



**INSTITUTO POLITÉCNICO
DE VIANA DO CASTELO**

LiDAR para estimativa da biomassa florestal
em parcelas de *Eucalyptus globulus* de terceira rotação

Dissertação de Mestrado

Engenharia do Território e Ambiente

Diogo Luís Palhares Gonçalves

Escola Superior Agrária do Instituto Politécnico de Viana do Castelo, novembro de 2025



INSTITUTO POLITÉCNICO
DE VIANA DO CASTELO

Diogo Luís Palhares Gonçalves

LiDAR para estimativa da biomassa florestal
em parcelas de *Eucalyptus globulus* de terceira rotação

Dissertação de Mestrado

Engenharia do Território e Ambiente

Trabalho efetuado sob orientação de:

Professor Doutor Joaquim Mamede Alonso

Professor Doutor Claudio Alexandre Araújo Paredes

Escola Superior Agrária do Instituto Politécnico de Viana do Castelo, novembro de 2025

*As doutrinas expressas neste
documento são da exclusiva
responsabilidade do autor*

*“Land, then, is not merely soil;
it is a fountain of energy flowing
through a circuit of soils, plants, and animals.”*

Aldo Leopold

ÍNDICE

Agradecimentos	viii
Resumo	ix
Abstract.....	x
Índice de Quadros	xi
Índice de Figuras	xii
Índice de equações.....	xiv
Acrónimos e Abreviaturas	xv
1. INTRODUÇÃO.....	1
2. ENQUADRAMENTO TEÓRICO	5
2.1. A Floresta no Contexto Ambiental, Climático e Socioeconómico	5
2.1.1. Funções ecológicas e importância global das florestas	5
2.1.2. Diversidade de biomas florestais e estrutura vertical	7
2.1.3. Ameaças e dinâmicas espaciais contemporâneas dos espaços florestais.....	9
2.2. Desafios da Monitorização Florestal em Grande Escala	11
2.2.1. Limitações dos métodos convencionais	11
2.2.3. Necessidade de tecnologias espaciais avançadas	14
2.3. Princípios Fundamentais e evolução/desenvolvimento da Tecnologia Lidar	16
2.4. Aplicações, Processamento e Produtos derivados de dados LiDAR	18
2.5. A Importância da Biomassa Florestal e o Uso de Dados LiDAR na sua Estimativa	21
2.5.1. A Importância da Biomassa Florestal no Contexto Ambiental e da Gestão Territorial.....	21
2.5.2. Uso de Dados LiDAR na Estimativa de Volume e Biomassa Florestal	22
3. Metodologia.....	26

3.1. Recolha e processamento dos dados.....	27
3.1.1. Dados de campo	27
3.1.2. Dados LiDAR.....	30
3.2. Pré-processamento dos Dados	31
3.2.1. Organização e tratamento dos dados	31
3.2.2. Construção das variáveis preditoras	34
3.3. Modelação preditiva	37
3.3.1. Modelos de regressão e machine learning.....	37
3.3.2. Integração dos modelos (ensemble)	39
3.4. Validação e Avaliação de Desempenho	40
3.4.1. Procedimento de validação.....	40
3.4.2. Critérios de avaliação e métricas de desempenho	40
3.5. Importância das Variáveis.....	42
3.5.1. Quantificação da importância das variáveis preditoras	42
4. Análise e discussão de resultados	44
4.1. Área de estudo	44
4.2. Recolha e processamento dos dados.....	45
4.2.1. Dados de campo	45
4.2.2. Dados LiDAR.....	46
4.3. Pré-processamento dos dados.....	47
4.3.1. Organização e tratamentos dos dados.....	47
4.3.2. Construção das variáveis preditoras	52
4.4. Resultados da modelação preditiva	57
4.5. Resultados da validação e avaliação de desempenho	61
4.6. Resultados da análise da importância das variáveis	67
5. CONCLUSÃO.....	72

6. REFERÊNCIAS BIBLIOGRÁFICAS	74
-------------------------------------	----

AGRADECIMENTOS

Ao Professor Doutor Joaquim Mamede Alonso e o Professor Doutor Cláudio Paredes, pela orientação, pela paciência e pela forma como me ajudaram a crescer enquanto estudante e investigador. Agradeço também aos meus colegas de trabalho, que tornaram este percurso mais leve, construtivo e cheio de aprendizagem partilhada.

À minha namorada, que mais do que me apoiar incondicionalmente, foi o meu porto seguro em todos os momentos deste caminho. Obrigado por me lembrares do meu valor quando a dúvida se instalava, por transformares dias cansativos em dias suportáveis e por conseguires dar-me força mesmo no silêncio. Obrigado por me mostrares, todos os dias, que há dez anos fiz a escolha mais bonita e mais acertada da minha vida. Agradeço-te também por toda a ajuda na revisão e formatação desta dissertação. Cada detalhe teu, cada minuto que dedicaste, cada preocupação que tiveste, fez com que este trabalho chegasse ao fim a tempo. Este trabalho traz muito de ti: do teu amor, da tua paciência, da tua forma de me cuidares sem nunca pedires nada em troca. Sem ti, este percurso teria sido muito mais difícil e certamente muito menos bonito.

Aos meus pais, o meu agradecimento é do tamanho de tudo o que fizeram por mim. Obrigado pelo amor incondicional, por acreditarem em mim mesmo quando eu ainda não sabia bem no que acreditar. Obrigado pelos sacrifícios silenciosos, pelos conselhos certos, pela força que me deram nos momentos difíceis e pelo orgulho que sempre fizeram questão de mostrar. Vocês são o alicerce de tudo o que sou e de tudo o que venho a conquistar. Nada disto existiria sem vocês.

Ao meu irmão, obrigado por trazeres sempre boa disposição aos meus dias. Pelas interrupções que às vezes me tiravam do sério, mas que na verdade eram a pausa perfeita. Pelas tuas perguntas, pelas tuas brincadeiras e por mostrares, à tua maneira, que estavas orgulhoso de mim. Mesmo sem perceberes bem o que eu estava a fazer, estiveste sempre por perto e isso vale muito mais do que imaginas.

Quero ainda agradecer ao Professor Doutor Juan Luis Rodríguez Somoza pela sua enorme disponibilidade e pela partilha generosa do seu conhecimento durante a recolha dos dados de campo. A sua colaboração foi essencial para tornar este trabalho possível.

RESUMO

As florestas assumem um papel determinante na regulação climática, no sequestro de carbono e no equilíbrio dos ecossistemas. A biomassa acima do solo um indicador essencial para compreender a sua estrutura e funcionamento. A sua estimativa em larga escala, permanece ainda um desafio sobretudo em povoamentos sujeitos a alterações estruturais significativas, como os de *Eucalyptus globulus* em terceira rotação.

Reconhecendo esta necessidade, este estudo explora o potencial dos dados LiDAR aerotransportados para caracterizar a estrutura tridimensional do coberto e traduzir essa informação em estimativas precisas e espacialmente explícitas de biomassa.

A integração das métricas LiDAR com dados dendrométricos recolhidos em campo permitiu capturar a variação estrutural do povoamento com elevado detalhe, recorrendo a modelos alométricos validados para quantificar a biomassa observada. A partir desta base, foram aplicadas diferentes abordagens de modelação preditiva capazes de explorar relações não lineares entre a estrutura vertical do coberto e a distribuição da biomassa.

Esta combinação revelou padrões estruturais de elevada relevância ecológica e contribuiu para identificar variáveis LiDAR particularmente informativas, relacionadas com a altura, densidade e rugosidade da copa. Os resultados obtidos demonstram a capacidade dos dados LiDAR, aliados a técnicas de modelação avançada, para representar de forma rigorosa a heterogeneidade estrutural e produtiva destes povoamentos, constituindo uma solução sólida e eficiente para apoiar práticas de gestão florestal orientadas para a sustentabilidade e para uma tomada de decisão mais informada.

Palavras-chave: *LiDAR aerotransportado; Biomassa acima do solo; Eucalyptus globulus; Estrutura florestal; Métricas de copa; Modelação preditiva; Machine learning; Inventário florestal; Terceira rotação; Gestão florestal sustentável.*

ABSTRACT

Forests play a fundamental role in climate regulation, carbon sequestration, and the stability of terrestrial ecosystems, with above-ground biomass serving as a key indicator of their structure and ecological functioning. Accurately estimating biomass across large areas, however, remains a challenge, particularly in forest stands that undergo substantial structural changes, such as *Eucalyptus globulus* plantations in their third rotation.

Addressing this need, the present study explores the potential of airborne LiDAR data to characterize the three-dimensional canopy structure and translate this information into precise, spatially explicit estimates of biomass.

By integrating LiDAR-derived structural metrics with dendrometric measurements collected in the field, it was possible to capture detailed variation in stand structure, using validated allometric models to quantify observed biomass. Building on this foundation, several predictive modelling approaches were applied to explore non-linear relationships between canopy vertical structure and biomass distribution.

This combination revealed ecologically meaningful structural patterns and contributed to the identification of LiDAR metrics—particularly those related to canopy height, density, and roughness—that provide strong predictive power. The results demonstrate the ability of airborne LiDAR, when coupled with advanced modelling techniques, to accurately represent the structural and productive heterogeneity of these forest stands. This highlights its effectiveness as a robust and efficient tool for supporting forest management practices that seek sustainability, improved spatial understanding, and more informed decision-making.

Keywords: *Airborne LiDAR; Above-ground biomass; Eucalyptus globulus; Forest structure; Canopy metrics; Predictive modelling; Machine learning; Forest inventory; Third rotation; Sustainable forest management.*

ÍNDICE DE QUADROS

Quadro 3.1. Métricas extraídas, adaptado de (Amoedo et al., 2024).	36
Quadro 3.2 - Modelos de regressão utilizados.	38
Quadro 4.1 - Volumes calculados por talhão de amostragem.....	48

ÍNDICE DE FIGURAS

Figura 3.1. Fluxograma metodológico.	26
Figura 3.2. Medição da distância entre o hipsómetro e o alvo para calibração.....	28
Figura 3.3. Processo de calibração.	28
Figura 3.4. Definição do centro de cada talhão de amostragem.....	28
Figura 3.5. Talhões de amostragem.	30
Figura 3.6. Instalação do sistema RTK.....	31
Figura 3.7. Dados LiDAR e respectivas quadriculas de predição de volumes.	34
Figura 4.1. Enquadramento da área de estudo.....	44
Figura 4.2. Correlação total entre o DAP e a Altura.....	46
Figura 4.3. Correlação entre DAP e Altura por talhão.	46
Figura 4.4. Nuvem de pontos LiDAR.	48
Figura 4.5. Classificação da nuvem de pontos.	49
Figura 4.6. Modelo Digital do Terreno.....	50
Figura 4.7. Normalização das alturas.	51
Figura 4.8. Alturas relativas.	51
Figura 4.9. Distribuição das alturas relativas ao longo da parcela.	52
Figura 4.10. Variabilidade das métricas extraídas a partir dos dados LiDAR.....	53
Figura 4.11. Correlação entre variáveis preditoras.	54
Figura 4.12. Correlação entre métricas LiDAR e volume de biomassa.	55
Figura 4.13. Análise dos principais componentes das métricas LiDAR.	56
Figura 4.14 - Matriz de correlação após análise de colinearidade.....	57
Figura 4.15. Distribuição dos volumes preditos por cada modelo de regressão.	58
Figura 4.16. Distribuição dos volumes preditos pelos diferentes modelos de regressão. ...	59
Figura 4.17. Distribuição espacial do volume predito segundo Random Forest, XGBoost, regressão linear múltipla, MLP e ensemble, valores expressos em m ³ /ha e m ³ /quadrícula.	60
Figura 4.18. Relação entre valores observados e preditos para cada modelo sob validação LOOCV.....	62
Figura 4.19. Distribuição dos resíduos dos modelos de predição do volume.	63
Figura 4.20. Comparação dos erros absolutos entre os diferentes modelos avaliados.	64

Figura 4.21. Comparação das métricas de desempenho (MAE, R^2 e RMSE) entre os modelos avaliados.	65
Figura 4.22. Erro de predição do volume (m^3/ha) por parcela.	66
Figura 4.23. Distribuição dos volumes preditos pelos modelos em toda a área de estudo..	67
Figura 4.24. Importância das métricas extraídas para o XGboost.	68
Figura 4.25. Importância das métricas extraídas para o Random Forest.....	69
Figura 4.26. Importância das métricas extraídas no Ensemble.	70

ÍNDICE DE EQUAÇÕES

Equação 3.1. Equação alométrica utilizada retirada de (Tomé et al., 2007).	32
Equação 3.2. Equação para conversão do volume por parcela em volume por hectare.	32
Equação 3.3. Equação do RMSE utilizada para quantificar o erro médio da predição.....	41
Equação 3.4. Equação do Mean Absolute Error (MAE) utilizada para quantificar o erro absoluto médio.....	41
Equação 3.5. Equação do Mean Bias Error (MBE), que quantifica o erro médio das predições.....	42
Equação 3.6. Equação do coeficiente de determinação.....	42

ACRÓNIMOS E ABREVIATURAS

Acrónimo/Abreviatura	Definição
DAP	Diâmetro à Altura do Peito
SAR	Sensores de Radar de Abertura Sintética
AGB	Biomassa acima do Solo
GEDI	Global Ecosystem Dynamics Investigation
GPS	Sistema de Posicionamento Global
IMU	Unidade de Medição Inercial
MDT	Modelo Digital do Terreno
MDS	Modelo Digital de Superfície
MDE	Modelo Digital de Elevação
SfM	Structure-from-Motion
SIG	Sistema de Informação Geográfica
RF	Random Forest
CHM	Canopy Height Models
TAs	Talhões de Amostragem
VANT	Veículo Aéreo Não Tripulado
RTK	Real Time Kinematic
LOOCV	Leave-One-Out
RLM	Regressão Linear Múltipla
XGB	Extreme Gradient Boosting
MLP	Perceptron Multicamadas
RMSE	Erro Quadrático Médio
MAE	Erro Absoluto Médio
MBE	Erro Médio
R ²	Coeficiente de Determinação
Hdf	Altura Dominante
LiDAR	Light Detection and Ranging
CDM	Distribuição acumulada

1. INTRODUÇÃO

As florestas constituem um dos pilares do equilíbrio ecológico global, funcionando como sistemas altamente complexos que interagem com os principais ciclos biogeoquímicos da Terra (Bugmann, 2014). A sua importância ultrapassa largamente a produção de bens tangíveis, refletindo-se no papel determinante que desempenham na regulação do clima, na proteção dos solos, na manutenção da biodiversidade e no suporte das dinâmicas hidrológicas (Artaxo et al., 2022). Estes ecossistemas participam ativamente no sequestro de carbono atmosférico, contribuindo para mitigar o aumento das concentrações de gases com efeito de estufa e, consequentemente, os efeitos das alterações climáticas (Anderegg et al., 2020). Além disso, influenciam o regime de precipitação, a evapotranspiração e a formação de microclimas locais e regionais, funcionando como verdadeiros reguladores térmicos e hídricos. É igualmente relevante considerar que as florestas atuam como reservatórios críticos de biodiversidade, albergando milhões de espécies de flora e fauna, muitas das quais dependem exclusivamente da complexidade estrutural e funcional proporcionada pelo coberto florestal e pelos seus múltiplos estratos vegetativos (Chazdon, 2008).

A diversidade estrutural das florestas, expressa através da sua organização vertical e horizontal, determina grande parte do seu comportamento ecológico, influenciando processos como a intercetação de luz, a dinâmica de nutrientes, a produtividade primária e a resiliência a distúrbios naturais ou antrópicos (Fichtner & Haerdtle, 2021). Florestas tropicais, temperadas ou mediterrânicas respondem de forma distinta às variações ambientais, apresentando padrões únicos de crescimento, mortalidade e regeneração (Gil-Tena et al., 2018). Nos sistemas mediterrânicos, como os encontrados em Portugal, fatores como a sazonalidade marcada, a elevada variabilidade interanual de precipitação e a recorrência de incêndios moldam profundamente a estrutura e o funcionamento dos ecossistemas florestais (Solomou et al., 2017). A crescente pressão das alterações climáticas, com secas mais intensas e prolongadas, temperaturas elevadas e eventos extremos mais frequentes, tem agravado a vulnerabilidade destes sistemas, alterando a sua capacidade produtiva e afetando a sua capacidade de prestação de serviços ecossistémicos essenciais (Doblas-Miranda et al., 2015).

A dimensão socioeconómica das florestas é igualmente relevante. Em muitos países, incluindo Portugal, os espaços florestais representam uma parte essencial da economia rural, sustentando atividades como a produção de madeira, cortiça, resina, biomassa

energética e produtos não lenhosos (Appiagyei et al., 2023). A multifuncionalidade das florestas — produção, regulação, conservação, recreio e proteção — torna imperativa uma gestão equilibrada e baseada em conhecimento científico rigoroso. No entanto, a realidade florestal portuguesa tem sido marcada por desafios significativos, como o abandono do espaço rural, a elevada fragmentação da propriedade, a tendência para povoamentos monoespecíficos e a elevada incidência de incêndios de grande escala (Fernandes, 2013). Estes fatores reforçam a necessidade de ferramentas modernas de monitorização que permitam caracterizar a estrutura florestal, avaliar o seu estado e apoiar decisões de gestão fundamentadas.

Nesse sentido, a caracterização estrutural das florestas assume um papel crucial. A estrutura vertical — que inclui desde a copa superior ao sub-bosque — influencia diretamente a distribuição da biomassa, a produtividade do ecossistema e a sua vulnerabilidade a distúrbios (Jayathunga et al., 2018). Por sua vez, a estrutura horizontal reflete padrões de continuidade ou descontinuidade do coberto, importantes para a análise de risco de incêndio, modelação ecológica e planeamento do território (Palahí et al., 2008). Em ecossistemas sujeitos a perturbações recorrentes, como os portugueses, compreender a estrutura florestal é condição essencial para avaliar a vitalidade dos povoamentos, prever a evolução futura dos sistemas e desenvolver estratégias de mitigação e adaptação que respondam aos desafios ambientais emergentes (Peñuelas et al., 2017).

A biomassa florestal constitui um indicador central na compreensão do funcionamento dos ecossistemas e do papel das florestas no ciclo global do carbono (Mitchard, 2018). A biomassa acima do solo, em particular, está diretamente relacionada com a capacidade de sequestro de carbono, com a produtividade primária líquida e com a resiliência dos sistemas florestais a fenómenos de perturbação como incêndios, tempestades, pragas ou secas extremas (Whitworth-Hulse et al., 2021). Assim, a quantificação rigorosa da biomassa é essencial para os inventários florestais, modelos ecológicos, políticas de mitigação das alterações climáticas e mecanismos de compensação de emissões (Díaz et al., 2019). No entanto, medir biomassa com precisão em larga escala constitui um desafio histórico, sobretudo devido à forte variabilidade estrutural das florestas, à diversidade de espécies e ao elevado custo associado às metodologias tradicionais. As equações alométricas e a amostragem dendrométrica, apesar da sua relevância científica e operacional, tendem a sub-representar a heterogeneidade espacial e a complexidade

vertical dos ecossistemas, podendo introduzir erros significativos nas estimativas (Burba et al., 2012).

A necessidade de métodos mais sólidos e espacialmente coerentes levou ao desenvolvimento e consolidação de técnicas baseadas em detecção remota, entre as quais o LiDAR se destaca pela sua capacidade única de captar a estrutura tridimensional da vegetação (Dubayah et al., 2020). Ao emitir pulsos laser e registrar múltiplos retornos, o LiDAR permite caracterizar detalhadamente a altura, densidade e distribuição dos elementos vegetais ao longo do perfil vertical do coberto florestal. As métricas derivadas dessa nuvem de pontos — incluindo percentis de altura, densidade por estrato, perfis volumétricos e índices de rugosidade — apresentam elevada correlação com variáveis estruturais chave, como volume lenhoso, área basal e biomassa (Lagouarde et al., 2010). Esta capacidade transforma o LiDAR numa ferramenta extremamente eficaz, especialmente em povoamentos densos ou em espécies de crescimento rápido, como *Eucalyptus globulus*, onde pequenas diferenças estruturais podem representar variações significativas na acumulação de biomassa.

A integração de dados LiDAR com técnicas modernas de modelação, incluindo algoritmos de machine learning e métodos de regressão multivariada, reforçou ainda mais o potencial da detecção remota para a estimativa da biomassa. Algoritmos como Random Forest, Gradient Boosting ou Support Vector Regression permitem explorar relações não lineares entre as métricas estruturais e a biomassa observada, reduzindo a margem de erro e aumentando a capacidade de generalização dos modelos (Belgiu & Drăgu, 2016). Esta abordagem orientada por dados é particularmente relevante em povoamentos de eucalipto em rotações sucessivas, onde a dinâmica do crescimento, a estrutura da copa e a produtividade podem apresentar variações significativas em função da idade, da densidade e das características do sítio (Lombard et al., 2022).

