

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS E TECNOLOGIAS PARA SUSTENTABILIDADE
PROGRAMA DE PÓS-GRADUAÇÃO EM PLANEJAMENTO E USO DE RECURSOS
RENOVÁVEIS

Maria Inês Corrêa de Paula Santos

**LIDAR NO SETOR FLORESTAL: CUBAGEM DE PILHAS DE MADEIRA E
FERRAMENTA PARA DIAGNÓSTICO DE ÁRVORES URBANAS**

Sorocaba

2026

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS E TECNOLOGIAS PARA SUSTENTABILIDADE

PROGRAMA DE PÓS-GRADUAÇÃO EM PLANEJAMENTO E USO DE RECURSOS
RENOVÁVEIS

Maria Inês Corrêa de Paula Santos

**LIDAR NO SETOR FLORESTAL: CUBAGEM DE PILHAS DE MADEIRA E
FERRAMENTA PARA DIAGNÓSTICO DE ÁRVORES URBANAS**

Tese apresentada ao Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis para obtenção do título de Doutora em Planejamento e Uso de Recursos Renováveis da Universidade Federal de São Carlos. Área de concentração: Biometria e Planejamento Florestal.

Orientação: Prof. Dr. Cláudio Roberto Thiersch
Orientação no exterior: Prof. Dr. Francesco Ferrini

Coorientação: Dr. Cristiano Rodrigues Reis
Financiamento: Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Sorocaba

2026

Paula Santos, Maria Inês Corrêa de

LiDAR no setor florestal: cubagem de pilhas de madeira
e ferramenta para diagnóstico de árvores urbanas /
Maria Inês Corrêa de Paula Santos -- 2026.
104f.

Tese (Doutorado) - Universidade Federal de São Carlos,
campus Sorocaba, Sorocaba

Orientador (a): Cláudio Roberto Thiersch

Banca Examinadora: Melodie Kern Sarubo Dorth

Sinegalia, Ximena Mendes de Oliveira, Carla Américo,
Livia Lanzi Aló

Bibliografia

1. Visão computacional. 2. Biometria. 3. Gestão. I. Paula
Santos, Maria Inês Corrêa de. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática
(SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Maria Aparecida de Lourdes Mariano -
CRB/8 6979

Folha de Aprovação

Defesa de Tese de Doutorado da candidata Maria Inês Corrêa de Paula Santos realizada em 17/06/2026.

Comissão Julgadora:

Profa. Dra. Melodie Kern Sarubo Dorth Sinegalia (UFSCar)

Profa. Dra. Ximena Mendes de Oliveira (UFSCar)

Profa. Dra. Carla Américo (UNESP)

Dra. Livia Lanzi Aló

Prof. Dr. Cláudio Roberto Thiersch (UFSCar)

À Jandira (in memoriam),
na saudade que aperta, encontro a força e a luz
que me guia.

AGRADECIMENTO

Escrever os agradecimentos nunca é simples. Sempre fica a dúvida: quem colocar, como não esquecer ninguém que fez parte dessa caminhada? Foram quatro anos intensos, cheios de encontros, despedidas, aprendizados e desafios. Nesse tempo, conheci pessoas incríveis no doutorado, em congressos e no doutorado sanduíche, reforcei amizades que vêm desde o mestrado e a graduação, e mantive ao meu lado pessoas que já fazem parte da minha vida há mais de 20 anos.

À minha família, não existem palavras suficientes. Foram quatro anos em que vocês estiveram comigo em todos os momentos, nos dias felizes e, principalmente, nos mais difíceis. Mesmo quando eu já estava pronta para desistir, vocês não deixaram. Sou grata todos os dias por fazer parte dessa família. Muito obrigada, mãe e pai, por tudo. À minha tia, que é uma segunda mãe para mim, e à minha madrastra, que eu nem consigo chamar assim, porque é, antes de tudo, uma amiga.

Aos amigos que permaneceram ao meu lado mesmo quando tudo parecia mais difícil, meu muito obrigada: Carla, Juliana, Nathalia, Suellen, Maria e Mellodie, Adriel, Marcia. À Camila, Mônica e Paulo, que, mesmo longe, sempre estiveram perto.

Obrigada, Márcia, por todo o apoio durante o doutorado sanduíche, mesmo estando nos Estados Unidos, a quilômetros de distância. À Fiorella e sua família, por tornarem esse período mais leve, mais alegre e cheio de música, e ao professor Francesco pela oportunidade.

Fernando, obrigada por toda a ajuda em campo, no laboratório e pela amizade ao longo desse caminho. Fabiana e Murilo, obrigada por deixarem os dias no laboratório mais leves e divertidos. Às professoras Franciane e Mônica, obrigada pelo apoio, pelas conversas e por serem exemplos de profissionais que eu levo como inspiração. Luciana, obrigada por toda a ajuda.

À Eucatex, especialmente ao Lucas, por proporcionar uma boa parte do trabalho em campo. À UNESP e ao Instituto Federal de São Paulo, pelas oportunidades de aprender e vivenciar à docência.

Professor Cláudio, minha gratidão por toda a caminhada, não só nesses quatro anos, mas também antes deles. Obrigada por acreditar na minha ideia de doutorado e por não desistir dela.

E, por fim, vó... obrigada por tudo. Queria muito que a senhora estivesse aqui para ver esse momento, mas sei o quanto foi essencial para que eu não desistisse. Esse trabalho também é seu.

A visão computacional não é apenas processar pixels, é a construção de significado a partir do caos visual, como a mente humana dá forma ao mundo invisível.

(FEI-FEI LI, adaptado)

RESUMO

PAULA-SANTOS, Maria Inês Corrêa de. **LiDAR no setor florestal: cubagem de pilhas de madeira e ferramenta para diagnóstico de árvores urbanas**. 2026. Tese (Doutorado em Planejamento e Uso de Recursos Renováveis) – Universidade Federal de São Carlos, Campus Sorocaba, Sorocaba, 2026.

A mensuração e o monitoramento de recursos florestais dependem, em grande parte, de métodos de campo onerosos, de caráter amostral e sujeitos à subjetividade do avaliador, seja na quantificação de estoques de madeira, ou no diagnóstico de árvores urbanas. Nesse cenário, a visão computacional e, em particular, a tecnologia LiDAR (*Light Detection and Ranging*), hoje disponível em dispositivos portáteis e de custo acessível, desponta como alternativa capaz de substituir estimativas visuais por mensuração instrumental. Diante disso, o objetivo deste estudo foi avaliar a aplicação da visão computacional no setor florestal, utilizando o LiDAR em três contextos, no mapeamento do estado da arte, o desenvolvimento de um método de cubagem de pilhas de madeira e a caracterização de árvores urbanas para análise de risco de queda.

A revisão sistemática, conduzida nas bases Web of Science e Scopus conforme o protocolo PRISMA, identificou 4.418 documentos, dos quais 155 artigos atenderam aos critérios finais de elegibilidade. Observou-se crescimento expressivo das publicações a partir de 2019, distribuídas em cinco temas: classificação de espécies arbóreas (50 artigos), monitoramento florestal (41), medição de parâmetros de árvores (26), segmentação e contagem de árvores (20) e detecção de defeitos (18). Os autores concentraram-se na China e nos Estados Unidos.

Desenvolveu-se então um método para estimativa volumétrica de pilhas de madeira de *Eucalyptus* sp. a partir de nuvens de pontos obtidas com um iPhone 14 Pro e um scanner laser móvel portátil (HMLS, do inglês *Hand-held Mobile Laser Scanner*), compreendendo remoção de ruído, normalização, estimativa da área da face por contorno côncavo e voxelização adaptativa para cálculo do fator de cubicação, com automação em aplicativo web desenvolvido em linguagem R. Os erros em relação à medição de referência variaram de -6,8% a +8,3%, todos dentro da faixa de aceitabilidade. Por fim o HMLS foi aplicado ao diagnóstico de árvores urbanas em uma praça pública no município de Piedade, SP, mediante adaptação do protocolo TRAQ (*Tree Risk Assessment Qualification*). Dos 19 indivíduos avaliados, o DAP variou de 14,7 a 91,4 cm e a inclinação média dos fustes foi de 5,24°, com apenas dois indivíduos na faixa de atenção. Conclui-se que o uso do LiDAR portátil constitui alternativa viável, replicável e de baixo custo aos procedimentos convencionais, ao permitir avaliação dos estoques de madeira sem exposição do operador a riscos e ao objetivar os parâmetros geométricos da análise de risco arbóreo.

Palavras-chave: visão computacional; biometria; gestão.

ABSTRACT

PAULA-SANTOS, Maria Inês Corrêa de. **LiDAR in the forestry sector: log pile scaling and a tool for urban tree diagnosis**. 2026. Thesis (Doctorate in Planning and Use of Renewable Resources) – Federal University of São Carlos, Sorocaba Campus, Sorocaba, 2026.

The measurement and monitoring of forest resources depend largely on costly field methods that are sample-based and subject to the evaluator's subjectivity, whether in quantifying timber stocks or in diagnosing urban trees. In this context, computer vision—and, in particular, LiDAR (Light Detection and Ranging) technology, now available in portable, affordable devices—emerges as an alternative capable of replacing visual estimates with instrumental measurement. Accordingly, the objective of this study was to evaluate the application of computer vision in the forestry sector, using LiDAR in three contexts: mapping the state of the art, developing a method for scaling log piles, and characterizing urban trees for fall-risk analysis.

The systematic review, conducted in the Web of Science and Scopus databases following the PRISMA protocol, identified 4,418 documents, of which 155 articles met the final eligibility criteria. A marked increase in publications was observed from 2019 onward, distributed across five themes: tree species classification (50 articles), forest monitoring (41), tree parameter measurement (26), tree segmentation and counting (20), and defect detection (18). Authorship was concentrated in China and the United States.

A method was then developed for the volumetric estimation of *Eucalyptus* sp. log piles from point clouds obtained with an iPhone 14 Pro and a Hand-held Mobile Laser Scanner (HMLS). The method comprised noise removal, normalization, estimation of the face area by concave hull, and adaptive voxelization to calculate the stacking factor, with automation in a web application developed in the R language. Errors relative to the reference measurement ranged from -6.8% to $+8.3\%$, all within the acceptable range. Finally, the HMLS was applied to the diagnosis of urban trees in a public square in the municipality of Piedade, São Paulo, through an adaptation of the TRAQ (Tree Risk Assessment Qualification) protocol. Of the 19 individuals evaluated, DBH ranged from 14.7 to 91.4 cm and the mean stem inclination was 5.24° , with only two individuals in the attention range. It is concluded that the use of portable LiDAR constitutes a viable, replicable, and low-cost alternative to conventional procedures, as it enables the assessment of timber stocks without exposing the operator to risks and objectifies the geometric parameters of arboreal risk analysis.

Keywords: computer vision; biometrics; management.

LISTA DE FIGURAS

Figura 1 - Representação esquemática do processo de RSL.	6
Figura 2 - Fluxograma PRISMA do processo de seleção dos artigos.	7
Figura 3 - Distribuição do número de artigo por ano encontrados por meio da revisão sistemática de literatura.	33
Figura 4 - Localização dos autores e coautores dos artigos analisados.	34
Figura 5 - Fluxograma das palavras mais encontradas nos artigos selecionados na revisão sistemática de literatura.	35
Figura 6 - LiGrip O1 Lite.	51
Figura 7 - Ilustração da localização do LiDAR no Iphone 14 Pro.	51
Figura 8 - Ilustração de um Pivotex.	52
Figura 9 - Pilha teste de madeira: A) parte frontal da pilha e B) a parte oposta.	53
Figura 10 - Pilha teste catalogada: A), vista frontal com cor amarela e B) lado oposto marcado com cor laranja.	54
Figura 11 - Fluxograma para encontrar o diâmetro equivalente.	54
Figura 12 - Área seccional e diâmetro equivalente.	56
Figura 13 - Aplicação do algoritmo concave hull na pilha teste.	57
Figura 14 - Cálculo da área da face da pilha pelo algoritmo concave hull.	60
Figura 15 - Fatia de maior densidade de pixels, selecionada como seção transversal representativa da pilha.	61
Figura 16 – Erro percentual de estimativa de volume por pilha obtido pelo método final com MBR seletivo.	66
Figura 17 - Interface inicial do aplicativo web.	67
Figura 18- Localização da praça Carlos Augusto no município de Piedade, estado de São Paulo.	76
Figura 19 - Histograma da distribuição vertical de pontos.	81
Figura 20 - Painel investigativo da árvore.	82
Figura 21 - Visualização do tronco.	84
Figura 22 - Análise da copa.	84

LISTA DE TABELAS

Tabela 1 - Quantidade de publicações encontradas na revisão sistemática.....	8
Tabela 2 - Artigos encontrados sobre o tema medição de parâmetros arbóreos.	10
Tabela 3 - Artigos encontrados sobre o tema segmentação e contagem de árvores.....	14
Tabela 4 - Artigos encontrados sobre o tema classificação de espécies arbóreas.	17
Tabela 5 - Artigos encontrados sobre o tema detecção de defeitos e anomalias.....	24
Tabela 6 - Artigos encontrados sobre o tema monitoramento florestal.....	27
Tabela 7 - Estimativa de volume da pilha utilizando os dados da frente e da costa da mesma imageados por LiDAR e medidos por fita e suta.....	63
Tabela 8 - Medição do volume de madeira da pilha utilizando a área da face da frente e das costas da pilha.....	64
Tabela 9 - Parâmetros de voxelização por pilha.....	65
Tabela 10 - Volume estimado por LiDAR versus volumes reais de referência.	66
Tabela 11 - Indivíduos situados na faixa de atenção de inclinação.....	86

LISTA DE QUADROS

Quadro 1 - Temas encontrados na revisão sistemática de literatura.....	6
Quadro 2 - Correspondência entre os campos do protocolo TRAQ e as métricas derivadas da nuvem de pontos.....	77
Quadro 3 - Árvores a serem consideradas para análise de nível 3.	87

SUMÁRIO

1. INTRODUÇÃO	1
2. APLICAÇÕES DA VISÃO COMPUTACIONAL NO SETOR FLORESTAL: UMA REVISÃO SISTEMÁTICA DA LITERATURA	3
2.1. INTRODUÇÃO.....	4
2.2. METODOLOGIA.....	5
2.3. RESULTADOS E DISCUSSÕES.....	7
2.4. CONCLUSÕES	37
2.5. REFERÊNCIAS	38
3. USO DA TECNOLOGIA LIDAR NA ESTIMATIVA VOLUMÉTRICA DE PILHAS DE MADEIRA	47
3.1. INTRODUÇÃO.....	48
3.2. MATERIAIS E MÉTODOS.....	50
3.2.1. Instrumentos utilizados	50
3.2.2. Pilha teste	52
3.2.3. Pilhas em campo (tamanho não comercial).....	58
3.3. RESULTADOS E DISCUSSÕES.....	62
3.3.1. Pilha teste	62
3.3.2. Pilhas em campo (tamanho não comercial).....	65
3.4. CONCLUSÕES	68
3.5. REFERÊNCIAS	68
4. AVALIAÇÃO DO USO DO HAND-HELD MOBILE LASER SCANNER NO DIAGNÓSTICO DE ÁRVORES URBANAS.....	72
4.1. INTRODUÇÃO.....	73
4.2. METODOLOGIA.....	75
4.2.1. Área de Estudo.....	75
4.2.2. Análise de Risco de Queda	76
4.2.3. Processamento da nuvem de pontos	80
4.2.4. Extração de métricas dendrométricas e estruturais.....	83
4.3. RESULTADOS	85
4.4. CONCLUSÃO.....	88
4.5. REFERÊNCIAS	89
5. CONCLUSÕES GERAIS	91
6. REFERÊNCIAS	92

1. INTRODUÇÃO

No Brasil a tecnologia avança em ritmo acelerado, ao se tornar onipresente no dia a dia das pessoas e impulsionar a demanda por ferramentas inovadoras, um reflexo direto da crescente globalização (Oliveira et al., 2020).

