a integração de dados LiDAR com imagens multiespectrais ou hiperespectrais tornou-se uma prática recomendada na literatura, pois fornece conjuntos de dados geográficos mais completos, face aos obtidos com apenas uma das fontes, potenciando a qualidade da classificação temática.

Em culturas permanentes, como vinhas, seja em latada ou cordão, olivais intensivos e pomares, estas métricas LiDAR são particularmente úteis para a gestão do vigor, a delimitação de talhões e o suporte a decisões de agricultura de precisão (Moreno et al., 2020; Karim et al., 2024). A vantagem competitiva do LiDAR, face aos métodos espectrais, consiste na capacidade de medir diretamente a geometria tridimensional da cultura, fornecendo informações críticas. No caso das vinhas, Moreno et al., 2020 mostraram que um sistema LiDAR terrestre consegue reconstruir com clareza a estrutura da videira, estimando os volumes de ramos e as métricas da copa, possibilitando uma gestão sítio-específica. Mais recentemente, Chedid et al. (2023) usaram dados LiDAR para extrair traços quantitativos de crescimento e demonstraram que esses traços explicam diferenças genéticas de vigor entre os diversos tipos de videira, validando o LiDAR como ferramenta para o mapeamento do vigor, a escolha das variedades e, eventualmente, a previsão da colheita (Chedid et al., 2023 ; Moreno et al., 2020).

Em olivais intensivos, a relação entre a estrutura da copa e o desempenho produtivo tem ganho destaque. Sardonís-Pozo et al. (2024) propuseram índices derivados de dados LiDAR que relacionaram com a produtividade e com atributos de qualidade, evidenciando que regimes de irrigação e azotagem distintos se refletem em diferenças mensuráveis na geometria e porosidade da copa. Estes resultados sugerem que mapas obtidos com índices LiDAR podem ser usados para ajustar a rega e a fertilização ao longo do ano agrícola, otimizando o compromisso entre produção e qualidade. Embora recentemente, esta linha de trabalho aponta para a operacionalização do LiDAR como sensor de apoio à tomada de decisão na olivicultura de precisão. Nos pomares, o foco tem sido a medição direta de parâmetros geométricos que sustentam a gestão diária, como a altura das árvores, o volume de copa e o espaçamento intralinha e entrelinhas. Karim et al. (2024) mostraram que estimativas da altura e do volume da copa, obtidas com dados LiDAR, apresentam elevada concordância com medições de campo, fornecendo indicadores operacionais para o planeamento da poda, a calibração da pulverização e o cálculo da área foliar equivalente. A possibilidade de repetir as aquisições ao longo do ciclo cultural permite construir séries temporais da estrutura, úteis para monitorizar respostas a práticas culturais e a episódios climáticos.

Para além da caracterização intra-talhão, o LiDAR ALS tem utilidade na cartografia do uso do solo agrícola, nomeadamente na separação de pomares de áreas florestais. Hycza e Kupidura (2021) mostraram que padrões espaciais regulares observáveis na nuvem de pontos permitem distinguir pomares de coberturas arbóreas naturais e, conseqüentemente, obter elevadas taxas de acerto. Tal é relevante em inventários oficiais e em cartografia temática, como a COS, onde a correta identificação

de “árvores dispersas em cultura” vs. “bosque” ou “pomar” vs. “matos” continua a ser um desafio quando da utilização apenas da informação espectral.

A nível internacional, muitos países conduziram programas nacionais de levantamento LiDAR para cobrir extensivamente os seus territórios com dados altimétricos de alta densidade. Nos EUA, por exemplo, o programa *3D Elevation Program* (3DEP) do USGS estabeleceu especificações padrão para dados LiDAR e visa disponibilizar um modelo de elevação 3D consistente para o país (USGS, 2014). Essas especificações padronizadas, como a densidade mínima de pontos, o erro vertical máximo e o formato LAS, asseguram que os dados LiDAR possam ser integrados nos produtos oficiais, como ortofotomapas, modelos digitais de terreno nacionais e mapas de ocupação do solo. Diversas agências europeias também adotaram o LiDAR, como no caso da Finlândia e da Suécia, onde os dados LiDAR são utilizados há anos para atualizar inventários florestais nacionais (Hyypä et al., 2008), enquanto nos Países Baixos, o LiDAR é parte integrante do sistema de informação geográfica nacional. À medida que a tecnologia se difunde, surgem esforços para estabelecer normas e protocolos que garantam a interoperabilidade e a qualidade dos dados e dos produtos. Um exemplo são as especificações base LiDAR definidas pelo USGS (2014) e entidades como a Sociedade Americana para a Fotogrametria e a Detecção Remota (*American Society for Photogrammetry & Remote Sensing*, ASPRS), que normalizam aspetos como o formato, o padrão LAS 1.4, as classes de pontos, a densidade mínima, a precisão vertical e até os procedimentos de calibração dos sensores. A adoção universal do formato LAS e de convenções comuns facilitou a partilha e reutilização de nuvens de pontos em diferentes projetos.

Resumindo, o LiDAR deixou de ser apenas uma curiosidade técnica para se tornar uma infraestrutura de dados geoespaciais básica. A produção da COS em Portugal exemplifica essa institucionalização pela adoção de uma metodologia que promove um maior alinhamento entre bases de dados territoriais de diferentes setores, com a combinação de fontes atualizadas como imagens de satélite, bases administrativas e dados LiDAR (DGT, 2025a). A integração do LiDAR nestes fluxos oficiais traz ganhos de eficiência, com processos mais rápidos e automatizados e coerentes, dada a compatibilidade entre a classificação da COS e outras tipologias, como a nomenclatura do Inventário Florestal Nacional (DGT, 2025a). Com a abertura dos dados LiDAR ao público e a contínua atualização tecnológica, espera-se que projetos institucionais futuros utilizem o LiDAR de forma ainda mais abrangente (Mandlbürger, 2024).

Em conclusão, o processamento de dados LiDAR para a geração de informação geográfica que possibilita melhorar significativamente a produção de cartografia de uso e de ocupação do solo atingiu um grau elevado de desenvolvimento, tal como é evidenciado pela literatura mais recente:

(1) a tecnologia LiDAR, inicialmente focada na obtenção de modelos de terreno, evoluiu para integrar plenamente projetos cartográficos de grande escala;

(2) a fusão de dados LiDAR com imagens óticas ou radar tornou-se parte integrante do estado da arte para melhorar a distinção de usos/coberturas;

(3) os dados LiDAR provaram o seu valor para discriminar classes complexas, embora persistam ainda alguns desafios na discriminação de algumas classes, potenciando o desenvolvimento de novas abordagens;

(4) as instituições cartográficas nacionais incorporam cada vez mais os dados LiDAR nos fluxos de produção de dados oficiais, beneficiando de dados 3D detalhados e atualizados.

## 5 Área de Estudo

### 5.1 Área de Estudo

A área de estudo corresponde ao Bloco 3A da divisão nacional de blocos de levantamento LiDAR, localizado na região centro-oeste de Portugal, que abrange a Grande Lisboa, a Zona Oeste, a região de Leiria, o Médio Tejo, a Lezíria do Tejo e a Península de Setúbal, como se observa na Figura 5.1. Esta zona caracteriza-se por uma grande diversidade de usos do solo. Esta heterogeneidade torna o Bloco 3A particularmente adequado para a análise, pois permite avaliar, de forma integrada, diferentes padrões de ocupação e cobertura do solo.

Para além disso, a escolha deste bloco justifica-se pelo facto de representar um território onde se cruzam realidades distintas, desde áreas agrícolas específicas, como os pomares, até zonas florestais relevantes, bem como áreas urbanas em expansão.

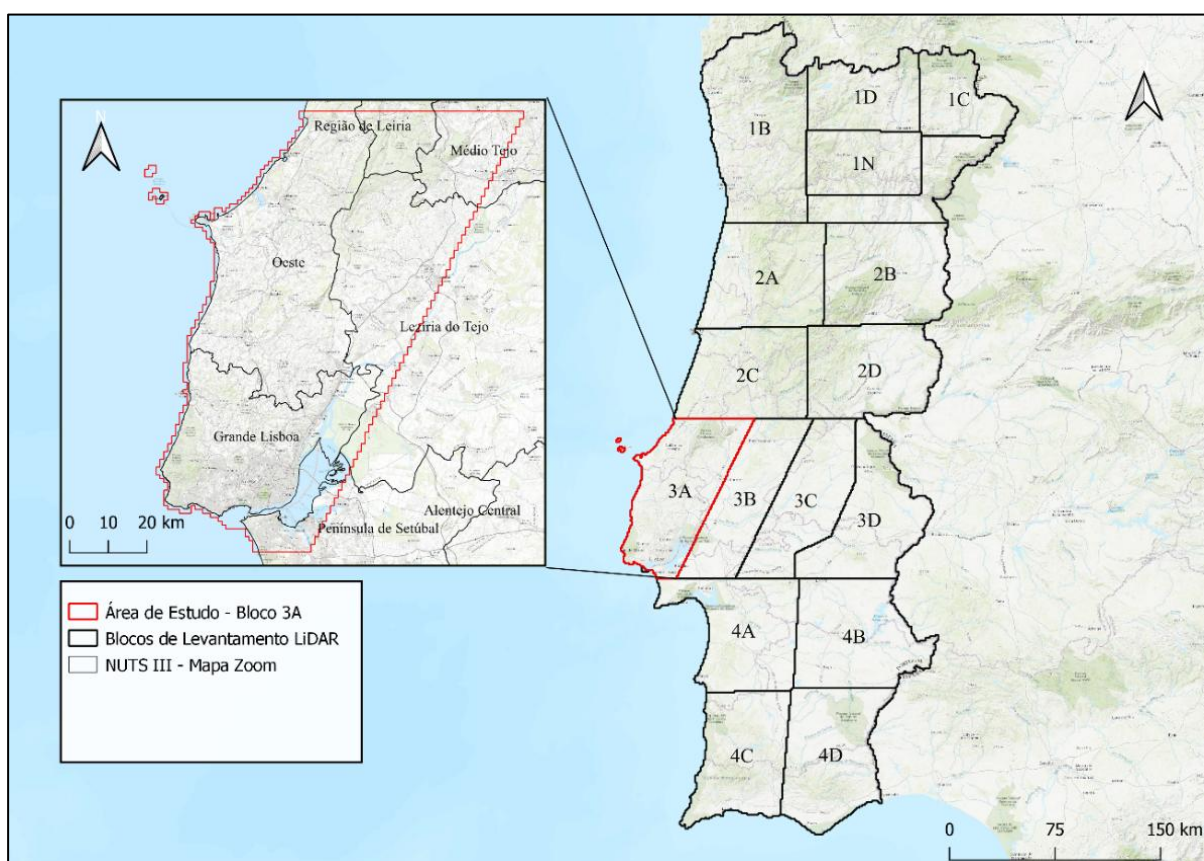


Figura 5.1. Enquadramento da área de estudo (Bloco 3A) na visão global dos blocos de Levantamento LiDAR e detalhe do respetivo enquadramento nas NUTS III.

O Bloco 3A caracteriza-se por uma elevada diversidade de usos do solo, como se observa na Figura 5.2 e na Tabela 5.1. A classe mais representativa é a agricultura, que ocupa uma área de cerca de 212 342 ha, correspondente a 34,9% da área total, o que demonstra a relevância do setor primário e a forte vocação agrícola do território. As florestas representam igualmente uma área significativa, cobrindo aproximadamente 133 285 ha (21,9%), desempenhando um papel essencial na estrutura ecológica e na manutenção dos serviços dos ecossistemas. Seguem-se os territórios

artificializados, que representam 92 960 ha (15,3%), correspondentes sobretudo a áreas urbanas e periurbanas, o que evidencia a pressão antrópica associada à expansão urbana.

Os matos ocupam cerca de 69 890 ha (11,5%), muitas vezes como zonas de transição entre sistemas florestais e agrícolas. As massas de água superficiais, associadas a rios, albufeiras e áreas costeiras, abrangem 50 411 ha (8,3%) e correspondem na sua maioria, ao estuário do Tejo, que assume particular importância no contexto da paisagem. Com expressão mais reduzida surgem as pastagens, que ocupam 42 702 ha (7,0%) e reforçam a presença de sistemas agro-pastoris tradicionais, e ainda as classes minoritárias como as zonas húmidas (3 359 ha; 0,6%), os espaços descobertos ou com pouca vegetação (2 184 ha; 0,4%) e as superfícies agroflorestais (1 370 ha; 0,2%), que, apesar da dimensão mais limitada, desempenham funções específicas no mosaico territorial.

Assim, a distribuição de usos e ocupação do solo no Bloco 3A revela um território multifuncional, em que coexistem áreas de forte peso agrícola, relevantes manchas florestais e zonas artificializadas, mas também áreas naturais e seminaturais de menor expressão, que contribuem para a diversidade ecológica. Esta composição mostra que o Bloco 3A combina um contexto fortemente marcado pela influência hídrica, com a presença de importantes massas de água, mas também pela existência de mosaicos agrícolas, áreas florestais e perímetros urbanos, que asseguram uma diversidade paisagística e funcional. Tal diversidade justifica plenamente a escolha desta área para análise, já que permite testar metodologias em cenários contrastantes de ocupação e uso do solo.

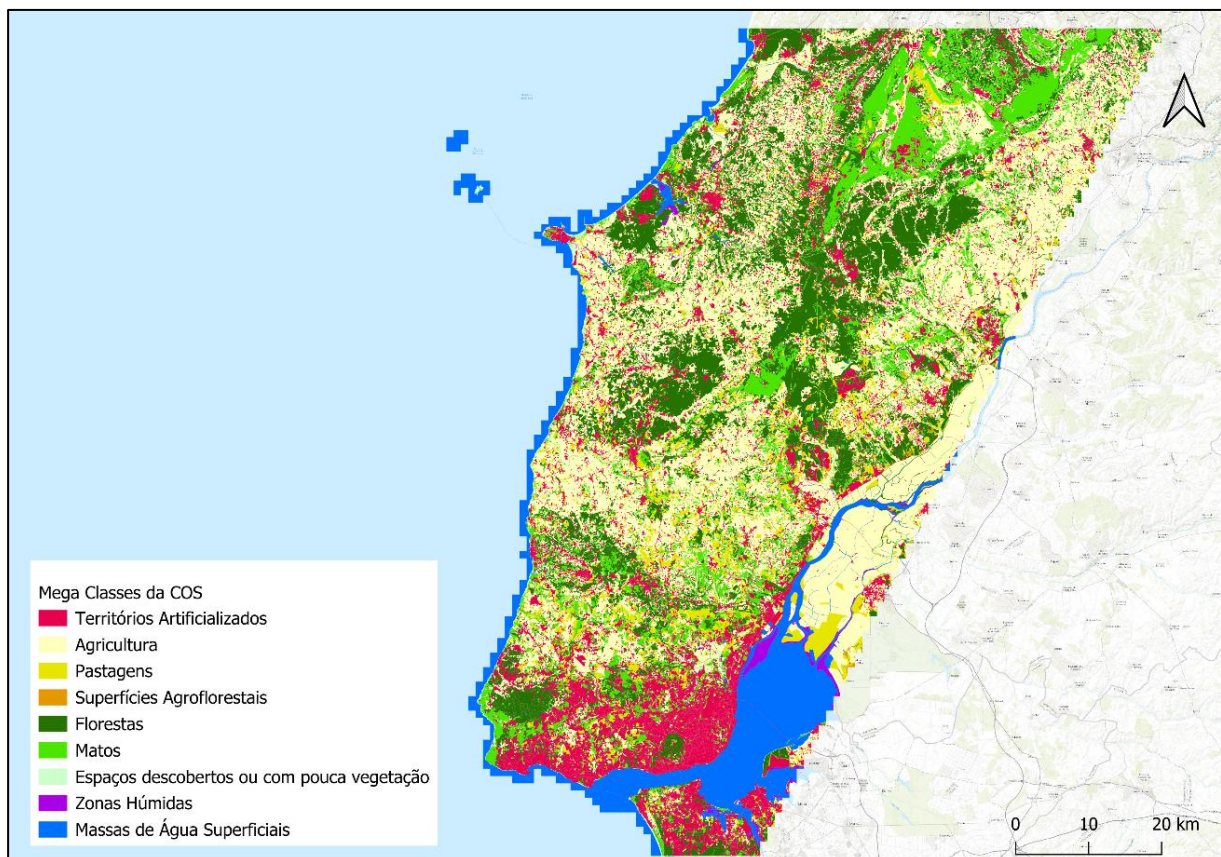


Figura 5.2. Ocupação do Solo no Bloco 3A (megaclasses da COS). Fonte de Dados: SNIG – COS2023.

Tabela 5.1. Representação de cada ocupação na globalidade do Bloco 3A.

<b>Classe de Ocupação do Solo</b>	<b>Valor de área em hectares</b>	<b>Percentagem de representação na área de estudo (%)</b>
<b>Territórios Artificializados</b>	92 960	15,3
<b>Agricultura</b>	212 342	34,9
<b>Pastagens</b>	42 702	7,0
<b>Superfícies Agroflorestais</b>	1 370	0,2
<b>Florestas</b>	133 285	21,9
<b>Matos</b>	69 890	11,5
<b>Espaços descobertos ou com pouca vegetação</b>	2 184	0,4
<b>Zonas Húmidas</b>	3 359	0,6
<b>Massas de Água Superficiais</b>	50 411	8,3

## 5.2 Especificações dos Dados Utilizados

O conjunto de dados LiDAR usado é uma nuvem de pontos de elevada resolução por ALS, juntamente com produtos matriciais derivados que cobrem Portugal Continental. Os dados estão organizados em mosaicos 1 km x 1 km com georeferenciação no sistema de coordenadas oficial nacional, ETRS89/PT-TM06. As nuvens de pontos são entregues em formato *LAS 1.4 (DGT, n.d.)*, que assegura a compatibilidade com atributos modernos de pontos LiDAR. Esta distribuição usa frequentemente a compressão .laz para otimizar a transferência e armazenamento. Os ficheiros matriciais derivados (MDT/MDS) são disponibilizados em formato *GeoTIFF* com resoluções espaciais ajustadas à densidade de pontos e disponíveis em resoluções de 50 cm e 2 m.

A densidade média é de 10 pontos por metro quadrado, com uma precisão altimétrica de 10 cm e uma precisão planimétrica na ordem de 30 cm. Estas características tornam o conjunto adequado para a modelação detalhada do terreno, a análise da estrutura da vegetação, a cartografia de infraestruturas e estudos ambientais. As observações encontram-se classificadas com base num esquema temático objetivo. As classes relevantes para análise são as que constam na Tabela 5.2.

Tabela 5.2. Classificação dos pontos derivados da nuvem de pontos do levantamento LiDAR (padrão LAS 1.4). Adaptado de: (DGT, n.d.).

Valor da classificação	Significados
1	Outro
2	Terreno
3	Vegetação Baixa (0 m até 0,5 m)
4	Vegetação Média (0,5 m até 2 m)
5	Vegetação Alta (acima de 2 m)
6	Construções
7	Ruído
9	Água
26	Pontes

A estrutura dos dados LiDAR apresenta diferentes atributos, em que cada ponto possui, além das coordenadas espaciais (X,Y,Z), um conjunto de atributos que permitem caracterizar o terreno. Na Tabela 5.3 estão listados os atributos existente em cada ficheiro LAS, tal como definidos pela *The American Society for Photogrammetry & Remote Sensing (ASPRS)*.

Tabela 5.3. Atributos de cada ponto LiDAR.