No caso específico do *Eucalyptus globulus* em terceira rotação a necessidade de caracterização rigorosa da biomassa torna-se ainda mais evidente. Nesta fase, os povoamentos podem apresentar sinais de esgotamento nutricional, alterações fisiológicas ou diminuição da produtividade, fatores que influenciam diretamente a distribuição espacial da biomassa (Bragg & Shelton, 2011). A utilização de LiDAR aerotransportado, complementado com inventários de campo, permite captar esta variação com elevada precisão, identificando padrões estruturais que seriam difíceis de observar através de métodos tradicionais (Shi et al., 2021). A aplicação de modelos preditivos baseados em

métricas LiDAR torna possível estimar a biomassa de forma contínua, espacialmente explícita e com robustez estatística, fornecendo uma base sólida para decisões de gestão florestal orientadas para a sustentabilidade e eficiência.

A metodologia adotada nesta dissertação integra dados LiDAR aerotransportados, inventário florestal de campo e técnicas de modelação preditiva avançadas. O processo metodológico inicia-se com a aquisição e pré-processamento dos dados LiDAR, incluindo filtragem, classificação, normalização e derivação de métricas estruturais relevantes, tais como percentis de altura, densidade de retornos por estrato, índice de rugosidade da copa e métricas volumétricas. Paralelamente, procedeu-se à recolha de dados dendrométricos em campo, nomeadamente diâmetro à altura do peito, altura total e densidade de pés, que serviram de base para a estimativa direta de biomassa através de modelos alométricos validados. A fase seguinte consistiu na integração dos dados estruturais e dendrométricos, seguida da implementação de diferentes abordagens de modelação, incluindo regressão linear múltipla, Random Forest e algoritmos de boosting. Todos os modelos serão avaliados com métricas robustas, como RMSE, MAE e R^2 , permitindo comparar o desempenho das diferentes metodologias. Finalmente, foram produzidos mapas temáticos de biomassa que traduzem espacialmente as estimativas resultantes dos modelos selecionados, permitindo uma análise espacial detalhada do povoamento.

A crescente necessidade de metodologias rigorosas e espacialmente abrangentes para caracterizar as florestas e estimar a biomassa acima do solo encontra resposta nas tecnologias LiDAR e nas técnicas modernas de modelação preditiva. A sua aplicabilidade em povoamentos de *Eucalyptus globulus*, especialmente em rotações avançadas, revela-se particularmente relevante num contexto de gestão florestal exigente e ecologicamente sensível. A presente dissertação contribui para o avanço metodológico neste domínio, propondo uma abordagem integrada que combina deteção remota, inventário de campo e modelação avançada para estimar biomassa de forma precisa, robusta e espacialmente explícita. Os resultados obtidos reforçam a importância da utilização de métricas estruturais na compreensão da dinâmica florestal e fornecem bases sólidas para decisões de gestão orientadas para a sustentabilidade e eficiência.

2. ENQUADRAMENTO TEÓRICO

2.1. A Floresta no Contexto Ambiental, Climático e Socioeconómico

2.1.1. Funções ecológicas e importância global das florestas

As florestas são ecossistemas indispensáveis ao equilíbrio do planeta. Cobrindo cerca de 30% da superfície terrestre, estas formações vegetais armazenam aproximadamente 80% da biomassa terrestre e desempenham funções ecológicas complexas, interligadas e vitais. Entre estas, destacam-se o sequestro de carbono, a regulação hidrológica, o suporte à biodiversidade e a regulação do clima global (Ollinger, 2003). Esta complexidade não decorre apenas da densidade da vegetação, mas sobretudo da interação entre os seus componentes bióticos e abióticos, que sustentam os principais ciclos biofísicos da Terra.

A função de sumidouro de carbono desempenhada pelas florestas é amplamente reconhecida. Estima-se que os ecossistemas florestais captem anualmente cerca de 2,4 petagramas de carbono, contribuindo significativamente para mitigar os efeitos das emissões antropogénicas de gases com efeito de estufa (Y. Pan et al., 2011). Este sequestro não ocorre apenas na biomassa acima do solo, mas também nos solos florestais, cuja capacidade de armazenamento de carbono é superior à de qualquer outro ecossistema terrestre (Kosanin et al., 2023). Este carbono é estabilizado através de complexas interações entre matéria orgânica, comunidades microbianas e propriedades físico-químicas do solo.

Paralelamente, as florestas influenciam acentuadamente os padrões climáticos. Através da evapotranspiração e da rugosidade da superfície, promovem a formação de nuvens e afetam diretamente o balanço energético da atmosfera (Bonan, 2008). As florestas tropicais, por exemplo, com copas densas e elevadas taxas de evapotranspiração, têm um efeito de arrefecimento local e regional. Já florestas boreais, cobertas por neve durante grande parte do ano, apresentam um baixo albedo, podendo provocar um ligeiro aquecimento regional devido à maior absorção de radiação solar (Rajasugunasekar et al., 2023).

No plano hidrológico, as florestas atuam como reguladoras naturais do ciclo da água. A copa reduz o impacto direto das chuvas, permitindo a infiltração da água no solo e diminuindo o escoamento superficial. O sub-bosque ajuda na retenção da humidade e reduz a erosão, desempenhando um papel essencial na recarga dos aquíferos e na

estabilidade das bacias hidrográficas (Singh et al., 2013). Estes serviços são particularmente críticos em regiões de elevada vulnerabilidade climática, como os trópicos e as zonas montanhosas.

As florestas são ainda os principais reservatórios de biodiversidade terrestre. Mais de 75% das espécies vegetais e animais conhecidas habitam ecossistemas florestais, em particular os ecossistemas tropicais, onde a diversidade funcional e filogenética é extremamente elevada (Fichtner & Härdtle, 2021). Esta diversidade confere resiliência ecológica e assegura a estabilidade funcional dos sistemas, mantendo processos como o ciclo de nutrientes, a produtividade primária e a resistência a pragas e doenças (Viera et al., 2016).

Por outro lado, as florestas fornecem um conjunto diversificado de serviços ecossistémicos. Os serviços de provisão incluem alimentos, madeira, fibras, óleos, plantas medicinais e água potável. Os serviços de regulação abrangem a purificação do ar, a regulação térmica, o controlo de inundações e a fixação de carbono. Aos serviços culturais e espirituais junta-se o suporte ecológico, com funções fundamentais como a formação de solo e a polinização (Reid et al., 2005).

A importância estratégica das florestas é também económica e social. Em todo o mundo, cerca de 1,6 mil milhões de pessoas dependem diretamente dos recursos florestais para a sua subsistência, nomeadamente através da agricultura familiar, da recolha de produtos não lenhosos e do ecoturismo. No entanto, os serviços que as florestas oferecem continuam largamente subvalorizados no mercado, o que contribui para a sua degradação e perda acelerada (Nguyen et al., 2020).

Apesar do seu papel incontornável, as florestas enfrentam ameaças severas. Desde a década de 1990, o planeta perdeu mais de 420 milhões de hectares de cobertura florestal, essencialmente devido à conversão para agricultura, exploração ilegal de madeira, expansão urbana e mineração (Jafarova & Hajiyeva, 2020). Estas perturbações afetam não só a biodiversidade, mas também a capacidade das florestas para armazenar carbono e regular o clima. Ao reconhecer o papel multifuncional das florestas, compreende-se que a sua proteção não é apenas uma medida conservacionista, mas uma exigência ecológica e climática. A integração da gestão florestal nos planos nacionais de adaptação e mitigação das alterações climáticas torna-se, assim, uma necessidade urgente.

2.1.2. Diversidade de biomas florestais e estrutura vertical

A diversidade estrutural das florestas é um dos principais fatores responsáveis pela sua complexidade ecológica e pela multiplicidade de funções que desempenham. A estrutura vertical – definida pela organização das plantas em diferentes estratos de altura – influencia a distribuição da luz, da humidade, dos nutrientes e da biodiversidade ao longo do perfil florestal. Essa organização tridimensional condiciona diretamente a produtividade primária, o sequestro de carbono, os padrões de evapotranspiração e a prestação de serviços ecossistêmicos (Anandita et al., 2024). À escala global, a estrutura das florestas varia consoante o bioma em que se inserem, sendo moldada por fatores como o clima, o solo, a altitude e a intervenção humana (Rajasugunasekar et al., 2023).

As florestas tropicais são os ecossistemas mais complexos e biodiversos do planeta. Caracterizam-se por copas densas, estratificação vertical marcada, abundância de espécies e elevadas taxas de produção de biomassa (Artaxo et al., 2022). Estas florestas, como as da Amazónia, do Congo e do Sudeste Asiático, apresentam normalmente três a cinco estratos vegetativos, com árvores emergentes que ultrapassam os 40 metros de altura, copas contínuas e sub-bosques densos. Esta complexidade permite uma elevada especialização ecológica, com espécies adaptadas a diferentes níveis de luz, humidade e competição. Por esta razão, são também das mais difíceis de monitorizar através de sensores remotos tradicionais, tornando-se fundamental o recurso a tecnologias como o LiDAR para captar a estrutura tridimensional da vegetação (Anandita et al., 2024).

Em contrapartida, as florestas boreais – localizadas nas latitudes altas do hemisfério norte – são dominadas por coníferas. Estas formações florestais são estruturalmente mais simples, com menor diversidade florística e menor densidade vertical (Bugmann, 2014). Apesar disso, têm uma importância global incontornável na regulação climática, uma vez que acumulam grandes quantidades de carbono no solo e na matéria orgânica em decomposição. As baixas temperaturas destas regiões retardam os processos de mineralização, contribuindo para a manutenção de reservas de carbono estáveis. No entanto, estas florestas encontram-se hoje entre as mais vulneráveis às alterações climáticas, devido ao aumento da frequência de incêndios, tempestades e ao degelo do permafrost (Bugmann, 2014; Rajasugunasekar et al., 2023).

As florestas temperadas, por sua vez, localizam-se sobretudo nas regiões de clima mediterrânico, atlântico e continental da Europa, América do Norte e Ásia Oriental. Apresentam uma estrutura intermédia em complexidade, com árvores caducifólias e

perenifólias, sazonalidade marcada e uma variedade de estratos vegetativos que conferem funcionalidade ecológica e resiliência (S. Liu et al., 2013). Este tipo de floresta é especialmente relevante em contextos de elevada pressão demográfica, como na Europa Ocidental, onde a multifuncionalidade florestal – proteção, produção e recreio – é frequentemente integrada na gestão territorial.

A estrutura florestal em Portugal insere-se maioritariamente no domínio das florestas temperadas e mediterrânicas, sendo marcada por uma elevada diversidade de formações. Os povoamentos de eucalipto (*Eucalyptus globulus*) e pinheiro-bravo (*Pinus pinaster*) dominam vastas áreas do território, seguidos por sobreirais e azinhais no sul, e por carvalhais autóctones em regiões montanhosas. Estas florestas apresentam uma estratificação geralmente menos complexa do que as tropicais, mas com significativa variabilidade em função do tipo de gestão, idade do povoamento e regime de perturbações (Raj et al., 2020). Por exemplo, os montados de sobreiro constituem sistemas agroflorestais de elevado valor ecológico e cultural, com uma estrutura aberta e sub-bosque rico em biodiversidade herbácea e arbustiva. Em contraste, os eucaliptais tendem a ser mais homogéneos e menos estruturados verticalmente, refletindo o seu carácter de exploração intensiva.

Em Portugal, a estrutura das florestas tem implicações diretas na prevenção de incêndios, na conservação da biodiversidade e na implementação de políticas climáticas. A ausência de estratificação vertical – como ocorre em povoamentos homogéneos e pouco geridos – favorece a continuidade do combustível e aumenta a vulnerabilidade ao fogo. Inversamente, uma estrutura florestal bem diferenciada, com sub-bosque limpo, copas descontínuas e mosaico paisagístico, contribui para mitigar a propagação dos incêndios e reforça a resiliência do ecossistema. Esta realidade reforça a importância da gestão ativa e da monitorização da estrutura florestal como ferramentas de ordenamento e mitigação de riscos (S. Liu et al., 2013).

Do ponto de vista técnico-científico, a medição e caracterização da estrutura vertical das florestas portuguesas são fundamentais para os inventários nacionais de carbono, os relatórios de biodiversidade e os modelos de risco. A integração de tecnologias como o LiDAR, em conjunto com imagens multiespectrais e dados de campo, tem permitido avanços notáveis na modelação tridimensional da vegetação (Anandita et al., 2024). Métricas como a altura média da copa, percentis de altura, densidade de retornos por

camada e rugosidade do coberto florestal são hoje essenciais para avaliar a biomassa, o volume de madeira e a vulnerabilidade estrutural das florestas nacionais.

Neste contexto, a estrutura vertical não deve ser vista apenas como um atributo físico da floresta, mas como uma dimensão crítica da sua funcionalidade ecológica, resiliência e valor económico (Praveen et al., 2025). A sua caracterização rigorosa, especialmente em territórios como Portugal, onde o risco de incêndio e a pressão sobre os recursos florestais são elevados, constitui uma prioridade tanto para a ciência florestal como para as políticas públicas de adaptação às alterações climáticas e promoção da sustentabilidade territorial.

2.1.3. Ameaças e dinâmicas espaciais contemporâneas dos espaços florestais

A floresta, enquanto ecossistema dinâmico e multifuncional, encontra-se atualmente sob forte pressão resultante de fatores de mudança global, cuja ação combinada ameaça a sua integridade ecológica, funcionalidade e capacidade de prestação de serviços ecossistémicos. A intensificação das alterações climáticas, o uso insustentável do solo e a crescente fragmentação do território constituem os principais vetores desta pressão. No contexto mediterrânico — e particularmente em países do sul da Europa como Portugal — os impactos são já tangíveis, traduzindo-se num aumento da frequência e intensidade de eventos extremos, como ondas de calor, secas prolongadas e incêndios de grande escala, que afetam diretamente a resiliência dos ecossistemas florestais (Peñuelas et al., 2017).

Estudos recentes indicam que os ecossistemas florestais do Mediterrâneo se encontram entre os mais vulneráveis às alterações climáticas a nível global. O aumento da aridez — devido à conjugação de temperaturas mais elevadas com uma redução significativa da precipitação — tem reduzido a produtividade primária líquida, afetado a regeneração natural e acelerado fenómenos de mortalidade arbórea em larga escala (Solomou et al., 2017). A alteração dos regimes climáticos compromete também a fenologia e a distribuição espacial de muitas espécies florestais, favorecendo a proliferação de pragas e doenças e diminuindo a capacidade de adaptação dos povoamentos florestais existentes (Matteucci et al., 2013).

Paralelamente, a fragmentação do coberto florestal emerge como um dos fatores mais disruptivos para a continuidade ecológica das paisagens. A expansão urbana, o abandono agrícola e a intensificação da ocupação turística conduzem à divisão das manchas florestais em pequenos núcleos isolados, comprometendo a conectividade ecológica, a

dispersão de espécies e a manutenção de processos ecológicos fundamentais (Gauquelin et al., 2018). Esta fragmentação contribui para a homogeneização da paisagem e para a perda de habitats críticos, sobretudo para espécies especialistas e de baixa mobilidade.

A análise de risco desenvolvida por Gil-Tena et al revelou que, até 2040, vastas áreas de florestas monoespecíficas no oeste mediterrânico, como as de *Pinus halepensis*, poderão perder a sua adequação climática. Estas projeções indicam que povoamentos dominados por espécies pouco tolerantes à seca estão entre os mais vulneráveis. As florestas mais antigas, apesar do seu valor ecológico, estão expostas a riscos acrescidos de incêndio e degradação, o que sublinha a necessidade urgente de estratégias de conservação proativas.

Outro fator de pressão crescente é o abandono da gestão florestal ativa. A cessação da pastorícia extensiva, da recolha de lenha e da agricultura de subsistência levou à acumulação de biomassa combustível e à proliferação de espécies invasoras, aumentando o risco de incêndios catastróficos e reduzindo a diversidade florística. Esta transição de paisagens humanizadas para sistemas abandonados, embora natural em aparência, representa um risco para a manutenção da biodiversidade e dos serviços ecossistémicos a longo prazo (Allen, 2019).

No sul da Europa, os incêndios florestais são uma das manifestações mais visíveis e destrutivas destas dinâmicas. Portugal, por exemplo, tem enfrentado uma frequência crescente de eventos extremos, como o de 2017, com perdas humanas, económicas e ecológicas sem precedentes. A conjugação de elevada carga combustível, condições meteorológicas severas e abandono do espaço rural constitui uma “tempestade perfeita” para a propagação rápida de incêndios. Adicionalmente, a estrutura social envelhecida das zonas rurais limita a capacidade de resposta comunitária e a eficácia dos programas de gestão do território (Palahí et al., 2008).

Por outro lado, o avanço das fronteiras urbanas e infraestruturais nas periferias metropolitanas contribui para a conversão de solos florestais em usos urbanos e industriais (Appiagyei et al., 2023). Esta pressão de artificialização é particularmente evidente nas zonas costeiras e periurbanas, onde a valorização económica do solo supera os benefícios ambientais dos ecossistemas existentes (Capotorti et al., 2011). A perda de áreas naturais e a impermeabilização do solo têm implicações diretas na capacidade de retenção hídrica, na regulação térmica urbana e na conectividade ecológica (Fusaro et al., 2015).

Neste contexto de múltiplas ameaças interligadas, as dinâmicas espaciais contemporâneas das florestas mediterrânicas exigem abordagens integradas de gestão e planejamento, baseadas em conhecimento científico, monitorização contínua e envolvimento multissetorial (Doblas-Miranda et al., 2015). A articulação entre políticas de conservação, ordenamento do território, agricultura e desenvolvimento rural é essencial para garantir a resiliência das paisagens florestais face às pressões ambientais e socioeconómicas emergentes (Palahí et al., 2008; Vizzarri et al., 2016).

2.2. Desafios da Monitorização Florestal em Grande Escala

2.2.1. Limitações dos métodos convencionais

Os métodos tradicionais de estimativa da biomassa florestal, baseados sobretudo em inventários de campo e em equações alométricas, continuam a ser amplamente utilizados. No entanto, estas abordagens revelam importantes limitações, tanto em termos de exatidão como de escalabilidade, especialmente quando aplicadas em florestas ecologicamente diversas ou em áreas extensas. A recolha de dados dendrométricos em campo, como o diâmetro à altura do peito (DAP) e a altura das árvores, requer equipas especializadas e apresenta elevados custos logísticos, o que restringe a sua aplicabilidade em regiões remotas ou de difícil acesso (Suwethaasri et al., 2025).

As equações alométricas, que transformam variáveis dendrométricas em estimativas de biomassa, foram desenvolvidas a partir de amostras destrutivas limitadas, o que levanta questões quanto à sua representatividade fora do intervalo de calibração original. Em muitos casos, equações genéricas são aplicadas de forma indiscriminada, ignorando diferenças locais de espécies, densidade da madeira, estrutura etária ou condições edafoclimáticas. Tal pode originar erros sistemáticos superiores a 30%, particularmente em florestas tropicais altamente biodiversas ou em sistemas agroflorestais complexos (Wakawa, 2016; F. Zhao et al., 2012)

A heterogeneidade espacial das florestas — em termos de estrutura vertical, composição de espécies e densidade — constitui um dos maiores obstáculos à extrapolação de dados de campo para escalas maiores. Parcelas amostrais localizadas dificilmente representam a variabilidade do território, especialmente em biomas complexos como a floresta amazónica ou florestas montanhosas. A dependência da medição de árvores de grande

porte, que concentram a maior parte da biomassa, acentua o risco de erros se estas forem subamostradas (Luo et al., 2023).

Além disso, os métodos convencionais apresentam dificuldades na captação da estrutura tridimensional das florestas. A estratificação vertical — que inclui sub-bosque, coberto intermédio e copas — é essencial para compreender a dinâmica do carbono e a produtividade, mas raramente é integrada nas estimativas obtidas por via das equações alométricas ou da amostragem linear tradicional (Jung & Crawford, 2010).

Do ponto de vista estatístico, a maioria das equações assume uma relação linear log-transformada entre as variáveis explicativas e a biomassa, o que pode ser inadequado em ecossistemas com resposta não linear, elevada diversidade e interferência antropogénica. Por outro lado, a ausência de padronização metodológica e terminológica dificulta a comparação entre estudos e compromete a harmonização de inventários a nível nacional e internacional (Somogyi et al., 2007).

Finalmente, os métodos destrutivos associados ao desenvolvimento de equações alométricas não são sustentáveis a longo prazo, tanto do ponto de vista ético como ecológico, especialmente em áreas protegidas ou com elevado valor de conservação. A pressão crescente para monitorizar as florestas de forma contínua, rápida e sem impacto físico reforça a inadequação de metodologias baseadas exclusivamente em campo (Negi et al., 1988).