Essa evolução tecnológica busca, cada vez mais, compreender e replicar aspectos da inteligência humana. Um exemplo é a visão computacional, que se dedica a replicar a visão humana em ambientes digitais. Este campo de estudo foca em entender as relações entre os dados visuais e os elementos do mundo real, como a estrutura 3D de um objeto ou sua classificação. Este conhecimento é, então, utilizado para gerar novas inferências, a partir de novas imagens (Prince, 2012).

Tanto os sistemas de visão biológica, quanto os computacionais, compartilham componentes fundamentais: uma fonte de radiação, uma câmera, um sensor, uma unidade de processamento e um atuador. Um sistema completo de visão computacional integra estes elementos, a fim de cobrir uma gama de processos, desde a formação da imagem até a obtenção de uma resposta às ações percebidas (Jahne, 2000).

Um exemplo de sensor amplamente utilizado é o LiDAR (*Light Detection and Ranging*), criado por Ring em 1963, o termo une os vocábulos "luz" e "radar", em analogia ao desenvolvimento do radar (*Radio Detection and Ranging*) (Dong e Chen, 2017). Seu princípio consiste em emitir pulsos de luz direcionados a uma superfície ou objeto e, ao atingir o alvo, a luz é refletida de volta ao sistema laser. A partir dos princípios de triangulação ou da medição do tempo de retorno do pulso refletido (*Time-of-Flight*), o sistema calcula a distância entre o sensor e o objeto, podendo operar a partir de plataformas terrestres fixas ou móveis, aeronaves ou sistemas orbitais, como satélites ou estações espaciais (Wagner et al., 2004).

Na maioria das vezes, esses modelos são gerados a partir de sensores aéreos ou de satélite, e as representações são melhoradas a partir do mapeamento de texturas realizado, majoritariamente, com imagens ópticas (Mastin et al., 2009; Kaminsky et al., 2009).

Uma das principais aplicações dessa tecnologia é o scanner laser terrestre (TLS, do inglês *Terrestrial Laser Scanner*), que coleta coordenadas XYZ de vários pontos no solo via emissão de pulsos de laser, medindo a distância do dispositivo ao alvo (Vosselman e Maas, 2010). Além das coordenadas 3D (x, y, z), os dados podem incluir a intensidade do eco e o número de ecos, que podem ser usados na caracterização dos objetos (Balenović et al., 2020).

Ao longo dos últimos anos, o TLS evoluiu de ferramenta experimental a instrumento consolidado na mensuração florestal, permitindo a coleta de nuvens de pontos densas com alta resolução das estruturas 3D de árvores e do dossel (Calders et al., 2020).

A reconstrução geométrica dessas nuvens de pontos em modelos 3D, comumente chamada de Modelos Estruturais Quantitativos (QSMs, do inglês *Quantitative Structural Models*), é uma aplicação inovadora na silvicultura, pois permite avaliar diversas características florestais relevantes de forma não destrutiva, como padrões de volume, arquitetura de copa, ecologia e propriedades estruturais de ramos (Ver Planck e Mac-Farlane, 2014; Lau et al., 2018; Lehnebach et al., 2018; Jackson et al., 2019).

Infelizmente, esses dispositivos apresentam custo elevado, requerem manuseio cuidadoso por especialistas e calibração complexa, além de demandar tempo considerável para a aquisição de dados em campo, o que restringe sua adoção em larga escala nos processos produtivos florestais (Lindberg et al., 2012).

Diante dessas limitações, o escaneamento móvel a laser portátil, principalmente na modalidade de mão (HMLS, do inglês *Hand-held Mobile Laser Scanner*), tem se consolidado como uma alternativa promissora em relação ao TLS, apresentando maior velocidade de aquisição de dados, com capacidade de escanear uma parcela de 400 m² em aproximadamente 3 a 10 minutos, maior mobilidade entre as árvores, menor exigência operacional, peso reduzido do equipamento, geolocalização eficiente dos dados, preço consideravelmente acessível e possibilidade de combinação com outras técnicas de mapeamento convencionais (Distefano et al., 2021; Liang et al., 2014; Balenović et al., 2020).

Com isso, o objetivo deste estudo foi avaliar a aplicação da visão computacional, considerando o LiDAR como uma das tecnologias inseridas nesse campo, no setor florestal em diferentes contextos: por meio de uma revisão sistemática da literatura para mapeamento do estado da arte; do desenvolvimento e validação de um método de cubagem de pilhas de madeira por escaneamento LiDAR móvel a mão; e da caracterização dendrométrica individual de árvores urbanas a partir de nuvens de pontos obtidas por escaneamento terrestre, com aplicações em praças e vias arborizadas no Brasil para análise de risco de queda.

2. APLICAÇÕES DA VISÃO COMPUTACIONAL NO SETOR FLORESTAL: UMA REVISÃO SISTEMÁTICA DA LITERATURA

RESUMO

A visão computacional tem se consolidado como uma ferramenta promissora para a mensuração e o monitoramento de recursos florestais, oferecendo alternativas eficientes aos métodos tradicionais de campo. Este estudo realizou uma revisão sistemática de literatura com o objetivo de analisar como e em que medida a visão computacional tem sido aplicada no contexto florestal. A busca foi conduzida nas bases de dados *Web of Science* e *Scopus*, utilizando os termos "*Machine vision and forestry*", "*computer vision and forestry*", "*deep learning and image classification and forestry*", e seus equivalentes em português. Dos 4.418 documentos inicialmente identificados, 155 artigos foram selecionados após três etapas de filtragem. Os trabalhos foram classificados em cinco categorias temáticas: monitoramento florestal (43), classificação de espécies arbóreas (40), medição de parâmetros de árvores (31), segmentação e contagem de árvores (23) e detecção de defeitos (18). A análise temporal revelou crescimento expressivo nas publicações a partir de 2019, com pico em 2024. A China concentrou o maior número de publicações (72), seguida pelos Estados Unidos (30) e pelo Brasil (13). As principais tecnologias de aquisição de dados identificadas foram imagens de satélite, Veículos Aéreos Não Tripulados (VANTs) e LiDAR. Os resultados indicam que a visão computacional representa uma alternativa viável e de crescente adoção para aplicações florestais, com potencial para automatizar inventários, monitorar a saúde florestal e subsidiar o planejamento e a gestão de florestas plantadas e urbanas.

Palavras-chave: aprendizado de máquina; LiDAR; classificação de imagens digitais.

ABSTRACT

Computer vision has established itself as a promising tool for the measurement and monitoring of forest resources, offering efficient alternatives to traditional field-based methods. This study conducted a systematic literature review (SLR) with the objective of analyzing how and to what extent computer vision has been applied in the forestry context. The search was carried out in the Web of Science and Scopus databases using the terms "*Machine vision and forestry*", "*Computer vision and forestry*", "*Deep learning and image classification and forestry*", and their equivalents in Portuguese. Of the 4,418 documents initially identified, 155 articles were selected after three filtering stages. The studies were classified into five thematic categories:

forest monitoring (43), tree species classification (40), tree parameter measurement (31), tree segmentation and counting (23), and defect detection (18). Temporal analysis revealed a significant growth in publications from 2019 onward, peaking in 2024. China accounted for the largest number of publications (72), followed by the United States (30) and Brazil (13). The main data acquisition technologies identified were satellite imagery, Unmanned Aerial Vehicles (UAVs), and LiDAR. The results indicate that computer vision represents a viable and increasingly adopted alternative for forestry applications, with the potential to automate forest inventories, monitor forest health, and support the planning and management of planted and urban forests.

Keywords: machine learning; LiDAR; digital image classification.

2.1. INTRODUÇÃO

A mensuração florestal desempenha um papel fundamental na quantificação de recursos florestais, ao atender diversos objetivos, como comércio, preservação, gestão e pesquisa. Por isso, as variáveis dendrométricas são essenciais, pois permitem extrair informações valiosas sobre a vegetação. No entanto, a análise em campo pode ser dispendiosa, demorada e, em alguns casos, inviável, devido a dificuldades de acesso à determinadas áreas. Diante destes desafios, a adoção de métodos alternativos de mensuração torna-se uma necessidade (Ribas e Elmiro, 2013).

Bertola (2002), ao reconhecer tais limitações, destacou que soluções baseadas em imagens digitais, como a visão computacional, podem ser empregadas para abordar essas questões com agilidade e com viabilidade econômica. Essa perspectiva é corroborada por Campos (2021), que aponta que o setor florestal tem passado por uma nova onda de inovação, centrada em dados, informações e serviços digitais.

A visão computacional pode ser definida como o campo de estudo que possibilita a localização automatizada de referências em mídias digitais. Esta área dedica-se à aquisição, compreensão e interpretação de informações visuais relevantes, contidas em imagens e vídeos, com o intuito de subsidiar a tomada de decisões (Adamian et al., 2020; Savekar e Kumar, 2021). Seu principal objetivo é permitir que máquinas percebam o ambiente de maneira semelhante à percepção humana. As tecnologias de inteligência artificial, que sustentam a visão computacional, capacitam as máquinas a compreenderem o entorno, por meio de suas próprias experiências (Bhatt et al., 2020).

Para analisar como a visão computacional tem sido aplicada no setor florestal, uma abordagem metodológica adequada é a revisão sistemática de literatura (RSL). A RSL é estruturada em torno de uma questão central, que constitui o núcleo da pesquisa, expressa por meio de conceitos e termos específicos. Estes elementos direcionam a busca por informações pertinentes a uma questão de pesquisa previamente definida, focalizada e estruturada (Biolchini, 2007).

A RSL possibilita incorporar um volume amplo de resultados relevantes, em contraste com análises limitadas a poucos artigos. Além disso, permite avaliar a consistência e a generalização dos achados, bem como suas especificidades e variações (Akobeng, 2005).

Diante disso, o objetivo deste capítulo foi de realizar uma RSL, visando analisar como e em que medida a visão computacional tem sido utilizada no contexto florestal.

2.2. METODOLOGIA

Ao considerar a natureza de uma RSL, que visa obter variedade de fontes (Cooper, 1994; Noronha e Ferreira, 2000; Berwanger, 2007; Biolchini, 2007), foram utilizadas duas bases de dados: *Web of Science* e *Scopus*.


A escolha das palavras-chave foi feita a partir da questão central deste capítulo: “Quais são os potenciais usos da visão computacional na área florestal?”. A partir disto, surgiram outras duas questões, secundárias: “Quais são os sensores/*softwares*/aplicativos utilizados?” e “Em qual área florestal são mais utilizados?”. Com isso, realizou-se a seleção dos termos abrangentes, a fim de identificar o maior número de pesquisas possível, e evitar a exclusão de estudos relevantes.

Para assegurar a inclusão de todos os artigos relacionados ao tema, foram escolhidos os termos de busca "*machine vision and forestry*", "*computer vision and forestry*" e "*deep learning and image classification and forestry*", bem como seus correspondentes em português. Essa abordagem permitiu, em um segundo momento, a avaliação específica de artigos brasileiros.

Todo o processo de busca e avaliação (Figura 1) ocorreu conforme PRISMA (2009), cujos critérios foram:

- Apenas produções em artigo científico, por passarem por avaliação por pares;
- Não houve restrição de idade, a fim de observar o desenvolvimento do uso da classificação de imagens digitais durante todo o tempo;
- Estudos com foco na área florestal, com exclusão do uso da visão computacional em outras áreas.

Figura 1 - Representação esquemática do processo de RSL.



Fonte: Autoria própria.

Primeiramente, foi feita uma análise dos documentos, em que foram filtrados apenas os relacionados à área florestal, seguido de avaliação do título e posterior leitura do resumo, em que foi verificado se condiziam com o tema escolhido. Cabe destacar que foram descartados os artigos concentrados em árvores e arbustos frutíferos de uso agrícola, como citros, maçãs e oliveiras, bem como aqueles relacionados a equipamentos florestais pesados e ao deslocamento desses maquinários.

Após a avaliação, o texto completo de todos os artigos selecionados foi obtido, para melhor análise e extração de dados. Para uma melhor percepção, os trabalhos foram organizados em temas (Quadro 1) e dispostos em tabelas (apêndices 1, 2, 3, 4 e 5) com autoria, ano de publicação, localização do autor e revista publicada.

Quadro 1 - Temas encontrados na revisão sistemática de literatura.


Tema	Descrição
Medição de parâmetros de árvores	Abordam a medição de altura, diâmetro, área foliar, volume e outros parâmetros, com o uso de diferentes tecnologias (<i>laser scanning</i> , imagens, sensores e fotogrametria).
Segmentação e contagem de árvores	Identificação e delimitação de árvores individuais em imagens e dados, o que inclui LiDAR aéreo, imagens em nível de rua, imagens de VANT e diferentes algoritmos de segmentação baseados em <i>deep learning</i> .
Classificação de espécies arbóreas	Exploram a classificação de espécies arbóreas com visão computacional e aprendizado de máquina, com foco em imagens de folhas, casca e madeira, além de imagens hiperespectrais e da integração de dados de satélite com LiDAR.
Deteção de defeitos e anomalias	Abordam a detecção de defeitos e anomalias em madeira e em árvores, com métodos de visão computacional e aprendizado de máquina, o que inclui defeitos na madeira (nós, rachaduras e fendas), falhas no plantio e identificação de árvores mortas ou doentes.
Monitoramento florestal	Utilizam técnicas de visão computacional para monitorar florestas, o que abrange detecção de incêndios florestais, mapeamento de áreas de desmatamento, extração de clareiras, estimativa de biomassa e estoques de carbono, e monitoramento de florestas urbanas.

Fonte: Autoria própria.

2.3. RESULTADOS E DISCUSSÕES

Foram identificados 4.418 registros (Figura 2). Foram removidos 928 registros repetidos, restando 3.490 registros únicos. Na triagem por título, 1.907 documentos foram excluídos por não serem artigos, resultando em 1.583 títulos.

Figura 2 - Fluxograma PRISMA do processo de seleção dos artigos.



Fonte: Autoria própria.

Na leitura dos resumos, outros 1.428 artigos foram excluídos por não tratarem do uso da visão computacional na área florestal, permanecendo assim 155 artigos.

Os quantitativos obtidos por base de dados e por estratégia de busca, ao longo das etapas de exclusão, são apresentados na Tabela 1. Como um mesmo artigo pode ser recuperado por mais de uma estratégia, os valores referem-se a registros por busca e podem conter sobreposições entre as linhas.

Tabela 1 - Quantidade de publicações encontradas na revisão sistemática.

		<i>Web of Science</i>	<i>Scopus</i>
<i>Machine Vision and Forestry</i>	Total	2	572
	Após 1ª exclusão	2	278
	Após 2ª exclusão	1	87
	Após 3ª exclusão	0	34
<i>Computer Vision and Forestry</i>	Total	966	1447
	Após 1ª exclusão	686	509
	Após 2ª exclusão	57	48
	Após 3ª exclusão	46	16
<i>Deep Learning and image classification and forestry</i>	Total	685	746
	Após 1ª exclusão	597	439
	Após 2ª exclusão	71	58
	Após 3ª exclusão	42	17

Fonte: Autoria própria.