<b>Data de criação</b>	Date (Day/Month/Year)
<b>Versão</b>	1.4
<b>Formato para dados</b>	Time, color, and near infrared are stored (8)
<b>Scale X</b>	0,001
<b>Scale Y</b>	0,001
<b>Scale Z</b>	0,001
<b>Deslocamento X</b>	0
<b>Deslocamento Y</b>	0
<b>Offset Z</b>	0
<b>Software ID</b>	<i>rlas R package</i>

As coordenadas tridimensionais (X, Y, Z) definem a localização exata de cada ponto no espaço, constituindo a base da informação geoespacial contida no ficheiro LAS. Em muitos conjuntos de dados LiDAR, podem estar também presentes atributos adicionais, como a intensidade do sinal refletido, os números de retorno, a classificação dos pontos ou parâmetros técnicos do sensor (o canal do scanner e a direção do varrimento, são alguns exemplos), que fornecem detalhes sobre a origem de cada ponto. No entanto, no conjunto de dados utilizado, apenas um subconjunto desses campos está presente, que inclui coordenadas espaciais, registo temporal e valores espectrais (cor e NIR). Estes atributos foram armazenados com fatores de escala de 0,001 e sem deslocamento, como indicado na Tabela 5.3, e o ficheiro foi obtido com recurso ao *R package*. Estes elementos demonstram que cada ponto LiDAR é

muito mais do que uma simples coordenada, reunindo um conjunto alargado de atributos, que possibilitam a realização de análises detalhadas e precisas sobre o território.

O outro conjunto de dados utilizado foi a COS2023, a mais recente carta de uso e cobertura do solo para o território de Portugal continental. Com base na explicação na *secção 2.1.2*, esta base cartográfica apresenta as características descritas na Tabela 5.4. Tem como referência o ano de 2023 e apresenta uma unidade mínima cartográfica de 1 ha, com uma distância mínima entre linhas de 20 metros. Apresenta 93 classes de uso e ocupação do solo, agrupadas em 9 megaclasses. A sua produção baseou-se em diversos conjuntos de dados combinando também métodos automáticos e fotointerpretação. Esta nova versão da COS está disponível no SNIG, a infraestrutura de âmbito nacional de informação geográfica, que permite o acesso aos dados em formato vetorial, no entanto, para a sua visualização recomenda-se a utilização do visualizador SMOS, o viSMOS.

*Tabela 5.4. Características da Carta de Uso e Ocupação do Solo (COS) 2023. Adaptado de: (DGT, 2025a).*

<b>Característica</b>	<b>Descrição</b>
<b>Referência Temporal</b>	2023
<b>Formato de Dados</b>	Vetorial
<b>Unidade mínima cartográfica</b>	1 ha
<b>Distância entre Linhas</b>	20 metros
<b>Número de classes</b>	93 classes, agrupadas em 9 megaclasses
<b>Dados Base</b>	Sistema de Identificação Parcelar (SIP), Regime Jurídico das Arborizações e Rearborizações (RJAAR), inventário florestal nacional (IFN), bases administrativas e conjuntos de apoio (CDG) derivados de imagens de satélite e LiDAR
<b>Disponibilidade</b>	SNIG <sup>2</sup>

<sup>2</sup> <https://snig.dgterritorio.gov.pt/rndg/srv/por/catalog.search#/metadata/e7d91649-71dd-4a3a-ae38-e680fc54be88>

## 6 Metodologia

### 6.1 Processamento dos dados LiDAR

O processamento dos dados LiDAR foi desenvolvido para transformar a nuvem de pontos bruta em produtos derivados, com aplicação direta na análise do uso e da ocupação do solo. A metodologia seguiu uma lógica sequencial, desde a preparação e normalização da informação até à criação de superfícies de referência (MDT e CHM) e à detecção de árvores individuais (Figura 6.1). Estes produtos permitem caracterizar com elevado detalhe a estrutura da vegetação e apoiar a cartografia temática.

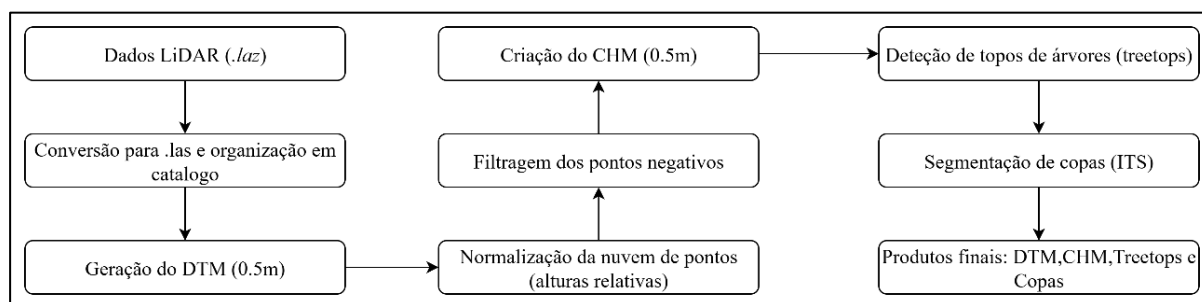


Figura 6.1. Fluxo de processamento de dados LiDAR para obter o MDT, o CHM, os topos das árvores (Treetops) e as copas das árvores (Crowns).

A metodologia seguida para o processamento dos dados LiDAR partiu da organização inicial dos ficheiros originais em formato comprimido (.laz) e da sua conversão para o formato não comprimido (.las), mais adequado ao processamento intensivo. No entanto, apesar de reduzir fortemente o tempo de processamento, tem o custo de ocupar 6 a 7 vezes mais espaço de armazenamento. Para garantir maior eficiência, os dados foram organizados em catálogos espaciais (LAScatalog) e criou-se um índice auxiliar (.lax), que também acelera a leitura e a análise. Todo o processamento foi realizado no RStudio, utilizando a linguagem de programação R (RCoreTeam, 2025). A biblioteca principal foi o lidR (4.0.2) (Roussel & Auty, 2025), que constitui a base para as etapas de geração do MDT, do CHM, dos topos das árvores (Treetops) e das copas das árvores (Crowns). O ecossistema foi complementado com bibliotecas de apoio para análise espacial e matricial (future, future.apply, tictoc, raster, terra e sf). Os procedimentos foram executados na workstation DGT-759, com as especificações técnicas descritas na Tabela 6.1:

Tabela 6.1. Características da Workstation DGT-759.

Componente	Especificação
Processador (CPU)	Intel® Xeon® Gold 6140 @ 2.30 GHz
N.º de Núcleos / Threads	18 / 36
Memória RAM	64 GB DDR4 @ 2666 MHz
Sistema Operativo	Windows 10

Importa ainda salientar que as metodologias de processamento LiDAR resultam e foram consolidadas a partir de um trabalho de investigação desenvolvido na DGT, no âmbito de iniciativas internas de melhoria de processos e transferência de conhecimento para a produção operacional.

Com base nesse fluxo de processamento, foi gerado um MDT com resolução de 0,5 m, recorrendo a algoritmos de interpolação de redes triangulares irregulares (Triangulated Irregular

*Network*, *TIN*) que permitem modelar a superfície do solo mantendo um elevado nível de detalhe. Este MDT serviu de base para normalizar a altura da nuvem de pontos, isto é, subtrair a altitude do terreno à altitude absoluta medida pelo LiDAR, resultando em alturas relativas que representam a vegetação. Para evitar ruído, aplicou-se uma filtragem pós-normalização que removeu pontos negativos, e nas fases subsequentes restringiu-se a análise às classes de vegetação.

Para a segmentação das copas (*Individual Tree Segmentation*, *ITS*), a partir da nuvem de pontos normalizada, foi inicialmente criado o CHM com uma resolução de 0,5 m, que corresponde a um ficheiro matricial com a altura máxima da vegetação em cada célula. O CHM foi obtido com a função «*lidR::grid\_canopy()*» usando o método *pit-free*, que interpola a superfície do copado para reduzir os vazios existentes tipicamente nas copas mais esparsas, ou seja, preencher as lacunas entre o terreno e a copa, para produzir uma superfície mais contínua e adequada às análises. Os valores negativos residuais foram substituídos por zero para evitar o ruído. Este modelo constitui um dos produtos fundamentais para a caracterização da estrutura florestal, uma vez que permite discriminar áreas arborizadas e analisar a sua variação espacial.

De seguida, a partir da nuvem de pontos normalizada, identificaram-se os máximos locais que representam os topos das árvores com a função «*lidR::locate\_trees()*», usando o método Local Maximum Filter (LMF). A dimensão da janela de procura variou linearmente com a altura segundo « $ws(h) = 0.07 * h + 3.5$ » (em metros), sendo definido um limiar mínimo de altura de 1,5 m ( $h_{min}=1.5$ ) para assim excluir a vegetação rasteira. O formato de saída desta etapa foi vetorial (ponto), e cada ponto inclui os atributos, ID das árvores e a altura do topo em metros que foi estimada à partida da função LMF. Para coerência, antes da deteção aplicou-se um filtro para manter apenas os pontos classificados como vegetação (classes 3, 4 e 5), garantindo que a análise incidia exclusivamente sobre vegetação, obtendo assim os topos das árvores (*Treetops*).

Por último, com base nos topos das árvores (*Treetops*), no CHM e nos pontos normalizados, foi delimitada a copa de cada árvore através da função «*lidR::segment\_trees()*», usando o algoritmo de Dalponte 2016 «*dalponte2016(CHM, treetops)*». Os polígonos resultantes foram regularizados e foi aplicado um filtro de área mínima de 1 m<sup>2</sup> para remover o ruído. Os resultados foram integrados num ficheiro vetorial que contém as copas segmentadas (*Crowns*), com o atributo da altura da árvore e o da área de cada copa.

Este processo reforça a fiabilidade do inventário individual ao combinar a posição do topo com a geometria da copa, o que permite análises espaciais detalhadas. Importa ainda referir que o desempenho de cada função é sensível ao número de núcleos usados, uma vez que diferentes áreas e ficheiros *LAS*, podem conter volumes de pontos distintos, pelo que a paralelização deve ser dimensionada, sempre que possível, em função da densidade de dados por mosaico.

De forma geral, o processo seguiu uma lógica sequencial:

- (i) preparação e conversão dos dados;
- (ii) geração de superfícies de referência (MDT e CHM);
- (iii) normalização e filtragem da nuvem de pontos;
- (iv) deteção e segmentação de árvores individuais.

Este conjunto de procedimentos resultou na criação de produtos derivados do LiDAR (MDT, CHM, topos de árvores e copas) que servem de base à análise espacial e à produção de informação

geográfica de apoio à cartografia do uso do solo e ao estudo da vegetação. Para a análise dos diferentes resultados, foram consideradas diferentes áreas no bloco. O Bloco 3A foi dividido em seis sub-blocos contíguos (Figura 6.2). Esta divisão teve o principal objetivo de aumentar a velocidade de processamento e de tornar o processamento LiDR exequível em computadores fixos (*desktop*). Os limites dos sub-blocos respeitam a continuidade territorial do bloco, sendo que, para a segmentação, foram mantidas dimensões semelhantes para os sub-blocos (cerca de 1000 *laz*). Tal facilitou computacionalmente a execução dos procedimentos na *WorkStation* fornecida pela DGT.

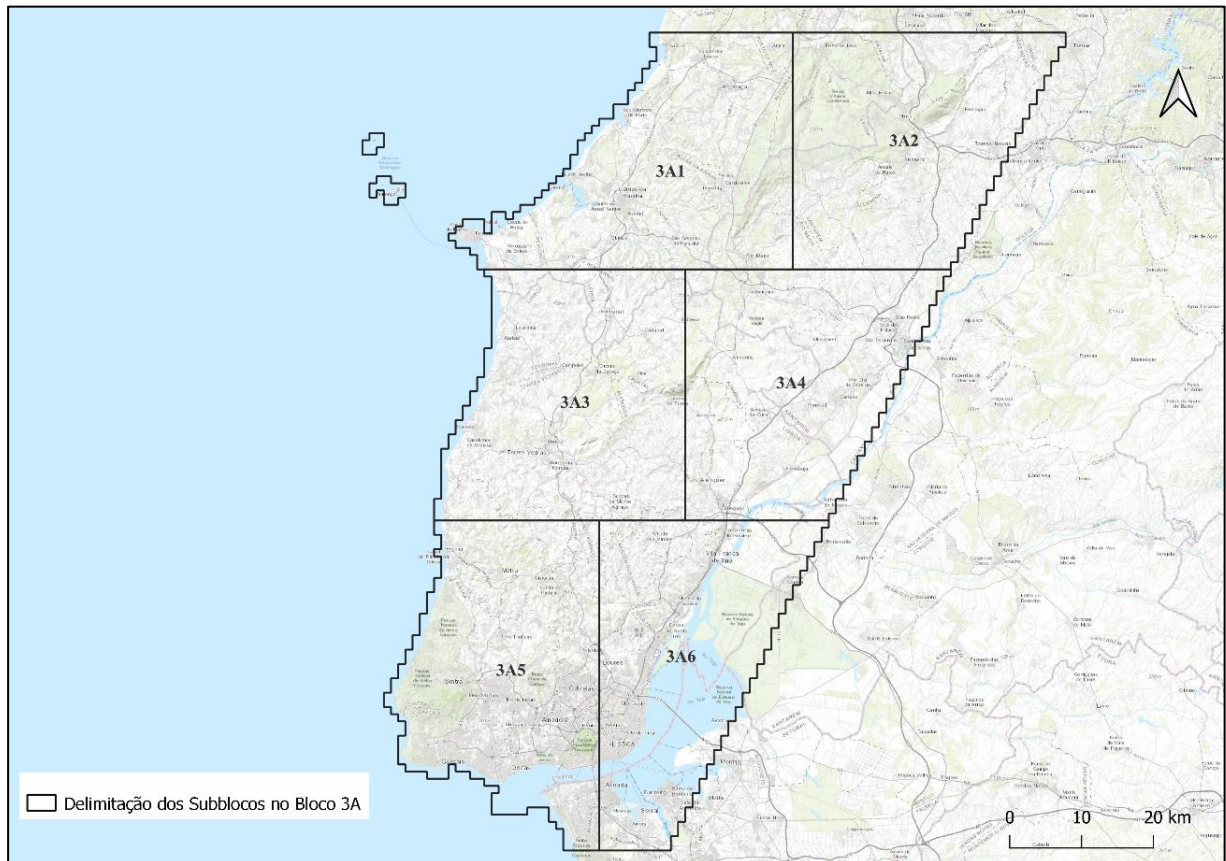


Figura 6.2. Delimitação dos sub-blocos no Bloco 3A.

## 6.2 Manchas Florestais

O objetivo desta parte prática é criar um conjunto de dados geográficos, a partir de produtos derivados do LiDAR, que funcione como alerta de potencial revisão dos polígonos da COS. O sistema vai sinalizar áreas que poderão estar omissas, inconsistentes ou precisar de verificação, para assim apoiar a produção e atualização da COS. Quando o alerta é validado, pode implicar divisão de um polígono maior em polígonos mais pequenos e atribuição de novas classes de uso e ocupação do solo. O sistema foca-se em zonas onde, pela experiência, é provável existirem manchas florestais com área superior a 0,5 ha, nomeadamente em classes da COS como culturas temporárias, arrozais, pastagens permanentes e espontâneas, praias, vegetação esparsa e espaços rochosos. Os alertas são emitidos sob a forma de polígonos com regras simples de prioridade, ou seja, maior área, maior prioridade, e a inclusão final é feita por fotointerpretação.

Tabela 6.2. Etapas de processamento para detetar manchas florestais nas paisagens agropastoris com os dados LiDAR.

Passo	Função	Parâmetros
1º	Seleção de Atributos	Filtrar a COS 2023 por áreas de interesse
2º	Clip	Cortar pela área do Bloco
3º	Clip raster by mask layer	Cortar o CHM pelas áreas de interesse
4º	r.mapcalc.simple	Fazer um ficheiro matricial binário com apenas píxeis com altura $\geq 4\text{m}$
5º	Polygonize (Raster to Vector)	Converter ficheiro matricial em polígonos
6º	Buffer + Dissolve (disjoint)	Aumentar o perímetro de 5m e unir áreas sobrepostas
7º	Filtragem por área	Calcular a área e eliminar áreas menores que 0,2 ha
8º	Buffer + Dissolve (disjoint)	Aumentar o perímetro de 5m e unir áreas sobrepostas
9º	Delete holes	Eliminar as lacunas internas dos polígonos 0,25ha
10º	Clip	Cortar pelas áreas de interesse da COS
11º	Filtragem final de área	Recalcular a área e manter polígonos com área $\geq 0,5$ ha

A metodologia (Tabela 6.2) para fazer a deteção destas manchas florestais e produzir alertas para apoio à COS assenta numa sequência replicável a todos os blocos LiDAR, por meio do QGIS (versão 3.8.1). Em primeiro lugar procedeu-se à filtragem da COS2023, para isolar as classes de interesse o que assegura uma análise concentrada nas unidades de utilização do solo relevantes para a identificação de árvores. A partir desses polígonos de referência é feita uma extração (*Clip*) das áreas de interesse e da área de estudo, o que garante assim coerência espacial e exige menos poder computacional. Para reduzir ainda mais o volume de dados e aumentar a velocidade do processamento, o CHM foi também recortado (*Clip raster by mask layer*) de acordo com as áreas de interesse. Com o CHM recortado, efetuou-se uma operação lógica com a ferramenta *r.mapcalc.simple* para a obtenção de um ficheiro matricial binário que identifica os píxeis cujo valor de altura é maior ou igual a 4 m (CHM  $\geq 4$  m), critério este escolhido para discriminar árvores com altura significativa para serem posteriormente identificadas na COS.

Este ficheiro binário foi, em seguida, convertido em polígono através da ferramenta *Polygonize (raster to vector)*, facilitando a aplicação de procedimentos em formato vetorial. Para reduzir a fragmentação e o ruído derivado da discretização do ficheiro matricial, aplicou-se uma operação de *Buffer*, adotando uma distância de 5 m, seguida da operação de *Dissolve* para agregar feições próximas. Após isso, calculou-se então a área e eliminaram-se as manchas com área inferior a 0,2 ha, devido a serem áreas muito reduzidas. Após a filtragem por área foi aplicada uma segunda operação de *Buffer*, igualmente de 5 m, e de novo a operação de *Dissolve* para juntar de novo polígonos contíguos. De seguida, procedendo à operação *Delete Holes* para tornar os polígonos mais regulares, foi definido um valor ótimo de 0,25 ha, após várias iterações de testes com diferentes valores. Por fim, para melhorar o contorno das manchas, os polígonos resultantes foram recortados pela COS2023 filtrada, mas desta vez com as classes inversas, garantindo consistência com as áreas de uso do solo. Por fim, recalculou-se a área das manchas, e ainda uma outra filtragem para eliminar áreas inferiores a 0,5 ha.

### 6.3 Culturas Permanentes

A detecção de pomares é importante para o planejamento agrícola e para entender a dinâmica de uso do território. Identificar estas áreas permite avaliar a distribuição das culturas arbóreas e monitorizar as mudanças ao longo do tempo. Com base na COS2023 e nos dados das copas de árvores (*Crowns*) derivados do LiDAR, aplicaram-se técnicas de SIG para isolar estas manchas (Tabela 6.3). A metodologia combina filtragem temática, análise espacial e agrupamento de pontos. A lógica deste procedimento é a produção de alertas para apoiar a revisão dos polígonos da COS, com área superior a 0,5 ha. Os alertas assinalam áreas de atualização e/ou reclassificação, como descrito no início da *secção* 6.2.

Tabela 6.3. Etapas de processamento de detecção de pomares com os dados LiDAR.