Perante este conjunto de limitações, a necessidade de integração com tecnologias de deteção remota torna-se evidente. Ferramentas como o LiDAR, sensores de radar de abertura sintética (SAR) e dados hiperespetrais estão a transformar a monitorização florestal, ao permitirem medições tridimensionais de alta resolução, cobrindo grandes áreas com menor custo e maior representatividade amostral (Ghasemi et al., 2011; Sodhi, 2021)

2.2.2. Complexidade estrutural e heterogeneidade florestal

A complexidade estrutural das florestas constitui um dos principais desafios para a estimativa precisa de biomassa através de técnicas de deteção remota, como o LiDAR. Esta complexidade resulta da organização espacial tridimensional da vegetação — tanto na vertical, com diferentes estratos como o sub-bosque, a copa intermédia e a copa superior, como na horizontal, devido à variação na densidade, composição e arranjo das espécies. Esta heterogeneidade influencia diretamente a forma como a luz, os nutrientes

e a humidade são distribuídos no ecossistema, afetando tanto a produtividade primária como a biodiversidade (Atkins et al., 2018; Jayathunga et al., 2018; Z. Zhang et al., 2017).

A variação na estrutura da copa, por exemplo, tem implicações significativas na forma como os sensores LiDAR interpretam a vegetação. Enquanto os sensores óticos tendem a saturar em florestas densas, o LiDAR permite penetrar na vegetação e captar detalhes da estrutura interna da floresta, fornecendo informações sobre a altura, a densidade e a distribuição espacial dos elementos vegetais. No entanto, mesmo o LiDAR enfrenta limitações em florestas tropicais com estratos sobrepostos densos e copas fechadas, onde as múltiplas reflexões dos pulsos laser podem dificultar a segmentação precisa dos estratos (Drake et al., 2002; Z. Zhang et al., 2017).

A estrutura das florestas varia igualmente consoante o tipo de ecossistema. Em florestas mistas de coníferas e folhosas, por exemplo, a distribuição da altura, densidade da copa e área de superfície das árvores pode apresentar padrões complexos que exigem uma combinação de métricas estruturais para serem corretamente caracterizados. Técnicas baseadas apenas na altura média ou em percentis de altura podem não captar a totalidade da variação estrutural, sendo necessário recorrer a métricas como os perfis verticais da copa (*canopy volume profiles*) ou índices de entropia estrutural como o *Lorenz-Entropy Index*, que avaliam a complexidade vertical de forma mais robusta (Mashhadi et al., 2025; Z. Zhang et al., 2017).

A variabilidade horizontal é outro elemento crítico. Áreas de floresta sujeitas a perturbações naturais ou antrópicas, como desbaste seletivo, incêndios ou deslizamentos, apresentam descontinuidades espaciais que afetam as leituras do LiDAR. Modelos alométricos calibrados em parcelas homogêneas podem falhar quando aplicados a áreas degradadas ou em recuperação, subestimando ou sobrestimando a biomassa devido à ausência de estratos intermédios ou à presença de clareiras (Knapp et al., 2018).

A integração de métricas complexas — como a densidade da copa por estrato, a razão superfície/volume das árvores ou a variabilidade do índice de rugosidade da copa (*rumple index*) — tem-se revelado eficaz para superar esses obstáculos. Modelos multivariados ou baseados em *machine learning*, como Random Forest ou redes neuronais convolucionais 3D, conseguem explorar a relação não linear entre estas variáveis e as estimativas de biomassa, aumentando a robustez das previsões (Z. Zhang et al., 2017; Zhong et al., 2022).

A complexidade estrutural não é estática: florestas em diferentes fases de sucessão ecológica apresentam perfis estruturais distintos, com implicações diretas na estimativa de biomassa e na compreensão da resiliência ecológica. Florestas secundárias em crescimento registam um incremento rápido na altura média e na densidade da copa, enquanto florestas maduras tendem a estabilizar esses parâmetros, mas a apresentar maior variabilidade vertical e presença de copas emergentes (Kane et al., 2010).

A heterogeneidade estrutural das florestas — tanto vertical como horizontal — representa um desafio significativo para a modelação da biomassa, exigindo abordagens metodológicas mais sofisticadas, baseadas em múltiplas fontes de dados e numa compreensão detalhada das especificidades locais de cada bioma.

2.2.3. Necessidade de tecnologias espaciais avançadas

A estimativa da biomassa florestal em larga escala continua a ser um desafio central para a comunidade científica e para os organismos de gestão ambiental. As limitações dos métodos convencionais baseados em inventário de campo — tais como a baixa representatividade espacial, o elevado custo e a dificuldade de aplicação em regiões remotas — tornam evidente a urgência de tecnologias de deteção remota mais precisas, escaláveis e integradas. Esta necessidade é ainda mais crítica em contextos de monitorização climática, onde a variabilidade espacial e temporal da biomassa interfere diretamente nos modelos de balanço de carbono e nos sistemas de créditos de carbono (Wakawa, 2016).

Neste contexto, tecnologias como o LiDAR, o radar de abertura sintética (SAR) e os sensores óticos multiespetrais e hiperespetrais têm desempenhado um papel cada vez mais relevante. O LiDAR, por exemplo, destaca-se pela sua capacidade de captar dados tridimensionais da estrutura da vegetação, incluindo altura, densidade e volume da copa e do sub-bosque, o que o torna uma das ferramentas mais fiáveis para a estimativa da biomassa acima do solo (AGB). No entanto, apesar da sua elevada precisão, a cobertura limitada e os custos de aquisição ainda restringem a sua aplicação contínua e global (Z. Zhang et al., 2017).

Para superar estas limitações, a integração de múltiplas fontes de dados tem vindo a ganhar destaque. A fusão de dados provenientes de sensores LiDAR, radar (ex.: Sentinel-1, ALOS PALSAR) e óticos (Sentinel-2, Landsat-8) permite obter modelos híbridos mais robustos, capazes de integrar tanto a estrutura vertical da floresta como os atributos

espectrais que indicam características biofísicas e fisiológicas da vegetação. Esta abordagem melhora significativamente a precisão das estimativas de biomassa, especialmente em florestas tropicais densas ou boreais com saturação do sinal ótico (Sodhi, 2021).

A literatura tem também destacado a crescente aplicação de modelos de *machine learning* e *deep learning* na modelação da biomassa com base em dados remotos. Técnicas como Random Forest, Support Vector Machines, redes neurais profundas e modelos híbridos demonstraram grande potencial na exploração de relações não lineares entre variáveis estruturais e espectrais derivadas dos sensores. Estes algoritmos têm sido aplicados com sucesso em florestas tropicais, temperadas e boreais, evidenciando capacidade para superar os limites das equações alométricas convencionais (Ganendra et al., 2016).

Adicionalmente, sistemas orbitais como o GEDI (*Global Ecosystem Dynamics Investigation*) e o ICESat-2 têm revolucionado a capacidade de mapeamento global da AGB, disponibilizando dados LiDAR sistemáticos com cobertura quase planetária. Quando combinados com dados de sensores aerotransportados e parcelas de campo, permitem a calibração de modelos em múltiplas escalas, reforçando a coerência dos inventários florestais e das avaliações regionais de carbono (X. Liu et al., 2022; Neuenschwander et al., 2024; B. Zhang et al., 2025).

Apesar dos avanços, subsistem vários desafios técnicos. A questão da saturação dos dados óticos em áreas com biomassa elevada, a escassez de dados LiDAR em países em desenvolvimento e a falta de harmonização entre metodologias são frequentemente apontadas como obstáculos à generalização das tecnologias. Além disso, a variabilidade nas densidades de pontos e nos parâmetros dos sensores pode comprometer a interoperabilidade entre plataformas, tornando essencial o desenvolvimento de padrões internacionais de calibração e validação (Sun et al., 2022; Zhu et al., 2023).

Estudos recentes têm também sugerido o uso de indicadores estruturais derivados de *wavelet transform* ou da entropia da copa como alternativas para contornar problemas de saturação e melhorar a representatividade da heterogeneidade estrutural nas estimativas (A. Liu et al., 2021; Yu et al., 2024).

A adoção de tecnologias espaciais avançadas, associada a algoritmos computacionais de última geração e a estratégias de fusão de dados, representa uma das vias mais promissoras para alcançar estimativas de biomassa fiáveis, replicáveis e economicamente

sustentáveis, fundamentais para a gestão florestal e para o cumprimento dos compromissos climáticos internacionais.

2.3. Princípios Fundamentais e evolução/desenvolvimento da Tecnologia Lidar.

A tecnologia LiDAR (Light Detection and Ranging), tem-se afirmado como uma das mais sofisticadas ferramentas de detecção remota ativa, destacando-se pela sua capacidade de adquirir dados espaciais tridimensionais com elevada precisão. O seu funcionamento assenta na emissão de feixes de luz laser em direção a superfícies e objetos, medindo o tempo que os impulsos de luz demoram a regressar ao sensor após a sua reflexão. Com base nesse intervalo temporal, e conhecendo-se a velocidade da luz, calcula-se a distância entre o sensor e o alvo, recorrendo ao princípio de tempo de voo. Ao repetir esse processo de forma intensiva e contínua, e conjugando os dados com sistemas de localização e orientação, é possível gerar uma nuvem de pontos tridimensional que descreve detalhadamente o relevo e os elementos presentes na superfície terrestre (Vosselman & Maas, 2010).

Esta tecnologia assenta numa composição técnica que integra diversos componentes essenciais ao seu desempenho. O emissor laser, responsável pela geração dos impulsos, atua em conjunto com um *scanner* que direciona o feixe segundo padrões predefinidos. Complementam-se o sistema de posicionamento global (GPS), que assegura a georreferenciação dos dados no momento da aquisição, e a unidade de medição inercial (IMU), que regista a orientação e os movimentos da plataforma durante o voo ou deslocação. A sinergia entre estes elementos garante a coerência geométrica dos dados recolhidos, permitindo a sua utilização em contextos que exigem elevada fiabilidade espacial.

A diversidade de aplicações impulsionou também a evolução das plataformas de aquisição. Os sistemas LiDAR são hoje utilizados em modalidades distintas, adaptadas a diferentes finalidades. O LiDAR aéreo, por exemplo, instalado em aviões ou drones, permite cobrir vastas extensões com elevada densidade de pontos, sendo particularmente útil na produção de cartografia topográfica e no inventário florestal. Em contrapartida, o LiDAR terrestre, operado a partir de tripés ou estruturas fixas, é mais adequado ao levantamento detalhado de elementos arquitetónicos ou de pequenas áreas. Já o LiDAR móvel, montado em veículos, permite recolher dados ao longo de corredores viários ou

cursos de água, sendo frequentemente utilizado na inspeção de infraestruturas lineares (Baltsavias, 1999; Glennie et al., 2013).

Combinando a flexibilidade das suas plataformas com a elevada resolução dos dados obtidos, o LiDAR distingue-se por características que o tornam único entre os sensores de teledeteção. A capacidade de funcionar independentemente da iluminação natural, a sua precisão métrica e a habilidade para penetrar coberturas vegetais densas são fatores que têm alargado o seu uso em diferentes setores. Os dados tridimensionais resultantes, quando processados, possibilitam a geração de modelos digitais de terreno (MDT), Glennie et al., 2013de superfície (MDS) e de elevação (MDE), bem como análises estruturais detalhadas, que alimentam estudos ambientais, urbanos e infraestruturais. No entanto, este potencial é também acompanhado por desafios técnicos e logísticos, como o elevado custo operacional, a sensibilidade a superfícies muito refletoras e a exigência de competências avançadas no processamento dos dados (Barber et al., 2008).

O percurso histórico do LiDAR reflete a constante inovação tecnológica desde as primeiras aplicações nos anos 1960, inicialmente orientadas para fins militares e atmosféricos. A viragem para usos civis ganhou expressão nas décadas seguintes, sustentada pela evolução dos sistemas GNSS e IMU, que permitiram a georreferenciação precisa e em tempo real dos dados. Esta transformação tecnológica contribuiu para que o LiDAR deixasse de ser uma ferramenta especializada e restrita a entidades governamentais, passando gradualmente a integrar projetos científicos, ambientais e de engenharia à escala global. O desenvolvimento de sensores mais compactos e acessíveis, com maior frequência de pulsos e capacidade de deteção de retornos múltiplos, impulsionou a disseminação do seu uso, democratizando o acesso a dados espaciais de alta qualidade (Lim et al., 2003; Vosselman & Maas, 2010).

O alargamento das aplicações do LiDAR foi paralelo à multiplicação dos contextos em que a informação tridimensional passou a ser crítica. Desde a análise estrutural de formações geológicas à reconstrução de sítios arqueológicos encobertos pela vegetação, ou ainda à deteção de falhas em redes de abastecimento urbano, a tecnologia revelou-se uma ferramenta transversal a várias disciplinas. Nos estudos ambientais, destaca-se a sua aplicabilidade na caracterização vertical da vegetação e na quantificação da biomassa, dado que os sensores modernos conseguem detetar múltiplos retornos por pulso, captando a estrutura em diferentes estratos da copa florestal e do sub-bosque.

Com o amadurecimento da tecnologia, a tendência atual aponta para uma integração cada vez mais frequente entre o LiDAR e outras fontes de dados geoespaciais. A utilização conjunta com imagens multiespectrais provenientes de satélites como o Sentinel-2 ou o Landsat-8 tem mostrado particular eficácia em tarefas de classificação do uso e cobertura do solo, onde a combinação entre estrutura e composição espectral permite distinções mais precisas entre classes semelhantes. Em paralelo, métodos fotogramétricos como o *Structure-from-Motion* (SfM) permitem gerar modelos tridimensionais detalhados a partir de imagens aéreas ou terrestres, cuja precisão pode ser aumentada através da calibração com dados LiDAR (James & Robson, 2012; Westoby et al., 2012).

A integração estende-se também a sensores hiperespectrais e térmicos, cujos dados, ao serem fundidos com as nuvens de pontos estruturais, permitem uma leitura mais completa dos sistemas observados. Esta combinação tem demonstrado utilidade em aplicações como a detecção de stress hídrico em culturas agrícolas, a identificação de doenças florestais, a análise da composição de materiais urbanos ou o mapeamento de propriedades biofísicas de ecossistemas em mudança (Asner et al., 2008; Dalponte & Coomes, 2013). Com esta abordagem multissensorial, a teledeteção adquire uma nova dimensão, na qual a complementaridade entre diferentes tecnologias reforça a capacidade de representação, análise e interpretação do território, promovendo maior rigor e eficácia na produção de conhecimento espacial (Anderson et al., 2018; Wulder et al., 2012).

2.4. Aplicações, Processamento e Produtos derivados de dados LiDAR

À medida que os sensores LiDAR se tornam mais avançados e acessíveis, a sua aplicação em contextos ambientais, urbanos e territoriais tem-se expandido substancialmente. A capacidade de gerar nuvens de pontos tridimensionais com elevada resolução e precisão proporciona uma base robusta para a extração de informações detalhadas sobre a morfologia do terreno, a estrutura da vegetação e as características das infraestruturas construídas. A análise destas nuvens de pontos depende de um processamento rigoroso que, para além da classificação básica, permite derivar modelos digitais e métricas especializadas adaptadas às exigências de diferentes domínios de aplicação. Esta transformação de dados brutos em produtos úteis envolve rotinas de filtragem, interpolação, normalização e análise morfométrica, fundamentais para garantir a fiabilidade e relevância dos resultados obtidos (Li & Wu, 2009; Montealegre et al., 2014; X. Zhang et al., 2013; X. Zhao et al., 2018).

No campo da cartografia topográfica, os modelos digitais de terreno (MDT) e os modelos digitais de superfície (MDS) são algumas das aplicações mais clássicas dos dados LiDAR. A produção destes modelos permite representar com grande qualidade as variações altimétricas e identificar feições do relevo mesmo sob densa cobertura vegetal. Esta capacidade tem-se revelado particularmente eficaz em contextos montanhosos, costeiros e florestais, onde o acesso físico pode ser limitado e os métodos tradicionais de levantamento são ineficazes. A aplicação do LiDAR em ambientes costeiros, por exemplo, tem permitido o mapeamento geomorfológico de ilhas-barreira e zonas de dunas, classificando feições dinâmicas sujeitas a erosão e eventos extremos, como tempestades tropicais ou intervenções antrópicas, como o enchimento artificial de praias (Telbisz et al., 2016).

A urbanização crescente e a complexidade das estruturas construídas tornaram o LiDAR uma ferramenta essencial para a modelação e monitorização de espaços urbanos. A geração automática de modelos tridimensionais de edifícios a partir de nuvens de pontos tem sido utilizada em aplicações como simulações de visibilidade, planeamento de redes de telecomunicações, controlo de construções ilegais e mapeamento cadastral tridimensional. Abordagens baseadas na classificação hierárquica dos pontos e em regras geométricas têm demonstrado eficiência na extração de modelos urbanos complexos a partir de dados brutos (Garcia-Sopo et al., 2015; Yastikli & Cetin, 2017). Em contextos mais dinâmicos, como o das infraestruturas viárias, a utilização de LiDAR móvel permite identificar deformações, subsidências e alterações ao longo de eixos rodoviários e ferroviários, contribuindo para estratégias de manutenção preventiva e avaliação estrutural contínua (Molua & Ataman, 2024).

No domínio ambiental e florestal, o LiDAR tem sido amplamente explorado para a caracterização estrutural da vegetação, permitindo estimar métricas como altura média, densidade de copas, volume de biomassa e estratificação vertical da copa. Estas métricas são essenciais para modelações ecológicas, inventário florestal e monitorização de habitats, sendo particularmente úteis em florestas urbanas, onde a diversidade de espécies, formas e idades impõe desafios adicionais. A utilização de dados de inventário arbóreo como ponto de partida para a deteção automática de copas tem mostrado resultados promissores em termos de delimitação individual e extração de atributos biofísicos relevantes (Plowright et al., 2015). Esta mesma abordagem tem sido aplicada à estimativa da biomassa acima do solo em florestas tropicais e temperadas, onde a modelação

estatística baseada em atributos derivados do LiDAR tem permitido uma estimativa espacialmente explícita e precisa da produtividade dos ecossistemas (Tamiminia et al., 2022).

O processamento de grandes volumes de dados LiDAR tem exigido o desenvolvimento de infraestruturas computacionais adequadas à gestão de séries temporais e coberturas extensas. Sistemas de gestão específicos, como os baseados em bases de dados relacionais espaciais, têm sido integrados em fluxos de trabalho com Sistemas de Informação Geográfica (SIG), permitindo o acesso simultâneo e a análise colaborativa de dados em ambientes distribuídos. Esta arquitetura é particularmente relevante em projetos de longo prazo que visam a análise de mudanças morfológicas ou estruturais em ambientes de alta montanha ou em zonas de risco, onde múltiplas campanhas de voo produzem dados com diferentes características temporais e espectrais (Montesano et al., 2013).

A complementaridade do LiDAR com outras tecnologias de teledeteção tem sido cada vez mais explorada para aumentar a robustez das análises e superar limitações específicas de cada sensor. A fusão com dados espectrais provenientes de sensores óticos ou hiperespetrais possibilita integrar a componente estrutural com a componente composicional do território, permitindo a diferenciação de classes de uso e cobertura do solo com maior acuidade. Esta sinergia tem mostrado particular utilidade em estudos de uso agrícola, avaliação de stress hídrico, análise de corredores ecológicos e definição de classes funcionais do território. A partir desta integração, os modelos digitais passam a refletir não apenas a forma e elevação, mas também propriedades biofísicas, térmicas e espectrais dos elementos analisados (Asner et al., 2008; Dalponte & Coomes, 2013; Luo et al., 2017; Tusa et al., 2020).

Com a expansão contínua da escala e da resolução dos dados adquiridos, os desafios associados ao armazenamento, normalização, interoperabilidade e reprodutibilidade dos processos tornam-se cada vez mais relevantes. A padronização dos formatos, a automatização dos fluxos de processamento e o desenvolvimento de algoritmos escaláveis são componentes fundamentais para garantir que os dados LiDAR possam ser utilizados de forma eficaz e consistente por instituições públicas, privadas e académicas. Neste contexto, a aplicação de técnicas de *machine learning* para classificação automatizada, deteção de padrões e previsão de tendências espaciais surge como um caminho promissor para transformar os dados tridimensionais em conhecimento aplicável ao ordenamento, planeamento e conservação dos territórios.

2.5. A Importância da Biomassa Florestal e o Uso de Dados LiDAR na sua Estimativa

2.5.1. A Importância da Biomassa Florestal no Contexto Ambiental e da Gestão Territorial

As florestas representam cerca de 30% da superfície terrestre, cobrindo aproximadamente 4,03 mil milhões de hectares em todo o planeta (Beer et al., 2010). Estas áreas são responsáveis por 75% da produção primária bruta terrestre e concentram cerca de 80% da biomassa vegetal total da Terra (Kindermann et al., 2008). Tal abundância traduz-se num papel ecossistémico inestimável, já que estas zonas arborizadas não só capturam carbono atmosférico, como também o armazenam em grandes quantidades sob forma de biomassa viva e matéria orgânica nos solos (S. Pan et al., 2019).