Os 155 trabalhos analisados distribuíram-se entre as cinco categorias temáticas, sendo a classificação de espécies arbóreas a mais recorrente (50 artigos), seguida pelo monitoramento florestal (41 artigos), medição de parâmetros de árvores (26 artigos), segmentação e contagem de árvores (20 artigos) e detecção de defeitos (18 artigos).

No que se refere à medição de parâmetros de árvores (Tabela 2), os estudos contemplaram variáveis como área foliar (Li *et al.*, 2023; Yun *et al.*, 2016; Gong *et al.*, 2013), diâmetro à altura do peito (DAP) (Wu *et al.*, 2019; Cheng *et al.*, 2013; Wells e Chung, 2023; Tran *et al.*, 2023), altura e diâmetro de copa (Panagiotidis *et al.*, 2017), altura de árvores (Huang *et al.*, 2019; Yang *et al.*, 2023), volume de madeira (Casas *et al.*, 2024; Moskalik *et al.*, 2022; Miller *et al.*, 2015) e diâmetro de toras (Carratù *et al.*, 2023; Lu *et al.*, 2024; Brodie *et al.*, 1994).

Para a segmentação e contagem de árvores (Tabela 3), os trabalhos concentraram-se na segmentação de copas individuais (Yun *et al.*, 2021; Brandtberg e Walter, 1998; Dersch *et al.*, 2024; Gu *et al.*, 2020) e na contagem geral de indivíduos arbóreos (Wang *et al.*, 2023; Moharram *et al.*, 2023; Ventura *et al.*, 2024), incluindo aplicações em ambiente urbano (Li e Yan, 2024; Firoze *et al.*, 2022).

A classificação de espécies arbóreas (Tabela 4) foi conduzida por meio de diferentes abordagens, incluindo imagens 2D de madeira, casca e folhas (Liu *et al.*, 2024a; Filho *et al.*, 2014; Boudra *et al.*, 2022; Warner *et al.*, 2024), análise anatômica assistida por computador

(He *et al.*, 2024; Kobayashi *et al.*, 2019; Owens *et al.*, 2024), imagens hiperespectrais (Wu *et al.*, 2024; Zhang *et al.*, 2020; Fricker *et al.*, 2019) e a integração de imagens de satélite com dados LiDAR (Li *et al.*, 2021; Hartling *et al.*, 2019; Ferreira *et al.*, 2024).

A detecção de defeitos (Tabela 5) abrangeu estudos sobre madeira serrada (Khoury Jr. *et al.*, 2006; Klinkhachorn *et al.*, 1993; Hittawe *et al.*, 2017), nós e defeitos superficiais (Gao *et al.*, 2021; Ye *et al.*, 2022), fissuras em elementos estruturais de madeira (Ding *et al.*, 2024), fendas em toras de eucalipto (Soares *et al.*, 2024), falhas no plantio (de Oliveira *et al.*, 2024) e identificação de árvores mortas (Liu *et al.*, 2021; Deng *et al.*, 2020).

O monitoramento florestal (Tabela 6), por sua vez, foi explorado sob as perspectivas de detecção de incêndios e fumaça (Huang *et al.*, 2024; Xue *et al.*, 2022; Shamsoshoara *et al.*, 2021), biomassa e estoques de carbono (Bortolot e Wynne, 2005; Illarionova *et al.*, 2024), estrutura da vegetação e inventário florestal (Dandois e Ellis, 2010; Fraser e Congalton, 2021; Winsen e Hamilton, 2023), detecção de desmatamento (Soto *et al.*, 2022), monitoramento de florestas urbanas (Branson *et al.*, 2018; Seiferling *et al.*, 2017; Stubbings *et al.*, 2019) e segurança florestal (He *et al.*, 2021).

Tabela 2 - Artigos encontrados sobre o tema medição de parâmetros arbóreos.

Título	Autores	Localização dos Autores	Ano	Revista
A handheld device for leaf area measurement	Gong, A.; Wu, X.; Qiu, Z.; He, Y.	China	2013	Computers and Electronics in Agriculture
Method for detecting tree ring boundary in conifers and broadleaf trees using Mask R-CNN and linear interpolation	Kim, D.; Ko, C.; Kim, D.	Coréia do Sul	2023	Dendrochronologia
A novel approach for leaf area retrieval from terrestrial laser scanned points	Li, S.; Lu, X.; Duojie, C.; Zhang, H.; Xue, L.; Yun, T.	China	2023	Journal of Nanjing Forestry University (Natural Sciences Edition)
A novel approach for retrieving tree leaf area from ground-based LiDAR	Yun, T.; An, F.; Li, W.; Sun, Y.; Cao, L.; Xue, L.	China	2016	Remote Sensing (MDPI)
Development of plant leaf area measurement instrument based on virtual instrument technology	Zhang, Y.; Qiao, X.; Wang, C.; Zhang, X.; Tian, H.	China	2005	Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering
Leaf abundance affects tree height estimation derived from UAV images	Huang, H.; He, S.; Chen, C.	China	2019	Forests (MDPI)
3D modelling of individual trees using a handheld camera: Accuracy of height, diameter and volume estimates	Miller, J.; Morgenroth, J.; Gomez, C.	Nova Zelândia	2015	Urban Forestry and Urban Greening

Título	Autores	Localização dos Autores	Ano	Revista
A Deep Learning Method for Log Diameter Measurement Using Wood Images Based on YOLOv3 and DeepLabv3+	Lu, Z.; Yao, H.; Lyu, Y.; He, S.; Ning, H.; Yu, Y.; Zhai, L.; Zhou, L.	China	2024	Sensors (MDPI)
A Deep Learning Solution for Height Estimation on a Forested Area Based on Pol-TomoSAR Data	Yang, W.; Vitale, S.; Aghababaei, H.; Ferraioli, G.; Pascazio, V.; Schirinzi, G.	Itália, Holanda	2023	IEEE Transactions on Geoscience and Remote Sensing
A Deformable Shape Model for Automatic and Real-Time Dendrometry	Wells, L. A.; Chung, W.	EUA	2023	Forests (MDPI)
Automatic Detection and Counting of Stacked Eucalypt Timber Using the YOLOv8 Model	Casas, G. G.; Ismail, Z. H.; Limeira, M. M. C.; da Silva, A. A. L.; Leite, H. G.	Brasil, Malásia	2023	Forests (MDPI)
Computer vision techniques in forest inventory assessment: Improving accuracy of tree diameter measurement using smartphone camera and photogrammetry	Woo, H.; Kim, I.; Choi, B.	Coreia do Sul	2021	Sensors and Materials
CPH-Fmnet: An Optimized Deep Learning Model for Multi-View Stereo and Parameter Extraction in Complex Forest Scenes	Dai, L.; Chen, Z.; Zhang, X.; Wang, D.; Huo, L.	China	2024	Forests (MDPI)
Determining tree height and crown diameter from high-resolution UAV imagery	Panagiotidis, D.; Abdollahnejad, A.; Surovy, P.; Chiteculo, V.	República Tcheca	2017	International Journal of Remote Sensing
Estimating the accuracy of smartphone app-based removal estimates against actual wood-harvesting data from clear cuttings	Vähä-Konka, V.; Korhonen, L.; Kärhä, K.; Maltamo, M.	Finlândia	2024	iForest - Biogeosciences and Forestry

Título	Autores	Localização dos Autores	Ano	Revista
Measurement of cylindrical objects through laser telemetry: Application to a new forest caliper	Demeyere, M.; Dereine, E.; Eugene, C.; Naydenov, V.	Bélgica	2002	IEEE Transactions on Instrumentation and Measurement
Measuring diameters at breast height using combination method of laser and machine vision	Cheng, P.; Liu, J.; Wang, D.	China	2013	Nongye Jixie Xuebao/Transactions of the Chinese Society for Agricultural Machinery
Measuring tree stem diameters and straightness with depth-image computer vision	Tran, H.; Woeste, K.; Li, B. W.; Verma, A.; Shao, G. F.	EUA	2023	Journal of Forestry Research
Methods of Wood Volume Determining and Its Implications for Forest Transport	Moskalik, T.; Tymendorf, A.; Van der Saar, J.; Trzcíński, G.	Polônia	2022	Sensors (MDPI)
MISF: A Method for Measurement of Standing Tree Size via Multi-Vision Image Segmentation and Coordinate Fusion	Mo, L.; Shi, L.; Wang, G.; Yi, X.; Wu, P.; Wu, X.	China	2023	Forests (MDPI)
Passive measurement method of tree diameter at breast height using a smartphone	Wu, X.; Zhou, S.; Xu, A.; Chen, B.	China	2019	Computers and Electronics in Agriculture
Quantifying solid volume of stacked eucalypt timber using detection-segmentation and diameter distribution models	Casas, G. G.; Ismail, Z. H.; Limeira, M. M. C.; Soares, C. P. B.; Gleriani, J. M.; Binoti, D. H. B.; Junior, C. A. A.; Shapiai, M. I.; Rodrigues, L. I.; Araujo, T. M.; Leite, H. G.	Brasil, Malásia	2024	Smart Agricultural Technology
Real-Time Computer Vision for Tree Stem Detection and Tracking	Wells, L. A.; Chung, W. D.	EUA	2023	Forests (MDPI)

Título	Autores	Localização dos Autores	Ano	Revista
Size assessment of stacked logs via the Hough transform	Brodie, J. R.; Hansen, A. C.; Reid, J. F.	EUA	1994	Transactions of the American Society of Agricultural Engineers
The use of computer vision to estimate tree diameter and circumference in homogeneous and production forests using a non-contact method	Putra, B. T. W.; Ramadhani, N. J.; Soedibyo, D. W.; Marhaenanto, B.; Indarto, I.; Yualianto, Y.	Indonésia	2021	Forest Science and Technology
Vision-Based System for Measuring the Diameter of Wood Logs	Carratù, M.; Gallo, V.; Liguori, C.; Lundgren, J.; O'Nils, M.; Pietrosanto, A.	Itália, Suécia	2023	IEEE Open Journal of Instrumentation and Measurement

Fonte: Autoria própria.

Tabela 3 - Artigos encontrados sobre o tema segmentação e contagem de árvores.

Título	Autores	Localização dos Autores	Ano	Revista
3D Reconstruction of Tree-Crown Based on the UAV Aerial Images	Xu, C.; Lu, Z.; Xu, G.; Feng, Z.; Tan, H.; Zhang, H.	China	2015	Mathematical Problems in Engineering
A comparison of forest tree crown delineation from unmanned aerial imagery using canopy height models vs. spectral lightness	Gu, J.; Grybas, H.; Congalton, R. G.	EUA	2020	Forests (MDPI)
A method for determining the spatial pattern of forest trees based on the uniformity theory	Shi, Y. Q.; Gao, X. L.; Lang, C. L.; Luo, C. W.	China	2024	Journal of Forestry Research
Att-Mask R-CNN: an individual tree crown instance segmentation method based on fused attention mechanism	Chen, W.; Guan, Z.; Gao, D.	China	2024	Canadian Journal of Forest Research
Automated delineation of individual tree crowns in high spatial resolution aerial images by multiple-scale analysis	Brandtberg, T.; Walter, F.	Suécia	1998	Machine Vision and Applications
BAMFORESTS: Bamberg Benchmark Forest Dataset of Individual Tree Crowns in Very-High-Resolution UAV Images	Troles, J.; Schmid, U.; Fan, W.; Tian, J.	Alemanha	2024	Remote Sensing (MDPI)
Comparison of ALS- and UAV(SfM)-derived high-density point clouds for individual tree detection in Eucalyptus plantations	Guerra-Hernandez, J. et al.	Espanha, Brasil, Portugal	2018	International Journal of Remote Sensing
Individual Tree Crown Detection and Classification of Live and Dead Trees Using a	Yao, S.; Hao, Z.; Post, C. J.; Mikhailova, E. A.; Lin, L.	China, EUA	2024	Forests (MDPI)

Título	Autores	Localização dos Autores	Ano	Revista
Mask Region-Based Convolutional Neural Network (Mask R-CNN)				
Individual tree crown segmentation from airborne LiDAR data using a novel Gaussian filter and energy function minimization-based approach	Yun, T.; Jiang, K.; Li, G. C.; Eichhorn, M. P.; Fan, J. C.; Liu, F. Z.; Chen, B. Q.; An, F.; Cao, L.	China, Irlanda	2021	Remote Sensing of Environment
Individual tree detection and species classification of Amazonian palms using UAV images and deep learning	Ferreira, M. P.; de Almeida, D. R. A.; Papa, D. D.; Minervino, J. B. S.; Veras, H. F. P.; Formighieri, A.; Santos, C. A. N.; Ferreira, M. A. D.; Figueiredo, E. O.; Ferreira, E. J. L.	Brasil	2020	Forest Ecology and Management
Individual tree detection in large-scale urban environments using high-resolution multispectral imagery	Ventura, J. et al.	EUA	2024	International Journal of Applied Earth Observation and Geoinformation
Individual tree segmentation and tree-counting using supervised clustering	Wang, Y.; Yang, X. B.; Zhang, L.; Fan, X. J.; Ye, Q. L.; Fu, L. Y.	China	2023	Computers and Electronics in Agriculture
Semi-supervised multi-class tree crown delineation using aerial multispectral imagery and lidar data	Dersch, S.; Schottl, A.; Krzystek, P.; Heurich, M.	Alemanha	2024	ISPRS Journal of Photogrammetry and Remote Sensing
Street tree segmentation from mobile laser scanning data using deep learning-based image instance segmentation	Li, Q. J.; Yan, Y.	China	2024	Urban Forestry & Urban Greening

Título	Autores	Localização dos Autores	Ano	Revista
Tree and building detection in dense urban environments using automated processing of IKONOS image and LiDAR data	Kim, J.; Muller, J. P.	Inglaterra	2011	International Journal of Remote Sensing
Tree Seedlings Detection and Counting Using a Deep Learning Algorithm	Moharram, D.; Yuan, X. G.; Li, D.	China	2023	Applied Sciences (MDPI)
Treetop detection using convolutional neural networks trained through automatically generated pseudo labels	Xiao, C.; Qin, R.; Huang, X.	EUA	2020	International Journal of Remote Sensing
Urban tree generator: spatio-temporal and generative deep learning for urban tree localization and modeling	Firoze, A.; Benes, B.; Aliaga, D.	EUA	2022	The Visual Computer
Using Deep Learning to Detect the Need for Forest Thinning: Application to the Lungau Region, Austria	Satlawa, P.; Fisher, R. B.	Áustria, Inglaterra	2023	Algorithms (MDPI)
Using u-net-like deep convolutional neural networks for precise tree recognition in very high resolution RGB (Red, Green, Blue) satellite images	Korznikov, K. A.; Kislov, D. E.; Altman, J.; Doležal, J.; Vozmishcheva, A. S.; Krestov, P. V.	Rússia, República Tcheca	2021	Forests (MDPI)

Fonte: Autoria própria.

Tabela 4 - Artigos encontrados sobre o tema classificação de espécies arbóreas.