Passo	Função	Parâmetros
1º	Seleção de atributos	Filtrar a COS 2023 por áreas de interesse
2º	Clip	Cortar pela área do subbloco
3º	Clip	Cortar os topos das árvores ( <i>Treetops</i> ) pela área de interesse
4º	Extract by expression	Selecionar os pontos com altura inferior a 10 m ( $Z \leq 10$ )
5º	DBScan Clustering	DBScan Clustering (min. 10 pontos, máx. 10m) para agrupar pontos próximos
6º	Minimum Bounding Geometry	Desenhar um polígono à volta dos pontos próximos ( <i>Convex hull</i> )
7º	Buffer + Dissolve (disjoint)	Aumentar perímetro de 5 m e unir áreas sobrepostas
8º	Clip	Recorte pelas áreas de interesse
9º	Filtro por área mínima	Selecionar áreas superiores a 0,5 ha

Esta metodologia partiu da utilização da COS2023, de onde foram selecionadas apenas as classes de interesse relacionadas com agricultura, à exceção de culturas permanentes e estufas, e pastagens. A escolha destas classes baseou-se na experiência de produção da COS e em conhecimento empírico, dado que nas áreas correspondentes a estas classes, surgem frequentemente manchas de culturas permanentes com área superior a 0,5 ha, valor usado como limiar de alerta, uma vez que a UMC de 1 ha da COS2023 pode levar à sua generalização noutras classes agrícolas. Após esta filtragem, os polígonos resultantes foram recortados com a ferramenta *Clip*, pela área correspondente ao sub-bloco em análise, assegurando que apenas a informação espacial relevante ficasse incluída. De seguida, procedeu-se ao recorte dos pontos correspondentes ao ficheiro com os topos de árvores (*Treetops*) pela mesma área dos polígonos da COS obtidos no passo anterior. A partir deste conjunto de pontos, foi aplicada uma extração adicional, mantendo apenas os topos de árvores com uma altura inferior ou igual a 10 m. Este limiar foi definido após análise de vários polígonos com culturas permanentes, constatando um valor ótimo de 10 m para a altura destas árvores, que garanta uma margem de segurança para acomodar eventuais sobrestimações.

Para organizar e estruturar espacialmente os pontos selecionados, foi aplicado o algoritmo de agrupamento *DBScan*, definindo um tamanho mínimo de 10 pontos por agregado de píxeis (*cluster*) e uma distância máxima de 10 m entre pontos vizinhos. Cada agrupamento serviu de base para a geração automática de polígonos através da aplicação da função de geometria envolvente mínima (*convex hull*), desenhando áreas que potencialmente delimitem conjuntos de árvores permanentes. Estes polígonos

foram depois sujeitos a uma operação de *Buffer*, considerando 5 m, com o objetivo de juntar áreas próximas e reduzir fragmentações. Em seguida, procedeu-se a uma operação de *Dissolve* das áreas sobrepostas, mantendo sempre as feições disjuntas separadas. Como passo final, os polígonos resultantes foram recortados pela COS2023 filtrada, mas desta vez com as classes inversas, garantindo consistência com as áreas de uso do solo. Apenas foram mantidos os polígonos com área superior a 0,5 ha, por causa das especificações técnicas da futura COS.

Este procedimento permitiu derivar de forma sistemática alertas para a identificação de áreas de interesse para apoio à produção da COS a partir da combinação entre dados LiDAR (*Treetops*) e a cartografia oficial de uso do solo, assegurando coerência espacial e consistência temática com a COS2023. Ainda se verificou que a metodologia permite detetar diferentes tipos de culturas permanentes, como vinhas (alturas médias mais baixas), pomares jovens (a partir de 1,5 m) e pomares adultos, com compassos regulares ou irregulares, e ainda olivais.

#### 6.4 Detecção de Edifícios

Para análises de ocupação do solo ou detetar elementos mais específicos, como os edifícios, é necessário transformar as nuvens de pontos em mapas matriciais. Este formato facilita a interpretação dos dados e permite identificar estruturas construídas com base nos valores predominantes em cada célula (Tabela 6.4).

Tabela 6.4. Metodologia da deteção de edifícios.

Passo	Função	Parâmetros
1º	Rotina adaptada em lidR	Obter um ficheiro matricial a com classificação LiDAR
2º	Reclassify	No ficheiro matricial destacar a classe 6 (edifícios)
3º	r.neighbors	Através de uma janela ( <i>kernel</i> ) 3x3 preencher buracos interiores da imagem
4º	Polygonise	Passar de matricial para vetorial
5º	Buffer	Fazer um buffer negativo de -0,5 m, para tirar o excesso criado anteriormente
6º	Simplify	Com o método <i>Douglas-Peucker</i> para suavizar os contornos

A metodologia gera uma classificação em formato matricial a partir de um catálogo de ficheiros LiDAR (*LAScatalog*) convertendo os pontos num mapa. A lógica, para cada célula, é calcular a classe mais frequente entre os pontos LiDAR dentro da mesma. Concretamente, é utilizada a função da moda («*get\_mode*») e aplicado o «*lidr::pixel\_metrics()*» sobre o catálogo, com uma resolução de 0,5 m, para desta forma obter o valor modal do atributo em cada célula (classe predominante do LAS). O processamento em sub-blocos e em paralelo, garante eficiência tanto no cálculo como na entrada e saída dos dados.

Pretende-se ainda transformar e simplificar a informação em formato matricial numa camada vetorial mais limpa e coerente. O processo, já em ambiente SIG, é iniciado com uma reclassificação, em que se mantém apenas a classe de interesse, que neste caso, é a classe 6 (edifícios). A seguir, é utilizado o *r.neighbors* (das ferramentas do *GRASS*) com a função moda, usando uma janela (*kernel*) 3x3, que vai

suavizar e preencher as pequenas falhas do ficheiro matricial, embora introduza um pequeno efeito de expansão, semelhante a uma área de zonamento de cerca de 1 m para fora. Posteriormente, a imagem é convertida em formato vetorial através da função *polygonize*.

Para ajustar melhor os limites, é aplicada uma operação de *Buffer*, definindo um valor negativo de -0,5 m, que corrige o excesso gerado no passo anterior. Por fim, utiliza-se uma operação de *simplify* com o algoritmo de *Douglas-Peucker* para suavizar os contornos, removendo pequenas irregularidades e tornando os polígonos mais simples e aproximados à geometria dos edifícios. Em termos práticos, este método gera polígonos mais consistentes e com limites suavizados, o que facilita a sua utilização em cartografia temática e reduz o ruído derivado da classificação inicial.

#### 6.4.1 Expansão urbana da COS a partir de dados LiDAR

O procedimento é iniciado com a operação de diferença espacial entre a camada de edifícios LiDAR e a camada resultante da interseção LiDAR–COS, isolando assim apenas os edifícios não classificados na cartografia de base (Tabela 6.5). Em seguida, foi calculado o centroide de cada edifício, obtendo-se o ponto central do polígono que representa a sua localização. Estes pontos serviram como referência para a etapa seguinte de agrupamento espacial, realizada através do algoritmo *DBScan*, com parâmetros de um mínimo de dois edifícios por grupo e uma distância máxima de 60 m entre eles, com base nas especificações definidas no manual de fotointerpretação para a produção da COS (*DGT, 2024a*). Esta operação permitiu identificar conjuntos de edifícios próximos, que potencialmente configuram novos núcleos edificadas.

Os resultados do agrupamento foram depois integrados com a camada original de edifícios por meio de um *join* espacial, atribuindo a cada polígono o identificador do respetivo grupo (*ClusterID*). Posteriormente, foi aplicada a ferramenta *Minimum Bounding Geometry*, com a opção *Convex Hull*, com base no identificador, para delimitar o contorno de cada agrupamento, criando polígonos que representam áreas de alerta correspondentes a concentrações de edifícios fora do tecido urbano da COS.

Tabela 6.5. Metodologia para criação de alertas para os edifícios.

<b>Passo</b>	<b>Função</b>	<b>Parâmetros</b>
<b>1º</b>	Diferença	Entre a interseção e o edifícios LiDAR
<b>2º</b>	Centroides	Criar ponto central de cada polígono de edifício
<b>3º</b>	DBScan Clustering	Criar agrupamentos, com parâmetros de 2 e 60 m
<b>4º</b>	Juntar Atributos por Localização	Juntar os valores criados anteriormente para identificar pelo ClusterID
<b>5º</b>	Minimum Bounding Geometry	Contornar por Convex Hull os edifícios que tem o mesmo ClusterID

## 7 Resultados

### 7.1 Apresentação e Contextualização dos Produtos derivados do LiDAR

O primeiro produto obtido foi o Modelo Digital do Terreno (MDT), que representa a superfície real do solo tendo como referência altimétrica o nível médio do mar. Este modelo é fundamental para compreender a morfologia do terreno e serve de referência para a normalização da nuvem de pontos, assegurando que as alturas são medidas relativamente ao solo. O MDT funciona, assim, como referência de base para todas as análises subsequentes, e o seu resultado é apresentado para o bloco completo, permitindo visualizar a variação topográfica global da área de estudo (Figura 7.1).

Para além da sua função técnica, o MDT tem um papel crítico na fiabilidade da metodologia, uma vez que pequenas imprecisões na representação do relevo podem afetar diretamente a precisão dos produtos derivados. A qualidade e consistência do MDT, processado à escala nacional, garantem assim a eficácia e comparabilidade dos resultados, constituindo o alicerce essencial para a caracterização temática e para a atualização cartográfica no âmbito da COS.

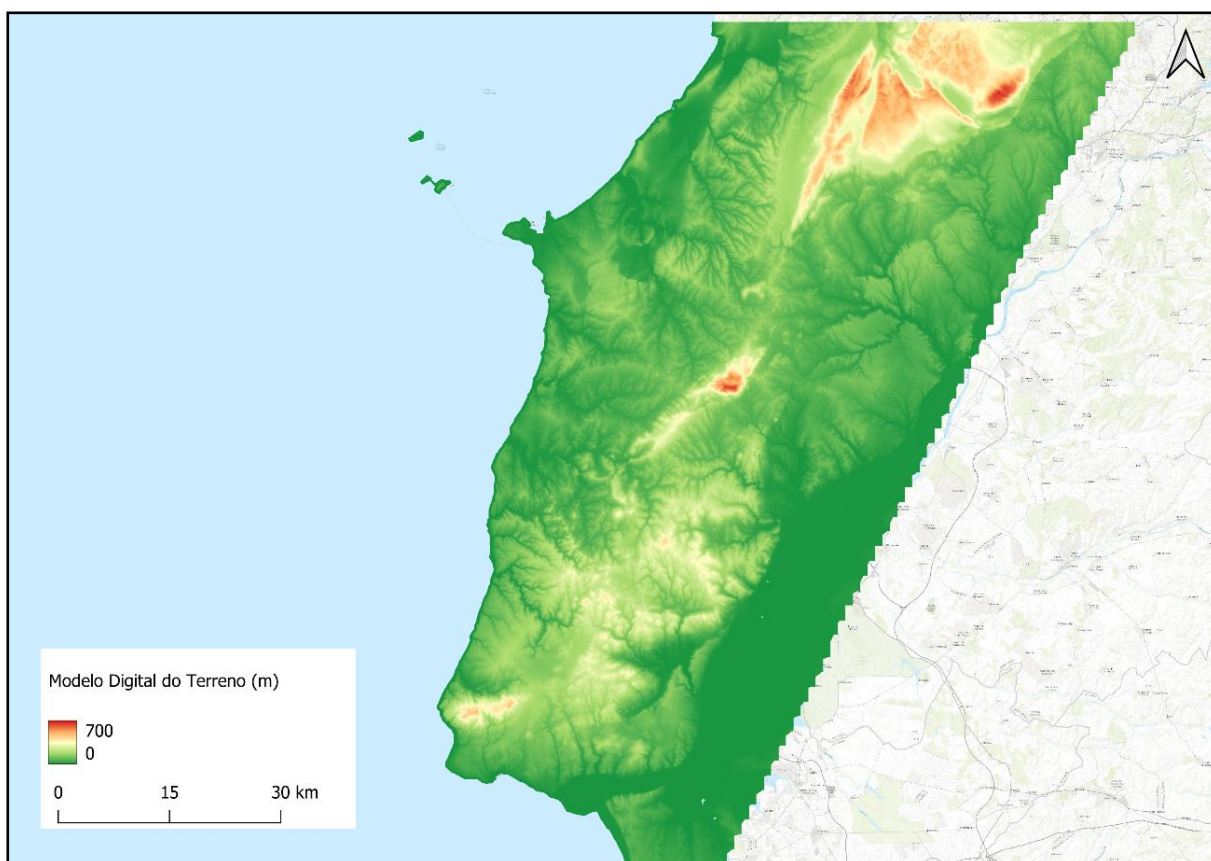


Figura 7.1. Modelo Digital do Terreno (MDT) do Bloco 3A.

A partir da nuvem de pontos normalizada e filtrada, foi gerado o Modelo de Altura do Coberto (CHM), em que em cada píxel está registada a altura máxima da vegetação. Este produto caracteriza todo o tipo de vegetação e permite analisar a distribuição espacial e variação de alturas, distinguindo as copas mais altas, a vegetação rasteira e clareiras de forma consistente. O CHM constitui uma ferramenta direta de observação da estrutura vertical da vegetação e, tal como o MDT, foi processado à escala nacional, o que assegura a consistência dos resultados em todo o território. O exemplo apresentado

corresponde ao bloco completo, permitindo observar de forma integrada a variação estrutural da cobertura vegetal na área de estudo (Figura 7.2). Este é uma base versátil para diversas aplicações, como a detecção de florestas, e a de culturas permanentes, a avaliação da densidade do coberto, a delimitação de clareiras e no apoio à detecção de edifícios. No contexto deste trabalho, o CHM apoia o sistema de alertas para a revisão da COS, orientando a atualização temática com base nas métricas estruturais da vegetação.



Figura 7.2. Canopy Height Model (CHM) do Bloco 3A.

Antes de apresentar a Figura 7.3, é importante sublinhar o objetivo de mostrar a aderência dos produtos LiDAR aos ortofotos e como estes acrescentam informação complementar, e em particular na caracterização da vegetação. Com base no CHM, foi possível detetar os topos das árvores individuais (*Treetops*) e segmentar as respetivas copas (*Crowns*), associando a cada árvore um polígono que representa a sua projeção planimétrica no terreno. Esta etapa permitiu identificar, de forma detalhada, a estrutura vertical e horizontal da vegetação, bem como calcular métricas relevantes, como o número de árvores, a densidade arbórea, a área das copas, entre outras.

Na Figura 7.3 estão representados os três produtos derivados do processamento LiDAR, o CHM, os topos das árvores (*Treetops*) e as copas das árvores (*Crowns*), os quais se encontram sobrepostos à base da fotointerpretação (ortofotos). O CHM fornece a altura do coberto com detalhe, os *Treetops* assinalam a posição dos topos das árvores, o que permite assim contar o número de árvores, e as *Crowns* delimitam as copas, o que vai facilitar a avaliação da densidade e distribuição das manchas florestais. Em conjunto, estes produtos vão reforçar a análise visual e melhorar a precisão da fotointerpretação, o que apresenta a vantagem de oferecer informação estrutural que os ortofotos não permitem.

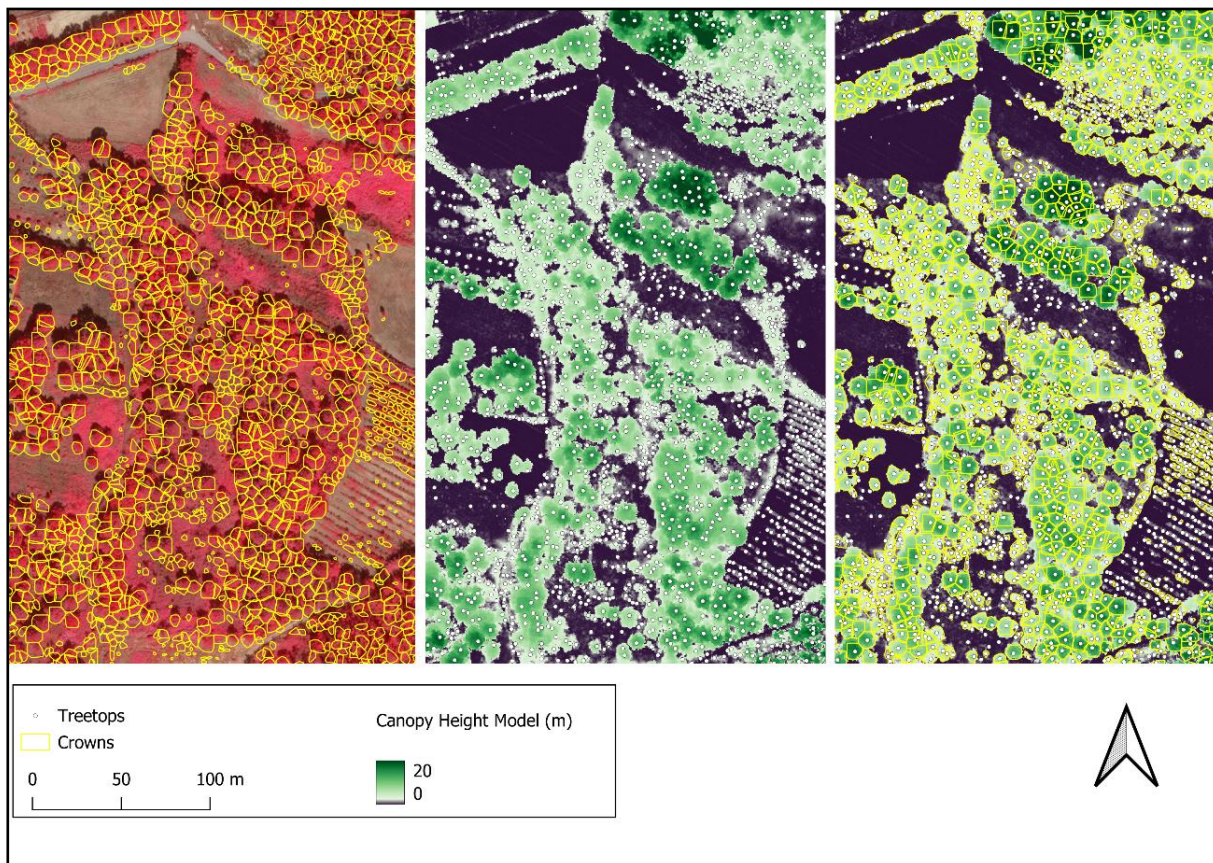


Figura 7.3. Conjugação dos diferentes produtos derivados do LiDAR para auxílio à produção da COS.

Na Figura 7.4, observa-se a sobreposição do CHM com os Treetops e as Crowns, evidenciando uma forte coerência espacial entre as diferentes camadas de informação. Nos povoamentos de alta densidade, as copas segmentadas surgem parcialmente sobrepostas, o que reflete o adensamento natural da vegetação. Já nas áreas mais esparsas, as copas aparecem bem delimitadas e isoladas, demonstrando a capacidade do algoritmo de distinguir árvores individuais. Esta representação integrada aproxima-se de uma visão tridimensional da vegetação e facilita a diferenciação de povoamentos e de níveis de densidade, ao mostrar em simultâneo a estrutura vertical e a distribuição horizontal. Resumindo, estes produtos tornam a fotointerpretação mais objetiva e rápida e podem servir de auxílio em diversas áreas de aplicações.