Além do seu contributo direto para o sequestro de carbono, as florestas influenciam o balanço energético do planeta. Elas atuam sobre o ciclo hidrológico através da interceção de chuva, infiltração e evapotranspiração, além de alterarem as trocas radiativas na superfície terrestre. Estima-se que cerca de 50% da precipitação em regiões florestais tropicais resulte diretamente da reciclagem da humidade via evapotranspiração. A sua influência estende-se ao transporte atmosférico de vapor de água e à modulação da temperatura local, regional e até continental.

Ao mesmo tempo, estudos têm demonstrado que a perturbação dos sistemas florestais compromete estes equilíbrios. A desflorestação de grandes extensões na Amazónia e em regiões do Sudeste Asiático tem alterado padrões de precipitação, aumentado eventos extremos e diminuído a resiliência climática regional. Esta sensibilidade realça a urgência de ações de conservação, restauração e monitorização contínua das florestas, com base em dados espaciais confiáveis e atualizados. O seu funcionamento como sumidouro de carbono é bem estabelecido, com estimativas apontando para uma absorção líquida anual de aproximadamente 2,4 petagramas de carbono (Y. Pan et al., 2013).

Além da capacidade de sequestro de carbono, as florestas regulam o clima por meio de mecanismos biogeoquímicos e biogeofísicos. Florestas tropicais, por exemplo, possuem elevada biomassa e taxas de evapotranspiração intensas, promovendo um efeito de arrefecimento regional e contribuindo para a formação de nuvens e precipitação local. Por outro lado, florestas boreais, com sua cobertura sazonal de neve e baixo albedo, tendem a intensificar o aquecimento local durante o inverno (Bonan, 2008b). Esta dualidade

evidencia a complexidade dos efeitos climáticos florestais e reforça a necessidade de abordagens diferenciadas de gestão florestal em cada bioma.

A distribuição da biomassa florestal não é homogênea. Ela reflete a interação entre fatores climáticos, edáficos, topográficos e antropogênicos. Compreender esta variabilidade espacial permite otimizar práticas de operação, apoiar políticas de restauração ecológica e planejar intervenções mais eficazes em áreas degradadas. A restauração florestal contemporânea vai além da simples replantação: implica restaurar funções ecossistêmicas como retenção hídrica, proteção contra erosão, manutenção da biodiversidade e suporte à resiliência climática (Chazdon, 2008).

A biomassa, enquanto recurso renovável, fornece matéria-prima para múltiplos setores, incluindo alimentação, energia, bioindústria e construção civil. A produtividade deste recurso depende fortemente das práticas de uso do solo e das condições ecológicas. Assim, a sua quantificação rigorosa torna-se um pilar para o planejamento sustentável e para o aproveitamento racional dos recursos naturais (Weisz et al., 2007).

Além da produção de bens tangíveis, a biomassa florestal sustenta serviços ecossistêmicos essenciais. Estes incluem serviços de provisão (alimentos, fibras, água, medicamentos), regulação (qualidade da água, sequestro de carbono, mitigação de desastres), culturais (identidade, espiritualidade, turismo) e de suporte (formação de solo, polinização, ciclos de nutrientes) (Reid et al., 2005). O colapso de qualquer destes serviços compromete diretamente o bem-estar humano e a estabilidade ecológica.

A definição clara do que constitui uma floresta é também crítica. A ausência de uma distinção clara entre desflorestação, degradação e conversão de uso do solo pode levar a interpretações errôneas nos inventários e comprometer políticas públicas de conservação e mitigação de emissões. Neste sentido, autores como (Putz & Redford, 2010) argumentam pela padronização conceitual que permita comparabilidade entre estudos e coerência nos relatórios de emissões.

2.5.2. Uso de Dados LiDAR na Estimativa de Volume e Biomassa Florestal

A biomassa florestal representa a quantidade total de matéria orgânica presente nos ecossistemas vegetais, sendo particularmente relevante pelo seu papel nos ciclos do carbono e como indicador da saúde ecológica das florestas. A medição da biomassa acima do solo (*Above Ground Biomass* – AGB) é crucial, tanto para a quantificação dos stocks de carbono como para a definição de estratégias de mitigação das alterações climáticas.

A utilização de tecnologias de detecção remota, em especial o LiDAR, tem permitido avanços significativos na estimativa da biomassa em larga escala, superando limitações das abordagens baseadas exclusivamente em inventários florestais convencionais (Laurin & et al., 2014).

Os métodos de estimativa da biomassa variam em sofisticação e exigência de dados. As abordagens empíricas, historicamente baseadas em dados de campo e regressões simples, continuam a ser utilizadas como referência para a calibração de modelos. Os modelos alométricos, que relacionam variáveis como o diâmetro à altura do peito (DAP), a altura total e a densidade da madeira ao volume ou biomassa da árvore, são amplamente aplicados. No entanto, estes modelos apresentam limitações quando utilizados em áreas extensas ou com elevada heterogeneidade estrutural. Por isso, métodos estatísticos multivariados e técnicas de *machine learning*, como regressões parciais por mínimos quadrados (PLSR), Random Forest e redes neurais profundas, têm ganho relevância pela sua capacidade de incorporar múltiplas métricas derivadas de dados LiDAR e de lidar com não linearidades complexas (Y. Pan & et al., 2020).

A principal mais-valia do LiDAR na estimativa da biomassa reside na sua capacidade de captar a estrutura tridimensional das copas, da vegetação intermédia e do sub-bosque. Métricas como altura média e máxima, percentis de altura, densidade de pontos por estrato vertical e modelos de altura da copa (*Canopy Height Models* – CHM) têm-se revelado fortemente correlacionadas com variáveis dendrométricas tradicionalmente obtidas em campo. Em florestas temperadas, por exemplo, (Takagi & et al., 2015) demonstraram que a altura média da copa obtida por LiDAR apresenta uma correlação r^2 superior a 0,80 com o volume e o carbono acima do solo (Takagi & et al., 2015). Em florestas tropicais da Costa Rica, (Clark & et al., 2011) obtiveram modelos com R^2 até 0,90 utilizando métricas simples como a altura média e máxima derivadas de LiDAR discreto (Clark & et al., 2011).

Estudos realizados em diferentes biomas têm reafirmado o potencial do LiDAR como ferramenta de modelação da biomassa. Na floresta tropical africana, a combinação de dados LiDAR com sensores hiperespetrais aumentou significativamente a acuidade dos modelos em comparação com o uso isolado de um único sensor (Laurin & et al., 2014). Na floresta boreal sueca, Askne e Santoro demonstraram ser possível estimar a biomassa utilizando modelos interferométricos sem dados de calibração de campo, com erros relativos inferiores a 20% (Askne & Santoro, 2015).

A integração de dados LiDAR com informação auxiliar, como inventários florestais, imagens de satélite multiespectrais (ex.: Landsat, Sentinel-2) e Sistemas de Informação Geográfica (SIG), permite desenvolver modelos híbridos mais robustos. Estudos na Galiza, Espanha, combinaram dados LiDAR públicos, índices de vegetação e dados do inventário nacional para estimar variáveis de biomassa com R^2 superiores a 0,80 (Yastikli & Cetin, 2017). Técnicas como a voxelização dos dados LiDAR, que permite estimar o volume por unidades volumétricas cúbicas, e a fusão com índices hiperespectrais sensíveis à clorofila, lignina ou teor de água, têm reforçado ainda mais a fiabilidade dos modelos para florestas estruturalmente complexas (Peñuelas et al., 2017; Stovall & Shugart, 2014; Zhou & et al., 2022).

Modelos baseados em *deep learning* têm sido progressivamente incorporados na estimativa de biomassa, especialmente através de redes convolucionais 3D que analisam diretamente a nuvem de pontos sem necessidade de conversão prévia para imagens ou mapas rasterizados. Estes modelos têm-se mostrado promissores na modelação da biomassa em florestas tropicais complexas, onde as estruturas verticais múltiplas e a diversidade florística impõem desafios aos métodos convencionais. A utilização de *frameworks* como o PointNet e as suas variantes tem permitido representar diretamente feições tridimensionais e gerar classificações de elevada precisão.

A modelação multiescalar baseada em LiDAR tem ganho destaque, nomeadamente através da combinação de sensores terrestres (TLS), aerotransportados (ALS) e orbitais (GEDI, ICESat-2). Este tipo de abordagem permite calibrar as medições obtidas por satélite com alta resolução espacial, conferindo maior fiabilidade às estimativas em larga escala. A escada de calibração, que parte de parcelas de campo e culmina em modelos continentais, é vista como uma solução viável para aplicações globais de monitorização florestal e de balanço de carbono (Ballhorn & et al., 2012).

Por outro lado, os desafios metodológicos mantêm-se relevantes. As relações alométricas ainda requerem adaptação local, e a heterogeneidade da vegetação, a topografia e a variabilidade na densidade dos pontos LiDAR geram incertezas que devem ser minimizadas através de processos rigorosos de calibração e validação. Existe também a necessidade de harmonização internacional dos métodos e métricas utilizados, com vista à comparabilidade entre estudos e regiões. Além disso, a sustentabilidade computacional, a acessibilidade a dados de alta resolução e a interoperabilidade entre plataformas

continuam a ser barreiras à massificação do uso do LiDAR em inventários florestais nacionais (García & et al., 2017).

As perspectivas futuras apontam para um aumento da resolução temporal dos dados e para a utilização de sensores combinados com inteligência artificial em fluxos automatizados. Avanços como a incorporação de sensores LiDAR de múltiplos comprimentos de onda e a fusão com dados térmicos e SAR prometem novas possibilidades de inferência biofísica. A contínua expansão da capacidade computacional e da disponibilidade de dados abertos tenderá a consolidar o LiDAR como um componente-chave em programas de monitorização ambiental e na avaliação da eficácia de políticas climáticas baseadas no carbono florestal.

3. METODOLOGIA

As etapas do processo de modelação, desde a aquisição dos dados até à predição final nas quadrículas, incluem os principais blocos operacionais — dados de entrada, extração de métricas, preparação das variáveis e modelação preditiva — bem como as respetivas relações (Figura 3.1).




Figura 3.1. Fluxograma metodológico.

3.1. Recolha e processamento dos dados

3.1.1. Dados de campo

Os talhões de amostragem (TAs) utilizados neste estudo foram estabelecidos numa área de produção pertencente à The Navigator Company, inserida num povoamento de *Eucalyptus globulus* em terceira rotação. O objetivo principal da instalação destes talhões foi obter dados dendrométricos de referência para a calibração e validação de modelos de predição baseados em métricas estruturais extraídas a partir de dados LiDAR.

Antes de iniciar a recolha dos dados dendrométricos, foi necessário calibrar o hipsómetro, para tal mediu-se com uma fita métrica uma distância de 10 metros entre o equipamento e o alvo (Figura 3.2), iniciando-se de seguida o processo de calibração, de modo a garantir que as medições realizadas fossem confiáveis (Figura 3.3). Após a calibração, foram demarcados cinco talhões circulares, cada um com raio de 10 m, distribuídos de forma a representar a variabilidade estrutural existente na área. Embora a área apresente uma elevada homogeneidade em termos de densidade e desenvolvimento, a definição de múltiplos talhões garantiu a representatividade estatística necessária para suportar os processos de calibração e avaliação dos modelos.

A definição dos centros dos talhões (Figura 3.4 e Figura 3.5) foi efetuada em campo utilizando um recetor STONEX S850A, conectado com a ReNEP para obtenção do posicionamento em tempo real, assegurando precisões abaixo dos 5 cm, garantido assim a melhor correspondência espacial possível entre os talhões e a nuvem de pontos. Esta precisão permitiu evitar discrepâncias entre o inventário e a extração das métricas LiDAR, uma vez que pequenas imprecisões no posicionamento podem originar diferenças significativas na composição da parcela intercetada pela nuvem de pontos.



Figura 3.2. Medição da distância entre o hipsómetro e o alvo para calibração.



Figura 3.3. Processo de calibração.



Figura 3.4. Definição do centro de cada talhão de amostragem.

Após a consolidação do centro de cada talhão, todos os indivíduos incluídos no círculo de 10 m foram marcados e identificados, permitindo isolar claramente as árvores inventariadas da vegetação envolvente. Esta marcação permitiu evitar duplicações, omissões ou registos indevidos fora do círculo de amostragem durante a recolha dos dados, especialmente em áreas de maior densidade. Em cada árvore mediu-se o diâmetro à altura do peito (DAP), recorrendo a uma suta. Em indivíduos com irregularidades evidentes na secção transversal, o DAP foi medido em direções perpendiculares, sendo utilizado o valor médio. Árvores com DAP inferior a 5 cm foram excluídas do inventário por não contribuírem significativamente para o volume lenhoso e por aumentarem desnecessariamente a variabilidade nos cálculos. A altura total foi obtida com recurso a um hipsómetro *Haglöf Vertex 5*, garantindo leituras consistentes mesmo em condições de visibilidade parcial da copa.

Os dados recolhidos em campo foram posteriormente organizados em folha de cálculo, onde se efetuou um controlo de qualidade preliminar, incluindo a verificação de valores extremos, medições incoerentes e correspondências entre DAP e altura. A relação entre estas duas variáveis não evidenciou um padrão linear, como seria expectável num povoamento homogéneo. Árvores com alturas moderadas apresentaram, em alguns casos, DAPs superiores aos de indivíduos mais altos, refletindo condições de crescimento desiguais típicas de povoamentos em rotações avançadas, onde a competição intraespecífica influencia o balanço entre crescimento em altura e incremento diamétrico.

O volume individual de cada árvore foi estimado utilizando a equação alométrica recomendada para *Eucalyptus globulus* em Portugal (Tomé et al., 2007), permitindo quantificar o volume dos talhões e expressá-lo posteriormente em m³/ha. Esta etapa foi fundamental para unificar a informação obtida no inventário e a estrutura tridimensional descrita pela nuvem LiDAR, constituindo o elo entre os dados de campo e o processo de modelação preditiva.




Figura 3.5. Talhões de amostragem.

3.1.2. Dados LiDAR

Os dados LiDAR foram adquiridos com recurso a um veículo aéreo não tripulado (VANT) DJI Matrice 300 RTK (DJI, 2021). O VANT foi equipado com o sensor DJI Zenmuse L1, que combina tecnologia LiDAR de varrimento contínuo, uma unidade inercial GNSS/IMU integrada e uma câmara RGB, permitindo georreferenciação direta e assegurando a sincronização entre posição, orientação e emissão dos pulsos laser.

O levantamento foi executado segundo um plano de voo oblíquo, adequado para contextos florestais, uma vez que reduz zonas de sombra associadas à forma e orientação das copas e aumenta a redundância angular dos retornos. Foram realizados cinco voos independentes, cada um com direções de varrimento e ângulos de gimbal distintos, garantindo uma cobertura uniforme e permitindo reconstruir de forma completa a estrutura tridimensional da vegetação.

As missões foram conduzidas a uma altura média de 80 metros, com sobreposição frontal e lateral de 70% e uma velocidade aproximada de 6 m/s, parâmetros que asseguraram estabilidade geométrica entre faixas e uma elevada densidade final da nuvem de pontos

(≈ 1500 pts/m²). Esta densidade permitiu captar com grande detalhe tanto o coberto como o sub-bosque, bem como a microtopografia do terreno.

Durante o voo, o sistema RTK (Real Time Kinematic) incorporado no M300 garantiu a georreferenciação direta da trajetória do VANT, reduzindo a dependência de pontos de controle no terreno e melhorando a precisão posicional dos dados (Figura 3.6).



Figura 3.6. Instalação do sistema RTK.

3.2. Pré-processamento dos Dados

3.2.1. Organização e tratamento dos dados

Após a recolha dos dados de campo e a aquisição da nuvem de pontos LiDAR, iniciou-se o processamento e preparação dos dados necessários à modelação preditiva do volume de biomassa.

A estimativa do volume de madeira resultante das medições de campo foi obtida a partir da aplicação de uma equação alométrica específica para *Eucalyptus globulus*. Para cada árvore medida, o volume total com casca foi calculado através da Equação 3.1.

$$v = 0,2105 \left(\frac{d}{100} \right)^{1,8191} h^{1,0307}$$

Equação 3.1. Equação alométrica utilizada retirada de (Tomé et al., 2007).

em que d corresponde ao diâmetro à altura do peito (DAP), medido em centímetros, e h representa a altura total da árvore, em metros. A inclusão do termo $d / 100$ tem como objetivo converter o diâmetro para metros dentro da própria equação, garantindo coerência dimensional e permitindo que os expoentes ajustados — derivados de estudos empíricos prévios — representem adequadamente a relação não linear entre forma, altura, diâmetro e volume.

Após o cálculo do volume individual de cada árvore, o volume total por parcela foi determinado através da soma dos volumes de todas as árvores incluídas no respectivo talhão de amostragem. Dado que cada parcela representa uma área fixa foi necessário aplicar um fator de expansão para converter o volume obtido para uma base por hectare. O volume por hectare foi assim calculado segundo a Equação 3.2.

$$V_{ha} = V_{parcela} \times \frac{10000}{314,16}$$

Equação 3.2. Equação para conversão do volume por parcela em volume por hectare.

correspondendo a um multiplicador aproximado de 31,83. Este procedimento garante que os volumes utilizados na modelação — expressos em m^3/ha — são comparáveis entre talhões de diferentes densidades ou composição e representam adequadamente a produtividade do povoamento. Os valores de volume por parcela e por hectare resultantes deste processo constituíram a variável resposta utilizada na calibração dos modelos preditivos.

Após o cálculo do volume de biomassa a partir dos dados de campo, procedeu-se à organização e preparação dos dados LiDAR de forma a assegurar a sua integração consistente com a informação das parcelas. A nuvem de pontos resultante do levantamento aéreo foi submetida a um conjunto de operações destinadas a tornar as alturas comparáveis entre parcelas e espacialmente coerentes. O primeiro passo consistiu na identificação dos pontos correspondentes ao solo, etapa necessária para derivar um

Modelo Digital do Terreno (MDT) contínuo, a partir do qual se obtiveram as alturas relativas da vegetação.

A normalização foi realizada subtraindo, a cada retorno LiDAR, a cota do MDT no ponto correspondente, produzindo assim uma nuvem de pontos expressa em alturas acima do solo. Apenas os retornos cuja altura relativa se encontrava dentro do intervalo considerado plausível para o povoamento (0–80 m) foram mantidos, eliminando reflexos espúrios e valores inconsistentes.

Com a nuvem de pontos já normalizada e limpa, definiram-se as unidades espaciais necessárias ao estudo: os talhões circulares de inventário (10 m de raio), que serviram de referência para a calibração e validação dos modelos, e uma grelha regular de quadriculas de 10×10 m, utilizada posteriormente para a aplicação espacial das previsões (Figura 3.7). Para cada parcela e para cada quadricula foram extraídos os retornos LiDAR contidos no respetivo polígono, garantindo que as métricas derivadas representassem exclusivamente a estrutura da vegetação presente nessa unidade.

Deste processo resultou um conjunto de dados organizado em duas bases paralelas: (i) uma tabela de treino, na qual as métricas LiDAR extraídas das parcelas foram associadas aos volumes observados em campo; e (ii) uma tabela de predição, constituída pelas mesmas métricas, mas calculadas para todas as quadriculas da área de estudo.




Figura 3.7. Dados LiDAR e respetivas quadriculas de predição de volumes.

3.2.2. Construção das variáveis preditoras

A construção das variáveis preditoras utilizadas na modelação baseou-se integralmente nas métricas LiDAR extraídas a partir da nuvem de pontos previamente normalizada (Quadro 3.1). Para cada talhão, procedeu-se ao recorte espacial da nuvem de pontos com base no limite geográfico do mesmo, extraíndo-se todas as alturas normalizadas dos retornos existentes no seu interior. Sobre este conjunto de alturas foi calculado um conjunto alargado e detalhado de métricas estruturais, com o objetivo de caracterizar de forma abrangente a distribuição vertical da vegetação presente em cada unidade amostral.

As métricas extraídas incluem, numa primeira fase, indicadores estatísticos fundamentais, nomeadamente a altura máxima, a altura média, o desvio-padrão das alturas, a proporção de pontos acima dos 2 metros e a densidade de retornos por metro quadrado, obtida através da razão entre o número total de pontos e a área da parcela. Para capturar características adicionais da estrutura do coberto, foi definido um subconjunto de alturas constituído apenas pelos pontos acima dos 3 metros, assumidos como representativos do estrato arbóreo dominante.