Título	Autores	Localização dos Autores	Ano	Revista
A convolutional neural network classifier identifies tree species in mixed-conifer forest from hyperspectral imagery	Fricker, G. A.; Ventura, J. D.; Wolf, J. A.; North, M. P.; Davis, F. W.; Franklin, J.	EUA	2019	Remote Sensing (MDPI)
A Deep Fusion uNet for Mapping Forests at Tree Species Levels with Multi-Temporal High Spatial Resolution Satellite Imagery	Guo, Y.; Li, Z. Y.; Chen, E. X.; Zhang, X.; Zhao, L.; Xu, E. E.; Hou, Y. A.; Liu, L. Z.	China	2021	Remote Sensing (MDPI)
A non-invasive learning branch to capture leaf-image attention for tree species classification	Song, Y. P.; He, F. Z.; Liu, Y. A.	China	2022	Multimedia Tools and Applications
A novel framework combining band selection algorithm and improved 3D prototypical network for tree species classification using airborne hyperspectral images	Wu, J.; Chen, L.; Wang, J. Q.; Li, Y. F.; Chen, E. X.; Zhang, X. L.	China	2024	Computers and Electronics in Agriculture
ACTL: Asymmetric Convolutional Transfer Learning for Tree Species Identification Based on Deep Neural Network	Shi, Y.; Ma, D. H.; Lv, J.; Li, J.	China	2021	IEEE Access
An End-to-End Deep Fusion Model for Mapping Forests at Tree Species Levels with High Spatial Resolution Satellite Imagery	Guo, Y.; Li, Z. Y.; Chen, E. X.; Zhang, X.; Zhao, L.; Xu, E.; Hou, Y. A.; Sun, R.	China	2020	Remote Sensing (MDPI)
Anatomical features of Fagaceae wood statistically extracted by computer vision approaches: Some relationships with evolution	Kobayashi, K.; Kegasa, T.; Hwang, S. W.; Sugiyama, J.	Japão	2019	PLoS ONE

Título	Autores	Localização dos Autores	Ano	Revista
Automatic Identification of Tree Species From Sentinel-2A Images Using Band Combinations and Deep Learning	Vaghela, H. P.; Alagu Raja, R. A.	Índia	2024	IEEE Geoscience and Remote Sensing Letters
Caveat emptor: On the Need for Baseline Quality Standards in Computer Vision Wood Identification	Ravindran, P.; Wiedenhoeft, A. C.	EUA	2022	Forests (MDPI)
CentralBark Image Dataset and Tree Species Classification Using Deep Learning	Warner, C.; Wu, F. Y.; Gazo, R.; Benes, B.; Kong, N.; Fei, S. L.	EUA	2024	Algorithms (MDPI)
Classification of tree species and stock volume estimation in ground forest images using Deep Learning	Liu, J. Z.; Wang, X. F.; Wang, T.	China	2019	Computers and Electronics in Agriculture
Classification of tree species based on UNet-ResNet14* semi-supervised learning using UAV images	Chen, L.; Zhou, X.; Li, C.; Lin, H.; Wang, Y.; Cui, Y.	China	2024	Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering
Classification of Tree Species Based on Point Cloud Projection Images with Depth Information	Fan, Z. M.; Zhang, W. X.; Zhang, R. Y.; Wei, J. H.; Wang, Z. Y.; Ruan, Y. K.	China	2023	Forests (MDPI)
CNN-based individual tree species classification using high-resolution satellite imagery and airborne LiDAR data	Li, H.; Hu, B.; Li, Q.; Jing, L.	China, Canadá	2021	Forests (MDPI)
Deep Learning in Forest Tree Species Classification Using Sentinel-2 on Google Earth Engine: A Case Study of Qingyuan County	He, T.; Zhou, H. K.; Xu, C. Y.; Hu, J. G.; Xue, X. Y.; Xu, L. C.; Lou, X. W.; Zeng, K.; Wang, Q.	China	2023	Sustainability (MDPI)

Título	Autores	Localização dos Autores	Ano	Revista
Deep learning-based training data augmentation combined with post-classification improves the classification accuracy for dominant and scattered invasive forest tree species	Likó, S. B.; Holb, I. J.; Oláh, V.; Burai, P.; Szabó, S.	Hungria	2024	Remote Sensing in Ecology and Conservation
Deepening the Accuracy of Tree Species Classification: A Deep Learning-Based Methodology	Cha, S.; Lim, J.; Kim, K.; Yim, J.; Lee, W.-K.	Coreia do Sul	2023	Forests (MDPI)
Developing deep learning models to automate rosewood tree species identification for CITES designation and implementation	He, T.; Lu, Y.; Jiao, L. C.; Zhang, Y. G.; Jiang, X. M.; Yin, Y. F.	China	2020	Holzforschung
Evaluation of Wood Species Identification Using CNN-Based Networks at Different Magnification Levels	Nguyen-Trong, K.	Vietnã	2023	International Journal of Advanced Computer Science and Applications
Exploring the Limits of Species Identification via a Convolutional Neural Network in a Complex Forest Scene through Simulated Imaging Spectroscopy	Chaity, M. D.; van Aardt, J.	EUA	2024	Remote Sensing (MDPI)
Field-Deployable Computer Vision Wood Identification of Peruvian Timbers	Ravindran, P.; Owens, F. C.; Wade, A. C.; Vega, P.; Montenegro, R.; Shmulsky, R.; Wiedenhoeft, A. C.	EUA, Brasil	2021	Frontiers in Plant Science
Forest species recognition using macroscopic images	Filho, P. L. P.; Oliveira, L. S.; Nisgoski, S.; Britto, A. S.	Brasil	2014	Machine Vision and Applications

Título	Autores	Localização dos Autores	Ano	Revista
Fusion of multi-temporal PlanetScope data and very high-resolution aerial imagery for urban tree species mapping	Neyns, R.; Efthymiadis, K.; Libin, P.; Canters, F.	Bélgica	2024	Urban Forestry & Urban Greening
How to discriminate wood of CITES-listed tree species from their look-alikes: using an attention mechanism with the ResNet model on an enhanced macroscopic image dataset	Liu, S. J.; Zheng, C.; Wang, J. J.; Lu, Y.; Yao, J.; Zou, Z. Y.; Yin, Y. F.; He, T.	China	2024	Frontiers in Plant Science
Identification of broad-leaf trees using deep learning based on field photographs of multiple leaves	Minowa, Y.; Kubota, Y.	Japão	2022	Journal of Forest Research
Identifying and extracting bark key features of 42 tree species using convolutional neural networks and class activation mapping	Kim, T. K.; Hong, J.; Ryu, D.; Kim, S.; Byeon, S. Y.; Huh, W.; Kim, K.; Baek, G. H.; Kim, H. S.	Coreia do Sul	2022	Scientific Reports
Improved Prototypical Network Model for Forest Species Classification in Complex Stand	Tian, X. M.; Chen, L.; Zhang, X. L.; Chen, E. R.	China	2020	Remote Sensing (MDPI)
Improved wood species identification based on multi-view imagery of the three anatomical planes	da Silva, N. R.; Deklerck, V.; Baetens, J. M.; Van den Bulcke, J.; De Ridder, M.; Rousseau, M.; Bruno, O. M.; Beeckman, H.; Van Acker, J.; De Baets, B.; Verwaeren, J.	Brasil, Bélgica, Inglaterra	2022	Plant Methods
Improvement and Assessment of Convolutional Neural Network for Tree Species Identification Based on Bark Characteristics	Cui, Z. L.; Li, X. R.; Li, T.; Li, M. Y.	China	2023	Forests (MDPI)

Título	Autores	Localização dos Autores	Ano	Revista
Improving urban tree species classification by deep-learning based fusion of digital aerial images and LiDAR	Ferreira, M. P.; dos Santos, D. R.; Ferrari, F.; Filho, L. C. T. C.; Martins, G. B.; Feitosa, R. Q.	Brasil	2024	Urban Forestry and Urban Greening
Individual Tree Species Identification for Complex Coniferous and Broad-Leaved Mixed Forests Based on Deep Learning Combined with UAV LiDAR Data and RGB Images	Zhong, H.; Zhang, Z. Y.; Liu, H. R.; Wu, J. Z.; Lin, W. S.	China	2024	Forests (MDPI)
Machine learning-based wood anatomy identification: towards anatomical feature recognition	He, X. et al.	China, Holanda	2024	IAWA Journal
Morphological Transformation and Spatial-Logical Aggregation for Tree Species Classification Using Hyperspectral Imagery	Zhang, M. M.; Li, W.; Zhao, X. D.; Liu, H.; Tao, R.; Du, Q.	China, EUA	2023	IEEE Transactions on Geoscience and Remote Sensing
Open-Set Recognition of Wood Species Based on Deep Learning Feature Extraction Using Leaves	Fang, T. Y.; Li, Z. Y.; Zhang, J. L.; Qi, D. W.; Zhang, L.	China, EUA	2023	Journal of Imaging (MDPI)
Predicting Hardwood Porosity Domains: Toward Cascading Computer-Vision Wood Identification Models	Owens, F. C.; Ravindran, P.; Costa, A.; Shmulsky, R.; Wiedenhoeft, A. C.	EUA	2024	BioResources
Rapid field identification of CITES timber species by deep learning	Olschofsky, K.; Köhl, M.	Alemanha	2020	Trees, Forests and People
Rapid Image Detection of Tree Trunks Using a Convolutional Neural Network and Transfer Learning	Yang, T. T.; Zhou, S. Y.; Xu, A. J.	China	2021	IAENG International Journal of Computer Science

Título	Autores	Localização dos Autores	Ano	Revista
The image recognition of urban greening tree species based on deep learning and CAMP-MKNet model	Sun, X. B.; Shi, Y. J.	China	2023	Urban Forestry & Urban Greening
Three-dimensional convolutional neural network model for tree species classification using airborne hyperspectral images	Zhang, B.; Zhao, L.; Zhang, X. L.	China	2020	Remote Sensing of Environment
Tree Species Classification in Subtropical Natural Forests Using High-Resolution UAV RGB and SuperView-1 Multispectral Imageries Based on Deep Learning Network Approaches: A Case Study within the Baima Snow Mountain National Nature Reserve, China	Chen, X.; Shen, X.; Cao, L.	China	2023	Remote Sensing (MDPI)
Tree species classification based on PointNet++ deep learning and true-colour point cloud	Liu, H. R.; Zhong, H.; Lin, W. S.; Wu, J. Z.	China	2024	International Journal of Remote Sensing
Tree species classification from airborne hyperspectral and LiDAR data using 3D convolutional neural networks	Mäyrä, J. et al.	Finlândia	2021	Remote Sensing of Environment
Tree species classification of airborne LiDAR data based on 3D deep learning	Liu, M.; Han, Z.; Chen, Y.; Liu, Z.; Han, Y.	China	2022	Guofang Keji Daxue Xuebao/Journal of National University of Defense Technology
Tree species classification on images from airborne mobile mapping using ML.NET	Michalowska, M.; Rapinski, J.; Janicka, J.	Polônia	2023	European Journal of Remote Sensing

Título	Autores	Localização dos Autores	Ano	Revista
Tree species classification using deep learning and RGB optical images obtained by an unmanned aerial vehicle	Zhang, C.; Xia, K.; Feng, H. L.; Yang, Y. H.; Du, X. C.	China	2021	Journal of Forestry Research
Tree trunk texture classification using multi-scale statistical macro binary patterns and CNN	Boudra, S.; Yahiaoui, I.; Behloul, A.	França, Argélia	2022	Applied Soft Computing
Urban forestry detection by deep learning method with GaoFen-2 remote sensing images	Xie, Y. N.; Xu, Y. F.; Hu, C. H.; Lu, L.; Hu, X. D.; Rong, Q. J.	China	2022	Journal of Applied Remote Sensing
Urban tree species classification using a WorldView-2/3 and LiDAR data fusion approach and deep learning	Hartling, S.; Sagan, V.; Sidike, P.; Maimaitijiang, M.; Carron, J.	EUA	2019	Sensors (MDPI)
Using time-series imagery and 3DLSTM model to classify individual tree species	Chen, C. Y.; Jing, L. H.; Li, H.; Tang, Y. W.; Chen, F. L.; Tan, B. X.	China	2024	International Journal of Digital Earth
Verification of a Deep Learning-Based Tree Species Identification Model Using Images of Broadleaf and Coniferous Tree Leaves	Minowa, Y.; Kubota, Y.; Nakatsukasa, S.	Japão	2022	Forests (MDPI)

Fonte: Autoria própria.

Tabela 5 - Artigos encontrados sobre o tema detecção de defeitos e anomalias.

Título	Autores	Localização dos Autores	Ano	Revista
A Fully Convolutional Neural Network for Wood Defect Location and Identification	He, T.; Liu, Y.; Xu, C. Y.; Zhou, X. L.; Hu, Z. K.; Fan, J. N.	China	2019	IEEE Access
Automatic Detection and Classification of Dead Nematode-Infested Pine Wood in Stages Based on YOLO v4 and GoogLeNet	Zhu, X. H.; Wang, R. R.; Shi, W.; Yu, Q.; Li, X. T.; Chen, X. W.	China	2023	Forests (MDPI)
BLNN: Multiscale Feature Fusion-Based Bilinear Fine-Grained Convolutional Neural Network for Image Classification of Wood Knot Defects	Gao, M. Y.; Wang, F.; Song, P.; Liu, J. Y.; Qi, D. W.	China	2021	Journal of Sensors
Comparison of deep learning-based models for detection of diseased trees using an image compression algorithm	Sarinova, A.; Rzaeva, L.; Abitova, G.; Yessenov, A.; Sansyzbayev, A.; Omirtay, Y.	Cazaquistão	2024	Eastern-European Journal of Enterprise Technologies
Detection and Location of Dead Trees with Pine Wilt Disease Based on Deep Learning and UAV Remote Sensing	Deng, X. L.; Tong, Z. J.; Lan, Y. B.; Huang, Z. X.	China	2020	AgriEngineering (MDPI)
Detection of natural wood defects with large color differences based on branched network	Wang, X.	China	2023	Multimedia Tools and Applications
Image detection of wood surface defects based on deep learning	Chen, X. M.; Wang, A. C.; Wang, C. Y.	China	2019	Chinese Journal of Liquid Crystals and Displays
Improved detection of planting failures by computer vision	de Oliveira, W. F.; Vieira, A. W.; Pimenta, S.; da Silva, L. A.	Brasil	2024	Scientia Agricola

Título	Autores	Localização dos Autores	Ano	Revista
Innovative computer vision-based full-scale timber element cracks detection, stitching, and quantification	Ding, Y. W. et al.	China	2024	Structural Health Monitoring
Machine vision for timber grading singularities detection and applications	Hittawe, M. M.; Sidibé, D.; Beya, O.; Mériaudeau, F.	França, Malásia	2017	Journal of Electronic Imaging
Mapping standing dead trees in temperate montane forests using a pixel- and object-based image fusion method and stereo WorldView-3 imagery	Liu, X.; Frey, J.; Denter, M.; Zielewska-Büttner, K.; Still, N.; Koch, B.	Alemanha	2021	Ecological Indicators
Neural networks for recognition of eucalypts lumber defects in digital images	Khoury Jr., J. K.; De Assis De Carvalho Pinto, F.; De Queiroz, D. M.; Della Lucia, R. M.; De Resende, R. C.	Brasil	2006	Scientia Forestalis
Phenotyping methodologies of log end splitting in eucalyptus (<i>Eucalyptus</i> spp.)	Soares, L. C. D.; Moreira, J. C.; Botega, G. P.; Carneiro, V. Q.; Lafetá, B. O.; de Figueiredo, I. C. R.; Gonsalves, F. M. A.	Brasil	2024	Plant Breeding
Prototyping an automated lumber processing system	Klinkhachorn, P.; Kothari, R.; Huber, H. A.; McMillin, C. W.; Mukherjee, K.; Barnekov, V.	EUA	1993	Forest Products Journal
Scientific Computational Visual Analysis of Wood Internal Defects Detection in View of Tomography Image Reconstruction Algorithm	Ye, R. C.; Pei, Y.; Wang, W. B.; Zhou, H. B.	China	2022	Mobile Information Systems
Using computer vision and compressed sensing for wood plate surface detection	Zhang, Y. Z.; Liu, S. J.; Tu, W. J.; Yu, H. L.; Li, C.	China	2015	Optical Engineering

Título	Autores	Localização dos Autores	Ano	Revista
Wood Defect Classification Based on Lightweight Convolutional Neural Networks	Xie, Y. H.; Ling, J. X.	China	2023	BioResources
Wood Defect Detection Based on Depth Extreme Learning Machine	Yang, Y. T.; Zhou, X. L.; Liu, Y.; Hu, Z. K.; Ding, F. L.	China	2020	Applied Sciences (MDPI)

Fonte: Autoria própria.