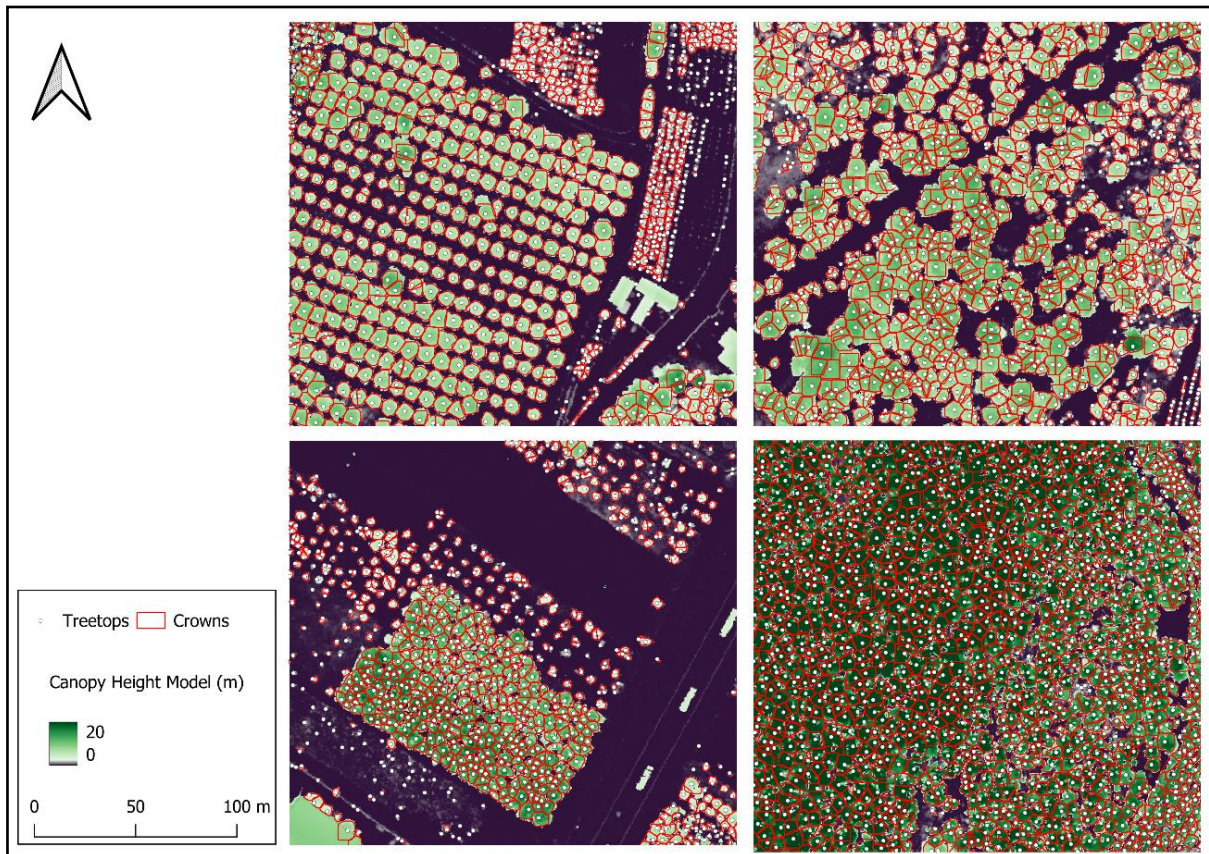


Figura 7.4. Exemplos de segmentação de *Treetops* e de *Crowns* sobre o CHM.

A integração dos diferentes produtos derivados do LiDAR permite uma visão abrangente e coerente do território, em que cada camada acrescenta uma dimensão própria à análise. O MDT fornece a referência topográfica essencial para compreender a morfologia do terreno, o CHM descreve a estrutura vertical da vegetação e revela a variação espacial, os *Treetops* identificam a posição e a distribuição das árvores individuais, e por fim, as *Crowns* delimitam com precisão a extensão das copas, demonstrando a sua forma e densidade. Esta combinação apoia a atualização temática da COS, reduz incertezas e aumenta a precisão cartográfica, ao cruzar informação estrutural e dimensão temática da cartografia.

## 7.2 Manchas Florestais

Na Figura 7.5, está representado um povoamento florestal isolado, que destaca a utilidade de integrar diferentes fontes de informação. Na ortografia em infravermelho próximo (à esquerda), a mancha florestal é claramente evidenciada devido à sua resposta espectral, representada em tons de vermelho, o que facilita a delimitação e a visão estrutural em paralelo com outros produtos. No CHM (à direita), que acrescenta uma dimensão estrutural, é mostrada a variação da altura da vegetação no interior da mancha. As zonas mais quentes (verde, amarelo e vermelho) indicam maior altura, enquanto as cores frias (azul) evidenciam clareiras ou vegetação mais baixa. A tonalidade de azul mais escura corresponde ao terreno ao nível do solo, sinalizando áreas com pouca ou nenhuma vegetação, o que complementa a interpretação do ortofoto.

A combinação das duas camadas permite delimitar, de forma eficaz, a fronteira do povoamento florestal, identificando o contorno com elevado detalhe. De notar que, para uso operativo em alertas de

edição cartográfica, e não para produzir polígonos perfeitos que possam ser incluídos na COS, foi aplicada uma pequena área de zonamento (*Buffer*) de segurança de 5 m, o que evita sub-delimitações pontuais. Assim, o método fornece geometrias precisas o suficiente para servir de base à revisão da COS, destacando limites, discontinuidades e transições.

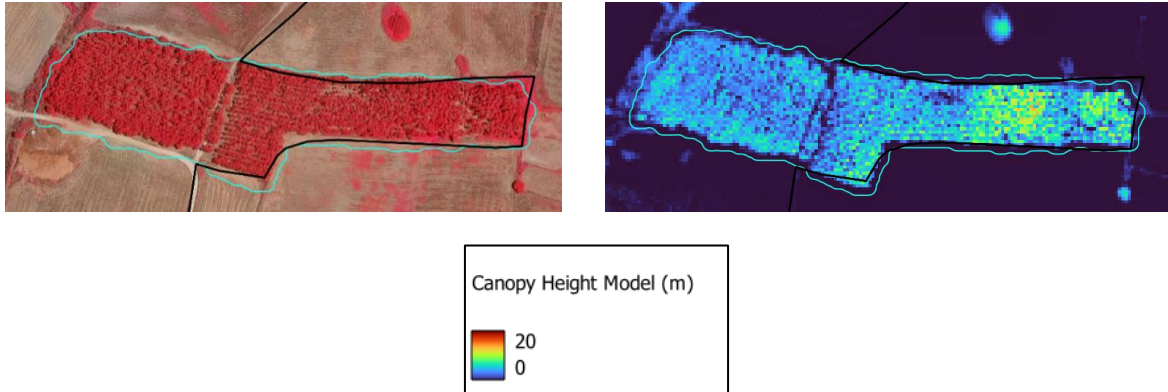


Figura 7.5. Detecção correta das manchas florestais.

A Figura 7.5 mostra uma mancha florestal bem definida, que é facilmente reconhecida na ortofotografia pelo padrão coeso e contínuo da vegetação. Já a Figura 7.6 mostra um povoamento mais disperso, em que a presença de árvores espaçadas pode levar a uma interpretação estritamente visual, fazendo com que esta não seja associada à classe de floresta. Ainda assim, a resposta espectral em vermelho indica vigor vegetativo e, quando analisada em conjunto com os produtos do LiDAR, pode reduzir a incerteza. A presença de agrupamentos localizados e de um corredor linear de árvores no lado esquerdo das imagens (Figura 7.6), poderá indicar que é uma zona de transição entre áreas arborizadas e espaços abertos, situando este caso no limiar de detecção como mancha florestal. Na Figura 7.5 e Figura 7.6 mostram que a metodologia é sensível às variações estruturais da vegetação. No entanto, na Figura 7.5 a mancha florestal é contínua, na Figura 7.6 o povoamento é mais disperso e pode se aproximar do limiar entre “floresta” e “vegetação dispersa”. Para evitar ambiguidades, a análise é baseada em limiares operacionais, o que permite distinguir transições.

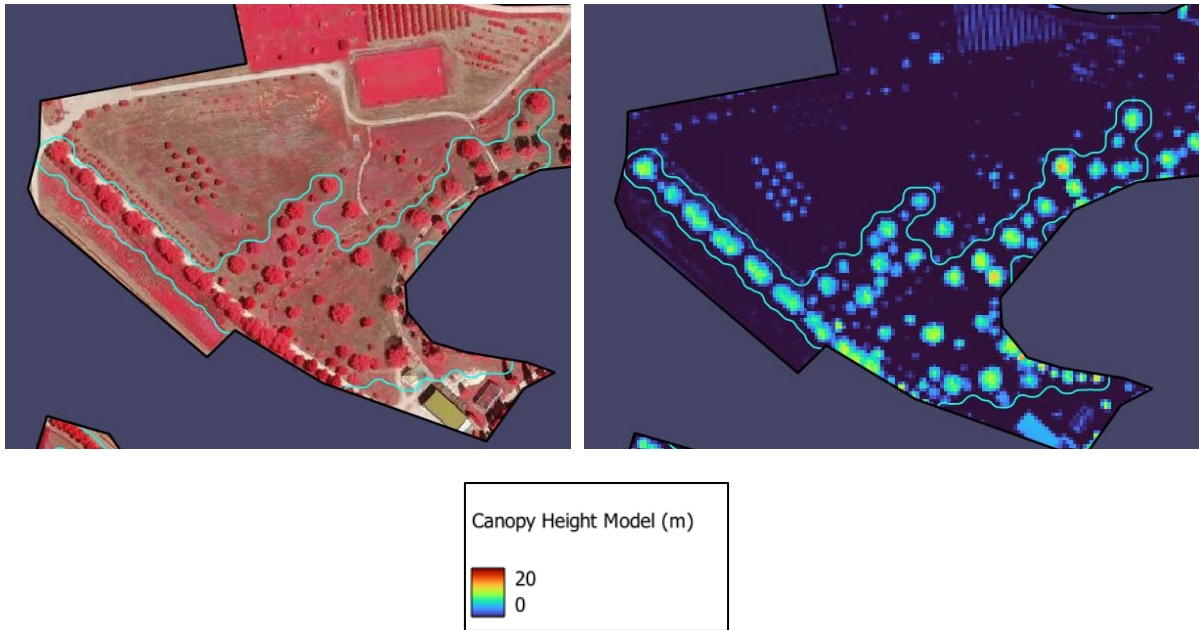


Figura 7.6. Exemplo do limiar de floresta a ser marcado.

No exemplo seguinte (Figura 7.7), a classificação é incorreta na detecção devido à presença de grandes clareiras no interior da mancha florestal, o que interrompe a continuidade necessária para que a área seja considerada floresta consolidada. Na ortofoto, observam-se extensas zonas abertas com solo exposto e vegetação descontínua, intercaladas com agrupamentos de árvores mais densos. Apesar de as áreas arborizadas apresentarem uma resposta espectral intensa em vermelho, que indica o vigor vegetativo, a distribuição fragmentada das copas impede a formação de uma mancha contínua. O CHM confirma esta interpretação, evidenciando valores de altura irregulares e amplas áreas em tom escuro, correspondentes às clareiras. A escassa densidade de pontos com alturas acima do solo evidencia que a estrutura vertical da vegetação é descontínua, reforçando o resultado de falso alerta (Figura 7.7). Este caso trata-se de um caso de falso positivo, em que há pequenas manchas arborizadas, mas a falta de continuidade estrutural e de densidade florestal inviabiliza a validação como mancha florestal. Situações como esta evidenciam a importância de combinar a ortofotografia e os dados LiDAR, permitindo distinguir florestas densas de áreas esparsamente arborizadas e evitar classificações ambíguas que possam comprometer a fiabilidade do alerta de fotointerpretação.

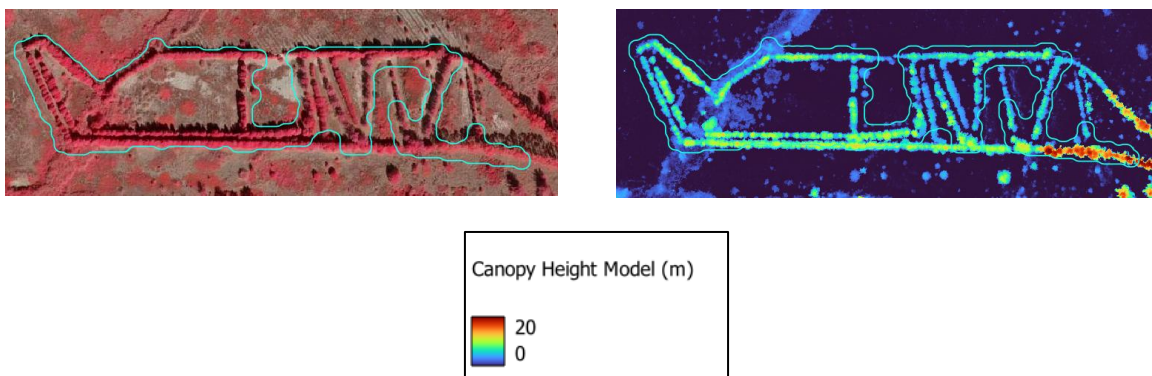


Figura 7.7. Classificação de falso positivo em contexto de presença de clareiras.

Estes exemplos mostram que, apesar da utilidade dos modelos, podem ocorrer interpretações menos adequadas em áreas de vegetação dispersa ou linear, o que reforça a importância de validar os resultados com análise visual e critérios cartográficos. Para orientar o trabalho de edição do fotointérprete, as manchas identificadas foram priorizadas segundo uma regra simples: quanto maior a área, maior a prioridade. Assim, as manchas mais representativas são analisadas primeiro, garantindo que o esforço da atualização da COS incide onde o contributo cartográfico é maior. Esse processo acaba por assegurar que o mapeamento reflète de forma rigorosa, a realidade do território. A priorização foi adaptada às classes de maior dimensão no Inventário Florestal Nacional (IFN), que organiza a análise por manchas e classes de área (Uva *et al.*, 2015). Contudo, tratando-se apenas de uma heurística operacional, a decisão final respeita sempre as especificações da COS. Foram, assim, adotadas as seguintes classes de área:

- Superiores a 10 ha, que correspondem a manchas florestais de grande dimensão e com forte expressão territorial, que representam áreas prioritárias para integração na COS pela sua relevância e impacto direto na ocupação do solo;
- Entre 5 ha e 10 ha, representam as manchas com papel significativo na estrutura e continuidade da cobertura florestal, devendo ser igualmente consideradas prioritárias na atualização cartográfica;
- Entre 2 ha e 5 ha, contribuem para a continuidade e conectividade da cobertura florestal, assegurando a representação de unidades intermédias que, embora menos extensas, mantêm relevância ecológica e espacial;
- Entre 0,5 ha e 2 ha, que engloba a unidade mínima cartográfica (1 ha) definida na COS. Apesar da sua menor dimensão, estas manchas podem ter importância local, sobretudo em áreas fragmentadas ou como elementos de ligação entre manchas maiores.

A definição de prioridades com base apenas na dimensão das manchas florestais permite organizar o processo de forma objetiva e prática. Ao distinguir as diferentes classes de área, é possível concentrar os recursos nas manchas mais significativas e, ao mesmo tempo, não ignorar as menores quando têm relevância local. Esta metodologia contribui para uma representação mais coerente e eficaz da realidade florestal na COS, demonstrando que a combinação de dados LiDAR e ortofotografia é essencial para garantir coerência e fiabilidade na deteção de manchas florestais.

### 7.3 Culturas Permanentes

Com a metodologia desenvolvida é possível gerar alertas automáticos para os diferentes tipos de culturas permanentes, nomeadamente vinhas, oliveiras e pomares. Os alertas permitem identificar as áreas em que a deteção foi bem-sucedida, bem como situações de erro de classificação que evidenciam limitações no processo. Como casos favoráveis (classificação correta), estão representados na Figura 7.8 alguns exemplares de vinhas, em que se observa a coerência entre a informação espectral e estrutural.

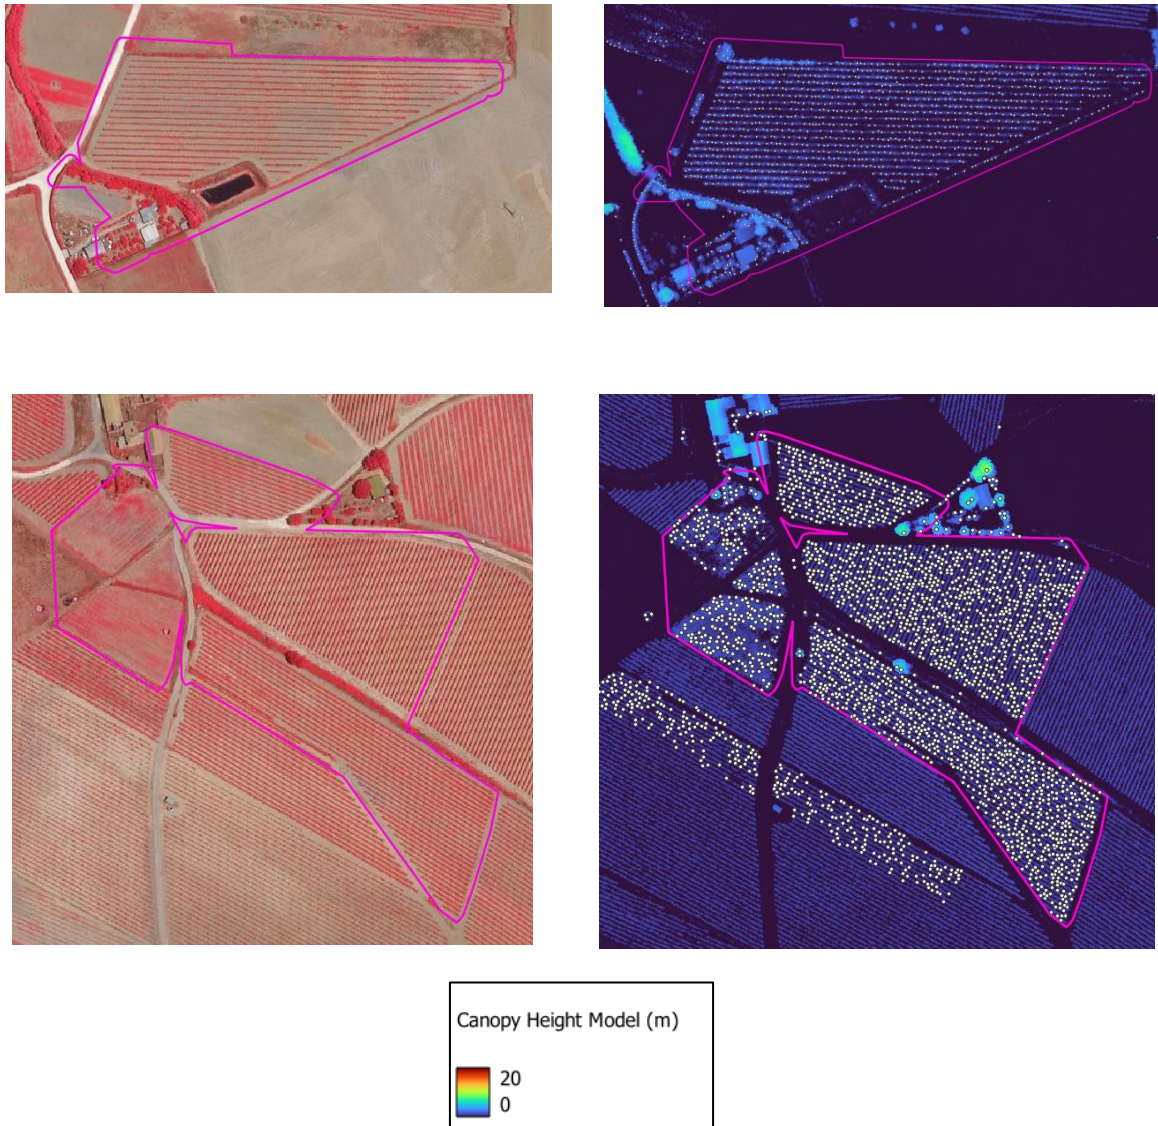


Figura 7.8. Identificação correta de vinhas com delimitação da COS sobre ortofotografia em falsa cor (à esquerda) e validação estrutural por meio do CHM com identificação dos *Treetops* a partir de dados LiDAR (à direita).

Nas imagens à esquerda é possível observar claramente os alinhamentos regulares das vinhas, que se destacam pelo padrão geométrico e pela resposta espectral característica da cultura cultivada. Os limites assinalados em magenta delimitam corretamente a área classificada como vinha não identificada na COS. Nas imagens à direita, observa-se a correspondência estrutural dessa mesma vinha. A altura da vegetação é evidenciada no CHM, e os pontos correspondentes aos topos das árvores (*Treetops*) identificam potencialmente os topos individuais das videiras ao longo das linhas de plantação.