Sobre este subconjunto foram calculados os quantis H25, H50, H75 e H95, bem como a média e o máximo das alturas filtradas, o coeficiente de variação, a curtose, o intervalo interquartil, a variância e uma métrica que relaciona a posição da média com a amplitude vertical (Hdf). A altura modal foi estimada através da análise de um histograma com classes regulares de 0,25 m, permitindo identificar a classe de altura mais frequente. Adicionalmente, foram calculadas métricas relativas à distribuição vertical da densidade, designadamente CDM3, CDM5, CDM7 e CDM8, que representam a proporção de pontos acima dos quantis 30%, 50%, 70% e 80% da distribuição vertical, respetivamente. Para complementar esta caracterização foram incluídos indicadores como PRO4 (proporção de pontos acima dos 4 metros), PROM (proporção de pontos acima da média das alturas filtradas) e a entropia normalizada da distribuição vertical, calculada a partir de histogramas divididos em 20 classes, refletindo o grau de heterogeneidade estrutural presente no coberto. Todas estas métricas foram agregadas num único registo por talhão, constituindo o conjunto inicial de variáveis preditoras derivadas da informação LiDAR.

As métricas extraídas foram posteriormente associadas aos dados de inventário de campo, onde se encontravam registados os valores observados de volume em m³/ha. Esta ligação

foi efetuada através do identificador único de parcela, assegurando a correspondência espacial entre os dados LiDAR e as observações de campo. Desta integração resultou uma base de dados consolidada em que cada linha representa uma parcela caracterizada simultaneamente pelas métricas LiDAR e pelo respetivo volume observado.

Procedeu-se à eliminação de variáveis redundantes ou pouco informativas, através da eliminação de variáveis com variância próxima de zero, uma vez que não contribuem significativamente para a capacidade preditiva dos modelos e podem introduzir ruído no processo de ajuste. Paralelamente, foi analisada a colinearidade entre as métricas LiDAR através do coeficiente de correlação de Pearson. As variáveis com correlação linear superior a $|r| > 0,95$ foram excluídas, preservando-se apenas uma de cada par de variáveis altamente correlacionadas. Este procedimento permite reduzir a dimensionalidade do conjunto de dados, melhorar a estabilidade dos modelos e evitar a sobreposição de informação estatística entre preditores.

Posteriormente, todas as variáveis numéricas foram submetidas a um processo de normalização e padronização, de modo a remover diferenças de magnitude e assegurar que todas contribuíssem de forma equilibrada para o processo de treino. Este passo é particularmente relevante para algoritmos sensíveis à escala das variáveis, como as redes neurais e os modelos de regressão linear.

Para a avaliação e calibração dos modelos, foi adotada a validação cruzada Leave-One-Out (LOOCV) (Yan et al., 2024). Este método consiste em ajustar o modelo várias vezes, utilizando em cada iteração todas as parcelas, exceto uma, para o treino, sendo a parcela excluída utilizada para teste. O processo é repetido até que todas as parcelas tenham sido utilizadas uma vez como amostra de teste. Esta abordagem maximiza o uso da informação disponível, proporcionando uma estimativa robusta e imparcial do desempenho preditivo, e reduz o risco de sobreajustamento dos modelos, uma vez que cada observação é testada individualmente. No final desta fase, obteve-se um conjunto de dados calibrado, normalizado e livre de redundâncias, adequado para o treino dos diferentes algoritmos de modelação.

O resultado deste conjunto de procedimentos permitiu obter uma matriz de variáveis predictoras composta exclusivamente por métricas LiDAR informativas, não redundantes, estatisticamente estáveis e devidamente normalizadas.

Quadro 3.1. Métricas extraídas, adaptado de (Amoedo et al., 2024).

Categoria	Métrica	Descrição	Símbolo / Cálculo
Altura	Altura máxima	Valor máximo das alturas normalizadas	$h_max = \max(Z)$
	Altura média	Média das alturas dos pontos acima do solo	$h_mean = \text{mean}(Z)$
	Desvio padrão da altura	Dispersão das alturas em relação à média	$h_sd = \text{sd}(Z)$
	Percentil 25	Altura abaixo da qual se encontram 25% dos pontos	H25
	Percentil 50 (mediana)	Altura que divide a distribuição em duas partes iguais	H50
	Percentil 75	Altura abaixo da qual se encontram 75% dos pontos	H75
	Percentil 95	Altura representativa do topo do coberto arbóreo	H95
Estrutura vertical	Coefficiente de variação da altura	Relação entre o desvio padrão e a média da altura	$Hcv = \text{sd}(Z)/\text{mean}(Z)$
	Variância da altura	Grau de dispersão da distribuição de alturas	Hvariance
	Intervalo interquartil	Diferença entre H75 e H25	$H_{iq} = H75 - H25$
	Desvio da forma vertical	Relação entre altura média e amplitude total	$Hdf = \frac{\text{mean}(Z) - \min(Z)}{\text{max}(Z) - \min(Z)}$
	Curtose	Grau de achatamento da distribuição de alturas	Hkurtosis
	Moda das alturas	Valor de altura com maior frequência	Hmode
Densidade e proporção de retornos	Densidade de pontos	Número total de retornos por m ²	dens_m2
	Proporção acima de 2 m	Percentagem de pontos acima de 2 m	p_above2
	Proporção acima de 4 m	Percentagem de pontos acima de 4 m	PRO4
	Proporção acima da média	Percentagem de pontos com altura superior à média	PROM
Distribuição acumulada (CDM)	CDM3	Proporção de pontos acima do percentil 30	CDM3
	CDM5	Proporção de pontos acima do percentil 50	CDM5

	CDM7	Proporção de pontos acima do percentil 70	CDM7	
	CDM8	Proporção de pontos acima do percentil 80	CDM8	
Complexidade estrutural	Entropia da altura	Grau de desordem vertical na distribuição de alturas	Entropy $-\sum(p \cdot \log(p))$ $\log(n)$	= /

3.3. Modelação preditiva

3.3.1. Modelos de regressão e machine learning

A estimativa do volume total de madeira foi realizada através da aplicação de diferentes modelos de regressão e aprendizagem automática, com o objetivo de comparar o desempenho de metodologias com distintos níveis de complexidade e capacidade de generalização. A escolha dos modelos (Quadro 3.2) procurou equilibrar a interpretabilidade dos métodos estatísticos tradicionais com a flexibilidade das técnicas mais avançadas de aprendizagem não linear, explorando de forma abrangente o potencial dos dados LiDAR para a modelação do volume florestal.

Entre os modelos utilizados, a regressão linear múltipla assumiu o papel de referência, por ser um método amplamente consolidado e de fácil interpretação. Através deste modelo, foi possível estabelecer uma relação direta entre as métricas derivadas do LiDAR e o volume observado, avaliando o contributo relativo de cada variável explicativa. Apesar da sua simplicidade e transparência, esta abordagem apresenta limitações quando as relações entre as variáveis não são estritamente lineares ou quando existem interações complexas entre os preditores, situação comum em ecossistemas florestais heterogêneos (Ryo & Rillig, 2017).

Para superar essas limitações e captar padrões de maior complexidade, foram implementados modelos não paramétricos, nomeadamente o Random Forest, o Extreme Gradient Boosting e o Perceptron Multicamadas. O Random Forest, baseado em múltiplas árvores de decisão construídas a partir de subconjuntos aleatórios dos dados, combina os resultados individuais de cada árvore para produzir uma estimativa mais robusta e estável. Esta técnica é particularmente eficaz na redução da variância e na mitigação do sobreajustamento, apresentando bom desempenho em contextos com elevada variabilidade estrutural e com variáveis correlacionadas.

O modelo Extreme Gradient Boosting segue um princípio semelhante, mas adota um processo de aprendizagem sequencial, em que cada árvore é ajustada para corrigir os erros do modelo anterior. Este mecanismo iterativo permite otimizar progressivamente o desempenho global, oferecendo elevada precisão e capacidade de generalização. No entanto, a sua eficácia depende de uma calibração adequada dos parâmetros internos, de modo a evitar o sobreajustamento e a garantir uma aprendizagem estável.

Complementarmente, o Perceptron Multicamadas foi utilizado para explorar a capacidade das redes neuronais artificiais na modelação de relações não lineares complexas. Através de camadas sucessivas de neurónios interligados, este modelo transforma as variáveis de entrada em representações internas mais abstratas, ajustando os seus pesos internos durante o processo de treino. Esta abordagem é particularmente útil quando os dados apresentam padrões intrincados e interdependentes, permitindo captar dinâmicas não lineares que outros métodos podem não conseguir representar adequadamente.

De forma integrada, a aplicação destes modelos permitiu comparar abordagens com diferentes pressupostos e mecanismos de aprendizagem, desde métodos lineares e interpretáveis até algoritmos não lineares e de natureza mais adaptativa. Esta diversidade metodológica possibilitou uma análise abrangente do potencial dos dados LiDAR para a previsão do volume florestal, fornecendo uma base sólida para a etapa subsequente de integração dos modelos e geração dos mapas preditivos.

Quadro 3.2 - Modelos de regressão utilizados.

Modelo	Descrição	Características principais
Regressão Linear Múltipla (LM)	Modelo estatístico clássico que estabelece uma relação linear entre as variáveis preditoras e a variável dependente.	Simplicidade e interpretabilidade elevadas; limitado na captura de relações não lineares.
Random Forest (RF)	Algoritmo baseado em múltiplas árvores de decisão geradas aleatoriamente a partir de subconjuntos de dados.	Elevada robustez; reduz variância e risco de sobreajustamento; capaz de lidar com variáveis correlacionadas.
Extreme Gradient Boosting (XGB)	Método de aprendizagem sequencial que otimiza iterativamente os erros cometidos por modelos anteriores.	Alta precisão; eficiente na modelação de relações complexas; requer calibração cuidadosa.

Perceptron Multicamadas (MLP)	Rede neuronal artificial composta por camadas de neurónios interligados que aprendem representações internas dos dados.	Capaz de modelar relações altamente não lineares; requer normalização dos dados e controlo do treino.
-------------------------------	---	---

3.3.2. Integração dos modelos (ensemble)

Após o treino individual dos modelos, foi implementada uma abordagem de integração (ensemble) com o objetivo de combinar as previsões obtidas e, assim, melhorar a precisão global da estimativa do volume florestal. A estratégia baseou-se na premissa de que diferentes algoritmos captam padrões distintos nos dados, pelo que a combinação dos seus resultados tende a reduzir o erro aleatório e a compensar as limitações inerentes a cada modelo isolado.

A integração foi realizada através de uma média simples das previsões provenientes dos quatro modelos individuais — Regressão Linear Múltipla, Random Forest, Extreme Gradient Boosting e Perceptron Multicamadas. Esta forma de ensemble, embora conceptualmente simples, tem demonstrado eficácia em estudos semelhantes, ao proporcionar uma estimativa mais estável e menos sensível a outliers ou a particularidades de um modelo específico. A média das previsões reflete, assim, uma ponderação equilibrada entre métodos de natureza linear e não linear, explorando as complementaridades entre a interpretabilidade dos modelos estatísticos e a capacidade de generalização dos algoritmos de aprendizagem automática.

A qualidade do ensemble foi avaliada comparativamente aos modelos individuais, utilizando as mesmas métricas de desempenho — Erro Quadrático Médio (RMSE), Erro Absoluto Médio (MAE), Erro Médio (MBE) e Coeficiente de Determinação (R^2). Este procedimento permitiu verificar se a combinação dos modelos contribuía efetivamente para a melhoria das previsões e para uma representação mais fiel da variação observada no volume florestal. Os resultados demonstraram que a abordagem ensemble tende a suavizar as discrepâncias entre modelos e a fornecer estimativas mais consistentes entre parcelas, reduzindo a influência de erros sistemáticos associados a cada algoritmo.

3.4. Validação e Avaliação de Desempenho

3.4.1. Procedimento de validação

A validação dos modelos preditivos é fundamental para assegurar a fiabilidade e a capacidade de generalização das estimativas de volume florestal obtidas. Dada a dimensão relativamente reduzida do conjunto de dados de treino, foi adotada a técnica de validação cruzada Leave-One-Out (LOOCV), amplamente utilizada em contextos com amostras limitadas devido à sua capacidade de maximizar o aproveitamento da informação disponível (Shao & Er, 2016).

Neste procedimento, o modelo é ajustado iterativamente, sendo em cada iteração excluída uma única parcela do conjunto de treino. A parcela removida é temporariamente utilizada como observação de teste, permitindo avaliar o desempenho do modelo na previsão de um caso não incluído no ajuste. O processo é repetido até que todas as parcelas tenham sido utilizadas uma vez como conjunto de validação, garantindo que cada observação contribui simultaneamente para o treino e para a avaliação.

Este método apresenta a vantagem de proporcionar uma estimativa quase imparcial do erro preditivo, uma vez que cada modelo é testado sobre dados independentes. Além disso, o LOOCV elimina a necessidade de dividir o conjunto de dados em subconjuntos de treino e teste fixos, o que seria ineficiente num contexto de amostra reduzida. Apesar de ser computacionalmente mais exigente, esta abordagem assegura uma boa avaliação da performance dos modelos, permitindo comparar os algoritmos de forma consistente e sem enviesamentos decorrentes de partições aleatórias dos dados.

O resultado desta etapa corresponde à média dos erros obtidos em todas as iterações, representando uma medida global da capacidade preditiva de cada modelo. Esta estimativa reflete não apenas a precisão dos algoritmos, mas também a sua estabilidade perante diferentes configurações dos dados, constituindo assim uma base sólida para a análise comparativa do desempenho entre modelos individuais e combinados.

3.4.2. Critérios de avaliação e métricas de desempenho

A avaliação do desempenho dos modelos preditivos teve como objetivo quantificar a capacidade de cada algoritmo em estimar o volume florestal com base nas métricas derivadas do levantamento LiDAR. Para este efeito, foram utilizadas quatro métricas estatísticas complementares — o Erro Quadrático Médio (RMSE), o Erro Absoluto Médio

(MAE), o Erro Médio (MBE) e o Coeficiente de Determinação (R^2) — que, em conjunto, permitiram avaliar a precisão, a tendência e a capacidade explicativa dos modelos.

O Erro Médio Quadrático (RMSE) mede a dispersão média das diferenças entre os valores observados (y_i) e os valores estimados ($\hat{y}_i$), sendo particularmente sensível a erros de grande magnitude. É calculado através da Equação 3.3.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Equação 3.3. Equação do RMSE utilizada para quantificar o erro médio da predição.

onde n representa o número total de observações. Valores mais baixos de RMSE indicam maior precisão global das previsões, refletindo uma boa correspondência entre as estimativas e os valores medidos em campo.

O Erro Absoluto Médio (MAE) representa a média das diferenças absolutas entre os valores observados e estimados, fornecendo uma medida intuitiva do erro médio sem considerar a direção do desvio, Equação 3.4.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Equação 3.4. Equação do Mean Absolute Error (MAE) utilizada para quantificar o erro absoluto médio.

Ao contrário do RMSE, o MAE é menos influenciado por outliers e fornece uma estimativa mais robusta do erro médio típico cometido pelo modelo.

O Erro Médio (MBE) avalia a tendência sistemática das estimativas, isto é, a tendência do modelo para sobrestimar ou subestimar os valores observados. É definido pela Equação 3.5.

$$MBE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)$$

Equação 3.5. Equação do Mean Bias Error (MBE), que quantifica o erro médio das predições.

Valores positivos de MBE indicam uma tendência para sobrestimação, enquanto valores negativos sugerem subestimação. Esta métrica é particularmente importante em contextos de inventário florestal, uma vez que permite identificar desvios sistemáticos que possam comprometer a fiabilidade das previsões.

Por fim, o Coeficiente de Determinação (R^2) quantifica a proporção da variância dos valores observados explicada pelo modelo, expressando o grau de ajustamento entre as estimativas e os valores reais. É calculado como o quadrado da correlação entre os valores observados e preditos, Equação 3.6.

$$R^2 = \left(\frac{cov(y, \hat{y})}{sd(y)sd(\hat{y})} \right)^2$$

Equação 3.6. Equação do coeficiente de determinação.

Valores próximos de 1 indicam elevada capacidade explicativa, sugerindo que o modelo consegue capturar de forma eficaz a variabilidade do volume florestal observada nas parcelas de treino.

A análise conjunta destas métricas permitiu comparar o desempenho dos diferentes algoritmos de forma abrangente, considerando simultaneamente a precisão (RMSE e MAE), a tendência (MBE) e a capacidade explicativa (R^2). Este conjunto de indicadores forneceu uma base sólida para a seleção do modelo mais adequado à previsão do volume florestal, equilibrando a exatidão estatística e a consistência ecológica das estimativas produzidas.

3.5. Importância das Variáveis

3.5.1. Quantificação da importância das variáveis preditoras

A quantificação da importância das variáveis preditoras teve como objetivo identificar o contributo relativo de cada métrica derivada do LiDAR na explicação da variabilidade

observada na variável dependente. Esta etapa permitiu caracterizar de forma objetiva o peso individual de cada preditor nos diferentes modelos ajustados, contribuindo para a compreensão da estrutura interna das relações modeladas e para a avaliação da robustez dos algoritmos aplicados.

A importância das variáveis foi calculada de acordo com os critérios definidos por cada técnica de modelação. No modelo de Random Forest, a importância foi estimada com base na redução média da impureza (Mean Decrease in Impurity) e na variação da precisão resultante da permutação de cada variável (Mean Decrease in Accuracy). Este procedimento avalia o impacto de cada variável na redução do erro preditivo e na qualidade das divisões geradas nas árvores, permitindo hierarquizar as métricas em função da sua relevância.

No caso do XGBoost, a importância foi quantificada através do ganho médio de informação (*Gain*) e da frequência com que cada variável foi utilizada para criar divisões nos nós das árvores (*Frequency*). As variáveis com maior contributo para a minimização do erro residual, ou que foram selecionadas mais frequentemente durante o processo de reforço de gradiente, foram consideradas mais relevantes para a predição do volume florestal.

Nos modelos Lineares (LM) e de Redes Neurais Artificiais (MLP), a importância das variáveis foi inferida a partir dos coeficientes de regressão padronizados e dos pesos sinápticos obtidos após o treino da rede. No caso do modelo linear, coeficientes de maior magnitude indicam maior influência na variável resposta, enquanto no modelo MLP a importância resulta da propagação e ponderação dos pesos entre as camadas, refletindo as relações não lineares estabelecidas entre as variáveis LiDAR e o volume estimado.

De forma a obter uma visão global, os resultados de importância produzidos pelos diferentes algoritmos foram normalizados e comparados, de modo a avaliar a consistência entre modelos e a robustez das métricas mais influentes.

4. ANÁLISE E DISCUSSÃO DE RESULTADOS

4.1. Área de estudo

A área de estudo (Figura 4.1) corresponde a uma parcela florestal localizada na freguesia de Arcozelo, concelho de Ponte de Lima, no norte de Portugal. A parcela possui cerca de 2,3 hectares e integra uma área de produção florestal sob gestão da The Navigator Company, dedicada à instalação e condução de povoamentos de eucalipto. Trata-se de um talhão contínuo, com limites bem definidos. A morfologia do terreno é relativamente homogénea, apresentando declives moderados e ausência de variações abruptas de relevo, o que reduz distorções na aquisição das métricas derivadas do modelo de altura. A envolvente é constituída por mosaicos florestais típicos da região, predominando áreas de eucalipto, regeneração natural e pequenos núcleos de matos. Esta configuração garante que a parcela é representativa do contexto operacional da Navigator na região e permite testar a capacidade dos modelos em condições florestais reais.




Figura 4.1. Enquadramento da área de estudo.

4.2. Recolha e processamento dos dados

4.2.1. Dados de campo

A análise dos dados recolhidos em campo revela uma certa homogeneidade entre as parcelas amostradas, refletindo um povoamento florestal com características estruturais semelhantes. As diferenças observadas nos volumes por parcela são pouco expressivas, indicando uma distribuição equilibrada da biomassa aérea e uma densidade de árvores comparável entre unidades de amostragem.

Embora os volumes médios por hectare revelem um padrão de relativa consistência entre parcelas, a análise das variáveis dendrométricas individuais evidenciou uma relação não linear entre o diâmetro à altura do peito (DAP) e a altura total das árvores. Em vários casos, observou-se que indivíduos com alturas inferiores apresentavam diâmetros superiores, contrariando a tendência alométrica típica esperada para povoamentos de crescimento regular. Este comportamento poderá estar relacionado com o historial do povoamento, nomeadamente com o facto de se tratar de uma área em terceira rotação, em que a regeneração vegetativa e a competição por recursos tendem a produzir estruturas de crescimento diferenciadas. Em rotações sucessivas, é comum observar variações no vigor dos rebentos e na capacidade de crescimento em altura, resultando em indivíduos com padrões de alocação de biomassa distintos. Assim, embora a correlação entre DAP e altura seja positiva (r de Pearson = 0,27), a sua magnitude reduzida evidencia uma elevada variabilidade intra-parcela.

Assim, embora a correlação entre DAP e altura total seja positiva, a sua magnitude reduzida evidencia uma elevada variabilidade intra-parcela (Figura 4.2). A análise desagregada por parcela (Figura 4.3) reforça essa observação: apesar de se manter a tendência geral de aumento da altura com o diâmetro, a relação apresenta flutuações entre parcelas, com padrões de dispersão mais acentuados em algumas delas (nomeadamente P2 e P4). Essas diferenças podem refletir pequenas variações locais nas condições de crescimento, na estrutura do coberto ou no estado de desenvolvimento dos rebentos — fatores que, embora não quantificados diretamente, contribuem para a diversidade estrutural observada.