Tabela 6 - Artigos encontrados sobre o tema monitoramento florestal.

Título	Autores	Localização dos Autores	Ano	Revista
A Comparison of UAV-Derived Dense Point Clouds Using LiDAR and NIR Photogrammetry in an Australian Eucalypt Forest	Winsen, M.; Hamilton, G.	Austrália	2023	Remote Sensing (MDPI)
A Forest Fire Smoke Monitoring System Based on a Lightweight Neural Network for Edge Devices	Huang, J. W.; Yang, H. Z.; Liu, Y. F.; Liu, H.	China, EUA	2024	Forests (MDPI)
A Hierarchical Urban Forest Index Using Street-Level Imagery and Deep Learning	Stubbings, P.; Peskett, J.; Rowe, F.; Arribas-Bel, D.	Inglaterra	2019	Remote Sensing (MDPI)
A multilayered urban tree dataset of point clouds, quantitative structure and graph models	Yazdi, H.; Shu, Q. G.; Rötzer, T.; Petzold, F.; Ludwig, F.	Alemanha	2024	Scientific Data
A Quantitative Analysis Method of Solar Shortwave Radiation within Forest Canopy Based on a Computer Simulation Model	Zhang, Y.; Zhang, H.; An, F.; Jiang, L.; Yun, T.	China	2024	Linze Kexue/Scientia Silvae Sinicae
A Small Target Forest Fire Detection Model Based on YOLOv5 Improvement	Xue, Z. Y.; Lin, H. F.; Wang, F.	China	2022	Forests (MDPI)
A Small-Target Forest Fire Smoke Detection Model Based on Deformable Transformer for End-to-End Object Detection	Huang, J. W.; Zhou, J. S.; Yang, H. Z.; Liu, Y. F.; Liu, H.	China, EUA	2023	Forests (MDPI)

Título	Autores	Localização dos Autores	Ano	Revista
Advancing forest carbon stocks' mapping using a hierarchical approach with machine learning and satellite imagery	Illarionova, S.; Tregubova, P.; Shukhratov, I.; Shadrin, D.; Efimov, A.; Burnaev, E.	Rússia	2024	Scientific Reports
Advancing Forest Fire Risk Evaluation: An Integrated Framework for Visualizing Area-Specific Forest Fire Risks Using UAV Imagery, Object Detection and Color Mapping Techniques	Aibin, M. et al.	Canadá	2024	Drones (MDPI)
Aerial imagery pile burn detection using deep learning: The FLAME dataset	Shamsoshoara, A.; Afghah, F.; Razi, A.; Zheng, L.; Fulé, P. Z.; Blasch, E.	EUA	2021	Computer Networks
An Estimation Model for Regional Forest Canopy Closure Combined with UAV LiDAR and High Spatial Resolution Satellite Remote Sensing Data	Xu, E.; Guo, Y.; Chen, E.; Li, Z.; Zhao, L.; Liu, Q.	China	2022	Wuhan Daxue Xuebao (Xinxi Kexue Ban)/Geomatics and Information Science of Wuhan University
Applying deep learning to real-time UAV-based forest monitoring: Leveraging multi-sensor imagery for improved results	Marques, T.; Carreira, S.; Miragaia, R.; Ramos, J.; Pereira, A.	Portugal	2024	Expert Systems with Applications
Automatic identification for standing tree limb pruning	Sun, R. S.; Li, W. B.; Tian, Y. C.; Hua, L.	China	2005	Frontiers of Forestry in China

Título	Autores	Localização dos Autores	Ano	Revista
Challenges for computer vision as a tool for screening urban trees through street-view images	Arevalo-Ramirez, T. et al.	Chile	2024	Urban Forestry and Urban Greening
Continent-wide urban tree canopy fine-scale mapping and coverage assessment in South America with high-resolution satellite images	Guo, J. H.; Hong, D. F.; Liu, Z. H.; Zhu, X. X.	Alemanha, China	2024	ISPRS Journal of Photogrammetry and Remote Sensing
Domain-Adversarial Neural Networks for Deforestation Detection in Tropical Forests	Soto, P. J.; Costa, G. A.; Feitosa, R. Q.; Ortega, M. X.; Bermudez, J. D.; Turnes, J. N.	França, Brasil, Canadá	2022	IEEE Geoscience and Remote Sensing Letters
Estimating forest biomass using small footprint lidar data: An individual tree-based approach that incorporates training data	Bortolot, Z. J.; Wynne, R. H.	EUA	2005	ISPRS Journal of Photogrammetry and Remote Sensing
Estimating Primary Forest Attributes and Rare Community Characteristics Using Unmanned Aerial Systems (UAS): An Enrichment of Conventional Forest Inventories	Fraser, B. T.; Congalton, R. G.	EUA	2021	Remote Sensing (MDPI)
Estimating Urban Forests Biomass with LiDAR by Using Deep Learning Foundation Models	Liu, H. Z.; Mou, C.; Yuan, J. T.; Chen, Z. B.; Zhong, L. H.; Cui, X. H.	China	2024	Remote Sensing (MDPI)
Feasibility of Google Tango and Kinect for crowdsourcing forestry information	Hyypä, J.; Virtanen, J.-P.; Jaakkola, A.; Yu, X.; Hyypä, H.; Liang, X.	Finlândia	2017	Forests (MDPI)

Título	Autores	Localização dos Autores	Ano	Revista
Forest digital twin: A new tool for forest management practices based on Spatio-Temporal Data, 3D simulation Engine, and intelligent interactive environment	Qiu, H.; Zhang, H.; Lei, K.; Zhang, H.; Hu, X.	China	2023	Computers and Electronics in Agriculture
Forest Fire Smoke Detection Based on Visual Smoke Root and Diffusion Model	Gao, Y.; Cheng, P. L.	China	2019	Fire Technology
Forest Gap Extraction Based on Convolutional Neural Networks and Sentinel-2 Images	Li, M. X.; Li, M. S.	China	2023	Forests (MDPI)
Forestry operations in the next century	Guimier, D. Y.	Canadá	1998	Journal of Forestry
From Google Maps to a fine-grained catalog of street trees	Branson, S.; Wegner, J. D.; Hall, D.; Lang, N.; Schindler, K.; Perona, P.	EUA, Suíça	2018	ISPRS Journal of Photogrammetry and Remote Sensing
Green streets - Quantifying and mapping urban trees with street-level imagery and computer vision	Seiferling, I.; Naik, N.; Ratti, C.; Proulx, R.	EUA, Canadá	2017	Landscape and Urban Planning
Improve the Deep Learning Models in Forestry Based on Explanations and Expertise	Cheng, X. M.; Doosthosseini, A.; Kunkel, J.	Alemanha	2022	Frontiers in Plant Science
Mapping Planted Forests in the Korean Peninsula Using Artificial Intelligence	Mitra, A. et al.	EUA, Equador, Coreia do Sul, Itália	2024	Forests (MDPI)


Título	Autores	Localização dos Autores	Ano	Revista
Mapping Tree Canopy in Urban Environments Using Point Clouds from Airborne Laser Scanning and Street Level Imagery	Rodríguez-Puerta, F.; Barrera, C.; García, B.; Pérez-Rodríguez, F.; García-Pedrero, A. M.	Espanha	2022	Sensors (MDPI)
MTL-FFDET: A Multi-Task Learning-Based Model for Forest Fire Detection	Lu, K. J.; Huang, J. W.; Li, J. H.; Zhou, J. S.; Chen, X. L.; Liu, Y. F.	China, Austrália	2022	Forests (MDPI)
Object-based classification of unmanned aerial vehicle (UAV) imagery for forest fires monitoring	Bilgilioglu, B. B.; Ozturk, O.; Sariturk, B.; Seker, D. Z.	Turquia	2019	Fresenius Environmental Bulletin
Outlook for the next generation's precision forestry in Finland	Holopainen, M.; Vastaranta, M.; Hyypä, J.	Finlândia	2014	Forests (MDPI)
Qualitative Forest Inventory in Eucalyptus Plantations Using Unmanned Aerial Vehicles, Multispectral Sensors, and Deep Learning	Magalhaes Albuquerque, A.; Debiasi, P.; Lourenco De Lima, T. V.; Hirokawa Higa, G. T.; Pistori, H.; Ferraco Scolforo, H.; Ferreira Silva, T. C.; De Andrade Porto, J. V.; Stape, J. L.	Brasil	2024	IEEE Geoscience and Remote Sensing Letters
Remote Sensing of Vegetation Structure Using Computer Vision	Dandois, J. P.; Ellis, E. C.	EUA	2010	Remote Sensing (MDPI)
Self-Organizing Deep Learning (SO-UNet) - A Novel Framework to Classify Urban and Peri-Urban Forests	Awad, M. M.; Lauteri, M.	Líbano, Itália	2021	Sustainability (MDPI)

Título	Autores	Localização dos Autores	Ano	Revista
Significance of AI-assisted techniques for epiphyte plant monitoring and identification from drone images	V. V., S. V.; V., S.; Sivanpillai, R.; Brown, G. K.	EUA, Índia	2024	Journal of Environmental Management
Visible and Infrared Image Fusion of Forest Fire Scenes Based on Generative Adversarial Networks with Multi-Classification and Multi-Level Constraints	Jin, Q. et al.	China	2023	Forests (MDPI)
Weakly Supervised Forest Fire Segmentation in UAV Imagery Based on Foreground-Aware Pooling and Context-Aware Loss	Wang, J. et al.	China	2023	Remote Sensing (MDPI)
Wildfire Detection with Deep Learning - A Case Study for the CICLOPE Project	Goncalves, A. M.; Brandao, T.; Ferreira, J. C.	EUA, Portugal	2024	IEEE Access
Wildfire Smoke Classification Based on Synthetic Images and Pixel- and Feature-Level Domain Adaptation	Mao, J.; Zheng, C. E.; Yin, J. Y.; Tian, Y.; Cui, W. B.	China, Canadá	2021	Sensors (MDPI)
Wireless Signal Propagation Prediction Based on Computer Vision Sensing Technology for Forestry Security Monitoring	He, J. L.; Xing, Z. R.; Xiang, T. Q.; Zhang, X.; Zhou, Y. H.; Xi, C. Y.; Lu, H.	China	2021	Sensors (MDPI)

Fonte: Autoria própria.

A análise temporal das publicações (Figura 3) revelou correspondência entre os temas abordados ao longo dos anos. A partir de 2019, observou-se crescimento expressivo no número de publicações, com destaque para os artigos voltados à classificação de espécies. Em 2024, o tema de maior recorrência foi o monitoramento florestal.

Figura 3 - Distribuição do número de artigo por ano encontrados por meio da revisão sistemática de literatura.



Os artigos publicados entre 1993 e 1998 apresentaram tecnologias específicas como a prototipagem de sistemas automatizados e algoritmos de delimitação de copas. Klinkhachorn et al. (1993) descreveram um sistema automatizado de processamento de madeira, desenvolvido com o objetivo de aumentar o rendimento da madeira de lei ao longo do processo de manufatura. Brandtberg e Walter (1998) apresentaram um algoritmo automático de múltiplas escalas para a delimitação de copas de árvores individuais em imagens aéreas coloridas de alta resolução espacial, cujo modelo descreveu a região da copa com base em seus segmentos de borda.

No mesmo ano, Guimier e Heidersdorf (1998) discutiram a aplicação da robótica e da visão de máquina em operações florestais futuras, apontando a visão de máquina como componente essencial para que os equipamentos avaliassem os objetos a serem manipulados, como árvores, toras e cavacos, respondendo de forma apropriada a cada situação. As aplicações específicas apresentadas pelos autores incluíam sistemas já implementados em serrarias, conforme descrito por Klinkhachorn et al. (1993), os quais precisariam ser adaptados às restrições do ambiente florestal.

Os resultados desta revisão sistemática corroboram as previsões de Guimier e Heidersdorf (1998) sobre a incorporação de tecnologias nas operações florestais, uma vez que tais tecnologias estão hoje presentes em diversas frentes de pesquisa e amplamente aplicadas no setor. Entre 2005 e 2006, foram identificados quatro artigos, abrangendo a medição de área foliar, a identificação para poda de galhos, a estimativa de biomassa por LiDAR e a detecção


de defeitos em madeira serrada. No período de 2010 a 2018, o número de publicações manteve-se baixa, entre um e quatro artigos por ano, com maior diversificação temática a partir de 2015, quando os cinco temas passaram a figurar de forma alternada.

Contudo, o período de maior destaque ocorre após 2019, com crescimento acentuado entre 2023 e 2024. Em 2024, foram registrados 42 artigos, com predominância da classificação de espécies arbóreas (14 artigos), seguida pelo monitoramento florestal (13 artigos).

Em relação à localização dos autores (Figura 4), a maioria dos artigos provém da China (72), seguida pelos Estados Unidos (30). Na América Latina, o Brasil destaca-se como o país com o maior número de publicações (13), cujos trabalhos abordaram diferentes temas, variando da detecção de falhas de plantio e inventários qualitativos até o uso de VANTs e LiDAR para a classificação de espécies e a estimativa do volume de madeira.

Embora o Brasil figure entre os países com o maior número de publicações na América Latina, os trabalhos nacionais identificados concentraram-se predominantemente em plantios comerciais de espécies exóticas, como eucalipto e pinus, com pouca atenção às espécies nativas.

Figura 4 - Localização dos autores e coautores dos artigos analisados.



Fonte: Autoria própria.


Em relação às palavras mais recorrentes nos títulos e resumos dos artigos encontrados (Figura 5), o termo *forestry* ocupou posição central na rede e concentrou o maior número de conexões, articulando-se com todos os agrupamentos identificados.

Ao seu redor destacaram-se os termos *deep learning*, *computer vision*, *machine learning*, *remote sensing* e *image analysis*, alinhado à proposta deste trabalho.

A rede organizou-se em agrupamentos temáticos que refletem as categorias identificadas nesta revisão. Um agrupamento reuniu termos associados ao aprendizado profundo e à classificação (*deep learning, convolutional neural network, artificial neural network, tree species classification, classification accuracy*), enquanto outro concentrou termos relacionados à madeira e à indústria de base florestal (*machine vision, timber, wood, lumber, logging*). Um terceiro agrupamento associou o sensoriamento remoto ao mapeamento e aos ecossistemas (*remote sensing, image resolution, mapping, ecosystems*), e um quarto reuniu a segmentação de imagens e as plataformas aéreas (*image segmentation, unmanned aerial vehicles, forest management, forest canopies*).