No caso dos pomares, destacam-se, na Figura 7.9, alguns exemplos de alertas bem identificados. A ortofotografia em infravermelho próximo (imagens à esquerda) evidencia um padrão granular de copas quase circulares, com espaçamento regular das árvores, característico deste tipo de culturas permanentes. O CHM (imagens à direita), complementado com a identificação dos *Treetops*, mostra a distribuição homogênea da altura das árvores, com pontos máximos alinhados de forma regular ao longo da plantação. As lacunas de pontos ou áreas de altura inferior podem corresponder a árvores jovens,

podadas, zonas de sombra ou ainda a erros no algoritmo, enquanto a ausência de *Treetops* junto a caminhos ou margens é coerente com zonas de transição sem árvores.

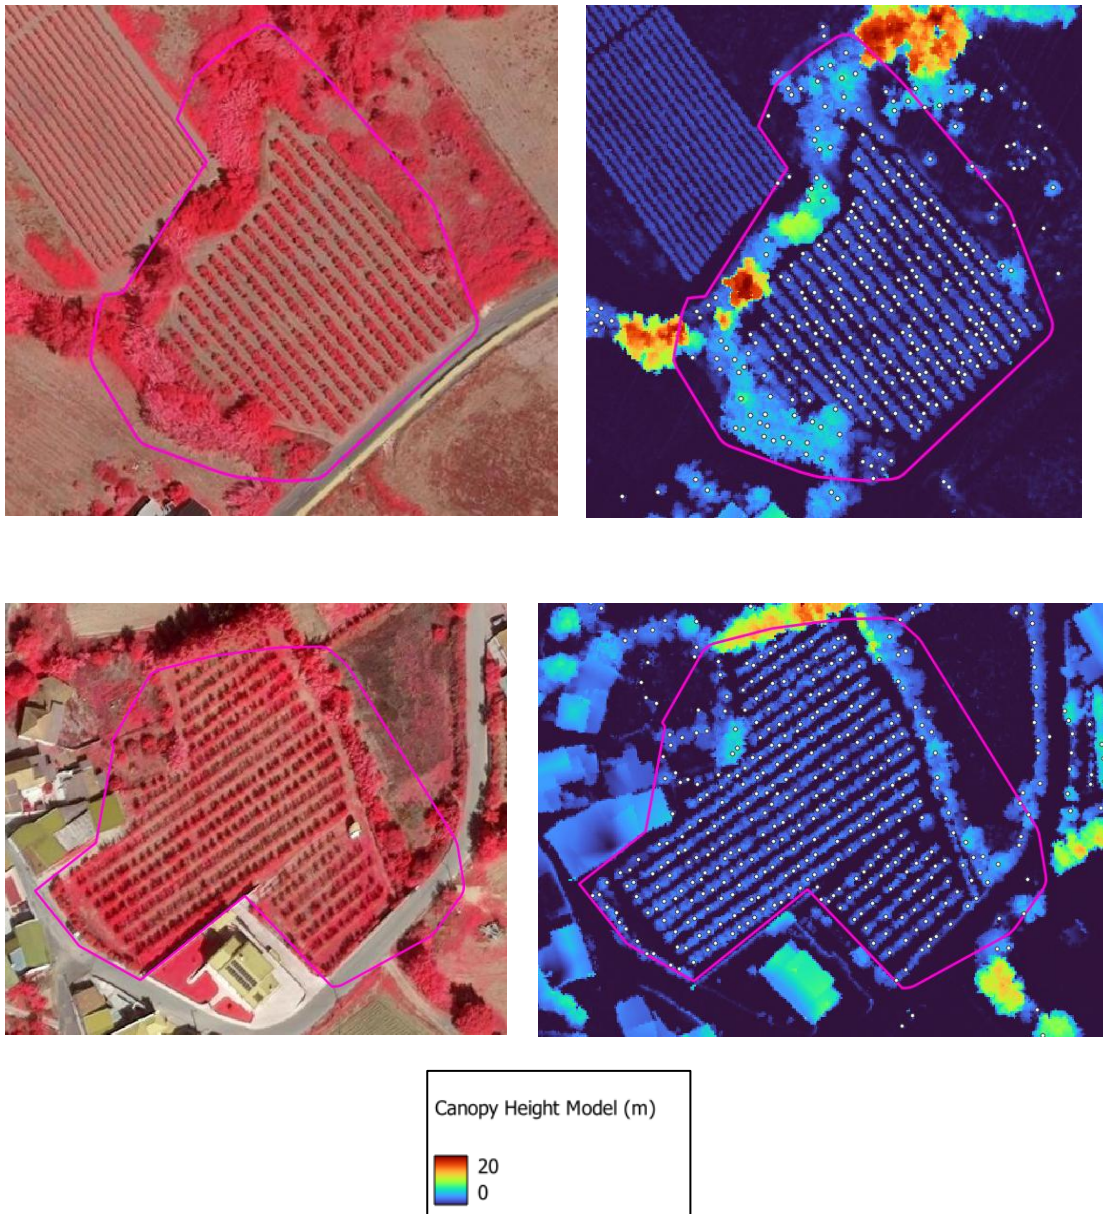


Figura 7.9. Identificação correta de pomares, com delimitação da COS sobre ortofotografia em falsa cor (à esquerda) e validação estrutural por meio do CHM com identificação dos *Treetops* a partir de dados LiDAR (à direita).

A correspondência entre o padrão espectral observado na ortofoto e a estrutura vertical representada no CHM confirma a classificação correta como pomar. Ainda assim, existem algumas limitações a considerar, como a possibilidade de ocorrerem omissões em árvores de porte baixo ou sob sombra densa, e de linhas de árvores dispersas dentro do polígono introduzirem confusão. Nestes casos, o CHM ajuda a distinguir melhor as árvores do pomar de outras estruturas arbóreas.

Por fim, no caso dos olivais destacam-se alguns exemplos na Figura 7.10. Tal como no caso dos pomares, os olivais apresentam uma estrutura regular e organizada, composta por árvores individuais com copas bem definidas e alinhamentos visíveis na ortofotografia. Distinguem-se, contudo, pela

tonalidade mais escura (bordô). O CHM, em conjunto com os *Treetops*, confirma esta organização espacial ao revelar alturas homogêneas e uma distribuição regular dos pontos máximos, coerente com os alinhamentos observados na ortofoto. Tal como nos pomares, também aqui se observa uma forte correspondência entre o padrão espectral e a estrutura vertical, confirmando a classificação correta da classe.




Figura 7.10. Identificação correta dos Olivais com delimitação da COS sobre ortofotografia em falsa cor (à esquerda) e validação estrutural por meio do CHM com identificação dos *Treetops* a partir de dados LiDAR (à direita).

Na ortofoto destacam-se os alinhamentos regulares e a textura homogénea das copas, enquanto o CHM confirma a uniformidade das alturas e a disposição organizada dos *Treetops* nos talhões. O processamento demonstrou adaptabilidade, face à diversidade em contextos agrícolas, classificando com alguma precisão as culturas permanentes. Esta consistência, verificada em olivais, pomares e vinhas, confirma o potencial da integração da ortofotografia e dos dados LiDAR como uma abordagem fiável para a caracterização e atualização das culturas permanentes na COS.

Na Figura 7.11 destacam-se alguns casos de falsos alertas, em que a classificação apresenta fragilidades claras. Na ortofotografia em infravermelho próximo (imagem à esquerda) observa-se uma área com vegetação heterogénea, caracterizada por uma mistura de árvores dispersas, matos e zonas de transição. O polígono delimitado não corresponde a um padrão agrícola típico deste tipo de cultura permanente, mas sim a uma mancha de vegetação irregular. No CHM, a altura da vegetação é igualmente muito variável, com valores baixos e dispersos, o que reflete a presença de arbustos e de árvores de pequeno porte. Os *Treetops* identificados aparecem de forma pouco estruturada, o que pode resultar das limitações do algoritmo de deteção que, por ser baseado em agregados (*clusters*) de pontos, tem dificuldade em distinguir áreas de culturas permanentes de outras formações arbóreas, que apresentam uma estrutura mais heterógena e dispersa.

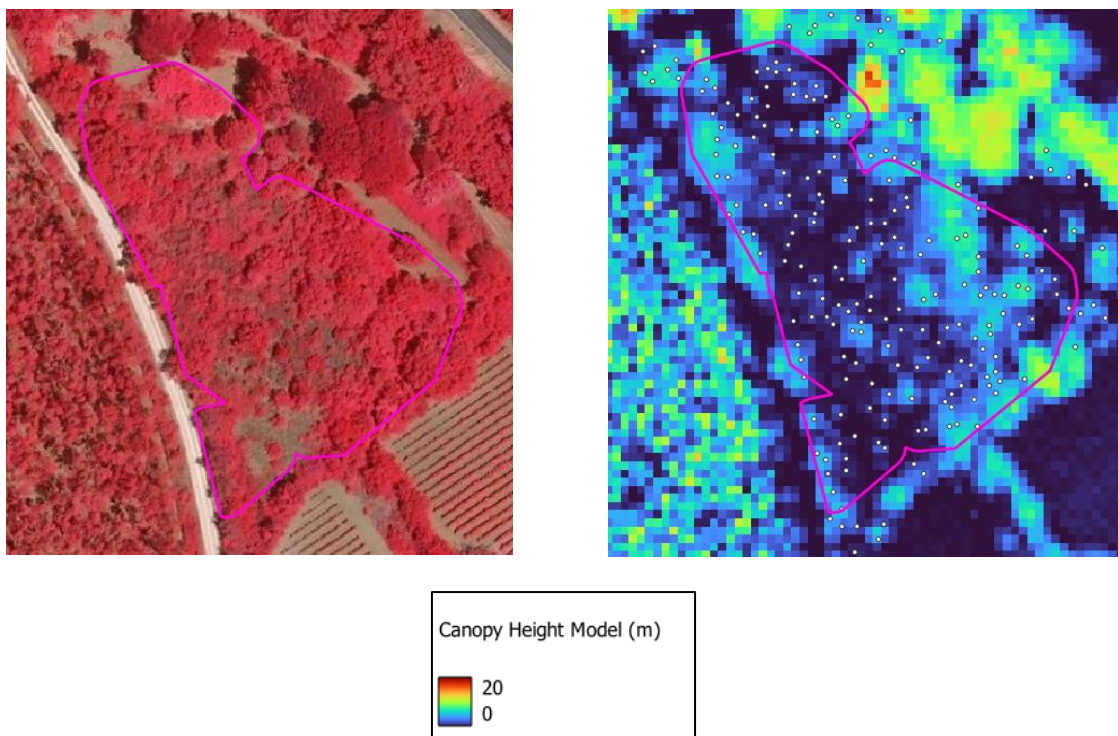



Figura 7.11. Identificação incorreta da metodologia com delimitação da COS sobre ortofotografia em falsa cor (à esquerda) e validação estrutural por meio do CHM com identificação dos *Treetops* a partir de dados LiDAR (à direita).

Este exemplo demonstra que, em áreas de transição entre usos agrícolas e vegetação natural, a metodologia pode produzir classificações ambíguas, resultando em falsos positivos. A presença de vegetação densa, mas irregular pode levar o modelo a interpretar erroneamente uma mancha como pomar ou olival.

Outro exemplo de classificação incorreta, neste caso em áreas com culturas temporárias, é apresentado na Figura 7.12. A classificação como pomares é considerada incorreta, pois a área

corresponde, na realidade, a culturas temporárias e não apresenta a estrutura típica de árvores permanentes. Na ortofotografia (imagem à esquerda) observa-se uma textura homogênea, sem o padrão regular de copas arredondadas característico de culturas permanentes. O CHM (imagem à direita) mostra alguma altura e identifica os *Treetops*, mas estes são esparsos e mal distribuídos, correspondendo provavelmente a vegetação alta ou a linhas de abrigo que se encontram dentro do talhão. No entanto, esta altura pode estar relacionada com uma fase de crescimento avançada da cultura antes da colheita, podendo atingir valores superiores a 1,5 m.



*Figura 7.12. Identificação incorreta da metodologia (em culturas permanentes) com delimitação da COS sobre ortofotografia em falsa cor (à esquerda) e validação estrutural por meio do CHM com identificação dos Treetops a partir de dados LiDAR (à direita).*

Este caso ilustra um falso positivo da metodologia, em que a presença de uma cultura temporária na fase de crescimento avançada leva à detecção de pontos que não correspondem a uma cultura permanente. A análise reforça a importância de validar os resultados cruzando a informação estrutural do LiDAR com a interpretação espectral da ortofotografia. Embora possam ocorrer alguns falsos alertas, estes funcionam como indicadores para a fotointerpretação e permitem identificar praticamente todas as culturas permanentes. Isto demonstra que a metodologia apresenta um nível de omissão muito reduzido, e é eficaz na distinção entre culturas permanentes e temporárias.

### 7.3.1 Identificação da Densidade dos Pomares e Olivais

Após a identificação das áreas de interesse, procede-se a uma nova etapa centrada na densidade da plantação. Nesta fase, utilizam-se estatísticas zonais calculadas com base em polígonos, com o objetivo de distinguir diferentes tipos de povoamento. A classificação baseia-se no número de árvores identificadas, quer através dos *Treetops*, quer das *Crowns*, o que permite caracterizar a densidade e a estrutura das plantações. Na COS estão definidas três categorias principais para as classes de pomares e olivais (Tabela 7.1):

- Baixa densidade;
- Alta densidade;
- Em sebe.

Esta classificação é feita de forma automática, com base nos critérios numéricos de contagem de *Treetops* e de *Crowns*, permitindo caracterizar objetivamente a intensidade de ocupação dos talhões:

*Tabela 7.1. Parâmetros para a classificação da densidade das culturas permanentes com base no manual de fotointerpretação.*

	<i>Treetops</i>	<i>Crowns</i>
<b>Baixa densidade</b>	300	300
<b>Alta densidade</b>	301 a 900	301 a 900
<b>Em sebe</b>	> 900	> 900

Para reduzir a variabilidade dos resultados é adotada uma margem de mais ou menos 50 em torno dos limiares. Os polígonos discriminados desta forma são marcados para revisão e, posteriormente, validados por fotointerpretação. Os mesmos limiares e a mesma margem foram usados consistentemente quando foi necessário quantificar densidade. Devido a limitações no processamento das *Crowns* no sub-bloco 3A1, foi necessário realizar a análise de classificação de densidade dos pomares e olivais noutra zona (Bloco 1N), mais especificamente no sub-bloco 1N4, como mostra na Figura 7.13. Esta etapa teve como objetivo avaliar a densidade da classificação oficial da COS2023.

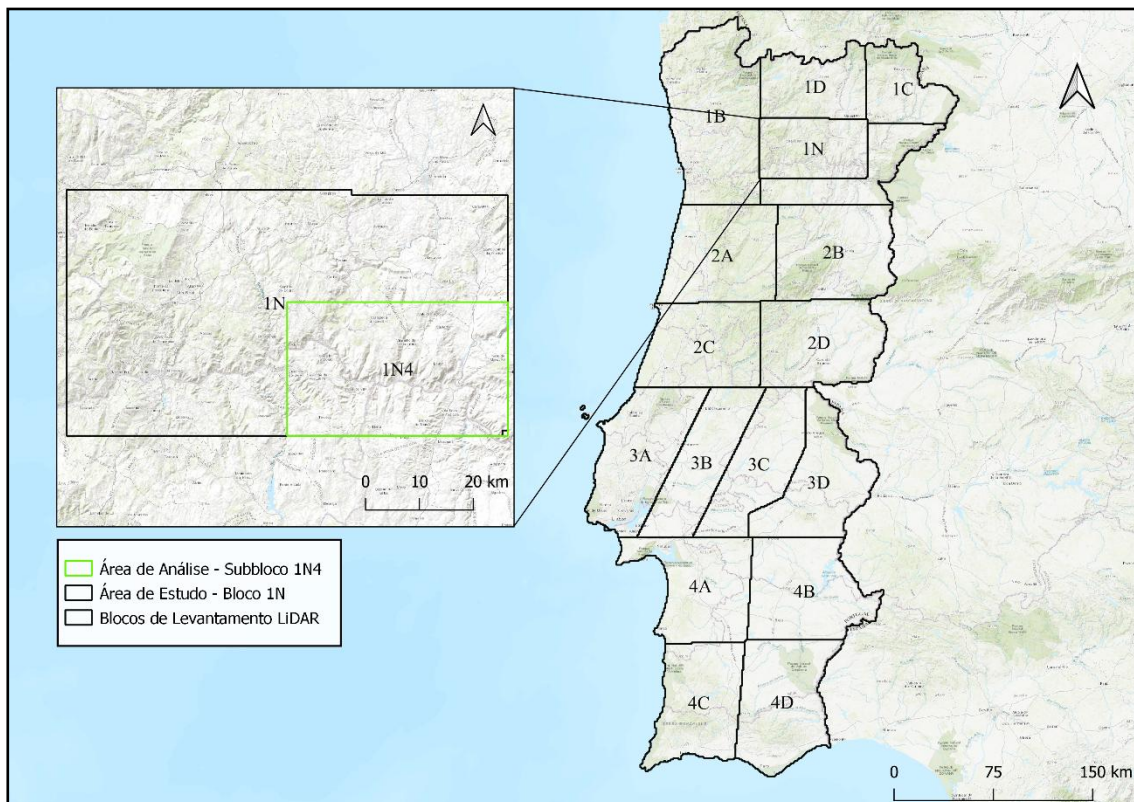


Figura 7.13. Área suplementar de análise (Bloco 1N, sub-bloco 1N4).

A metodologia utilizada para a análise de densidade e intensidade das culturas permanentes baseou-se na extração de indicadores estruturais a partir dos produtos LiDAR *Treetops* e *Crowns*. O objetivo foi obter métricas que permitissem quantificar o número de árvores por ha aplicando os critérios definidos para a classificação em baixa densidade, alta densidade e em sebe (Tabela 7.1).

Com base numa análise manual prévia dos valores do *Treetops*, verificou-se que, nas áreas de pomares e olivais, a altura das árvores não ultrapassava 7 m. Assim, os pontos e polígonos acima deste valor foram considerados ruído e removidos do processamento. A partir da COS2023, foram selecionados os polígonos correspondentes às classes de pomares e olivais, aplicando-se uma área de zonamento (*Buffer*) negativo de 10 m para eliminar zonas de transição e minimizar interferências com áreas adjacentes. Após esta filtragem espacial, os produtos *Treetops* e *Crowns* foram processados separadamente, para a obtenção de indicadores quantitativos de densidade.

No caso dos *Treetops*, foi aplicada a ferramenta *Join Attributes by Location (Summary)*, utilizando os polígonos de interesse e os pontos filtrados do *Treetops*. A relação espacial definida foi *contain*, tendo sido resumido o campo “Z”, correspondente à altura das árvores. A operação gerou os campos *Z\_count*, *Z\_min*, *Z\_max*, *Z\_mean* e *Z\_std*, representando o número total de árvores, as alturas mínima, máxima e média, e o desvio padrão, respetivamente. Posteriormente, foi calculada no QGIS a área de cada polígono em ha, através da expressão (7.1):

$$\text{round}(\$area/10000,3) \quad (7.1)$$

e a densidade de árvores por ha, através da expressão (7.2):

$$tree\_per\_ha = Z\_count / area\_poligono\_ha \quad (7.2)$$

Para o produto *Crowns*, foi utilizado o mesmo procedimento de junção espacial, com o campo “*convhull\_area*”, correspondente à área individual de cada copa, cuja segmentação foi inicialmente usando a rotina lidR.