Figura 4.2. Correlação total entre o DAP e a Altura.




Figura 4.3. Correlação entre DAP e Altura por talhão.

Esta heterogeneidade, ainda que discreta, é relevante no contexto da modelação da biomassa, uma vez que permite testar a capacidade dos modelos na captação de variações estruturais subtis dentro do mesmo povoamento. A utilização de medições de campo precisas e de equações alométricas ajustadas à região assegura que estas diferenças sejam devidamente incorporadas nas estimativas de volume e biomassa, garantindo maior realismo às previsões obtidas a partir dos dados LiDAR.

4.2.2. Dados LiDAR

A análise preliminar dos dados provenientes do levantamento LiDAR permite avaliar, de forma cautelosa, a adequação do conjunto adquirido para os objetivos do estudo. O sistema utilizado — um DJI Matrice 300 RTK equipado com o sensor DJI Zenmuse L1 — integra GNSS/IMU e LiDAR num único módulo, permitindo a georreferenciação direta da trajetória e dos retornos laser. Embora não tenham sido calculados indicadores formais de exatidão posicional (como RMSE horizontal ou vertical), a utilização de RTK assegura, em princípio, uma estabilidade geométrica superior à de sistemas sem correção diferencial.

Um aspeto relevante do sensor L1 é o uso do modo de varrimento “*non-repetitive*”. Ao contrário dos sensores LiDAR de varrimento linear tradicional, que repetem o mesmo

padrão angular em cada ciclo, este modo de varrimento distribui os pulsos de forma dinâmica dentro de um campo de visão definido, garantindo uma amostragem angular mais variada ao longo do voo. Na prática, isto tende a aumentar a probabilidade de capturar retornos em diferentes faces das copas e reduzir a formação de caminhos vazios sistemáticos no interior do coberto.

As missões foram conduzidas a 80 m de altitude, com sobreposições frontal e lateral de 70% e velocidade de cerca de 6 m/s. Estes parâmetros, em combinação com o modo de varrimento non-repetitive, favorecem a redundância angular e espacial dos retornos, contribuindo teoricamente para uma cobertura mais uniforme. A realização de cinco voos com direções distintas de varrimento e diferentes orientações do gimbal reforça esta redundância, mas os efeitos concretos desta estratégia (como a melhoria da continuidade vertical ou a redução de sombras) não foram quantificados com métricas específicas.

A densidade resultante, próxima de 1500 pontos/m², é elevada para contexto florestal e garante um número suficiente de retornos para o cálculo robusto das métricas utilizadas na modelação. Apesar disso, a distribuição desses pontos entre solo, estratos intermédios e copa não foi analisada separadamente, pelo que não é possível estimar a proporção de retornos efetivamente úteis para cada métrica ou avaliar a penetração do feixe em diferentes zonas do coberto.

A calibração da IMU foi realizada antes de cada missão, seguindo o procedimento recomendado pelo fabricante. Este passo visa reduzir erros de atitude que poderiam distorcer o alinhamento das faixas.

4.3. Pré-processamento dos dados

4.3.1. Organização e tratamentos dos dados

A integração dos dados de campo com a informação proveniente do LiDAR revelou-se um processo crítico para a construção do conjunto final de modelação. Não foram detetados erros sistemáticos de medição nem omissões significativas. A consolidação das variáveis de campo revelou uma proximidade muito elevada tanto nos valores de volume por hectare entre as cinco unidades consideradas como o próprio volume efetivo entre parcelas (Quadro 4.1).

Quadro 4.1 - Volumes calculados por talhão de amostragem.

TA	Nº de árvores	Volume por parcela	Volume por hectare
P1	27	2.69	85.73
P2	33	2.75	87.70
P3	30	2.61	83.32
P4	24	2.39	76.22
P5	31	2.86	91.22

A nuvem de pontos apresenta uma cobertura densa e homogênea sobre a área de estudo, garantindo uma representação contínua do relevo e da estrutura do povoamento (Figura 4.5). Observa-se um gradiente altimétrico bem definido, com altitudes variando entre aproximadamente 250 e 285 m, o que reflete a morfologia suave da encosta onde se inserem as parcelas. A distribuição uniforme dos retornos indica uma boa penetração do feixe laser, sem lacunas visíveis nem zonas de saturação, assegurando a fiabilidade dos produtos derivados.




Figura 4.4. Nuvem de pontos LiDAR.

A classificação dos retornos em pontos de solo (*ground*) e não-solo (*non-ground*) revelou uma separação nítida entre a superfície do terreno e a vegetação (Figura 4.5). Os retornos de solo formam uma malha contínua que acompanha o relevo, enquanto os pontos de vegetação se distribuem de forma densa e regular sobre o coberto, correspondendo às

copas dos eucaliptos. Esta distinção evidencia a eficácia da detecção múltipla de retornos e a capacidade do levantamento para captar simultaneamente as estruturas superiores e o terreno subjacente.



Figura 4.5. Classificação da nuvem de pontos.

O modelo digital do terreno (Figura 4.6) resultante dessa classificação mostra uma topografia suave, com variações altimétricas de cerca de 30 metros entre o ponto mais baixo ao ponto mais alto da parcela que acompanham o gradiente observado na nuvem original. A superfície gerada apresenta continuidade e ausência de artefactos, o que confirma a consistência dos retornos classificados como solo. Pequenas ondulações locais refletem irregularidades naturais do solo, possivelmente associadas à microtopografia ou ao padrão de drenagem superficial.




Figura 4.6. Modelo Digital do Terreno.

A Figura 4.7 apresenta o perfil vertical da nuvem de pontos antes e depois da normalização, mostrando a diferença entre as alturas absolutas e as relativas ao terreno. Antes da normalização, as copas acompanham o declive natural do terreno, enquanto após a correção observa-se a uniformização das alturas das árvores em relação ao solo. A nuvem de pontos normalizada (Figura 4.8) revela uma concentração de retornos entre 10 e 20 m de altura, correspondendo ao estrato dominante do coberto. Os valores mais baixos, entre 0 e 2 m, são menos frequentes e estão associados a vegetação de sub-bosque residual ou a irregularidades do terreno. Esta distribuição demonstra a eficácia do processo de normalização, permitindo isolar a componente estrutural da vegetação e evidenciar um povoamento maduro e estruturalmente homogêneo, com copas bem desenvolvidas e um sub-bosque pouco expressivo, típico de eucaliptais em terceira rotação.




Figura 4.7. Normalização das alturas.




Figura 4.8. Alturas relativas.

O histograma (Figura 4.9) mostra a distribuição vertical dos retornos LiDAR em função da altura relativa ao terreno. A análise permite observar dois agrupamentos principais: um primeiro pico muito marcado junto aos 0 m e um segundo pico, mais amplo, entre 10 e 20 m. O pico junto ao solo corresponde maioritariamente a retornos de terreno (pontos classificados como solo), podendo também incluir reflexões provenientes da base dos troncos ou da vegetação rasteira que o feixe laser atinge antes de alcançar o terreno.

Em superfícies inclinadas ou com pequenas irregularidades, este efeito torna-se ainda mais visível, originando uma acumulação significativa de retornos nos primeiros decímetros acima do solo. Entre 2 m e 8 m observa-se uma redução acentuada na frequência de retornos, sugerindo escassez de vegetação intermédia e, consequentemente, ausência de um sub-bosque desenvolvido. Por fim, o pico localizado entre 10 e 20 m representa o estrato dominante do coberto, associado às copas dos eucaliptos.




Figura 4.9. Distribuição das alturas relativas ao longo da parcela.

4.3.2. Construção das variáveis preditoras

A análise das distribuições estatísticas das métricas (Figura 4.10) evidencia que, apesar do número reduzido de parcelas, existe variabilidade suficiente para distinguir diferentes padrões estruturais da vegetação. Observa-se que grande parte das métricas apresenta amplitudes relativamente estreitas e concentrações marcadas de valores, refletindo a homogeneidade estrutural do povoamento amostrado. Ainda assim, indicadores relacionados com a distribuição vertical das alturas (percentis, mediana, altura média), medidas de variabilidade (desvio-padrão, coeficiente de variação, intervalo interquartil), métricas condicionais (CDM) e a densidade de retornos revelam comportamentos diferenciados entre parcelas, sugerindo potencial informativo relevante para a modelação do volume.

A análise conjunta das métricas destaca igualmente diferenças pronunciadas de escala entre variáveis — com algumas, como a densidade de pontos (`dens_m2`), a apresentarem valores muito superiores às restantes — o que reforça a necessidade de centrar e normalizar os dados antes do ajuste dos modelos. Paralelamente, identificaram-se métricas cuja variância é extremamente reduzida, limitando a sua capacidade de contribuir para a explicação da variabilidade do volume e justificando a sua posterior exclusão no processo de seleção de preditores.



Figura 4.10. Variabilidade das métricas extraídas a partir dos dados LiDAR.

A matriz de correlação entre métricas (Figura 4.11) permitiu identificar blocos bem definidos de variáveis fortemente correlacionadas, sobretudo entre os vários percentis (H25, H50, H75, H95), as alturas média e máxima, e as medidas de dispersão vertical. Isto sugere que muitas destas métricas capturam essencialmente a mesma informação estrutural, o que justifica a remoção subsequente de variáveis colineares e métricas de variância quase nula. Por outro lado, métricas como CDM3, CDM5, PRO4, PROM e Entropy apresentam relações fracas com as restantes variáveis, desempenhando um papel mais complementar na descrição da estrutura vertical.




Figura 4.11. Correlação entre variáveis preditoras.

A relação entre cada métrica e o volume observador (Figura 4.12) confirmou que determinadas variáveis possuem elevada capacidade explicativa. A métrica CDM3 destacou-se com uma correlação extremamente elevada com o volume, evidenciando que a proporção de retornos acima de limiares intermédios é um indicador robusto da densidade e do desenvolvimento do coberto. Métricas como H25, dens_m2, Hvariance, Hcv e h_mean apresentaram também correlações fortes, mostrando que a altura dos estratos inferiores e a variabilidade vertical são fatores fundamentais na explicação do volume. Por contraste, métricas como CDM5, CDM8 ou Hkurtosis exibiram correlações mais fracas ou mesmo negativas, sugerindo que representam aspetos da estrutura que não se relacionam diretamente com o volume.




Figura 4.12. Correlação entre métricas LiDAR e volume de biomassa.

A Figura 4.13 resultante da PCA revelou que a primeira componente principal concentra a maior parte da variabilidade das métricas, evidenciando uma forte redundância entre as variáveis associadas à distribuição vertical da vegetação. As componentes seguintes explicam parcelas progressivamente menores em termos de variância, estabilizando a partir da terceira componente. Esta estrutura confirma que muitas métricas capturam informação altamente semelhante, justificando a remoção de variáveis com variância residual ou colinearidade extrema. O padrão observado indica que a maior parte da informação estrutural relevante está concentrada em apenas 1–2 dimensões latentes, o que é coerente com o comportamento observado durante a modelação preditiva.




Figura 4.13. Análise dos principais componentes das métricas LiDAR.

No conjunto, os resultados obtidos demonstram que as métricas extraídas descrevem adequadamente as diferenças estruturais entre parcelas e que existe uma relação clara entre diversas métricas e o volume observado. A matriz de correlação final (Figura 4.14), construída após a remoção de métricas com variância quase nula e de variáveis altamente colineares, evidencia que o conjunto de métricas retido apresenta níveis reduzidos de redundância e uma estrutura interna mais estável e informativa. Esta verificação garante que as relações observadas entre variáveis são estatisticamente consistentes e que cada métrica contribui de forma efetiva e complementar para a descrição da estrutura do coberto. A presença de associações fortes, mas não redundantes com o volume confirma, por sua vez, o potencial das métricas finais para suportar modelos de predição volumétrica robustos.




Figura 4.14 - Matriz de correlação após análise de colinearidade.

4.4. Resultados da modelação preditiva

A análise exploratória das predições dos cinco modelos ajustados (LM, RF, XGB, MLP e Ensemble) permitiu avaliar não apenas os valores estimados, mas também o comportamento estatístico e espacial das predições antes da avaliação formal do desempenho. A Figura 4.15 mostra que todos os modelos apresentam valores centrais muito próximos, com medianas concentradas entre 84 e 87 m³/ha. Esta proximidade sugere que, apesar das diferenças metodológicas, todos os modelos convergem para uma gama volumétrica coerente com o contexto das parcelas. No entanto, a variabilidade interna difere entre abordagens: o Random Forest apresenta a maior amplitude interquartil, indicando maior dispersão das estimativas, enquanto o ensemble evidencia uma distribuição mais compacta, refletindo maior estabilidade e consistência entre tesselas. A presença de alguns valores extremos em modelos específicos indica que determinadas combinações de métricas provocaram desvios localizados relativamente ao padrão geral.




Figura 4.15. Distribuição dos volumes preditos por cada modelo de regressão.

A análise das curvas de densidade reforça estas observações (Figura 4.16). As distribuições das predições apresentam elevada sobreposição entre modelos, o que confirma a coerência geral das estimativas. Ainda assim, surgem diferenças relevantes: a curva que o RF apresenta evidencia a sua maior variabilidade; o LM, XGB e MLP apresentam densidades mais estreitas, revelando maior concentração dos valores previstos em torno de um intervalo reduzido; e o ensemble posiciona-se entre estes comportamentos, mantendo uma forma regular e suavizada resultante da combinação das previsões individuais.




Figura 4.16. Distribuição dos volumes preditos pelos diferentes modelos de regressão.

A análise espacial das superfícies de predição (Figura 4.17) evidencia como as diferenças estatísticas entre modelos se refletem no território, revelando padrões consistentes de variação volumétrica. Todos os modelos identificam de forma coerente as zonas de maior densidade estrutural e distinguem áreas de menor volume, mas apresentam respostas distintas em termos de heterogeneidade visual. O modelo linear gera superfícies mais fragmentadas, com alternância rápida de classes adjacentes, refletindo uma forte sensibilidade a pequenas oscilações nas métricas LiDAR. Em contraste, o Random Forest produz mapas mais homogêneos, com extensas regiões de valores semelhantes, evidenciando a tendência dos métodos de árvores para gerar partições mais discretas e suavizadas. Os modelos XGBoost e MLP posicionam-se entre estes extremos, captando detalhes locais sem originar padrões excessivamente irregulares. O ensemble combina de forma equilibrada estas características, reduzindo a irregularidade do modelo linear e evitando a suavização excessiva observada no RF, resultando numa superfície espacialmente mais estável e realista.

Um aspeto transversal a todos os modelos é a presença do efeito bordadura, em que as áreas localizadas junto ao limite da parcela tendem a apresentar valores de volume superiores aos do interior. Este efeito não corresponde a uma característica ecológica real, mas resulta do modo como as métricas LiDAR são calculadas nas células periféricas,

onde as janelas de amostragem interceptam áreas exteriores à parcela e incorporam informação de copas ou vegetação adjacente mais alta, elevando artificialmente estatísticas como alturas percentílicas ou densidade acima de limiares. Embora o efeito esteja presente em todos os modelos, a sua expressão visual varia: é mais evidente no modelo linear, devido à combinação entre maior sensibilidade a pequenas variações e à discretização da simbologia, e menos pronunciado no RF, MLP e XGboost cujas predições tendem a ser mais suavizadas. O ensemble atenua parcialmente este contraste, integrando a coerência espacial dos modelos mais estáveis com a capacidade de detalhe dos modelos mais sensíveis. Assim, as superfícies de predição refletem simultaneamente o comportamento estatístico dos modelos e as limitações inerentes ao processo de amostragem nas zonas limítrofes.




Figura 4.17. Distribuição espacial do volume predito segundo Random Forest, XGBoost, regressão linear múltipla, MLP e ensemble, valores expressos em m³/ha e m³/quadrícula.

No conjunto, a análise aprofundada das distribuições numéricas e dos padrões espaciais revela que os cinco modelos produzem estimativas consistentes e coerentes entre si, mas com diferenças relevantes na variabilidade, na forma das distribuições e na representação das transições espaciais. Nenhum modelo apresenta comportamento anormal nesta fase, e as diferenças observadas fornecem informação importante para interpretar os resultados

que serão analisados posteriormente na avaliação de desempenho. O ensemble destaca-se como uma solução intermédia robusta, conseguindo reduzir extremos sem perder resolução espacial, reforçando o seu potencial como abordagem preditiva fiável para a estimativa de volume florestal.

4.5. Resultados da validação e avaliação de desempenho

A validação dos modelos foi realizada através do método leave-one-out (LOOCV), adequado ao número muito reduzido de parcelas disponíveis. Apesar desta limitação, os gráficos obtidos permitem identificar com clareza o comportamento individual de cada modelo e a sua capacidade de generalização na estimativa do volume com base em métricas LiDAR. A análise do gráfico observado vs. predito (Figura 4.18) revela imediatamente uma divisão entre modelos com ajuste artificialmente perfeito e modelos que apresentam variação realista. A regressão linear múltipla (LM) e o perceptron multicamada (MLP) alinham-se exatamente sobre a linha 1:1, o que sugere, não um desempenho preditivo excecional, mas sim um caso evidente de sobreajustamento: os modelos memorizaram totalmente os valores das parcelas. Este fenómeno é consistente com o reduzido tamanho amostral. Em contraste, o Random Forest (RF) apresenta maior dispersão em torno da linha, evidenciando incerteza e variabilidade nas predições. Embora este comportamento resulte em menor precisão imediata, representa também uma maior resistência ao sobreajustamento. O XGBoost (XGB) e o ensemble surgem como soluções intermédias: aproximam-se da linha ideal, mas preservam pequenos desvios que indicam que não memorizaram exatamente as parcelas, oferecendo maior capacidade de generalização.




Figura 4.18. Relação entre valores observados e preditos para cada modelo sob validação LOOCV.

A interpretação deste padrão é reforçada pelos resíduos (Figura 4.19). LM e MLP apresentam resíduos essencialmente nulos, o que à primeira vista indicaria um excelente desempenho, mas corresponde novamente à memorização dos dados. O RF, pelo contrário, exibe a maior amplitude residual, refletindo a sua natureza não paramétrica e a tendência para produzir respostas menos ajustadas quando a amostra é pequena. O XGB e o ensemble mantêm os resíduos próximos de zero, com magnitudes reduzidas e sem tendência aparente para sobrestimação ou subestimação sistemática, sugerindo um equilíbrio saudável entre precisão e robustez.




Figura 4.19. Distribuição dos resíduos dos modelos de predição do volume.

O mesmo padrão surge na dispersão do erro absoluto (Figura 4.20). O RF domina o intervalo superior de erro, apresentando grande dispersão e valores extremos, o que é consistente com a sua variabilidade interna e com a ausência de sobreajustamento. Em contraste, o XGB apresenta erros absolutos muito reduzidos e consistentes, enquanto o ensemble mantém um comportamento próximo, com valores ainda baixos, mas ligeiramente superiores ao XGB. LM e MLP surgem novamente com erro absoluto nulo, uma vez mais indicando degeneração do modelo — não falham porque não generalizam, limitando-se a reproduzir as parcelas.




Figura 4.20. Comparação dos erros absolutos entre os diferentes modelos avaliados.

A comparação direta das métricas globais (Figura 4.21) clarifica a interpretação gráfica. As métricas MAE, RMSE e R^2 parecem, à primeira vista, favorecer LM e MLP devido aos seus erros nulos e R^2 igual a 1. Contudo, estes valores são enganosos e não representam qualidade preditiva real. O RF apresenta os piores valores de RMSE e MAE, o que reflete a sua variabilidade, enquanto o XGB apresenta os valores mais baixos entre os modelos que realmente generalizam. O ensemble oferece métricas intermédias muito favoráveis, confirmando o seu papel como solução robusta e equilibrada.




Figura 4.21. Comparação das métricas de desempenho (MAE, R^2 e RMSE) entre os modelos avaliados.

A análise do erro por parcela para o ensemble (Figura 4.22) mostra que o modelo mantém desvios pequenos, sem tendência sistemática para sobrestimar ou subestimar qualquer parcela. A amplitude moderada dos erros indica que o ensemble suaviza as flutuações dos modelos individuais, oferecendo maior estabilidade preditiva. Isto confirma que o ensemble herda os benefícios do XGB e atenua tanto o sobreajustamento do LM/MLP como a variabilidade excessiva do RF.




Figura 4.22. Erro de predição do volume (m³/ha) por parcela.