A recorrência conjunta de *remote sensing, image analysis* e *machine learning* reforça o crescimento das publicações voltadas à classificação de espécies e ao monitoramento no meio florestal.

Figura 5 - Fluxograma das palavras mais encontradas nos artigos selecionados na revisão sistemática de literatura.



Fonte: Autoria própria.

Em termos de gestão, análise e planejamento florestal, duas áreas se destacaram: as florestas plantadas e as florestas urbanas. A visão computacional oferece soluções eficientes e precisas que superam as limitações dos métodos tradicionais manuais, uma vez que automatiza

tarefas complexas e demoradas, fornece dados em tempo real e de alta precisão, reduz custos e aumenta a escalabilidade.

No manejo de florestas plantadas, a visão computacional permite a automatização de inventários florestais, incluindo a detecção e contagem de árvores e mudas, a quantificação do volume de madeira empilhada, a identificação de falhas no plantio, o monitoramento da saúde das plantas e a estimativa de biomassa de forma não destrutiva. Como exemplo, Wu et al. (2019) propuseram um método de medição passiva do diâmetro à altura do peito (DAP) de múltiplas árvores a partir de uma única imagem capturada por *smartphone*, utilizando técnicas de visão computacional e fotogrametria de curto alcance.

Para as áreas verdes e florestas urbanas, a visão computacional auxilia na detecção, no mapeamento e na análise de árvores e coberturas verdes; nos inventários de árvores urbanas; no monitoramento do bem-estar das árvores; na identificação de doenças ou riscos mecânicos e, consequentemente, nas análises de risco de queda nos níveis 1 e 2; na quantificação da cobertura de copa (UTC, do inglês *Urban Tree Canopy*); e na avaliação dos serviços ecossistêmicos, como mitigação da poluição do ar, redução do efeito de ilha de calor e sequestro de carbono.

Um exemplo prático do uso da visão computacional em florestas urbanas é o estudo de Liu et al. (2024), no qual os autores propuseram uma solução para estimar a biomassa de florestas urbanas combinando dados LiDAR, que fornecem características geográficas tridimensionais detalhadas; dados do *Open Street Map*, que oferecem percepções sobre a evolução florestal ao longo do tempo; e modelos de aprendizado profundo (deep learning), com o objetivo de otimizar a precisão das estimativas.

Quanto às tecnologias de aquisição de dados, imagens de satélite foram identificadas em 68 dos 155 artigos analisados, seguidas pelo uso de Veículos Aéreos Não Tripulados (VANTs) (37) e LiDAR (32). O crescimento no número de publicações envolvendo VANTs e LiDAR a partir de 2019 reflete os avanços tecnológicos ocorridos no período, que contribuíram para a ampliação de sua aplicação em pesquisas e atividades de campo.

Os 155 trabalhos mostram uma trajetória de amadurecimento da visão computacional na área florestal: se nos anos 1990 as aplicações restringiam-se ao ambiente controlado das serrarias e a objetos isolados, a produção recente opera em escala de paisagem e em campo aberto. A previsão de Guimier (1998) confirmou-se, porém o avanço não veio da robótica embarcada, mas da capacidade de extrair informação de imagens.

2.4. CONCLUSÕES

Este estudo mostrou que a visão computacional tem se consolidado como uma área de crescente interesse e aplicação no setor florestal, com expansão expressiva no número de publicações a partir de 2019, culminando em 42 artigos publicados em 2024, o maior número da série analisada.

Os artigos demonstraram que a visão computacional abrange amplas aplicações que confirmam o potencial da visão computacional como alternativa viável e eficiente aos métodos tradicionais de campo, especialmente na automatização de inventários, no monitoramento da saúde florestal e no suporte ao planejamento e à gestão de florestas plantadas e urbanas.

Quanto às tecnologias de aquisição de dados e ferramentas utilizadas, imagens de satélite foram as mais recorrentes, presentes em 68 dos 155 artigos analisados, seguidas por VANTs e LiDAR. Do ponto de vista computacional, os algoritmos de aprendizado profundo, em especial as redes neurais convolucionais, destacaram-se como as abordagens mais adotadas, refletindo o avanço dessas técnicas a partir de 2019 e sua crescente aplicação em tarefas de classificação de espécies, segmentação de copas e detecção de defeitos no meio florestal.

Cabe destacar que, embora a China e os Estados Unidos concentrem a maior parte das publicações, o Brasil apresenta participação relevante no cenário internacional, com contribuições em temas estratégicos para o setor, como inventários florestais, uso de VANTs e estimativa de volume de madeira. Isso reflete o potencial do país para avançar nessa área, dada a expressividade de seu setor florestal.

Essa concentração geográfica dos autores, porém, tem implicações metodológicas. Grande parte dos modelos disponíveis foi treinada em florestas temperadas, de composição relativamente homogênea, o que restringe sua transferência direta para florestas tropicais heterogêneas.

Mesmo no Brasil, os trabalhos identificados concentram-se em plantios comerciais de espécies exóticas, cuja uniformidade aproxima as condições daquelas em que os métodos foram originalmente desenvolvidos. As florestas nativas, nas quais o inventário e a identificação de espécies são mais custosos, permanecem pouco representadas na literatura.

Recomenda-se que estudos futuros aprofundem as aplicações voltadas às condições específicas das florestas tropicais, desenvolvam ferramentas acessíveis e adaptadas à realidade do setor florestal brasileiro, com especial atenção à identificação de espécies nativas, e integrem a visão computacional aos inventários florestais já consolidados.

2.5. REFERÊNCIAS

- ADAMIAN, N; et al. An Open-Source Computer Vision Tool for Automated Voca Fold Tracking From Videoendoscopy. **Laryngoscope**, n.0, p.1–7, 2020. DOI: [10.1002/lary.28669](https://doi.org/10.1002/lary.28669).
- AIBIN, M. E. T. A. L. Advancing Forest Fire Risk Evaluation: An Integrated Framework for Visualizing Area-Specific Forest Fire Risks Using UAV Imagery, Object Detection and Color Mapping Techniques. **Drones** (MDPI), 2024.
- AKOBENG, A. K. Understanding systematic reviews and meta-analysis. **Arch Dis Child**. 2005.
- AREVALO-RAMIREZ, T. E. T. A. L. Challenges for computer vision as a tool for screening urban trees through street-view images. **Urban Forestry and Urban Greening**, 2024.
- AWAD, M. M.; LAUTERI, M. Self-Organizing Deep Learning (SO-UNet) - A Novel Framework to Classify Urban and Peri-Urban Forests. **Sustainability** (MDPI), 2021.
- BERTOLA, A. **Uso de fotografias digitais para quantificar o volume sólido de madeira empilhada**. Dissertação de mestrado, Viçosa, 64 p. 2002.
- BERWANGER, O. Como avaliar criticamente revisões sistemáticas e metanálises? **Rev. Bras. Ter. Intensiva**, São Paulo, v.19, n.4, p.475-480, 2007. DOI: <https://doi.org/10.1590/S0103-507X2007000400012>.
- BHATT, Dulari; et al. CNN Variants for Computer Vision: History, Architecture, Application, Challenges and Future Scope. **Electronics**, v.10, n.2470, 2021. DOI: [10.3390/electronics10202470](https://doi.org/10.3390/electronics10202470).
- BILGILIOGLU, B. B. et al. Object-based classification of unmanned aerial vehicle (UAV) imagery for forest fires monitoring. **Fresenius Environmental Bulletin**, 2019.
- BIOLCHINI, J.C.A. et al. Scientific research ontology to support systematic review in software engineering. **Advanced Engineering Informatics**, v.21, n.2, p.133-151, 2007. DOI: [10.1016/j.aei.2006.11.006](https://doi.org/10.1016/j.aei.2006.11.006).
- BORTOLOTT, Z. J.; WYNNE, R. H. Estimating forest biomass using small footprint LiDAR data: an individual tree-based approach that incorporates training data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 59, n. 6, p. 342–360, 2005. DOI: <https://doi.org/10.1016/j.isprsjprs.2005.07.001>.
- BOUDRA, S.; YAHIAOUI, I.; BEHLOUL, A. Tree trunk texture classification using multi-scale statistical macro binary patterns and CNN. **Applied Soft Computing**, v. 118, p. 108473, 2022. DOI: <https://doi.org/10.1016/j.asoc.2022.108473>.
- BRANDTBERG, T.; WALTER, F. Automated delineation of individual tree crowns in high spatial resolution aerial images by multiple-scale analysis. **Machine Vision and Applications**, v.11, p.64–73, 1998. DOI: <https://doi.org/10.1007/s001380050091>.
- BRANSON, S. et al. From Google Maps to a fine-grained catalog of street trees. **ISPRS Journal of Photogrammetry and Remote Sensing**, 2018.
- BRODIE, J. R.; HANSEN, A. C.; REID, J. F. Size assessment of stacked logs via the Hough transform. **Transactions of the American Society of Agricultural Engineers**, 1994.
- CAMPOS, F. Serviços Digitais para uma colheita 4.0. **Revista Opiniões**, 2021. Disponível em: <https://florestal.revistaopinioes.com.br/revista/detalhes/14-servicos-digitais-parauma-colheita-40/>.
- CARRATÙ, M.; GALLO, V.; LIGUORI, C.; LUNDGREN, J.; O’NILS AND A. PIETROSANTO, M. Vision-Based System for Measuring the Diameter of Wood Logs. **IEEE Open Journal of Instrumentation and Measurement**, v.2, p.1-12, 2023. DOI: [10.1109/OJIM.2023.3264042](https://doi.org/10.1109/OJIM.2023.3264042).

- CASAS, G. G. et al. Automatic Detection and Counting of Stacked Eucalypt Timber Using the YOLOv8 Model. **Forests** (MDPI), 2023.
- CASAS, G. G.; ISMAIL, Z. H.; LIMEIRA, M. M. C.; SOARES, C. P. B.; GLERIANI, J. M.; BINOTI, D. H. B.; ARAÚJO JÚNIOR, C. A.; SHAPIAI, M. I.; RODRIGUES, L. I.; ARAÚJO, T. M.; LEITE, H. G. Quantifying solid volume of stacked eucalypt timber using detection-segmentation and diameter distribution models. **Smart Agricultural Technology**, v.9, n.100653, 2024. DOI: <https://doi.org/10.1016/j.atech.2024.100653>.
- CHA, S. et al. Deepening the Accuracy of Tree Species Classification: A Deep Learning-Based Methodology. **Forests** (MDPI), 2023.
- CHAITY, M. D.; VAN AARDT, J. Exploring the Limits of Species Identification via a Convolutional Neural Network in a Complex Forest Scene through Simulated Imaging Spectroscopy. **Remote Sensing** (MDPI), 2024.
- CHEN, C. et al. Using time-series imagery and 3DLSTM model to classify individual tree species. **International Journal of Digital Earth**, v. 17, n. 1, 2024. DOI: <https://doi.org/10.1080/17538947.2024.2308728>.
- CHEN, X.; SHEN, X.; CAO, L. Tree Species Classification in Subtropical Natural Forests Using High-Resolution UAV RGB and SuperView-1 Multispectral Imageries Based on Deep Learning Network Approaches: A Case Study within the Baima Snow Mountain National Nature Reserve, China. **Remote Sensing** (MDPI), 2023.
- CHENG, P.; JINHAO, L.; WANG, D. Measuring diameters at breast height using combination method of laser and machine vision. **Nongye Jixie Xuebao/Transactions of the Chinese Society for Agricultural Machinery**, v.44, n.11, 2013. DOI: [10.6041/j.issn.1000-1298.2013.11.046](https://doi.org/10.6041/j.issn.1000-1298.2013.11.046).
- CHENG, X. M.; DOOSTHOSSEINI, A.; KUNKEL, J. Improve the Deep Learning Models in Forestry Based on Explanations and Expertise. **Frontiers in Plant Science**, 2022.
- COOPER, H. HEDGES, L.V. **The Handbook of Research Synthesis**, Russell Sage Foundation, New York, 1994.
- CUI, Z. L. et al. Improvement and Assessment of Convolutional Neural Network for Tree Species Identification Based on Bark Characteristics. **Forests** (MDPI), 2023.
- DA SILVA, N. R. et al. Improved wood species identification based on multi-view imagery of the three anatomical planes. **Plant Methods**, 2022.
- DAÍ, L. et al. CPH-Fmnet: An Optimized Deep Learning Model for Multi-View Stereo and Parameter Extraction in Complex Forest Scenes. **Forests** (MDPI), 2024.
- DANDOIS, J. P.; ELLIS, E. C. Remote Sensing of Vegetation Structure Using Computer Vision. **Remote Sensing** (MDPI), 2010.
- DE OLIVEIRA, W. F. et al. Improved detection of planting failures by computer vision. **Scientia Agricola**, 2024.
- DEMEYERE, M. et al. Measurement of cylindrical objects through laser telemetry: Application to a new forest caliper. **IEEE Transactions on Instrumentation and Measurement**, 2002.
- DENG, X. L. et al. Detection and Location of Dead Trees with Pine Wilt Disease Based on Deep Learning and UAV Remote Sensing. **AgriEngineering** (MDPI), 2020.
- DERSCH, S. et al. Semi-supervised multi-class tree crown delineation using aerial multispectral imagery and lidar data. **ISPRS Journal of Photogrammetry and Remote Sensing**, 2024.

- DING, Y. W. E. T. A. L. Innovative computer vision-based full-scale timber element cracks detection, stitching, and quantification. **Structural Health Monitoring**, 2024.
- FANG, T. Y. et al. Open-Set Recognition of Wood Species Based on Deep Learning Feature Extraction Using Leaves. **Journal of Imaging** (MDPI), 2023.
- FERREIRA, M. P. et al. Improving urban tree species classification by deep-learning based fusion of digital aerial images and LiDAR. **Urban Forestry and Urban Greening**, 2024.
- FERREIRA, M. P. et al. Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. **Forest Ecology and Management**, 2020.
- FILHO, P. L. P.; OLIVEIRA, L. S.; NISGOSKI, S.; et al. Forest species recognition using macroscopic images. **Machine Vision and Applications**, v. 25, p. 1019–1031, 2014. DOI: <https://doi.org/10.1007/s00138-014-0592-7>.
- FIROZE, A.; BENES, B.; ALIAGA, D. Urban tree generator: spatio-temporal and generative deep learning for urban tree localization and modeling. **The Visual Computer**, v. 38, p. 3327–3339, 2022. DOI: <https://doi.org/10.1007/s00371-022-02526-x>.
- FRASER, B. T.; CONGALTON, R. G. Estimating Primary Forest Attributes and Rare Community Characteristics Using Unmanned Aerial Systems (UAS): An Enrichment of Conventional Forest Inventories. **Remote Sensing** (MDPI), 2021.
- FRICKER, G. A. et al. A convolutional neural network classifier identifies tree species in mixed-conifer forest from hyperspectral imagery. **Remote Sensing** (MDPI), 2019.
- GAO, M. Y. et al. BLNN: Multiscale Feature Fusion-Based Bilinear Fine-Grained Convolutional Neural Network for Image Classification of Wood Knot Defects. **Journal of Sensors**, 2021.
- GAO, Y.; CHENG, P. L. Forest Fire Smoke Detection Based on Visual Smoke Root and Diffusion Model. **Fire Technology**, 2019.
- GONCALVES, A. M.; BRANDAO, T.; FERREIRA, J. C. Wildfire Detection with Deep Learning - A Case Study for the CICLOPE Project. **IEEE Access**, 2024.
- GONG, A. et al. A handheld device for leaf area measurement. **Computers and Electronics in Agriculture**, 2013.
- GU, J.; GRYBAS, H.; CONGALTON, R. G. A comparison of forest tree crown delineation from unmanned aerial imagery using canopy height models vs. spectral lightness. **Forests** (MDPI), 2020.
- GUERRA-HERNANDEZ, J. E. T. A. L. Comparison of ALS- and UAV(SfM)-derived high-density point clouds for individual tree detection in Eucalyptus plantations. **International Journal of Remote Sensing**, 2018.
- GUIMIER, D. Y.; HEIDERSDORF, E. Forestry operations into the next century. **The Forestry Chronicle**, v. 74, n. 1, p. 68-71, 1998. DOI: <https://doi.org/10.5558/tfc74068-1>.
- GUO, J. H. et al. Continent-wide urban tree canopy fine-scale mapping and coverage assessment in South America with high-resolution satellite images. **ISPRS Journal of Photogrammetry and Remote Sensing**, 2024.
- GUO, Y. et al. A Deep Fusion uNet for Mapping Forests at Tree Species Levels with Multi-Temporal High Spatial Resolution Satellite Imagery. **Remote Sensing** (MDPI), 2021.
- GUO, Y. et al. An End-to-End Deep Fusion Model for Mapping Forests at Tree Species Levels with High Spatial Resolution Satellite Imagery. **Remote Sensing** (MDPI), 2020.