Desta operação resultou o atributo *convhull\_area\_count*, que representa o número de copas por polígono. A partir destes valores, foi calculado o número de copas por ha, através da expressão (7.3):

$$crown\_per\_ha = convhull\_area\_count / area\_poligono\_ha \quad (7.3)$$

A análise consistiu, num primeiro momento, em verificar as áreas já classificadas na COS2023 com intensidade atribuída (baixa e alta densidade) e em verificar se cumpriam os limiares definidos pelos dois produtos LiDAR. Estes limiares foram estabelecidos com base na combinação das regras de fotointerpretação e na verificação de vários polígonos representativos. Assim, para cada talhão classificado, com base nas métricas obtidas anteriormente, foi avaliado em que medida os valores definidos coincidiam.

A análise da classificação de pomares de baixa densidade permitiu avaliar a coerência entre os resultados obtidos a partir dos produtos LiDAR e a informação na COS2023. Numa primeira fase, analisaram-se separadamente os resultados derivados dos *Treetops* e das *Crowns* para calcular o número de polígonos classificados como correspondentes, não correspondentes e sem dados. Os resultados do *Treetops* mostram 387 polígonos correspondentes à classificação oficial, 94 não correspondentes e 56 sem dados (Figura 7.14). Apesar disso, a correspondência obtida é elevada, o que confirma a boa sensibilidade da margem definida para detetar plantações de baixa densidade. Os polígonos correspondem provavelmente a polígonos muito pequenos ou a polígonos onde o terreno está limpo, e em casos muito pontuais à possibilidade de novas plantações sem altura significativa (< 1,5 m), o que impossibilita a identificação do topo e da copa das árvores (Figura 7.15) sendo estes casos replicáveis para os diferentes tipos de densidade e permanente.

No caso das *Crowns* (Figura 7.14), a correspondência aumentou para 421 polígonos, com apenas 9 não correspondentes e 107 sem dados. Este resultado reflete uma interpretação mais estável e conservadora da densidade, uma vez que o algoritmo de segmentação tende a unir copas contíguas, o que reduz a contagem total, mas fornece uma visão mais próxima da realidade física das árvores no terreno, uma vez que muitas árvores podem não ter densidade suficiente para permitir a identificação da copa.

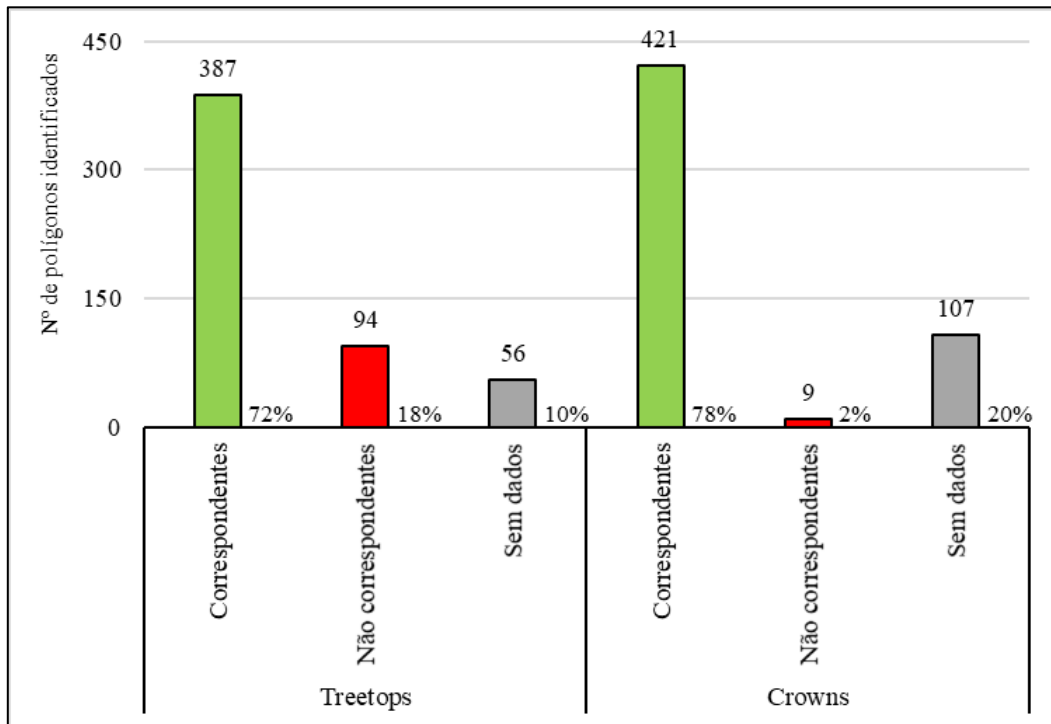


Figura 7.14. Estatísticas dos pomares de baixa densidade.

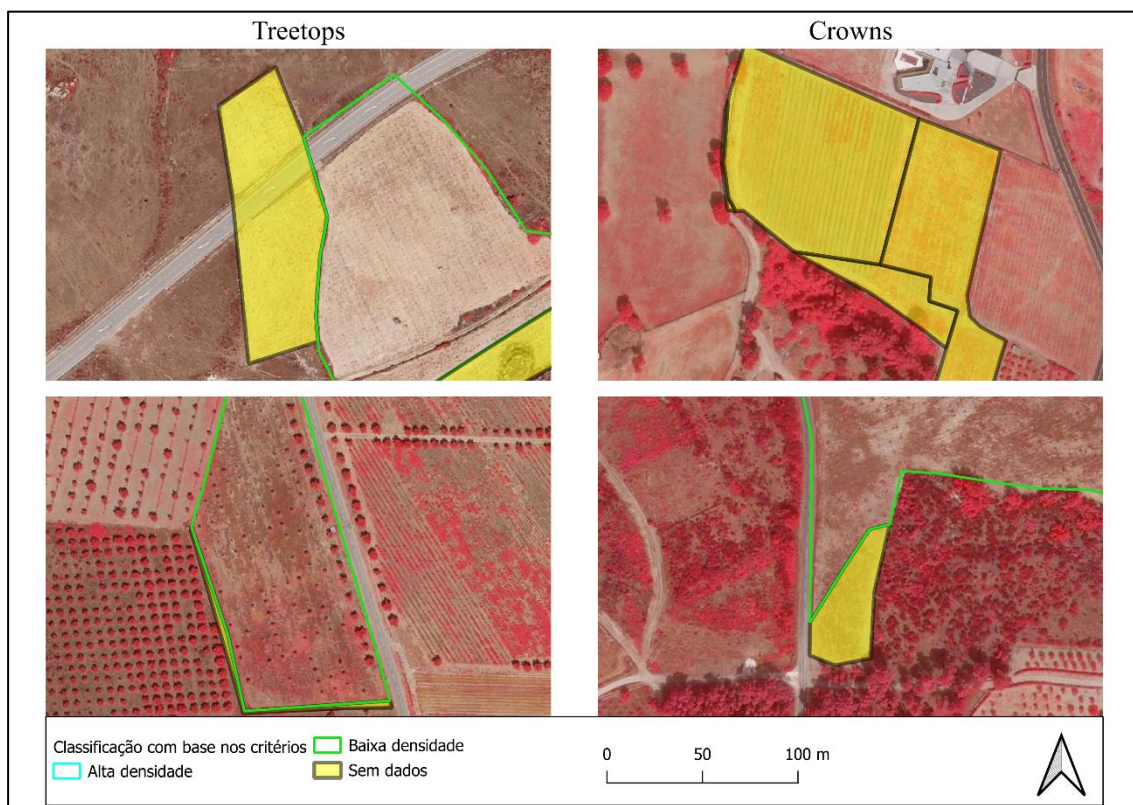


Figura 7.15. Exemplos de classificação "Sem dados".

Na fase seguinte, os dois produtos foram combinados, cruzando as áreas correspondentes identificadas nos produtos *Treetops* e *Crowns*. O resultado mostra um total de 459 polígonos

correspondentes, 22 não correspondentes e 56 sem dados, evidenciando que o critério combinado das duas fontes produz resultados mais consistentes e fiáveis (Figura 7.16). A conjugação das camadas permitiu reduzir significativamente os casos de erro e de ausência de dados, confirmando que a utilização conjunta de métricas estruturais melhora a coerência da classificação. Estes resultados demonstram que o método é potencialmente vantajoso, sendo capaz de reproduzir de forma consistente o padrão estrutural dos pomares de baixa densidade. As pequenas discrepâncias observadas podem dever-se, sobretudo, a heterogeneidades internas dos talhões, efeitos de filtragem espacial, ou até limitações na deteção em áreas com menor densidade de pontos LiDAR.

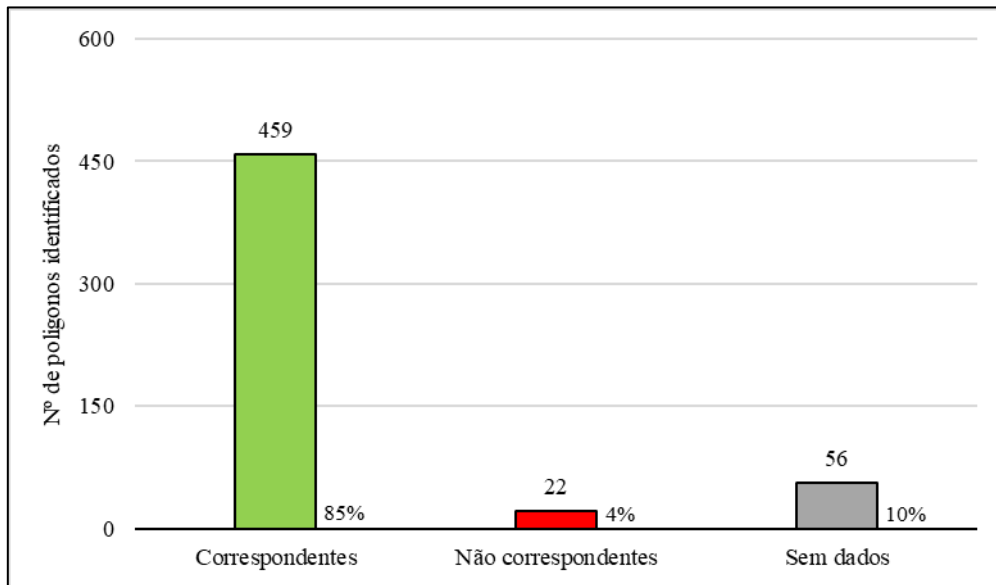


Figura 7.16. Estatísticas de classificação na combinação de variáveis para pomares de baixa densidade.

Nos pomares de alta densidade, os resultados mostram que os *Treetops* revelaram um melhor desempenho do que as *Crowns*. No caso dos *Treetops* foram obtidos 61 polígonos correspondentes à classificação da COS2023, 14 não correspondentes e 11 sem dados (Figura 7.17). Já com as *Crowns*, a correspondência foi menor, com 39 polígonos correspondentes, 36 não correspondentes e 11 sem dados. Esta diferença é explicada pela forma como cada produto LiDAR representa a estrutura das árvores. Nos talhões mais compactos, os *Treetops* conseguem detetar melhor os topos das árvores individuais, mesmo quando as copas se tocam, o que leva a uma contagem mais próxima da realidade. Por outro lado, as *Crowns* tendem a agrupar várias copas vizinhas num único polígono, o que resulta numa subestimação da densidade e num maior número de discrepâncias em relação à COS.




Figura 7.17. Estatísticas de classificação dos pomares de alta densidade.

Quando se combinaram os dois produtos, o resultado foi idêntico ao obtido apenas com os *Treetops*, com 61 polígonos correspondentes, 14 não correspondentes e 11 sem dados (Figura 7.18). Este comportamento mostra que em áreas de plantação densa, a integração das duas variáveis não produz melhorias significativas e que a informação proveniente dos *Treetops* é suficiente e mais estável para a caracterização de pomares de alta densidade.

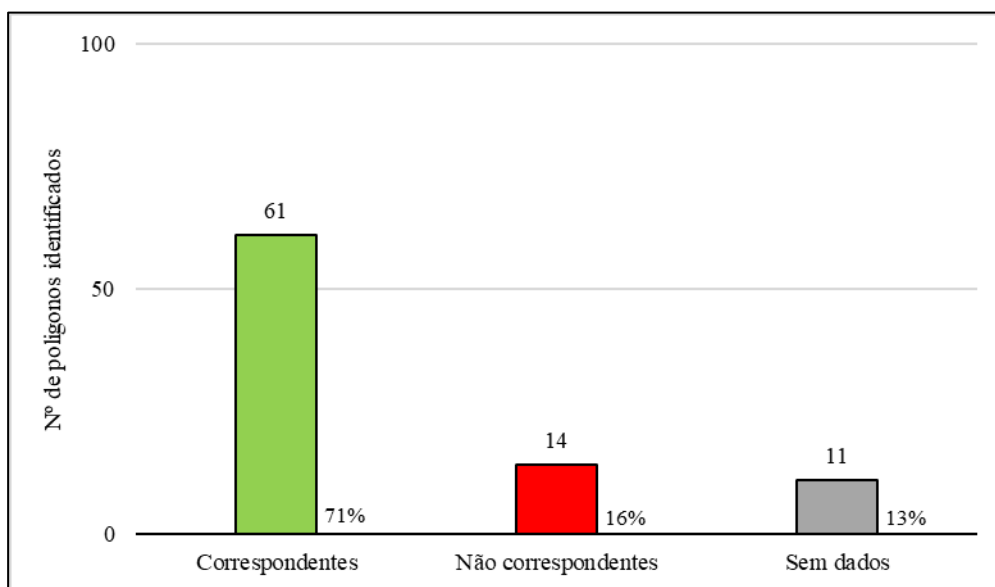


Figura 7.18. Estatísticas da combinação das duas variáveis na classificação dos pomares de alta densidade.

De forma geral, estes resultados indicam que os *Treetops* são mais eficazes para representar culturas com copas muito próximas e alinhadas, enquanto as *Crowns* são mais adequadas para áreas

mais abertas ou de baixa densidade. Assim, a metodologia demonstrou boa capacidade de adaptação, permitindo ajustar a escolha do produto LiDAR conforme o tipo de estrutura agrícola.

No caso dos olivais com copas de baixa densidade, com a variável *Treetops*, foram encontrados 66 polígonos correspondentes e 12 não correspondentes, enquanto com a variável *Crowns*, obtiveram-se 75 polígonos correspondentes e 3 casos sem dados (Figura 7.19). Estes resultados mostram que a variável *Crowns* é ligeiramente mais eficaz na identificação de olivais de baixa densidade, o que reflete um comportamento semelhante ao observado em outros tipos de pomar. Ao considerar apenas as copas, obtém-se uma correspondência mais precisa do que ao considerar apenas os topos das árvores.

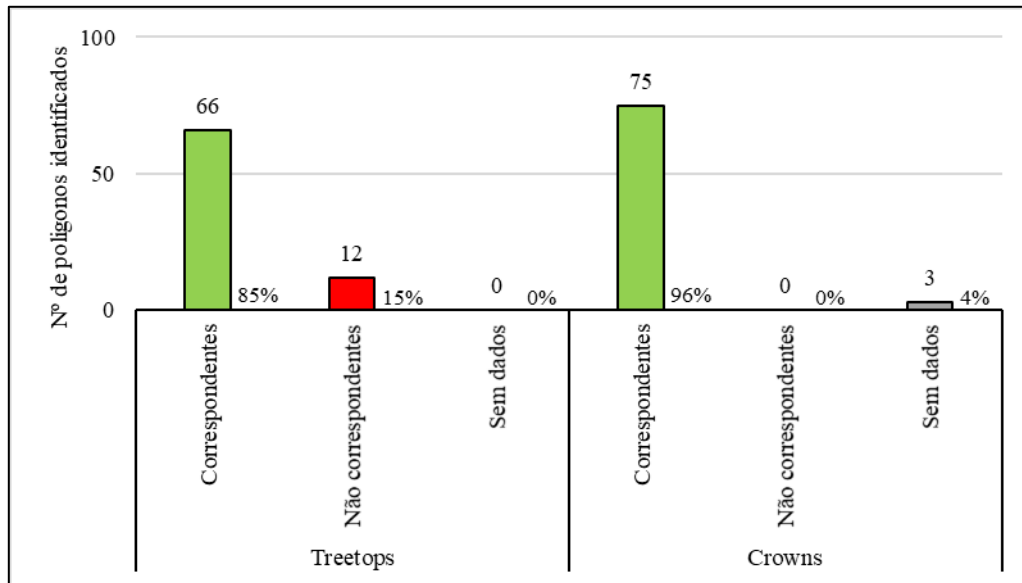


Figura 7.19. Estatísticas de classificação dos olivais de baixa densidade.

No entanto, quando se combinam as duas variáveis a correspondência torna-se total, ou seja, todos os polígonos estão corretamente identificados na COS conforme a densidade, demonstrando que a utilização conjunta das duas variáveis permite compensar as falhas de cada uma individualmente, resultando numa classificação mais fiável. No caso dos polígonos classificados como de alta densidade, observou-se apenas um único caso em que não houve correspondência com ambos os critérios avaliados. Esta discrepância sugere que o talhão poderá não corresponder, na realidade, a uma área de alta densidade, estando incorretamente classificado. Desta forma, pode afirmar-se que a conjugação das duas variáveis acaba por ser mais vantajosa na classificação do que a utilização de apenas uma.

Com base nesta análise, verificou-se que ainda existem polígonos na COS2023 que não têm a sua densidade atribuída. Assim, o próximo passo consistiu em tentar classificar a densidade desses polígonos, recorrendo à combinação das variáveis *Treetops* e *Crowns* para obter uma identificação mais precisa e completa da densidade dos pomares e olivais em todo o território. Como demonstrado anteriormente, os *Treetops* apresentam melhor desempenho em situações de alta densidade, enquanto as *Crowns* são mais adequadas em situações de baixa densidade. Deste modo, para uma classificação equilibrada é importante conjugar as duas variáveis de modo a obter a melhor classificação possível, o que resulta da aplicação do seguinte código à simbologia das camadas vetoriais em QGIS.

```

CASE
-- Quando variáveis estão sem
WHEN "tree_per_ha" IS NULL AND "Crown_per_ha" IS NULL THEN 999
-- Quando apenas Crowns estão disponíveis → usar as Crowns
WHEN "tree_per_ha" IS NULL THEN
CASE
WHEN "Crown_per_ha" < 350 THEN 1 -- baixa densidade
ELSE 0 -- alta densidade
END
-- Quando apenas Trees disponíveis → usar as Trees
WHEN "Crown_per_ha" IS NULL THEN
CASE
WHEN "tree_per_ha" < 350 THEN 1 -- baixa densidade
ELSE 0 -- alta densidade
END
-- Quando ambas têm dados e indicam o mesmo tipo
WHEN "Crown_per_ha" < 350 AND "tree_per_ha" < 350 THEN 1 -- ambas indicam baixa
WHEN "Crown_per_ha" >= 350 AND "tree_per_ha" >= 350 THEN 0 -- ambas indicam alta
-- Quando há divergência entre as duas variáveis
WHEN "Crown_per_ha" < 350 AND "tree_per_ha" >= 350 THEN 0 -- confiar nas Trees (alta)
WHEN "Crown_per_ha" >= 350 AND "tree_per_ha" < 350 THEN 1 -- confiar nas Crowns (baixa)
ELSE 999 -- casos excepcionais
END

```

Na Figura 7.20, observa-se o resultado da classificação de intensidade dos pomares e olivais, em que as áreas a ciano correspondem à classe de alta densidade e as áreas a verde à classe de baixa densidade. A distinção baseou-se na densidade de árvores identificadas através dos produtos LiDAR, de acordo com os critérios definidos para cada nível de intensidade. Os resultados mostram uma boa

correspondência com a estrutura visível na ortofotografia. As zonas classificadas como de alta densidade (ciano) apresentam um padrão regular e compacto de copas, com espaçamento reduzido entre as árvores, típico de pomares mais intensivos ou recentes. Por outro lado, as áreas classificadas como de baixa densidade (verde) exibem um espaçamento mais amplo, compatível com pomares menos intensivos.