A distribuição das predições espaciais (Figura 4.23) diferenças importantes na coerência das predições dos modelos. O LM apresenta caudas longas, incluindo valores impossíveis ou incoerentes com a realidade silvícola, reflexo da extrema sensibilidade do modelo a pequenas variações nas métricas. Esta característica já tinha sido observada na etapa de extrapolação espacial, onde o LM produziu valores negativos e valores extremamente elevados, confirmando falta de robustez. O RF mostra uma distribuição muito mais dispersa e irregular, coerente com a sua variabilidade residual. O XGB e o ensemble apresentam distribuições estreitas e estáveis, centradas em valores plausíveis, indicando coerência espacial e fiabilidade das predições. Entre os dois, o ensemble mantém uma distribuição ainda mais consistente, reforçando a sua adequação para mapeamento contínuo.




Figura 4.23. Distribuição dos volumes preditos pelos modelos em toda a área de estudo.

Em síntese, os gráficos analisados mostram que, embora LM e MLP apresentem métricas estatisticamente “perfeitas”, este desempenho resulta de sobreajustamento severo e não representa capacidade preditiva real. O RF, apesar de mais variável, é menos propenso a memorizar os dados, mas perde precisão. O XGB destaca-se como o modelo mais equilibrado, combinando baixo erro, coerência espacial e resistência ao sobreajustamento. O ensemble ultrapassa ligeiramente o XGB em termos de estabilidade, oferecendo uma solução robusta, moderadamente precisa e adequada para extrapolação espacial, sendo, portanto, a abordagem mais fiável para a produção cartográfica e estimativa de volume florestal no contexto deste estudo.

4.6. Resultados da análise da importância das variáveis

A avaliação da importância das variáveis permite identificar quais métricas LiDAR contribuem de forma mais consistente para a estimativa do volume florestal. Nos três modelos analisados — Random Forest, XGBoost e Ensemble — emergem padrões claros que convergem na interpretação estrutural da vegetação. As Figura 4.24 (RF), Figura 4.25 (XGBoost) e Figura 4.26 (Ensemble) apresentam as importâncias calculadas para cada abordagem.

No caso do XGBoost, observou-se um padrão extremamente claro: as métricas Hdf, dens_m2 e h_mean dominam de forma marcante o ganho total do modelo. Estas três

variáveis representam, respetivamente, a altura dominante, a densidade de deteções por metro quadrado e a altura média — todas medidas diretamente relacionadas com biomassa e volume. A contribuição acumulada destas três métricas ultrapassa a grande maioria das restantes, sugerindo que a estrutura vertical principal do coberto florestal é o elemento mais informativo na predição do volume. Métricas adicionais, como *h_sd* (variabilidade vertical) e *p_above2* (proporção de retornos acima de 2 m), apresentam importância não negligenciável, reforçando a ideia de que a diferenciação estrutural da copa melhora a capacidade discriminativa do modelo.




Figura 4.24. Importância das métricas extraídas para o XGboost.

O Random Forest, por sua vez, apresenta um padrão diferente, característico deste tipo de algoritmo. Embora também reconheça a relevância das métricas estruturais, dá particular destaque a *h_sd*, *H25* e *CDM7*, que surgem como as variáveis mais influentes. Esta diferença é típica de modelos de árvore, que privilegiam métricas capazes de estabelecer divisões eficazes ao longo dos thresholds, mesmo que estas não sejam necessariamente as mais correlacionadas com o volume. A forte importância atribuída ao

desvio-padrão da altura (h_sd) é coerente com o facto de o RF promover variáveis que geram separações nítidas entre parcelas, mesmo quando o número total de observações é reduzido. No entanto, o modelo também atribui importância moderada a métricas como p_above2 , Hdf , e indicadores de distribuição vertical (CDM3, CDM5, CDM8), mostrando uma utilização mais diversificada das métricas LiDAR.




Figura 4.25. Importância das métricas extraídas para o Random Forest.

Já o Ensemble, ao combinar os padrões extraídos pelos modelos base, apresenta um comportamento mais equilibrado. De forma notável, mantém o domínio das três métricas principais — Hdf , $dens_m2$ e h_mean — mas suaviza diferenças extremas presentes nos modelos individuais. O Ensemble reduz a importância excessiva que o Random Forest atribui a métricas específicas e ao mesmo tempo regulariza a dominância extrema observada no XGBoost. O resultado é uma hierarquia mais coerente com a estrutura real

do povoamento florestal, na qual a altura dominante e a densidade de vegetação constituem os principais determinantes do volume, complementados por métricas secundárias relacionadas com variabilidade estrutural (h_sd) e proporções verticais (p_above2). Esta distribuição mais homogénea indica que o Ensemble consegue capturar diferentes aspetos da estrutura vertical da floresta, combinando a capacidade discriminativa do RF com o rigor interpretativo do XGBoost.




Figura 4.26. Importância das métricas extraídas no Ensemble.

A comparação global dos três modelos revela que Hdf , $dens_m2$ e h_mean são universalmente reconhecidas como variáveis essenciais, independentemente da técnica utilizada. Estas métricas representam características fundamentais do coberto florestal — altura dominante, densidade do coberto e altura média — que, combinadas, capturam

dimensões críticas associadas ao volume. Métricas baseadas na variabilidade vertical e na distribuição dos retornos (como `h_sd`, `CDMx` e `p_above2`) surgem como complementares, reforçando a discriminação entre áreas estruturalmente distintas.

No conjunto, a análise de importância das variáveis confirma que o volume está fortemente associado à estrutura vertical dominante e ao grau de ocupação do espaço aéreo pelo coberto. Os modelos diferem na forma como distribuem a importância relativa entre as métricas secundárias, mas convergem na identificação das variáveis-chave. Esta consistência reforça a validade das relações extraídas entre métricas LiDAR e volume florestal, e sustenta a utilização do Ensemble como abordagem final, dado que combina de forma robusta a hierarquia de variáveis dos modelos individuais.

5. CONCLUSÃO

A integração entre dados LiDAR aerotransportados de elevada densidade, inventário dendrométrico de campo e modelos de regressão baseados em técnicas avançadas de aprendizagem automática demonstrou elevada capacidade para explicar a variabilidade estrutural e volumétrica de povoamentos de *Eucalyptus globulus*. Os resultados evidenciaram que a estrutura vertical, captada através de métricas como a altura dominante (Hdf), densidade de retornos (dens_m2) e altura média (h_mean), constitui o principal determinante do volume, refletindo a forte dependência entre parâmetros de arquitetura do coberto e acumulação de biomassa aérea. A análise de correlação, a PCA e a subsequente seleção de variáveis confirmaram a existência de redundância significativa entre métricas associadas à distribuição das alturas, validando o processo de filtragem para redução de colinearidade e maximização da informação estrutural efetivamente útil.

Os modelos testados revelaram comportamentos diferenciados em termos de generalização e robustez estatística. A regressão linear múltipla e o perceptron multicamada apresentaram ajustes perfeitos aos dados de treino — um fenómeno típico de sobreajustamento em cenários de baixa dimensão amostral —, não devendo ser considerados abordagens fiáveis para extrapolação espacial. O Random Forest, embora mais resistente ao sobreajustamento, apresentou maior variabilidade residual e menor precisão global. O XGBoost destacou-se pela capacidade de capturar relações não lineares com estabilidade, produzindo previsões coerentes e erros reduzidos, enquanto o ensemble, combinando as previsões dos modelos base, apresentou o desempenho mais equilibrado, mitigando outliers, estabilizando o espaço de predição e reduzindo a variância sem perda de resolução estrutural. A coerência espacial das superfícies geradas pelo ensemble confirma a sua adequação para aplicações operacionais em cartografia de volume, mesmo em contextos com amostra reduzida.

A análise crítica dos resultados revelou ainda a presença de anomalias de processamento, como o efeito de bordadura, inerente às janelas móveis aplicadas ao cálculo das métricas LiDAR nas células periféricas. Este efeito, embora mitigado pelo ensemble e pelo XGBoost, evidencia a necessidade de incorporar estratégias de correção espacial em aplicações futuras, como buffers externos, janelas adaptativas ou métodos de deconvolução do sinal LiDAR. A normalização rigorosa da nuvem e a consistência morfológica observada no MDE validam a qualidade geométrica do levantamento, reforçando a fiabilidade das métricas estruturais derivadas.

Adicionalmente, embora a elevada densidade de pontos LiDAR utilizada tenha permitido extrair métricas estruturais altamente detalhadas, importa compreender até que ponto tal densidade é verdadeiramente necessária para garantir a precisão dos resultados. Densidades muito elevadas podem aumentar a redundância informação e, simultaneamente prolongar os tempos de processamento. Assim, uma melhoria futura consiste em determinar o limiar mínimo de densidade de pontos por metro quadrado que assegura a estabilidade das métricas estruturais e a coerência espacial dos modelos de volume, sem comprometer a sua robustez. A definição deste patamar ótimo permitiria otimizar aquisições, reduzir substancialmente o esforço computacional e aumentar a viabilidade operacional do método em contextos de larga escala.

Embora os resultados obtenham forte suporte técnico-científico, a reduzida dimensão amostral (cinco parcelas) limita a generalização dos modelos e a robustez estatística das conclusões. Recomenda-se, por conseguinte, a expansão do desenho amostral a múltiplos talhões, idades, rotações e condições de sítio, bem como a integração de variáveis adicionais de natureza espectral ou provenientes de LiDAR full-waveform. Abordagens futuras poderão também beneficiar de metodologias bayesianas, modelos hierárquicos ou frameworks de aprendizagem profunda orientada por estrutura.

Em síntese, os resultados confirmam que as métricas LiDAR capturam de forma eficaz a arquitetura tridimensional do povoamento e constituem base sólida para a modelação quantitativa do volume e biomassa acima do solo. O ensemble emergiu como a abordagem preditiva mais estável e tecnicamente robusta, validando o potencial da integração entre deteção remota e modelação avançada como ferramenta central para a monitorização, planeamento e gestão de eucaliptais de alta intensidade em rotações avançadas.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- Allen, H. (2019). Mediterranean Forests, Woods and Shrublands. *Geography in Britain after World War II*. https://doi.org/10.1007/978-3-030-28323-0_8
- Amoedo, A. L., Xeoespacial Para, I., Forestal, X., & Minifundio, S. : (2024). *Escola Internacional de Doutorado "Mención Industrial."*
- Anandita, K., Sinha, A. K., & Jeganathan, C. (2024). Understanding and mitigating climate change impacts on ecosystem health and functionality. *Rendiconti Lincei. Scienze Fisiche e Naturali*. <https://doi.org/10.1007/s12210-024-01259-4>
- Anderegg, W. R. L., Trugman, A. T., Badgley, G., Anderson, C. M., Bartuska, A., Ciais, P., Cullenward, D., Field, C. B., Freeman, J., Goetz, S. J., Hicke, J. A., Huntzinger, D., Jackson, R. B., Nickerson, J., Pacala, S., & Randerson, J. T. (2020). Climate-driven risks to the climate mitigation potential of forests. *Science*, 368(6497). <https://doi.org/10.1126/SCIENCE.AAZ7005>;WEBSITE:WEBSITE:AAAS-SITE;JOURNAL:JOURNAL:SCIENCE;WGROU:STRING:PUBLICATION
- Anderson, L. O., Gastellu-Etchegorry, J.-P., Brede, B., & Wulder, M. A. (2018). A unifying framework for characterizing structure from lidar and optical imagery in forest environments. *Forest Ecology and Management*, 430, 570–584.
- Appiagyei, B. D., Belhoucine-Guezouli, L., Bessah, E., & Morsli, B. (2023). The changing land use and land cover in the Mediterranean Basin: implications on forest ecosystem services. *Folia Oecologica*, 50, 60–71. <https://doi.org/10.2478/foecol-2023-0005>
- Artaxo, P., Hansson, H., Machado, L., & Rizzo, L. (2022). Tropical forests are crucial in regulating the climate on Earth. *PLOS Climate*. <https://doi.org/10.1371/journal.pclm.0000054>
- Askne, J., & Santoro, M. (2015). Estimation of biomass in boreal forests using interferometric SAR coherence and height. *IEEE Transactions on Geoscience and Remote Sensing*, 53(4), 1796–1805.
- Asner, G. P., Jones, M. O., Martin, R. E., Knapp, D. E., & Hughes, R. F. (2008). Invasive species detection in forest ecosystems using airborne imaging spectroscopy and lidar. *Remote Sensing of Environment*, 112(5), 1942–1955.
- Atkins, J., Bohrer, G., Fahey, R., Hardiman, B., Morin, T., Stovall, A., Zimmerman, N., & Gough, C. (2018). Quantifying vegetation and canopy structural complexity from terrestrial LiDAR data using the *forestr* r package. *Methods in Ecology and Evolution*, 9, 2057–2066. <https://doi.org/10.1111/2041-210X.13061>
- Ballhorn, U., & et al. (2012). A lidar-based estimation of above-ground biomass and its uncertainty in tropical forests of the Pacific. *Carbon Balance and Management*, 7(1), 1–9.

- Baltsavias, E. P. (1999). A comparison of way lidar data and photogrammetry can be used to generate digital elevation models. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54(2–3), 83–94.
- Barber, D., Mills, J., & Smith-Voysey, S. (2008). A digital surface model for 3D building reconstruction using airborne lidar data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(1), 121–134.
- Belgiu, M., & Drăgu, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/J.ISPRSJPRS.2016.01.011>
- Bonan, G. B. (2008a). Forests and Climate Change: Forcings, Feedbacks, and the Climate Benefits of Forests. *Science*, 320(5882), 1444–1449. <https://doi.org/10.1126/science.1155121>
- Bonan, G. B. (2008b). Forests and Climate Change: Forcings, Feedbacks, and the Climate Benefits of Forests. *Science*, 320(5882), 1444–1449. <https://doi.org/10.1126/science.1155121>
- Bragg, D. C., & Shelton, M. G. (2011). Lessons from 72 years of monitoring a once-cut pine-hardwood stand on the Crossett Experimental Forest, Arkansas, U.S.A. *Forest Ecology and Management*, 261(5), 911–922. <https://doi.org/10.1016/J.FORECO.2009.12.021>
- Bugmann, H. (2014). *Forests and Global Change: Forests in a greenhouse atmosphere: predicting the unpredictable?* <https://doi.org/10.1017/CBO9781107323506.017>
- Burba, G., Schmidt, A., Scott, R. L., Nakai, T., Kathilankal, J., Fratini, G., Hanson, C., Law, B., Mcdermitt, D. K., Eckles, R., Furtaw, M., & Velgersdyk, M. (2012). Calculating CO₂ and H₂O eddy covariance fluxes from an enclosed gas analyzer using an instantaneous mixing ratio. *Global Change Biology*, 18(1), 385–399. <https://doi.org/10.1111/J.1365-2486.2011.02536.X>;REQUESTEDJOURNAL:JOURNAL:13652486;JOURNAL:13652486;ISSUE:ISSUE:DOI
- Capotorti, G., Frondoni, R., Mollo, B., Tilia, A., & Blasi, C. (2011). *The contribution of plant sociology to the ecosystem service approach in urban and peri-urban areas: Evidences from a Mediterranean metropolis case study (Rome, Italy)*. 48, 127–135. <https://consensus.app/papers/the-contribution-of-plant-sociology-to-the-ecosystem-tilia-biasi/c44025a1f8575289aceabda438656f95/>
- Chazdon, R. L. (2008). Beyond Deforestation: Restoring Forests and Ecosystem Services on Degraded Lands. *Science*, 320(5882), 1458–1460. <https://doi.org/10.1126/science.1155365>
- Clark, D. B., & et al. (2011). Hyperspectral remote sensing of tropical forest biophysical properties. *Ecological Applications*, 21(8), 2289–2302.
- Dalponte, M., & Coomes, D. A. (2013). Individual tree species classification using airborne laser scanning and hyperspectral data. *Remote Sensing of Environment*, 137, 20–31.

- Díaz, S., Settele, J., Brondízio, E. S., Ngo, H. T., Agard, J., Arneeth, A., Balvanera, P., Brauman, K. A., Butchart, S. H. M., Chan, K. M. A., Lucas, A. G., Ichii, K., Liu, J., Subramanian, S. M., Midgley, G. F., Miloslavich, P., Molnár, Z., Obura, D., Pfaff, A., ... Zayas, C. N. (2019). Pervasive human-driven decline of life on Earth points to the need for transformative change. *Science*, 366(6471).
<https://doi.org/10.1126/SCIENCE.AAX3100>;WEBSITE:WEBSITE:AAAS - SITE;JOURNAL:JOURNAL:SCIENCE;WGROU:STRING:PUBLICATION
- Doblas-Miranda, E., Martínez-Vilalta, J., Lloret, F., Alvarez, A., Avila, A., Bonet, F., Brotons, L., Castro, J., Yuste, J., Díaz, M., Ferrandis, P., García-Hurtado, E., Iriondo, J., Keenan, T., Latron, J., Llusà, J., Loepfe, L., Mayol, M., Moré, G., ... Retana, J. (2015). Reassessing global change research priorities in mediterranean terrestrial ecosystems: how far have we come and where do we go from here? *Global Ecology and Biogeography*, 24, 25–43.
<https://doi.org/10.1111/GEB.12224>
- Drake, J., Dubayah, R., Clark, D., Knox, R., Blair, J., Hofton, M., Chazdon, R., Weishampel, J., & Prince, S. (2002). Estimation of tropical forest structural characteristics using large-footprint lidar. *Remote Sensing of Environment*, 79, 305–319. [https://doi.org/10.1016/S0034-4257\(01\)00281-4](https://doi.org/10.1016/S0034-4257(01)00281-4)
- Fernandes, P. M. (2013). Fire-smart management of forest landscapes in the Mediterranean basin under global change. In *Landscape and Urban Planning* (Vol. 110, Issue 1, pp. 175–182). Elsevier B.V.
<https://doi.org/10.1016/j.landurbplan.2012.10.014>
- Fichtner, A., & Haerdtle, W. (2021). *Forest Ecosystems: A Functional and Biodiversity Perspective* (pp. 383–405). https://doi.org/10.1007/978-3-030-57710-0_16
- Fichtner, A., & Härdtle, W. (2021). Forest Ecosystems: A Functional and Biodiversity Perspective. *Environmental Challenges and Solutions*.
https://doi.org/10.1007/978-3-030-57710-0_16
- Fusaro, L., Salvatori, E., Mereu, S., Marando, F., Scassellati, E., Abbate, G., & Manes, F. (2015). Urban and peri-urban forests in the metropolitan area of Rome: Ecophysiological response of *Quercus ilex* L. in two green infrastructures in an ecosystem services perspective. *Urban Forestry & Urban Greening*, 14, 1147–1156.
<https://doi.org/10.1016/J.UFUG.2015.10.013>
- Ganendra, T., Khan, N., Razak, W., Kouame, Y., & Mobarakeh, E. (2016). Unveiling topographical changes using LiDAR mapping capability: case study of Belaga in Sarawak, East-Malaysia. *IOP Conference Series: Earth and Environmental Science*, 37. <https://doi.org/10.1088/1755-1315/37/1/012010>
- García, M., & et al. (2017). Inventorying forest resources using airborne LiDAR: A review of the main issues. *Remote Sensing of Environment*, 198, 95–110.
- Garcia-Sopo, M. A., Cuartero, A., Rodríguez, P. G., & Plaza, A. (2015). Hyperspectral and lidar data integration and classification. *2015 IEEE*

- International Geoscience and Remote Sensing Symposium (IGARSS)*, 57–60. <https://doi.org/10.1109/IGARSS.2015.7325696>
- Gauquelin, T., Michon, G., Joffre, R., Duponnois, R., Génin, D., Fady, B., Dagher-Kharat, B., Derridj, A., Slimani, S., Badri, W., Alifriqui, M., Auclair, L., Simenel, R., Aderghal, M., Baudoin, E., Galiana, A., Prin, Y., Sanguin, H., Fernandez, C., & Baldy, V. (2018). Mediterranean forests, land use and climate change: a social-ecological perspective. *Regional Environmental Change*, 18, 623–636. <https://doi.org/10.1007/s10113-016-0994-3>
- Ghasemi, N., Sahebi, M., & Mohammadzadeh, A. (2011). A review on biomass estimation methods using synthetic aperture radar data. *International Journal of Geomatics and Geosciences*, 1, 776–788. <https://consensus.app/papers/a-review-on-biomass-estimation-methods-using-synthetic-ghasemi-sahebi/c1d719ab6791577b9dac259613979dab/>
- Gil-Tena, A., Morán-Ordóñez, A., Comas, L., Retana, J., Vayreda, J., & Brotóns, L. (2018). A quantitative assessment of mid-term risks of global change on forests in Western Mediterranean Europe. *Regional Environmental Change*, 19, 819–831. <https://doi.org/10.1007/s10113-018-1437-0>
- Glennie, C., Carter, W. E., Shrestha, R. L., & Dietrich, W. E. (2013). Rigorous 3D lidar calibration using automated feature-based matching. *ISPRS Journal of Photogrammetry and Remote Sensing*, 82, 26–39.
- Jafarova, F., & Hajiyeve, A. (2020). *FAO 2020*.
- James, M. R., & Robson, S. (2012). Structure-from-motion photogrammetry: A low-cost, effective tool for geoscience applications. *Geology Today*, 28(1), 28–33.
- Jayathunga, S., Owari, T., & Tsuyuki, S. (2018). Analysis of forest structural complexity using airborne LiDAR data and aerial photography in a mixed conifer–broadleaf forest in northern Japan. *Journal of Forestry Research*, 29, 479–493. <https://doi.org/10.1007/s11676-017-0441-4>
- Jung, J., & Crawford, M. (2010). *INTEGRATION OF WAVEFORM LIDAR AND HYPERSPECTRAL DATA TO ESTIMATE STRUCTURAL ATTRIBUTES OF TROPICAL FORESTS*. <https://consensus.app/papers/integration-of-waveform-lidar-and-hyperspectral-data-to-jung-crawford/0da99c2ff2135c9d885867e6b43db9bc/>
- Kane, V., Bakker, J., McGaughey, R., Lutz, J., Gersonde, R., & Franklin, J. (2010). Examining conifer canopy structural complexity across forest ages and elevations with LiDAR data. *Canadian Journal of Forest Research*, 40, 774–787. <https://doi.org/10.1139/X10-064>
- Knapp, N., Fischer, R., & Huth, A. (2018). Linking lidar and forest modeling to assess biomass estimation across scales and disturbance states. *Remote Sensing of Environment*, 205, 199–209. <https://doi.org/10.1016/J.RSE.2017.11.018>
- Kosanin, O., Markić, Z. G., Ljubičić, J., & Nešić, M. (2023). The importance of forests in the environment. *ОДРЖИВИ РАЗВОЈ И УПРАВЉАЊЕ ПРИРОДНИМ РЕСУРСИМА РЕПУБЛИКЕ СРПСКЕ*. <https://doi.org/10.7251/eoru2309579k>