- HARTLING, S. et al. Urban tree species classification using a worldview-2/3 and LiDAR data fusion approach and deep learning. **Sensors** (MDPI), 2019.
- HE, T. et al. Developing deep learning models to automate rosewood tree species identification for CITES designation and implementation. **Holzforschung**, 2020.
- HITTAWA, M. M. et al. Machine vision for timber grading singularities detection and applications. **Journal of Electronic Imaging**, 2017.
- HOLOPAINEN, M.; VASTARANTA, M.; HYYPPÄ, J. Outlook for the next generation's precision forestry in Finland. **Forests** (MDPI), 2014.
- HUANG, H.; HE, S.; CHEN, C. Leaf Abundance Affects Tree Height Estimation Derived from UAV Images. **Forests**, 2019. <https://doi.org/10.3390/f10100931>.
- HUANG, J. W. et al. A Small-Target Forest Fire Smoke Detection Model Based on Deformable Transformer for End-to-End Object Detection. **Forests** (MDPI), 2023.
- HUANG, J.; YANG, H.; LIU, Y.; LIU, H. A Forest Fire Smoke Monitoring System Based on a Lightweight Neural Network for Edge Devices. **Forests**, v. 15, n. 7, p. 1092, 2024. DOI: <https://doi.org/10.3390/f15071092>.
- HYYPPÄ, J. et al. Feasibility of Google Tango and Kinect for crowdsourcing forestry information. **Forests** (MDPI), 2017.
- ILLARIONOVA, S. et al. Advancing forest carbon stocks' mapping using a hierarchical approach with machine learning and satellite imagery. **Scientific Reports**, 2024.
- KHOURY JR, J. K.; PINTO, F. A. C.; QUEIROZ, D.M.; LUCIA, R. M. D.; RESENDE, R. C. Redes neurais para reconhecimento de defeitos de madeira serrada de eucalipto em imagens digitais. **Scientia Forestalis**, Piracicaba, n. 70, p. 85–96, abr. 2006. Disponível em: <https://www.ipcf.br/publicacoes/scientia/nr70/cap09.pdf>. Acesso em: 19 dez. 2024.
- KIM, D.; KO, C.; KIM, D. Method for detecting tree ring boundary in conifers and broadleaf trees using Mask R-CNN and linear interpolation. **Dendrochronologia**, 2023.
- KIM, J.; MULLER, J. P. Tree and building detection in dense urban environments using automated processing of IKONOS image and LiDAR data. **International Journal of Remote Sensing**, 2011.
- KIM, T. K. et al. Identifying and extracting bark key features of 42 tree species using convolutional neural networks and class activation mapping. **Scientific Reports**, 2022.
- KLINKHACHORN, P. et al. Prototyping an automated lumber processing system. **Forest Products Journal**, v. 43, n. 2, p. 11-18, 1993. Disponível em: <https://www.fs.usda.gov/treearch/pubs/viewpubs.jsp?pubid=19807>. Acesso em: 2024.
- KOBAYASHI, K. et al. Anatomical features of Fagaceae wood statistically extracted by computer vision approaches: Some relationships with evolution. **PLoS ONE**, 2019.
- KORZNIKOV, K. A. et al. Using u-net-like deep convolutional neural networks for precise tree recognition in very high resolution rgb (Red, green, blue) satellite images. **Forests** (MDPI), 2021.
- LI, H.; HU, B.; LI, Q.; JING, L. CNN-Based Individual Tree Species Classification Using High-Resolution Satellite Imagery and Airborne LiDAR Data. **Forests**, v. 12, n. 12, p. 1697, 2021. DOI: <https://doi.org/10.3390/f12121697>.

LI, S. et al. A novel approach for leaf area retrieval from terrestrial laser scanned points. **Journal of Nanjing Forestry University (Natural Sciences Edition)**, v. 47, n. 5, p. 28-38, 2023. DOI: [10.12302/j.issn.1000-2006.202210012](https://doi.org/10.12302/j.issn.1000-2006.202210012).

LIKÓ, S. B. et al. Deep learning-based training data augmentation combined with post-classification improves the classification accuracy for dominant and scattered invasive forest tree species. **Remote Sensing in Ecology and Conservation**, 2024.

LIU, H. et al. Estimating Urban Forests Biomass with LiDAR by Using Deep Learning Foundation Models. **Remote Sensing**, v. 16, n. 9, p. 1643, 2024. DOI: <https://doi.org/10.3390/rs16091643>.

LIU, J. Z.; WANG, X. F.; WANG, T. Classification of tree species and stock volume estimation in ground forest images using Deep Learning. **Computers and Electronics in Agriculture**, 2019.

LIU, M. et al. Tree species classification of airborne LiDAR data based on 3D deep learning. **Guofang Keji Daxue Xuebao/Journal of National University of Defense Technology**, 2022.

LU, K. J. et al. MTL-FFDET: A Multi-Task Learning-Based Model for Forest Fire Detection. **Forests (MDPI)**, 2022.

MAGALHAES ALBUQUERQUE, A. et al. Qualitative Forest Inventory in Eucalyptus Plantations Using Unmanned Aerial Vehicles, Multispectral Sensors, and Deep Learning. **IEEE Geoscience and Remote Sensing Letters**, 2024.

MAO, J. et al. Wildfire Smoke Classification Based on Synthetic Images and Pixel- and Feature-Level Domain Adaptation. **Sensors (MDPI)**, 2021.

MARQUES, T. et al. Applying deep learning to real-time UAV-based forest monitoring: Leveraging multi-sensor imagery for improved results. **Expert Systems with Applications**, 2024.

MÄYRÄ, J. E. T. A. L. Tree species classification from airborne hyperspectral and LiDAR data using 3D convolutional neural networks. **Remote Sensing of Environment**, 2021.

MICHALOWSKA, M.; RAPINSKI, J.; JANICKA, J. Tree species classification on images from airborne mobile mapping using ML.NET. **European Journal of Remote Sensing**, 2023.

MILLER, J.; MORGENROTH, J.; GOMEZ, C. 3D modelling of individual trees using a handheld camera: Accuracy of height, diameter and volume estimates. **Urban Forestry and Urban Greening**, 2015.

MINOWA, Y.; KUBOTA, Y. Identification of broad-leaf trees using deep learning based on field photographs of multiple leaves. **Journal of Forest Research**, 2022.

MINOWA, Y.; KUBOTA, Y.; NAKATSUKASA, S. Verification of a Deep Learning-Based Tree Species Identification Model Using Images of Broadleaf and Coniferous Tree Leaves. **Forests (MDPI)**, 2022.

MITRA, A. E. T. A. L. Mapping Planted Forests in the Korean Peninsula Using Artificial Intelligence. **Forests (MDPI)**, 2024.

MOHARRAM, D.; YUAN, X. G.; LI, D. Tree Seedlings Detection and Counting Using a Deep Learning Algorithm. **Applied Sciences (MDPI)**, 2023.

MOHER, D.; LIBERATI, A.; TETZLAFF, J.; ALTMAN, D.G.; PRISMA Group. Reprint- preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. **Phys Ther**, 2009. DOI: [10.1093/ptj/89.9.873](https://doi.org/10.1093/ptj/89.9.873).

- MOSKALIK, T. et al. Methods of Wood Volume Determining and Its Implications for Forest Transport. **Sensors** (MDPI), 2022.
- NEYNS, R.; EFTHYMIADIS, K.; LIBIN, P.; CANTERS, F. Fusion of multi-temporal PlanetScope data and very high-resolution aerial imagery for urban tree species mapping. **Urban Forestry & Urban Greening**, v. 99, p. 128410, 2024. ISSN 1618-8667. DOI: <https://doi.org/10.1016/j.ufug.2024.128410>.
- NGUYEN-TRONG, K. Evaluation of Wood Species Identification Using CNN-Based Networks at Different Magnification Levels. **International Journal of Advanced Computer Science and Applications**, 2023.
- NORONHA, D.P.; FERREIRA, S.M.S.P. Revisões de Literatura. In: Campello BV, Kremer JM, organizadores. **Fontes de informação para pesquisadores e profissionais**. Editora UFMG, Belo Horizonte, p.191-198, 2000.
- OLIVEIRA, W. F. de; VIEIRA, A. W.; SANTOS, S. R. dos; PIMENTA, S.; SILVA, L. A. da. Improved detection of planting failures by computer vision. **Sci. agric. (Piracicaba, Braz.)**, v. 81, p. 1-11, 2024. Disponível em: <https://www.scielo.br/j/sa/a/PWNnZ5KV7jSRk7qnWNNLcmx/?lang=en#>.
- OLSCHOFSKY, K.; KÖHL, M. Rapid field identification of cites timber species by deep learning. **Trees, Forests and People**, 2020.
- OWENS, F. C. et al. Predicting Hardwood Porosity Domains: Toward Cascading Computer-Vision Wood Identification Models. **BioResources**, 2024.
- PANAGIOTIDIS, D.; ABDOLLAHNEJAD, A.; SUROVÝ, P.; CHITECULO, V. Determining tree height and crown diameter from high-resolution UAV imagery. *International Journal of Remote Sensing*, 2017. DOI: <https://doi.org/10.1080/01431161.2016.1264028>.
- PUTRA, B. T. W. et al. The use of computer vision to estimate tree diameter and circumference in homogeneous and production forests using a non-contact method. **Forest Science and Technology**, 2021.
- QIU, H. et al. Forest digital twin: A new tool for forest management practices based on Spatio-Temporal Data, 3D simulation Engine, and intelligent interactive environment. **Computers and Electronics in Agriculture**, 2023.
- RAVINDRAN, P. et al. Field-Deployable Computer Vision Wood Identification of Peruvian Timbers. **Frontiers in Plant Science**, 2021.
- RAVINDRAN, P.; WIEDENHOEFT, A. C. Caveat emptor: On the Need for Baseline Quality Standards in Computer Vision Wood Identification. **Forests** (MDPI), 2022.
- RIBAS, R.P.; ELMIRO, M.A.T. Individualização de árvores em ambiente florestal nativo utilizando métodos de segmentação em modelos digitais produzidos a partir da tecnologia LiDAR. **Revista Brasileira de Cartografia**. 2013. DOI: <https://doi.org/10.14393/rbcv65n4-43856>.
- RODRÍGUEZ-PUERTA, F. et al. Mapping Tree Canopy in Urban Environments Using Point Clouds from Airborne Laser Scanning and Street Level Imagery. **Sensors** (MDPI), 2022.
- SARINOVA, A. et al. Comparison of deep learning-based models for detection of diseased trees using an image compression algorithm. **Eastern-European Journal of Enterprise Technologies**, 2024.
- SATLAWA, P.; FISHER, R. B. Using Deep Learning to Detect the Need for Forest Thinning: Application to the Lungau Region, Austria. **Algorithms** (MDPI), 2023.
- SAVEKAR, A.; KUMAR, V. AI in Computer Vision Market: global opportunity analysis and industry forecast. Portland: **Allied Market Research**, 2021.

- SEIFERLING, I. et al. Green streets - Quantifying and mapping urban trees with street-level imagery and computer vision. **Landscape and Urban Planning**, 2017.
- SHAMSOSHOARA, A. et al. Aerial imagery pile burn detection using deep learning: The FLAME dataset. **Computer Networks**, 2021.
- SHI, Y. et al. ACTL: Asymmetric Convolutional Transfer Learning for Tree Species Identification Based on Deep Neural Network. **IEEE Access**, 2021.
- SHI, Y. Q. et al. A method for determining the spatial pattern of forest trees based on the uniformity theory. **Journal of Forestry Research**, 2024.
- SONG, Y. P.; HE, F. Z.; LIU, Y. A. A non-invasive learning branch to capture leaf-image attention for tree species classification. **Multimedia Tools and Applications**, 2022.
- SOTO, P. J. et al. Domain-Adversarial Neural Networks for Deforestation Detection in Tropical Forests. **IEEE Geoscience and Remote Sensing Letters**, 2022.
- STUBBINGS, P. et al. A Hierarchical Urban Forest Index Using Street-Level Imagery and Deep Learning. **Remote Sensing (MDPI)**, 2019.
- SUN, R. S. et al. Automatic identification for standing tree limb pruning. **Frontiers of Forestry in China**, 2005.
- SUN, X. B.; SHI, Y. J. The image recognition of urban greening tree species based on deep learning and CAMP-MKNet model. **Urban Forestry & Urban Greening**, 2023.
- TIAN, X. M. et al. Improved Prototypical Network Model for Forest Species Classification in Complex Stand. **Remote Sensing (MDPI)**, 2020.
- TRAN, H. et al. Measuring tree stem diameters and straightness with depth-image computer vision. **Journal of Forestry Research**, 2023.
- TROLES, J. et al. BAMFORESTS: Bamberg Benchmark Forest Dataset of Individual Tree Crowns in Very-High-Resolution UAV Images. **Remote Sensing (MDPI)**, 2024.
- VAGHELA, H. P.; ALAGU RAJA, R. A. Automatic Identification of Tree Species From Sentinel-2A Images Using Band Combinations and Deep Learning. **IEEE Geoscience and Remote Sensing Letters**, 2024.
- VÄHÄ-KONKA, V. et al. Estimating the accuracy of smartphone app-based removal estimates against actual wood-harvesting data from clear cuttings. **iForest - Biogeosciences and Forestry**, 2024.
- VENTURA, J. E. T. A. L. Individual tree detection in large-scale urban environments using high-resolution multispectral imagery. **International Journal of Applied Earth Observation and Geoinformation**, 2024.
- WANG, Y.; YANG, X.; ZHANG, L.; FAN, X.; YE, Q.; FU, L. Individual tree segmentation and tree-counting using supervised clustering. **Computers and Electronics in Agriculture**, v. 205, p. 107629, 2023. DOI: <https://doi.org/10.1016/j.compag.2023.107629>.
- WARNER, C. et al. CentralBark Image Dataset and Tree Species Classification Using Deep Learning. **Algorithms (MDPI)**, 2024.
- WELLS, L. A.; CHUNG, W. A Deformable Shape Model for Automatic and Real-Time Dendrometry. **Forests**, 2023. DOI: <https://doi.org/10.3390/f14122299>.
- WINSEN, M.; HAMILTON, G. A Comparison of UAV-Derived Dense Point Clouds Using LiDAR and NIR Photogrammetry in an Australian Eucalypt Forest. **Remote Sensing (MDPI)**, 2023.