Esta diferenciação confirma a eficácia da metodologia em captar variações estruturais no interior das mesmas classes temáticas da COS. Em alguns casos, é possível observar que áreas contíguas dentro de um mesmo polígono da COS apresentam densidades distintas, o que demonstra o potencial do LiDAR para refinar e detalhar a informação existente, permitindo distinguir diferentes tipologias de uma mesma cultura. De forma geral, o resultado confirma a validade dos critérios definidos para a classificação de intensidade e demonstra que a integração de *Treetops* e *Crowns* fornece uma representação coerente e realista da estrutura dos pomares. Esta abordagem contribui para uma melhor caracterização das culturas permanentes e reforça a utilidade do LiDAR como ferramenta complementar na atualização e monitorização das áreas agrícolas representadas na COS.



Classificação da densidade de Pomares

- Alta densidade
- Baixa densidade

0 100 200 m



Classificação de densidade dos Olivais

- Alta densidade
- Baixa densidade

0 100 200 m



Figura 7.20. Classificação correta da densidade dos pomares e olivais.

Apesar de os resultados obtidos demonstrarem boa coerência entre a informação LiDAR e a classificação da COS, verificam-se alguns casos de classificações errôneas, as quais resultam de fatores estruturais e geométricos das próprias áreas analisadas. Na Figura 7.21 (em cima), está representado um exemplo em que os polígonos classificados podem suscitar dúvida devido à sua disposição. Embora a classificação indique áreas de baixa densidade, a distribuição não é totalmente homogênea. Nestes casos, em que coexistem diferentes padrões de ocupação do solo, por exemplo, uma distribuição de copas com dimensões distintas, não é possível uma classificação automática, sendo necessária uma avaliação visual para confirmação.

É apresentado outro exemplo de classificação incorreta, neste caso associado à presença de matos baixos e de vegetação espontânea no interior do polígono (Figura 7.21, em baixo). Esta vegetação, ao ser captada pelo sensor LiDAR, poderá gerar retornos semelhantes aos de copas e topos de árvores pequenas, levando o modelo a confundir áreas de mato denso com culturas permanentes. O mesmo efeito pode ocorrer em zonas de declive acentuado ou de vegetação mista, onde o padrão estrutural é menos regular e a altura da vegetação não corresponde a uma plantação organizada.

Estes exemplos evidenciam limitações do método, sobretudo na diferenciação entre culturas permanentes e áreas florestais ou de matos, também com estrutura variável. Em termos práticos, o procedimento identifica topos de árvores ou arbustos altos, mas não capta a organização espacial das copas. Como melhoria futura, poderá integrar-se uma métrica espacial para avaliar o padrão de distribuição, reforçando a capacidade de distinguir pomares de outros cobertos naturais com densidade semelhante. De forma geral, as análises mostram que o método é muito útil, pois permite uma classificação quase automática da densidade das culturas permanentes na COS, o que acelera o trabalho e orientação da edição. Ainda assim, é necessária intervenção humana para validar os casos mais difíceis, garantindo que as particularidades locais sejam corretamente interpretadas.




Figura 7.21. Classificação incorreta da densidade dos pomares e olivais.

## 7.4 Detecção de Edifícios

Com a metodologia desenvolvida, foi inicialmente gerado um ficheiro matricial, a partir da classificação do LiDAR, no qual se destaca a classe 6 (a vermelho na Figura 7.22), que corresponde aos edifícios. Este primeiro procedimento permitiu identificar e localizar previamente as construções existentes no bloco. Com a aplicação dos restantes passos, foi obtido um ficheiro em formato vetorial com a delimitação dos edifícios, de forma mais evidente e com uma delimitação mais definida da classe 6, que serviu de base para as análises seguintes. Com esta primeira análise, pretendeu-se comparar os edifícios identificados a partir dos dados LiDAR com o tecido urbano representado na COS no sub-bloco 3A5.

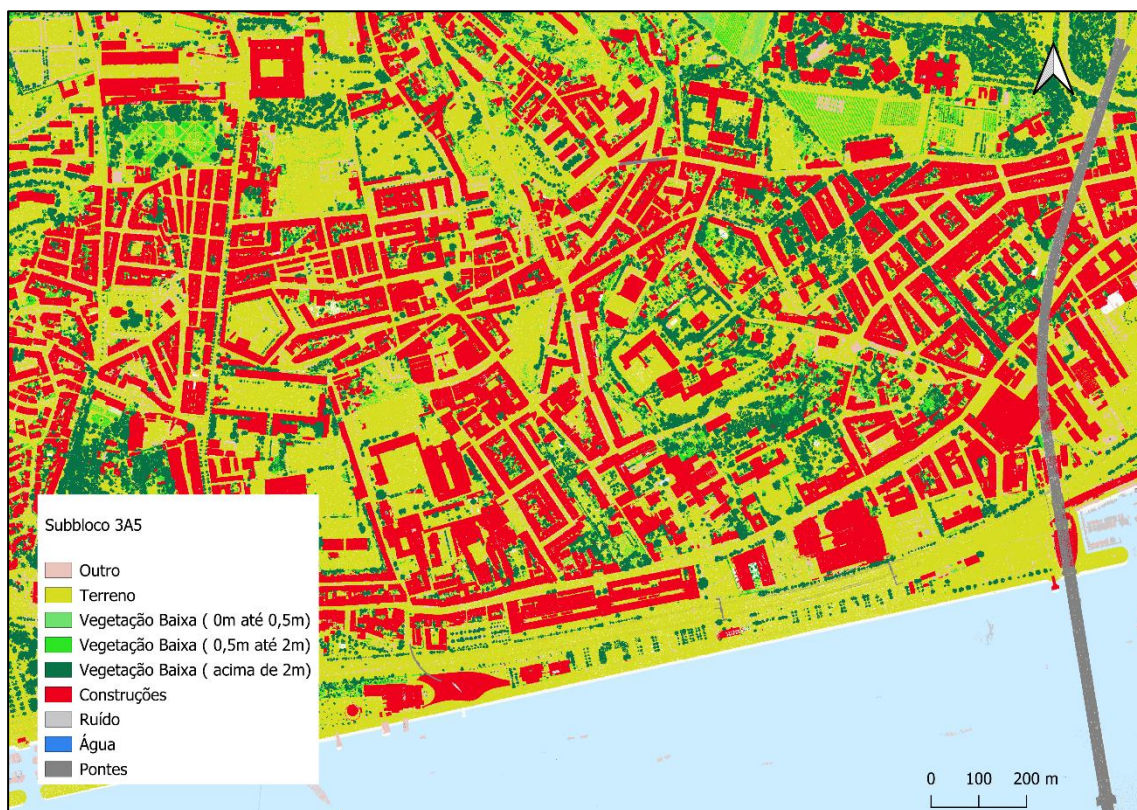


Figura 7.22. Classificação do LiDAR numa sub-área do sub-bloco 3A5.

Os resultados mostram que a área total dos edifícios extraídos do LiDAR corresponde a 8220,01 ha, enquanto o tecido edificado da COS ocupa aproximadamente 29349,7 ha. Da comparação espacial, obteve-se uma área de interseção de 29349,7 ha, implicando que a grande maioria dos edifícios identificados nos dados LiDAR coincide com as áreas já classificadas como urbanas na COS (Figura 7.23). Este resultado traduz-se numa taxa de marcação de cerca de 94,8%, o que evidencia a boa classificação da cartografia oficial nas principais áreas edificadas (Tabela 7.2).

Por outro lado, foram identificados 430,36 ha (5,24%) de edifícios LiDAR fora do tecido urbano da COS, que podem corresponder a expansão urbana recente ou a omissões cartográficas devidas às regras que regem a produção da COS. Esta diferença, embora reduzida, é relevante do ponto de vista analítico, pois demonstra que o LiDAR é mais sensível à realidade física do terreno, permitindo detetar pequenas construções e anexos que, pela sua dimensão, dispersão ou erros de classificação, não foram incluídos na COS. Desta forma, o método evidencia a complementaridade entre as duas fontes de dados:

a COS, enquanto cartografia oficial, mantém uma elevada coerência nas áreas consolidadas, enquanto o LiDAR acrescenta níveis de detalhe e atualidade, revelando novas dinâmicas territoriais e zonas de crescimento que ainda não estão refletidas na cartografia de base.



Figura 7.23. Análise entre COS e LiDAR em edifícios.

O índice de Jaccard, medido pelo *Intersect over Union* (IoU), foi de 98,55%, o que corresponde a uma sobreposição quase total entre os polígonos resultantes da metodologia desenvolvida e os representados na COS. Este valor indica que as duas fontes apresentam elevada consistência na delimitação das áreas urbanas, com discrepâncias residuais observadas em cerca de 5% da área. Assim, pode concluir-se que a cartografia de base possui uma elevada fiabilidade, enquanto os dados LiDAR se assumem como um contributo complementar relevante para reforçar a precisão espacial e a coerência da informação cartográfica.

Tabela 7.2. Síntese dos valores da análise dos edifícios.

<b>Indicador</b>	<b>Descrição</b>	<b>Valor</b>	<b>Interpretação</b>
<b>Área de edifícios LiDAR</b>	Área total dos edifícios detetados a partir do LiDAR	8220,01 ha	Representa a área total de edifícios identificados no LiDAR no sub-bloco 3A5
<b>Área de tecido edificado COS</b>	Área total classificada como tecido edificado na COS	29349,7 ha	Corresponde à área de tecido edificado oficial da COS para o sub-bloco 3A5
<b>Área de interseção LiDAR-COS</b>	Área comum entre os edifícios LiDAR e o tecido edificado na COS	29349,7 ha	Indica coincidência elevada entre as duas fontes de dados
<b>Taxa de marcação</b>	Percentagem de edifícios LiDAR coincidentes com a COS	94,76%	Mostra boa correspondência entre LiDAR e COS
<b>Área LiDAR fora da COS</b>	Edifícios LiDAR fora do tecido urbano da COS	430,36 ha	Pode indicar expansão urbana recente ou omissões cartográficas
<b>Diferença relativa</b>	Percentagem e edifícios LiDAR não coincidentes	5,24%	Representa as discrepâncias residuais
<b>Índice de Jaccard (IoU)</b>	Medida de sobreposição entre LiDAR e COS	98,55%	Revela elevada consistência espacial entre as duas fontes de dados

Para complementar a análise da correspondência entre o edificado LiDAR e o tecido urbano da COS, foi realizado um cruzamento entre as duas bases de dados. Este procedimento teve como objetivo identificar potenciais áreas de expansão urbana ou omissões cartográficas, através da análise espacial dos edifícios LiDAR que não apresentaram interseção com a COS. Este processo automatizado permitiu gerar alertas geográficos para zonas com presença de edifícios identificados pelo LiDAR não mapeados na COS, através da metodologia referida na *secção 6.4.1* (Figura 7.24).



Figura 7.24. Alertas para o tecido edificado não identificado na COS.

Após comparar os edifícios detetados pelo LiDAR com os da COS, surgiram pequenos polígonos adicionais. Estas áreas correspondem a edifícios que foram corretamente captados pelo LiDAR, mas que não estavam totalmente incluídos na COS. Durante o processamento, esses fragmentos acabaram por se ligar e sobrepor de forma incorreta à COS. Na prática, são zonas que já estavam identificadas e foram novamente detetadas pela metodologia, criando uma sobreposição desnecessária, Figura 7.25. O principal resultado é a identificação de áreas edificadas fora do tecido urbano da COS, que funciona como alerta de expansão urbana. Estes alertas servem para ajustar limites e, quando pertinente, incluir na classe urbana já desenhada. Assim, a comparação entre LiDAR-COS não resulta numa correspondência perfeita, mas permite sinalizar omissões e mudanças recentes que devem ser validadas por fotointerpretação e atualizadas na COS.



*Figura 7.25. Classificação incorreta de alertas para o tecido edificado*

O cruzamento dos edifícios detetados pelo LiDAR, fora do tecido urbano da COS, com a COS exibe uma forte incidência de edifícios em mosaicos agrícolas e em áreas com culturas temporárias e ainda, em áreas com matos e pastagens, refletindo um padrão típico de edificado disperso rural e periurbano (Tabela 7.3). A presença em áreas florestais e de agricultura corresponde sobretudo a estruturas de apoio, enquanto as ocorrências em pomares e vinhas são residuais, associadas a instalações agrícolas existentes nos talhões. A Tabela 7.3 lista as classes da COS2023 com área superior a 1 ha e a restantes classes encontram-se listadas no Anexo 1.

Tabela 7.3. Cruzamento dos edifícios LiDAR fora do tecido urbano com a COS2023.

Classes da COS	Soma da Área (ha)
Mosaicos culturais e parcelares complexos	93,458
Culturas temporárias de sequeiro e regadio	82,263
Matos	52,945
Agricultura com espaços naturais e seminaturais	32,773
Pastagens espontâneas	25,962
Florestas de pinheiro bravo	19,341
Florestas de outras folhosas	17,238
Espaços verdes	17,167
Pastagens melhoradas	14,483
Florestas de pinheiro manso	13,704
Agricultura e viveiros protegidos	12,001
Vazios sem construção	9,251
Pomares	8,915
Florestas de eucalipto	8,415
Pedreiras	5,053
Praias, dunas e areais costeiros	4,256
Equipamentos de lazer	4,174
Florestas de outras resinosas	4,026
Vinhas	1,977

Os resultados mostram que o LiDAR acrescenta cobertura e detalhe onde a COS tende a sub-representar o edificado disperso, ao privilegiar o urbano contínuo. O cruzamento entre LiDAR e COS revela omissões e expansão urbana recente, especialmente em contextos agrícolas e rurais. Na Figura 7.26, estão assinalados (a ciano) os edifícios detetados pelo LiDAR fora do tecido urbano da COS, podendo observar-se padrões de crescimento descontínuo junto a áreas consolidadas que, pela dimensão ou pela data de construção, não foram incorporadas na COS. Agrupando essas deteções por proximidade, é possível delinear novas zonas urbanas e gerar alertas prioritários para posterior revisão. Esta informação é relevante para futuras edições da COS, porque permite antecipar áreas em expansão e orientar a atualização temática com base em evidências recentes e objetivas.



Figura 7.26. Exemplos de edifícios identificados pelo LiDAR fora do tecido urbano da COS2023.

Na Figura 7.27, apresentam-se exemplos de edifícios detetados pelo LiDAR fora do tecido urbano da COS, localizados em áreas classificadas como agricultura e culturas permanentes, que embora sejam classes marcadas por uma fronteira bem definida, requerem uma avaliação caso a caso, como precaução. Estes casos representam situações em que a presença de edificado pode não corresponder a expansão urbana, mas sim à existência de estruturas de apoio à atividade agrícola, como armazéns ou instalações de gestão de exploração. Na ortofotografia é possível observar que os edifícios (a ciano na Figura 7.27), se encontram integrados em talhões agrícolas, sem continuidade com o tecido urbano mais próximo. A delimitação da COS (a verde na Figura 7.27) confirma que estas parcelas pertencem a classes agrícolas, reforçando a interpretação de que se trata de construções funcionais e isoladas, típicas de ambientes rurais produtivos.

A deteção destes edifícios fora do perímetro urbano evidencia a sensibilidade do LiDAR na identificação de pequenas estruturas que, embora não representem crescimento urbano, são relevantes para a caracterização do uso do solo. Estes casos ilustram a importância de distinguir entre expansão urbana e edificação dispersa de apoio agrícola, uma vez que ambas produzem respostas semelhantes no modelo, mas possuem significados distintos para a atualização da COS. A nível metodológico, este tipo de ocorrência sublinha a necessidade de contextualizar espacialmente os resultados do LiDAR com a informação temática da COS, de modo a evitar interpretações erradas do crescimento urbano. Em áreas agrícolas, a presença de edifícios isolados deve ser entendida como parte da dinâmica rural e não necessariamente como alteração de uso.

Ainda assim, a identificação destes edifícios é importante para a gestão e atualização da cartografia, pois permite detetar e registar infraestruturas agrícolas não mapeadas, contribuindo para

uma representação mais completa e detalhada do território. Estes exemplos mostram que o LiDAR não só é eficaz na detecção de expansão urbana, como é essencial para caracterizar o edificado disperso e reforçar a coerência temática da COS. Além disso, a informação extraída pode alimentar bases cartográficas de maior detalhe, como áreas edificadas e interfaces urbano-rurais, o que apoia a revisão de fronteiras e a atualização temática em outras bases de dados.



Figura 7.27. Exemplos de edifícios identificados pelo LiDAR.

Outra avaliação efetuada foi a correspondência entre as duas fontes de dados de edifícios. A interseção espacial entre os edifícios identificados a partir do LiDAR e os *Microsoft Buildings Footprints* (MBF) em Agosto de 2024. O MBF é um produto criado pela *Microsoft* com base em imagens de satélite de alta resolução e em inteligência artificial, especificamente redes neurais convolucionais (CNNs), que permitem identificar automaticamente o contorno dos edifícios a partir da análise de imagens de satélite de muito alta resolução espacial (*Microsoft, n.d.*). Este procedimento permitiu comparar diretamente as duas bases e identificar áreas comuns e diferenças. A análise revelou que o LiDAR apresenta maior capacidade de deteção revelando cerca de 34,09 % mais área do que o MBF (Figura 7.28). Estes edifícios, provenientes do LiDAR, representam áreas de construções que o MBF não captou, demonstrando a maior sensibilidade do LiDAR à realidade física do terreno, por incorporar a altura e o volume das estruturas.



Figura 7.28. LiDAR vs. MBF.

De forma geral, a comparação mostra que o LiDAR oferece uma representação mais detalhada e precisa do edificado, enquanto o MBF tende a apresentar uma generalização geométrica e algumas omissões, sobretudo em contextos rurais e periurbanos. Estes resultados reforçam a vantagem do uso de dados LiDAR para a detecção e atualização de edifícios, garantindo maior fiabilidade e completude na caracterização do tecido urbano.

## 8 Conclusão

Este trabalho demonstrou, de forma concreta, as vantagens da integração de dados LiDAR no processo de produção e atualização da COS. A metodologia desenvolvida provou ser eficaz e relevante, evidenciando que a informação tridimensional fornecida pelo LiDAR complementa de forma significativa a fotointerpretação. Com o apoio destes dados, foi possível identificar com maior precisão os padrões estruturais do território, nomeadamente manchas florestais, culturas permanentes e edificações, ampliando o detalhe e a qualidade do mapeamento.

No caso das manchas florestais, os dados LiDAR permitiram uma identificação com um maior detalhe estrutural da vegetação, superando as limitações dos métodos convencionais. A altura e a distribuição da vegetação mostraram ser indicadores fiáveis para distinguir áreas arborizadas relevantes para a COS. Esta metodologia demonstrou eficácia na sinalização de áreas com potencial de revisão, reforçando a capacidade de deteção de floresta densa, áreas de transição e situações omissas na cartografia existente.

Quanto às culturas permanentes, o LiDAR captou, de forma correta, os padrões característicos destas áreas, permitindo a sua diferenciação com base na geometria e na altura das árvores. A metodologia desenvolvida possibilitou gerar alertas com baixo nível de omissões, contribuindo para uma melhor delimitação e caracterização das áreas agrícolas permanentes. Além disso, a análise de densidade com métricas derivadas do *Treetops* e *Crowns* revelou potencial para classificar automaticamente a intensidade das plantações, facilitando futuras atualizações da COS.

Por fim, na deteção de edificações através do LiDAR apresentou uma elevada taxa de correspondência com o tecido urbano já representado na COS, ao mesmo tempo que permitiu identificar construções dispersas e zonas de expansão urbana que ainda não mapeadas. Esta abordagem reforça a precisão da cartografia oficial e demonstra a utilidade do LiDAR como fonte complementar para a deteção de alterações no território. A capacidade de gerar alertas automáticos baseados em variações físicas acrescenta valor ao processo de atualização e monitorização.