- Lagouarde, J. P., Hénou, A., Kurz, B., Moreau, P., Irvine, M., Voogt, J., & Mestayer, P. (2010). Modelling daytime thermal infrared directional anisotropy over Toulouse city centre. *Remote Sensing of Environment*, 114(1), 87–105. <https://doi.org/10.1016/J.RSE.2009.08.012>
- Laurin, G. V, & et al. (2014). Above-ground biomass estimation with hyperspectral and LiDAR data in tropical forests. *International Journal of Applied Earth Observation and Geoinformation*, 30, 72–81.
- Li, Y., & Wu, H. (2009). DEM Extraction from LIDAR Data by Morphological Gradient. *2009 Fifth International Joint Conference on INC, IMS and IDC*, 1301–1306. <https://doi.org/10.1109/NCM.2009.46>
- Lim, K.-K., Treitz, P., Wulder, M., St-Onge, B., & Flood, M. (2003). Lidar remote sensing of forest structure. *Progress in Physical Geography*, 27(1), 88–106.
- Liu, A., Cheng, X., & Chen, Z. (2021). Performance evaluation of GEDI and ICESat-2 laser altimeter data for terrain and canopy height retrievals. *Remote Sensing of Environment*, 264, 112571. <https://doi.org/10.1016/J.RSE.2021.112571>
- Liu, S., Innes, J., & Wei, X. (2013). Shaping forest management to climate change: An overview. *Forest Ecology and Management*, 300, 1–3. <https://doi.org/10.1016/J.FORECO.2013.02.018>
- Liu, X., Su, Y., Hu, T., Yang, Q., Liu, B., Deng, Y., Tang, H., Tang, Z., Fang, J., & Guo, Q. (2022). Neural network guided interpolation for mapping canopy height of China's forests by integrating GEDI and ICESat-2 data. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2021.112844>
- Lombard, L., Ismail, R., & Poona, N. K. (2022). Modelling forest species using LiDar-derived metrics of forest canopy gaps. *South African Journal of Geomatics*, 9(1), 31–43. <https://doi.org/10.4314/sajg.v9i1.3>
- Luo, S., Wang, C., Xi, X., Pan, F., Peng, D., Zou, J., Nie, S., & Qin, H. (2017). Fusion of airborne LiDAR data and hyperspectral imagery for aboveground and belowground forest biomass estimation. *Ecological Indicators*, 73, 378–387. <https://doi.org/10.1016/J.ECOLIND.2016.10.001>
- Luo, S., Xu, L., Yu, J., Zhou, W., Yang, Z., Wang, S., Guo, C., Gao, Y., Xiao, J., & Shu, Q. (2023). Sampling Estimation and Optimization of Typical Forest Biomass Based on Sequential Gaussian Conditional Simulation. *Forests*. <https://doi.org/10.3390/f14091792>
- Mashhadi, N., Sanchez-Azofeifa, A., & Valbuena, R. (2025). LiDAR-derived Lorenz-entropy metric for vertical structural complexity: A comparative study of tropical dry and moist forests. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2024.114545>
- Matteucci, G., Cammarano, M., Dezi, S., Mancini, M., Mugnozza, G., & Magnani, F. (2013). *Climate Change Impacts on Forests and Forest Products in the Mediterranean Area*. 71–100. https://doi.org/10.1007/978-94-007-5772-1_5
- Mitchard, E. T. A. (2018). The tropical forest carbon cycle and climate change. *Nature* 2018 559:7715, 559(7715), 527–534. <https://doi.org/10.1038/s41586-018-0300-2>

- Molua, C., & Ataman, J. (2024). Applications of Lidar Technology in Urban Geophysical Surveys. *June-July 2024*. <https://doi.org/10.55529/ijitc.44.47.58>
- Montealegre, A., Lamelas, M. T., & Riva, J. (2014). Filtering methods and interpolation routines assessment for generating Digital Elevation Models to normalize LiDAR point clouds in forestry applications in a Mediterranean environment. *IEEE Transactions on Geoscience and Remote Sensing*, 52(9), 5930–5944. <https://doi.org/10.1109/TGRS.2013.2293531>
- Montesano, P., Cook, B., Sun, G., Simard, M., Nelson, R., Ranson, K., Zhang, Z., & Luthcke, S. (2013). Achieving accuracy requirements for forest biomass mapping: A spaceborne data fusion method for estimating forest biomass and LiDAR sampling error. *Remote Sensing of Environment*, 130, 153–170. <https://doi.org/10.1016/J.RSE.2012.11.016>
- Negi, J., Sharma, S., & Sharma, D. (1988). Comparative Assessment of Methods for Estimating Biomass in Forest Ecosystem. *The Indian Forester*, 114, 136–144. <https://consensus.app/papers/comparative-assessment-of-methods-for-estimating-biomass-negi-sharma/d631cb7984765edeaf785c3d1ccf5efe/>
- Neuenschwander, A., Duncanson, L., Montesano, P., Minor, D., Guenther, E., Hancock, S., Wulder, M., White, J. C., Purslow, M., Thomas, N., Mandel, A., Feng, T., Armston, J., Kellner, J. R., Andersen, H. E., Boschetti, L., Fekety, P., Hudak, A., Pisek, J., ... Stereńczak, K. (2024). Towards global spaceborne lidar biomass: Developing and applying boreal forest biomass models for ICESat-2 laser altimetry data. *Science of Remote Sensing*. <https://doi.org/10.1016/j.srs.2024.100150>
- Nguyen, M., Ancev, T., & Randall, A. (2020). Forest governance and economic values of forest ecosystem services in Vietnam. *Land Use Policy*, 97, 103297. <https://doi.org/10.1016/J.LANDUSEPOL.2018.03.028>
- Ollinger, S. (2003). *Forest Ecosystems*. <https://doi.org/10.2307/1937056>
- Palahí, M., Mavsar, R., Gracia, C., & Birot, Y. (2008). *Mediterranean Forests Under Focus*. 10, 676–688. <https://doi.org/10.1505/for.10.4.676>
- Pan, S., Guan, H., Yu, Y., Li, J., & Peng, D. (2019). A Comparative Land-Cover Classification Feature Study of Learning Algorithms: DBM, PCA, and RF Using Multispectral LiDAR Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12, 1314–1326. <https://doi.org/10.1109/JSTARS.2019.2899033>
- Pan, Y., Birdsey, R. A., Fang, J., Houghton, R., Kauppi, P. E., Kurz, W. A., Phillips, O. L., Shvidenko, A., Lewis, S. L., Canadell, J. G., Ciais, P., Jackson, R. B., Pacala, S. W., McGuire, A. D., Piao, S., Rautiainen, A., Sitch, S., & Hayes, D. (2011). A Large and Persistent Carbon Sink in the World's Forests. *Science*, 333(6045), 988–993. <https://doi.org/10.1126/science.1201609>
- Pan, Y., Birdsey, R. A., Phillips, O. L., & Jackson, R. B. (2013). The structure, distribution, and biomass of the world's forests. In *Annual Review of Ecology, Evolution, and Systematics* (Vol. 44, pp. 593–622). Annual Reviews Inc. <https://doi.org/10.1146/annurev-ecolsys-110512-135914>

- Pan, Y., & et al. (2020). Estimating forest aboveground biomass by combining hyperspectral and LiDAR data: A comparison of machine learning algorithms. *Remote Sensing*, 12(5), 777.
- Peñuelas, J., Sardans, J., Filella, I., Estiarte, M., Llusà, J., Ogaya, R., Carnicer, J., Bartrons, M., Rivas-Ubach, A., Grau, O., Peguero, G., Margalef, O., Pla-Rabès, S., Stefanescu, C., Asensio, D., Preece, C., Liu, L., Verger, A., Barbeta, A., ... Terradas, J. (2017). Impacts of Global Change on Mediterranean Forests and Their Services. *Forests*, 8, 463. <https://doi.org/10.3390/F8120463>
- Praveen, Poonia, P., Abhishek, Kumar, M., Devi, A., Manisha, & Dikshant. (2025). Forests in the Anthropocene: Addressing Climate Change Impacts on Ecosystem Dynamics. *Journal of Geography, Environment and Earth Science International*. <https://doi.org/10.9734/jgeesi/2025/v29i3873>
- Putz, F. E., & Redford, K. H. (2010). The importance of defining “Forest”: Tropical forest degradation, deforestation, long-term phase shifts, and further transitions. *Biotropica*, 42(1), 10–20. <https://doi.org/10.1111/j.1744-7429.2009.00567.x>
- Raj, A., Jhariya, M., Yadav, D., & Banerjee, A. (2020). *Forests for Resource Management and Environmental Protection*. 1–24. <https://doi.org/10.1201/9780429276026-1>
- Rajasugunasekar, D., Patel, A. K., Devi, K. B., Singh, A., Selvam, P., & Chandra, A. (2023). An Integrative Review for the Role of Forests in Combating Climate Change and Promoting Sustainable Development. *International Journal of Environment and Climate Change*. <https://doi.org/10.9734/ijecc/2023/v13i113614>
- Reid, W., Mooney, H., Cropper, A., Capistrano, D., Carpenter, S., & Chopra, K. (2005). *Millennium Ecosystem Assessment. Ecosystems and human well-being: synthesis*.
- Ryo, M., & Rillig, M. C. (2017). Statistically reinforced machine learning for nonlinear patterns and variable interactions. *Ecosphere*, 8(11). <https://doi.org/10.1002/ecs2.1976>
- Shao, Z., & Er, M. (2016). Efficient Leave-One-Out Cross-Validation-Based Regularized Extreme Learning Machine. *Neurocomputing*, 194. <https://doi.org/10.1016/j.neucom.2016.02.058>
- Shi, G., Ma, P., Hu, X., Huang, B., & Lin, H. (2021). Surface response and subsurface features during the restriction of groundwater exploitation in Suzhou (China) inferred from decadal SAR interferometry. *Remote Sensing of Environment*, 256, 112327. <https://doi.org/10.1016/J.RSE.2021.112327>
- Singh, R. P., Dubey, C. S., Singh, S. K., Shukla, D. P., Mishra, B. K., Tajbakhsh, M., Ningthoujam, P. S., Sharma, M., & Singh, N. (2013). A new slope mass rating in mountainous terrain, Jammu and Kashmir Himalayas: Application of geophysical technique in slope stability studies. *Landslides*, 10(3), 255–265. <https://doi.org/10.1007/s10346-012-0323-y>

- Sodhi, H. S. (2021). Application of Remote Sensing for Above-Ground Biomass Estimation. *International Journal of Science and Research (IJSR)*. <https://doi.org/10.21275/sr21403150310>
- Solomou, A., Proutsos, N., Karetos, G., & Tsagari, K. (2017). Effects of Climate Change on Vegetation in Mediterranean Forests: A review. *International Journal of Environment, Agriculture and Biotechnology*, 2, 238666. <https://doi.org/10.22161/IJEAB/2.1.31>
- Somogyi, Z., Cienciala, E., Mäkipää, R., Muukkonen, P., Lehtonen, A., & Weiss, P. (2007). Indirect methods of large-scale forest biomass estimation. *European Journal of Forest Research*, 126, 197–207. <https://doi.org/10.1007/s10342-006-0125-7>
- Stovall, A., & Shugart, H. H. (2014). Forest aboveground biomass estimation using LiDAR and hyperspectral data fusion in a tropical forest in Panama. *Forests*, 5(3), 560–577.
- Sun, M., Cui, L., Park, J., García, M., Zhou, Y., Silva, C., He, L., Zhang, H., & Zhao, K. (2022). Evaluation of NASA's GEDI Lidar Observations for Estimating Biomass in Temperate and Tropical Forests. *Forests*. <https://doi.org/10.3390/f13101686>
- Suwethasri, D., Baranidharan, K., Ravi, R., Tilak, M., Kalpana, M., Ragunath, K., Hemalatha, P., Vijayabhama, M., Bargavi, S., & Eniya, A. (2025). A critical review of exploring the recent trends and technological advancements in forest biomass estimation. *Plant Science Today*. <https://doi.org/10.14719/pst.6695>
- Takagi, K., & et al. (2015). Estimating aboveground biomass and carbon stocks of deciduous broad-leaved forests using LiDAR data and field observations. *Remote Sensing*, 7(11), 15053–15073.
- Tamiminia, H., Salehi, B., Mahdianpari, M., Beier, C., Johnson, L., Phoenix, D., & Mahoney, M. (2022). Decision tree-based machine learning models for above-ground biomass estimation using multi-source remote sensing data and object-based image analysis. *Geocarto International*, 37, 12763–12791. <https://doi.org/10.1080/10106049.2022.2071475>
- Telbisz, T., Látos, T., Deák, M., Székely, B., Koma, Z., & Standovár, T. (2016). The advantage of lidar digital terrain models in doline morphometry compared to topographic map based datasets – Aggtelek karst (Hungary) as an example. *Acta Carsologica*, 45(1), 5–18. <https://doi.org/10.3986/AC.V45I1.4138>
- Tomé, M., Tomé, J., Ribeiro, F., Faias, S., Catedrática, P., & Florestal, E. (2007). Equação de Volume Total, Volume Percentual e de Perfil do Tronco para *Eucalyptus globulus* Labill. em Portugal. In *Silva Lusitana* (Vol. 15, Issue 1).
- Tusa, E., Monnet, J., Barr'e, J., Dalla Mura, M., & Chanussot, J. (2020). Fusion of LiDAR and hyperspectral data for semantic segmentation of forest tree species. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B3-2020, 487–494. <https://doi.org/10.5194/isprs-archives-xliii-b3-2020-487-2020>

- Viera, M., Caldeira, M., Rovani, F. F. M., & Castro, K. C. (2016). *Ecological and Environmental Aspects of Nutrient Cycling in the Atlantic Forest, Brazil*. <https://doi.org/10.5772/64188>
- Vizzarri, M., Bottalico, F., Antonello, L., Barbati, A., Chirici, G., Corona, P., Cullotta, S., Garfi, V., Giannico, V., Laforteza, R., Veca, D., Lombardi, F., Maetzke, F., Marchetti, M., Nocentini, S., Pesola, L., Riccioli, F., Travaglini, D., & Sallustio, L. (2016). *The MIMOSE approach to support large-scale statistics on forest ecosystem services*. 1–8. <https://consensus.app/papers/the-mimose-approach-to-support-largescale-statistics-on-barbati-lombardi/4691f8fbcaaa52f7998540b90fe24fe6/>
- Vosselman, G., & Maas, H.-G. (2010). *Airborne and Terrestrial Laser Scanning*. CRC Press.
- Wakawa, L. (2016). Biomass estimation in forest ecosystems - a review. *Journal of Research in Forestry, Wildlife and Environment*, 8, 126–144. <https://consensus.app/papers/biomass-estimation-in-forest-ecosystems-a-review-wakawa/6a8825b322d75af2a4685d404ee29dfe/>
- Weisz, H., Krausmann, F., Amann, C., Eisenmenger, N., Erb, K.-H., Hubacek, K., & Fischer-Kowalski, M. (2007). The physical economy of the European Union: Cross-country comparison and determinants of material consumption. *Ecological Economics*, 58(4), 676–698. <https://doi.org/10.1016/j.ecolecon.2006.09.007>
- Westoby, M. J., Brasington, J., Glasser, N. F., Hambrey, M. J., & Reynolds, J. M. (2012). ‘Structure-from-Motion’ photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology*, 179, 300–314.
- Whitworth-Hulse, J. I., Magliano, P. N., Zeballos, S. R., Aguiar, S., & Baldi, G. (2021). Global patterns of rainfall partitioning by invasive woody plants. *Global Ecology and Biogeography*, 30(1), 235–246. <https://doi.org/10.1111/GEB.13218>;JOURNAL:JOURNAL:14668238;WG ROUP:STRING:PUBLICATION
- Wulder, M. A., Coops, N. C., Hudak, A. T., Morsdorf, F., Nelson, R. F., Newnham, G. J., Renslow, M., & Vierling, L. A. (2012). Lidar remote sensing of forest environments. In *Remote Sensing of Forest Environments* (pp. 3–10). Springer.
- Yan, Y., Lei, J., & Huang, Y. (2024). Forest Aboveground Biomass Estimation Based on Unmanned Aerial Vehicle–Light Detection and Ranging and Machine Learning. *Sensors*, 24(21). <https://doi.org/10.3390/s24217071>
- Yastikli, N., & Cetin, Z. (2017). AUTOMATIC 3D BUILDING MODEL GENERATIONS WITH AIRBORNE LiDAR DATA. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 411–414. <https://doi.org/10.5194/ISPRS-ANNALS-IV-4-W4-411-2017>
- Yu, Q., Ryan, M., Ji, W., Prihodko, L., Anchang, J., Kahiu, N., Nazir, A., Dai, J., & Hanan, N. (2024). Assessing canopy height measurements from ICESat-2 and GEDI orbiting LiDAR across six different biomes with G-LiHT LiDAR. *Environmental Research: Ecology*, 3. <https://doi.org/10.1088/2752-664x/ad39f2>

- Zhang, B., Wang, Z., Tiantian, Wang, Z., Li, H., Ji, W., He, M., Jiao, A., & Feng, Z. (2025). Correcting forest aboveground biomass biases by incorporating independent canopy height retrieval with conventional machine learning models using GEDI and ICESat-2 data. *Ecol. Informatics*, 86, 103045. <https://doi.org/10.1016/j.ecoinf.2025.103045>
- Zhang, X., Chen, P., Sun, B., & Wang, Y. (2013). A new filtering approach of lidar data based on topographic change detection. *Proceedings of SPIE*, 8917. <https://doi.org/10.1117/12.2031162>
- Zhang, Z., Cao, L., & She, G. (2017). Estimating Forest Structural Parameters Using Canopy Metrics Derived from Airborne LiDAR Data in Subtropical Forests. *Remote. Sens.*, 9, 940. <https://doi.org/10.3390/RS9090940>
- Zhao, F., Guo, Q., & Kelly, M. (2012). Allometric equation choice impacts lidar-based forest biomass estimates: A case study from the Sierra National Forest, CA. *Agricultural and Forest Meteorology*, 165, 64–72. <https://doi.org/10.1016/J.AGRFORMET.2012.05.019>
- Zhao, X., Su, Y., Li, W., Hu, T., Liu, J., & Guo, Q. (2018). A Comparison of LiDAR Filtering Algorithms in Vegetated Mountain Areas. *Canadian Journal of Remote Sensing*, 44, 287–298. <https://doi.org/10.1080/07038992.2018.1481738>
- Zhong, H., Lin, W., Liu, H., Ma, N., Liu, K., Cao, R., Wang, T., & Ren, Z. (2022). Identification of tree species based on the fusion of UAV hyperspectral image and LiDAR data in a coniferous and broad-leaved mixed forest in Northeast China. *Frontiers in Plant Science*, 13, 964769. <https://doi.org/10.3389/fpls.2022.964769>
- Zhou, Y., & et al. (2022). Improving forest aboveground biomass estimation using fusion of multi-sensor data and deep learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 182, 163–177.
- Zhu, X., Nie, S., Zhu, Y., Chen, Y., Yang, B., & Li, W. (2023). Evaluation and Comparison of ICESat-2 and GEDI Data for Terrain and Canopy Height Retrievals in Short-Stature Vegetation. *Remote. Sens.*, 15, 4969. <https://doi.org/10.3390/rs15204969>