Deste modo, o trabalho evidencia o potencial dos dados LiDAR como recurso para apoiar a DGT na modernização dos processos de produção e atualização da COS. A metodologia desenvolvida demonstrou ser um contributo eficiente para a cartografia nacional, ao integrar informação tridimensional de elevada qualidade e métodos convencionais. O uso do LiDAR representa um avanço significativo no sistema de monitorização do território. Contudo, importa reconhecer as limitações associadas, nomeadamente o elevado custo dos levantamentos LiDAR aéreos e a consequente baixa cadência temporal. A ausência de atualizações frequentes implica que a informação possa rapidamente deixar de refletir a realidade do terreno, sobretudo em territórios sujeitos a dinâmicas intensas, como incêndios florestais, cortes, reconversão de usos do solo ou expansão urbana.

Em termos de perspetivas futuras no âmbito do melhoramento deste trabalho, torna-se particularmente relevante aprofundar a distinção entre classes de floresta, matos e vegetação rasteira, bem como entre classes com características semelhantes que tendem a ser confundidas, ajustando descritores tridimensionais e estratégias de classificação de forma a reduzir erros de inclusão e omissão. Para além da componente florestal, a metodologia poderá ser estendida à identificação de jardins e outros espaços verdes nas áreas urbanas, tirando partido da informação tridimensional para os diferenciar de outras superfícies urbanas. A contabilização e caracterização dos edifícios constitui outra linha de evolução, permitindo explorar de forma mais sistemática o potencial do LiDAR na discriminação de

volumes edificados e na melhoria da representação das áreas urbanas na COS. De salientar que não se perspetiva a repetição da cobertura LiDAR num futuro próximo, o que significa que a utilidade máxima destes dados se verifica sobretudo num horizonte temporal de curto prazo, alinhado com a futura COS2025.

## Referências Bibliográficas

- Ackermann, F. (1999) Airborne Laser Scanning—Present Status and Future Expectations. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54, 64-67. [Airborne laser scanning—present status and future expectations - ScienceDirect](#)
- Antonarakis, A. S., Richards, K. S., & Brasington, J. (2008). Object-based land cover classification using airborne LiDAR. *Remote Sensing of environment*, 112(6), 2988-2998. <https://www.sciencedirect.com/science/article/abs/pii/S0034425708000667>
- Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichfuss, S., & Bareth, G. (2014). Estimating biomass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. *Remote sensing*, 6(11), 10395-10412. <https://www.mdpi.com/2072-4292/6/11/10395>
- Brown, C. F., Brumby, S. P., Guzder-Williams, B., Birch, T., Hyde, S. B., Mazzariello, J., ... & Tait, A. M. (2022). Dynamic World, Near real-time global 10 m land use land cover mapping. *Scientific data*, 9(1), 251. <https://www.nature.com/articles/s41597-022-01307-4>
- Büttner, G., Kosztra, B., Maucha, G., & Pataki, R. (2012). Implementation and achievements of CLC2006. European Environment Agency. [https://www.eea.europa.eu/data-and-maps/data/corine-land-cover-3/clc-final-report/clc-final-report/@@download/file/Implementation\\_and\\_achievements\\_of%20CLC2006.pdf](https://www.eea.europa.eu/data-and-maps/data/corine-land-cover-3/clc-final-report/clc-final-report/@@download/file/Implementation_and_achievements_of%20CLC2006.pdf)
- Chedid, E., Avia, K., Dumas, V., *et al.* (2023). LiDAR Is Effective in Characterizing Vine Growth and Detecting Associated Genetic Loci. *Plant Phenomics*, 5(7). <https://doi.org/10.34133/plantphenomics.0116>
- Copernicus Data Space Ecosystem. (n.d.). *Sentinel-2*. Copernicus Data Space Ecosystem – Documentation. <https://documentation.dataspace.copernicus.eu/Data/SentinelMissions/Sentinel2.html>
- Dalponte, M., Bruzzone, L., & Gianelle, D. (2008). Fusion of hyperspectral and LIDAR remote sensing data for classification of complex forest areas. *IEEE Transactions on Geoscience and Remote Sensing*, 46(5), 1416-1427. [https://www.researchgate.net/publication/3205857\\_Fusion\\_of\\_Hyperspectral\\_and\\_LIDAR\\_Remote\\_Sensing\\_Data\\_for\\_Classification\\_of\\_Complex\\_Forest\\_Areas](https://www.researchgate.net/publication/3205857_Fusion_of_Hyperspectral_and_LIDAR_Remote_Sensing_Data_for_Classification_of_Complex_Forest_Areas)
- Direção-Geral do Território (DGT). (2020). Carta de Ocupação do Solo (COS 2018). Lisboa: Direção-Geral do Território. <https://www.dgterritorio.gov.pt/cartografia/cartografia-tematica/SMOS-CLMS> [Consultado em: 4 de Julho de 2025]
- Direção-Geral do Território (DGT). (2022). SMOS - Sistema de Monitorização da Ocupação do Solo [Brochura]. Disponível em: [https://smos.dgterritorio.gov.pt/sites/default/files/documents/Brochura\\_SMOS\\_09\\_2022.pdf](https://smos.dgterritorio.gov.pt/sites/default/files/documents/Brochura_SMOS_09_2022.pdf) [Consultado em: 4 de Julho de 2025]
- Direção-Geral do Território (DGT). (2022a). *Cartografia de uso e ocupação do solo: Ficha de produto (SMOS)* [PDF]. SMOS – Sistema de Monitorização da Ocupação do Solo. [Ficha de produto Cartografia de uso e ocupacao do solo v 20-12-2022.pdf](https://www.dgterritorio.gov.pt/sites/default/files/documents/Ficha_de_produto_Cartografia_de_uso_e_ocupacao_do_solo_v_20-12-2022.pdf) [Consultado em: 4 de Julho de 2025]

Direção-Geral do Território (DGT). (2024). Levantamento LiDAR de Portugal Continental. Disponível em: <https://www.dgterritorio.gov.pt/Levantamento-LiDAR-de-Portugal-Continental>. [Consultado em: 4 de Julho de 2025]

Direção-Geral do Território (DGT). (2024a). Manual de fotointerpretação da Carta de Uso e Ocupação do Solo (COS) de Portugal Continental. Relatório Técnico. Direção-Geral do Território

Direção-Geral do Território (DGT). (2025). Sistema de Monitorização da Ocupação do Solo. Disponível em: <https://smos.dgterritorio.gov.pt/sobre-o-smos>. [Consultado em: 4 de Julho de 2025]

Direção-Geral do Território (DGT). (2025a). *Especificações técnicas da Série 2 da Carta de Uso e Ocupação do Solo (COS) de Portugal Continental*. Relatório Técnico, DGT, Lisboa. Disponível em: <https://geo2.dgterritorio.gov.pt/cos/ET/COS-Serie2-EspecificacoesTecnicas.pdf> [Consultado em: 30 de Julho de 2025]

Direção-Geral do Território (DGT). (n.d.). *Modelos digitais* (Cartografia Topográfica). Direção-Geral do Território. [Modelos Digitais do Relevo | Direção-Geral do Território](#) [Consultado em: 10 de Agosto de 2025]

Foley, J. A., DeFries, R., Asner, G. P., Barford, C., Bonan, G., Carpenter, S. R., ... & Snyder, P. K. (2005). Global consequences of land use. *science*, 309(5734), 570-574. <https://www.science.org/doi/abs/10.1126/science.1111772>

Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote sensing of environment*, 80(1), 185-201. <https://www.sciencedirect.com/science/article/abs/pii/S0034425701002954>

GIS Geography. (n.d.). *A complete guide to LiDAR: Light detection and ranging*. GIS Geography. [A Complete Guide to LiDAR: Light Detection and Ranging - GIS Geography](#) [Consultado em: 10 de Agosto de 2025]

Gong, P., Wang, J., Yu, L., Zhao, Y., Zhao, Y., Liang, L., ... & Chen, J. (2013). Finer resolution observation and monitoring of global land cover: First mapping results with Landsat TM and ETM+ data. *International journal of remote sensing*, 34(7), 2607-2654. <https://www.tandfonline.com/doi/full/10.1080/01431161.2012.748992>

Hycza, T., & Kupidura, P. (2021). Methods for separating orchards from forest using airborne LiDAR. *Annals of Forest Science*, 78(4), 101. <https://link.springer.com/article/10.1007/s13595-021-01116-6>

Hyypä, J., Hyypä, H., Leckie, D., Gougeon, F., Yu, X., & Maltamo, M. (2008). Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. *International Journal of Remote Sensing*, 29(5), 1339-1366. <https://www.tandfonline.com/doi/abs/10.1080/01431160701736489>

Hyypä, J., Yu, X., Hyypä, H., Vastaranta, M., Holopainen, M., Kukko, A., ... & Alho, P. (2012). Advances in forest inventory using airborne laser scanning. *Remote sensing*, 4(5), 1190-1207. <https://www.mdpi.com/2072-4292/4/5/1190>

IBM. (2023). *O que é LiDAR?* IBM Think. [O que é LiDAR? | IBM](#) [Consultado em: 10 de Agosto de 2025]

Karim, M. R., Ahmed, S., Reza, M. N., Lee, K. H., Sung, J., & Chung, S. O. (2024). Geometric Feature Characterization of Apple Trees from 3D LiDAR Point Cloud Data. *Journal of Imaging*, 11(1), 5. <https://www.mdpi.com/2313-433X/11/1/5>

Kinzel, P. J., Wright, C. W., Nelson, J. M., et al. (2013). Mapping river bathymetry with a small-footprint green LiDAR: Applications and challenges. *Journal of the American Water Resources Association*, 49(1). <https://onlinelibrary.wiley.com/doi/10.1111/jawr.12008>

Kuras, A., Brell, M., Rizzi, J., & Burud, I. (2021). Hyperspectral and LiDAR data applied to urban land cover machine learning and neural-network-based classification: A review. *Remote Sensing*, 13(17), 3393. <https://www.mdpi.com/2072-4292/13/17/3393>

Li, R. (2024). *Mastering LiDAR with DJI Enterprise: An introductory booklet*. DJI Enterprise – Insights. [Mastering LiDAR with DJI Enterprise: An Introductory Booklet](#)

Li, Y., Xiao, X. (2025). Deep learning-based fusion of optical, radar, and LiDAR data for advancing land monitoring. *Sensors*, 25(16), 4991. <https://www.mdpi.com/1424-8220/25/16/4991>

Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International journal of Remote sensing*, 28(5), 823-870. [Full article: A survey of image classification methods and techniques for improving classification performance](#)

Mallet, C., & Bretar, F. (2009). Full-waveform topographic lidar: State-of-the-art. *ISPRS Journal of photogrammetry and remote sensing*, 64(1), 1-16. <https://www.sciencedirect.com/science/article/abs/pii/S0924271608000993>

Mandlbürger, G. (2024, December 30). *Airborne Lidar: A Tutorial for 2025 — Part I: Lidar basics*. LIDAR Magazine. [Airborne Lidar: A Tutorial for 2025 - LIDAR Magazine](#)

Microsoft. (n.d.). *Microsoft Global Building Footprints* [Dataset]. Microsoft Planetary Computer. <https://planetarycomputer.microsoft.com/dataset/ms-buildings> [Consultado em: 7 de Setembro de 2025]

Moreno, H., Valero, C., Bengochea-Guevara, J. M., Ribeiro, Á., Garrido-Izard, M., & Andújar, D. (2020). On-ground vineyard reconstruction using a LiDAR-based automated system. *Sensors*, 20(4), 1102. <https://www.mdpi.com/1424-8220/20/4/1102>

NASA. (n.d.). *Lunar Orbiter Laser Altimeter (LOLA)*. NASA Science. <https://science.nasa.gov/mission/lro/lola/> [Consultado em: 20 de Julho de 2025]

Niemeyer, J., Rottensteiner, F., & Soergel, U. (2014). Contextual classification of lidar data and building object detection in urban areas. *ISPRS journal of photogrammetry and remote sensing*, 87, 152-165. <https://www.sciencedirect.com/science/article/abs/pii/S0924271613002359>

Popescu, S. C., Wynne, R. H., & Nelson, R. F. (2003). Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass. *Canadian journal of remote sensing*, 29(5), 564-577. [\(PDF\) Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass](#)

R Core Team. (2025). R: The R project for Statistical Computing. [Computer software]. [R: The R Project for Statistical Computing](#)  
[Consultado em: 29 de Outubro de 2025]

Roussel, J. R., Auty, D. (2025). lidR: Airborne LiDAR Data Manipulation and Visualization for Forestry Applications. [R package]. [CRAN: Package lidR](#)  
[Consultado em: 29 de Outubro de 2025]

Sandonís-Pozo, L., Rufat, J., Pascual, M., Villar, J. M., Arnó, J., Escolà, A., ... & Martínez-Casasnovas, J. A. Lidar-Derived Indices and Their Relationship with Productivity and Oil Quality Attributes in High-Density Olive Orchards. *Available at SSRN 5013544*.  
[https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=5013544](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=5013544)

Sequeira, A. C., Nunes, L., Caetano, M., Marcelino, F., Rocha, M., & Rego, F. C. (2022). Dinâmicas de uso e ocupação do solo entre 1951-80 e 2018 em Portugal Continental. *Silva Lusitana*, 30(2), 87-105. <https://silva-lusitana.edpsciences.org/articles/silu/abs/2022/02/silu2022302p87/silu2022302p87.html>

Song, J. H., Han, S. H., Yu, K. Y., & Kim, Y. I. (2002). Assessing the possibility of land-cover classification using lidar intensity data. *International archives of photogrammetry remote sensing and spatial information sciences*, 34(3/B), 259-262. [FOREWORD](#)

Sun, X. (2016). Light detection and ranging (LiDAR) from space: laser altimeters. In *Wiley Encyclopedia of Electrical and Electronics Engineering*. John Wiley & Sons. <https://ntrs.nasa.gov/citations/20170003769>

Szafarczyk, A., & Toś, C. (2023). *The use of green laser in LiDAR bathymetry: State of the art and recent advancements*. *Sensors*, 23, 292. <https://www.mdpi.com/1424-8220/23/1/292>

Trawny, N., Marcus, C. L., Chen, P.-T., Hewitt, R. A., & Setterfield, T. P. (2022). Real-world testing of LiDAR-inertial based navigation and mapping for precision landing. *Jet Propulsion Laboratory, NASA*. <https://ntrs.nasa.gov/citations/20230006930>

Turner, B. L., Lambin, E. F., & Reenberg, A. (2007). The emergence of land change science for global environmental change and sustainability. *Proceedings of the National Academy of Sciences*, 104(52), 20666-20671. <https://www.pnas.org/doi/abs/10.1073/pnas.0704119104>

U.S. Geological Survey (USGS). (2014). *Lidar Base Specification* (Version 1.2, November 2014) – Standards for USGS LiDAR data. Techniques and Methods 11–B4, Reston, VA: USGS National Geospatial Program. <https://pubs.usgs.gov/tm/11b4/Version1.2/tm11-B4.pdf>

Uva J S, Onofre R, Moreira J, Faias S P, Barreiro S, Santos E, Capelo J, Corte-Real L, Martins J, Ribeiro J R, Cancela J, Rainha M, Amaral N, Santos C, Perpétua J, Pinho J, Araújo J M, Reis L, Canaveira P, Paulino J, Pina A (2021): Forestry Inventory 2015. v1. ICNF - Instituto da Conservação da Natureza e

das Florestas. <https://cdn.pefc.org/pefc.pt/media/2020-08/88597cd3-8e82-4bc6-aae6-fb66adb5303f/22eabe74-d55e-5246-bfec-15be43c3c1c9.pdf>

Wehr, A., & Lohr, U. (1999). Airborne laser scanning—An introduction and overview. *ISPRS Journal of Photogrammetry & Remote Sensing*, 54(2-3), 68–82. <https://www.sciencedirect.com/science/article/abs/pii/S0924271699000118>

Wulder, M.A., Masek, J.G., Cohen, W.B., Loveland, T.R. and Woodcock, C.E. (2012) Opening the Archive: How Free Data Has Enabled the Science and Monitoring Promise of Landsat. *Remote Sensing of Environment*, 122, 2-10. <http://dx.doi.org/10.1016/j.rse.2012.01.010>

Yan, W. Y., Shaker, A., & El-Ashmawy, N. (2015). Urban land cover classification using airborne LiDAR data: A review. *Remote sensing of environment*, 158, 295-310. <https://www.sciencedirect.com/science/article/abs/pii/S0034425714004374>

Yan, W. Y., Shaker, A., & El-Ashmawy, N. (2015). Urban land cover classification using airborne LiDAR data: A review. *Remote sensing of environment*, 158, 295-310. <https://www.sciencedirect.com/science/article/abs/pii/S0034425714004374>

Zhao, D., Ji, L., Yang, F., & Liu, X. (2022). A Possibility-Based Method for Urban Land Cover Classification Using Airborne Lidar Data. *Remote Sensing*, 14(23), 5941. <https://www.mdpi.com/2072-4292/14/23/5941>

Zhu, X. X., Tuia, D., Mou, L., Xia, G. S., Zhang, L., Xu, F., & Fraundorfer, F. (2017). Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE geoscience and remote sensing magazine*, 5(4), 8-36. <https://ieeexplore.ieee.org/document/8113128>

## Anexo 1

Tabela 1.1 Cruzamento dos edifícios LiDAR for a do tecido urbano com a COS2023.

<b>Classes da COS</b>	<b>Área total (ha)</b>
Mosaicos culturais e parcelares complexos	93,458
Culturas temporárias de sequeiro e regadio	82,263
Matos	52,945
Agricultura com espaços naturais e seminaturais	32,773
Pastagens espontâneas	25,962
Florestas de pinheiro bravo	19,341
Florestas de outras folhosas	17,238
Espaços verdes	17,167
Pastagens melhoradas	14,483
Florestas de pinheiro manso	13,704
Agricultura e viveiros protegidos	12,001
Vazios sem construção	9,251
Pomares	8,915
Florestas de eucalipto	8,415
Pedreiras	5,053
Praias, dunas e areais costeiros	4,256
Equipamentos de lazer	4,174
Florestas de outras resinosas	4,026
Vinhas	1,977
Florestas de sobreiro	0,819
Desembocaduras fluviais	0,623
Olivais	0,521
Espaços rochosos	0,428
Florestas de outros carvalhos	0,294
Superfícies silvopastoris de pinheiro manso	0,134
Florestas de acácias	0,084
Superfícies silvopastoris de sobreiro	0,075
Superfícies silvopastoris de outras folhosas	0,062
Aterros	0,061
Albufeiras de barragens	0,056
Superfícies silvopastoris de outros carvalhos	0,048
Lagos e lagoas interiores artificiais	0,045
Pauis e turfeiras	0,028
Oceano	0,024
Vegetação esparsa	0,022
Culturas temporárias e/ou pastagens melhoradas associadas a vinha	0,019
Culturas temporárias e/ou pastagens melhoradas associadas a olival	0,016
Florestas de azinheira	0,015
Cursos de água naturais	0,012
Superfícies agrossilvícolas de outros carvalhos	0,011
Sapais	0,009
Charcas	0,006
Áreas de estacionamento	0
Áreas edificadas residenciais contínuas predominantemente horizontais	0
Áreas edificadas residenciais contínuas predominantemente verticais	0
Áreas edificadas residenciais descontínuas	0

Áreas edificadas residenciais descontínuas esparsas	0
Áreas em construção	0
Cemitérios	0
Comércio e serviços	0
Equipamentos culturais	0
Equipamentos desportivos	0
Indústria e logística	0
Infraestruturas de drenagem e tratamento de águas residuais	0
Instalações agrícolas e pecuárias	0
Marinas e docas pesca	0
Outros equipamentos e instalações turísticas	0