- WOO, H.; KIM, I.; CHOI, B. Computer vision techniques in forest inventory assessment: Improving accuracy of tree diameter measurement using smartphone camera and photogrammetry. **Sensors and Materials**, 2021.
- WU, J. et al. A novel framework combining band selection algorithm and improved 3D prototypical network for tree species classification using airborne hyperspectral images. **Computers and Electronics in Agriculture**, 2024.
- WU, X. et al. Passive measurement method of tree diameter at breast height using a smartphone. **Computers and Electronics in Agriculture**, v. 163, p. 104875, jul. 2019. DOI: [10.1016/j.compag.2019.104875](https://doi.org/10.1016/j.compag.2019.104875).
- XIAO, C.; QIN, R.; HUANG, X. Treetop detection using convolutional neural networks trained through automatically generated pseudo labels. **International Journal of Remote Sensing**, 2020.
- XIE, Y. H.; LING, J. X. Wood Defect Classification Based on Lightweight Convolutional Neural Networks. **BioResources**, 2023.
- XIE, Y. N. et al. Urban forestry detection by deep learning method with GaoFen-2 remote sensing images. **Journal of Applied Remote Sensing**, 2022.
- XU, C. et al. 3D Reconstruction of Tree-Crown Based on the UAV Aerial Images. **Mathematical Problems in Engineering**, 2015.
- XU, E. et al. An Estimation Model for Regional Forest Canopy Closure Combined with UAV LiDAR and High Spatial Resolution Satellite Remote Sensing Data. **Wuhan Daxue Xuebao (Xinxi Kexue Ban)/Geomatics and Information Science of Wuhan University**, 2022.
- XUE, Z. Y.; LIN, H. F.; WANG, F. A Small Target Forest Fire Detection Model Based on YOLOv5 Improvement. **Forests (MDPI)**, 2022.
- YANG, T. T.; ZHOU, S. Y.; XU, A. J. Rapid Image Detection of Tree Trunks Using a Convolutional Neural Network and Transfer Learning. **IAENG International Journal of Computer Science**, 2021.
- YANG, Y. T. et al. Wood Defect Detection Based on Depth Extreme Learning Machine. **Applied Sciences (MDPI)**, 2020.
- YAO, S. et al. Individual Tree Crown Detection and Classification of Live and Dead Trees Using a Mask Region-Based Convolutional Neural Network (Mask R-CNN). **Forests (MDPI)**, 2024.
- YAZDI, H. et al. A multilayered urban tree dataset of point clouds, quantitative structure and graph models. **Scientific Data**, 2024.
- YE, R. C. et al. Scientific Computational Visual Analysis of Wood Internal Defects Detection in View of Tomography Image Reconstruction Algorithm. **Mobile Information Systems**, 2022.
- YUN, T.; AN, F.; LI, W.; SUN, Y.; CAO, L.; XUE, L. A Novel Approach for Retrieving Tree Leaf Area from Ground-Based LiDAR. **Remote Sens.**, 2016. DOI: <https://doi.org/10.3390/rs8110942>.
- YUN, T.; JIANG, K.; LI, G.; EICHHORN, M. P.; FAN, J.; LIU, F.; CHEN, B.; AN, F.; CAO, L. Individual tree crown segmentation from airborne LiDAR data using a novel Gaussian filter and energy function minimization-based approach. **Remote Sensing of Environment**, v.256, p.112307, 2021. DOI:<https://doi.org/10.1016/j.rse.2021.112307>.
- ZHANG, B.; ZHAO, L.; ZHANG, X. L. Three-dimensional convolutional neural network model for tree species classification using airborne hyperspectral images. **Remote Sensing of Environment**, 2020.

ZHANG, C. et al. Tree species classification using deep learning and RGB optical images obtained by an unmanned aerial vehicle. **Journal of Forestry Research**, 2021.

ZHANG, Y. et al. A Quantitative Analysis Method of Solar Shortwave Radiation within Forest Canopy Based on a Computer Simulation Model. **Linze Kexue/Scientia Silvae Sinicae**, 2024.

ZHANG, Y. et al. Development of plant leaf area measurement instrument based on virtual instrument technology. **Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering**, 2005.

ZHANG, Y. Z. et al. Using computer vision and compressed sensing for wood plate surface detection. **Optical Engineering**, 2015.

ZHONG, H. et al. Individual Tree Species Identification for Complex Coniferous and Broad-Leaved Mixed Forests Based on Deep Learning Combined with UAV LiDAR Data and RGB Images. **Forests (MDPI)**, 2024.

ZHU, X. H. et al. Automatic Detection and Classification of Dead Nematode-Infested Pine Wood in Stages Based on YOLO v4 and GoogLeNet. **Forests (MDPI)**, 2023.

3. USO DA TECNOLOGIA LIDAR NA ESTIMATIVA VOLUMÉTRICA DE PILHAS DE MADEIRA

RESUMO

A mensuração volumétrica de pilhas de madeira é uma etapa essencial na gestão da produção florestal, porém os métodos tradicionais apresentam limitações operacionais relevantes, como alto custo, caráter amostral e demanda de mão de obra especializada, além de expor os trabalhadores a riscos de acidentes. Este estudo teve como objetivo desenvolver uma aplicação para a cubagem de pilhas de madeira de *Eucalyptus* sp. por meio da tecnologia LiDAR, utilizando dois dispositivos: um iPhone 14 Pro e um scanner laser móvel portátil (HMLS LiGrip O1 Lite). O método baseou-se no processamento de nuvens de pontos tridimensionais, com etapas de remoção de ruído, normalização, estimativa da área da face por contorno côncavo, voxelização adaptativa e correção de alinhamento pelo retângulo envolvente mínimo (MBR, do inglês *Minimum Bounding Rectangle*), sendo automatizado em um aplicativo web desenvolvido em linguagem R com o framework Shiny. O método foi validado em uma pilha teste e em seis pilhas de porte intermediário, comparando-se os volumes estimados pelo LiDAR com medições obtidas pelo princípio de Arquimedes (Dinatex) e por cubagem rigorosa. Na pilha teste, os volumes das toras individuais estimados pelo LiDAR (1,71 m³ e 1,72 m³ para as faces frontal e posterior) mostraram-se próximos aos obtidos com fita métrica e suta, enquanto a análise da face completa evidenciou superestimativa associada ao ruído do sensor do smartphone. Nas pilhas intermediárias, os erros variaram de -6,8% a +8,3%, todos dentro da faixa de aceitabilidade ($|\text{erro}| \leq 10\%$), com quatro pilhas apresentando erro absoluto inferior a 6%. Conclui-se que o método é viável, replicável e de baixo custo, e que o aplicativo desenvolvido torna a técnica acessível ao uso operacional em empresas florestais.

Palavras-chave: cubagem; nuvem de pontos; fator de cubicação.

ABSTRACT

Volumetric measurement of wood piles is an essential step in forest production management; however, traditional methods have significant operational limitations, such as high cost, sample-based nature, and the demand for specialized labor, in addition to exposing workers to accident risks. This study aimed to develop an application for the scaling of *Eucalyptus* sp. wood piles using LiDAR technology, employing two devices: an iPhone 14 Pro Max and a portable handheld mobile laser scanner (HMLS LiGrip O1 Lite). The method was based on the

processing of three-dimensional point clouds, including steps of noise removal, height normalization, face area estimation by concave hull, adaptive voxelization, and alignment correction using the Minimum Bounding Rectangle (MBR), and was automated in a web application developed in the R language with the Shiny framework. The method was validated on a test pile and on six intermediate-sized piles by comparing the LiDAR-estimated volumes with measurements obtained by the Archimedes principle (Dinatex) and by rigorous scaling. In the test pile, the volumes of individual logs estimated by LiDAR (1.71 m³ and 1.72 m³ for the front and rear faces) were close to those obtained with a measuring tape and a caliper, while the analysis of the complete face revealed an overestimation associated with the smartphone sensor noise. In the intermediate piles, errors ranged from -6.8% to +8.3%, all within the acceptability range ($|\text{error}| \leq 10\%$), with four piles showing an absolute error below 6%. It is concluded that the method is feasible, replicable, and low-cost, and that the developed application makes the technique accessible for operational use in forestry companies.

Keywords: timber volume estimation; point cloud; stacking factor

3.1. INTRODUÇÃO

O monitoramento, o planejamento e o controle da produção florestal constituem etapas fundamentais para a gestão eficiente de madeira em pátios e em campo, auxiliando na tomada de decisões operacionais e estratégicas nas empresas do setor. Nesse contexto, a mensuração dos volumes estocados é um desafio, uma vez que as pilhas de madeira apresentam características próprias que dificultam sua quantificação com acurácia.

Entre os principais fatores que comprometem a precisão das medições destacam-se: a variabilidade dimensional das toras, que abrangem diferentes comprimentos e diâmetros; a irregularidade do padrão de empilhamento, condicionada tanto pelas condições operacionais do pátio quanto pelas características morfológicas individuais de cada peça; e as dimensões consideráveis que essas estruturas frequentemente atingem, tornando inviável a aplicação direta de métodos convencionais de cubagem.

Por isso há a dificuldade de se determinar o volume em metro estéreo (mst) e o volume em metros cúbicos (m³), mas a determinação confiável do volume armazenado é, contudo, essencial para o cálculo de rendimentos industriais, o controle de estoques e o cumprimento de obrigações contratuais e fiscais.

A ausência de metodologias padronizadas e de alta precisão para a mensuração volumétrica gera incertezas que se propagam ao longo de toda a cadeia produtiva, reforçando a

necessidade de estudos que proponham abordagens inovadoras para o controle de pilhas de madeira em escala industrial.

Os métodos clássicos, como a cubagem rigorosa e os métodos fundamentados nos princípios de Arquimedes, apresentam limitações operacionais significativas, entre as quais se destacam a elevada demanda de mão de obra, o alto custo de execução e a demora do processo. Somam-se a essas restrições a dificuldade de quantificação de grandes volumes e a inviabilidade de monitoramento contínuo do estoque. Embora reconhecidos por sua precisão (Barros, 2017; Oliveira, 2018; Soares et al., 2003), tais métodos possuem caráter amostral e não censitário, o que os torna inadequados para uma avaliação completa da totalidade do material estocado nos empreendimentos florestais.

Em pilhas de campo, é tradicional a medição em metro estéreo (mst) e a posterior conversão para metro cúbico (m^3) por meio de amostragens de pequenas porções da pilha, utilizando-se cubagem rigorosa ou análise fotográfica. Nos pátios de estocagem, o método fundamentado no princípio de Arquimedes supre parcialmente essas limitações, porém ainda se configura como uma abordagem amostral, com custos de investimento relevantes e restrições quanto à cobertura total do estoque.

Além dos aspectos operacionais e econômicos, a segurança do trabalho constitui uma preocupação central das empresas florestais, uma vez que os procedimentos tradicionais de mensuração de pilhas expõem os trabalhadores a riscos significativos de acidentes. Tanto nos pátios de estocagem quanto nas áreas de plantio, a medição manual exige a aproximação e, por vezes, a escalada das pilhas, estruturas que podem atingir grandes dimensões e apresentar instabilidade, sujeitando os operadores a quedas, esmagamentos por rolamento de toras e demais incidentes associados à movimentação de máquinas no entorno.

No Brasil, a Norma Regulamentadora nº 31 (NR-31) estabelece os preceitos de segurança e saúde no trabalho aplicáveis à silvicultura e à exploração florestal, determinando que os empregadores implementem ações de prevenção de acidentes com prioridade para a eliminação dos riscos nos processos produtivos (BRASIL, 2020). Dessa forma, a adoção de tecnologias de mensuração remota, que dispensam o contato direto com as pilhas, alinha-se às políticas de saúde e segurança ocupacional do setor e ao disposto na legislação vigente, contribuindo para a redução da exposição dos trabalhadores a ambientes de risco e reforçando a relevância de abordagens não invasivas para o controle volumétrico.

A rápida evolução das técnicas de processamento de imagens e o uso de mídias digitais, bem como uma nova geração de tecnologias em sensoriamento remoto, tem levado à revolução na modelagem digital, principalmente com a modelagem 3D, em que esses modelos são

especialmente valiosos em simulações. Para a coleta dessas informações, existem inúmeros procedimentos disponíveis, sendo o LiDAR (Light Detection and Ranging) um dos mais utilizados no setor florestal.

No cenário europeu e internacional, Beland et al. (2019) destacaram como as plataformas de varredura a laser revolucionaram as pesquisas nos últimos anos. Elas proporcionaram maior produtividade e economia significativas em grandes empresas, ao auxiliar diretamente a gestão de florestas.

Atualmente, com a expansão do uso de tecnologias, alguns smartphones já dispõem de sensores capazes de realizar funções semelhantes às do TLS e HMLS, com menor custo e maior facilidade de manuseio.

Assim, o objetivo deste estudo foi desenvolver uma aplicação para realizar a cubagem de pilhas de madeira por meio de imagens LiDAR, obtidas a partir de um iPhone 14 Pro e um HMLS, a fim de avaliar sua acurácia em relação à medição tradicional.

3.2. MATERIAIS E MÉTODOS

Este estudo foi dividido em duas etapas. Na primeira, avaliou-se uma pilha de teste por meio de cubagem rigorosa e modelagem 3D via LiDAR, utilizando um iPhone 14 Pro. Na segunda, foram medidas pilhas de pequeno porte em campo, imageadas por HMLS, cujos volumes estimados pelo escaneamento 3D foram comparados com a medição tradicional baseada no princípio de Arquimedes. Por fim, para essa segunda etapa, foi desenvolvido um aplicativo para visualização interativa dos resultados.

3.2.1. Instrumentos utilizados

3.2.1.1. *Hand-held mobile laser scanner LiGrip O1 Lite*

O LiGrip O1 Lite (Figura 6) é um scanner LiDAR portátil e leve, com precisão de varredura de até 2 cm, alcance de até 70 m, taxa de 200.000 pontos por segundo e peso aproximado de 1 kg. O equipamento suporta os métodos de mapeamento RTK-SLAM, PPK-SLAM e SLAM, além de gerar nuvens de pontos em formatos como LAS e LAZ, o que o torna adequado para aplicações de levantamento em campo (GreenValley International, 2024).

Figura 6 - LiGrip O1 Lite.




Fonte: GreenValley International (2024).

3.2.1.2. Sensor LiDar - Iphone 14 Pro

O *LiDAR* em *smartphones* da *Apple* (Figura 7) é fundamentado principalmente no princípio de *Time-of-Flight* (ToF), mais especificamente na tecnologia *Direct Time-of-Flight* (dToF), que mede, de forma direta, o tempo necessário para que um pulso de luz chegue ao alvo e volte ao receptor (SystemPlus Consulting, 2020).

Ele é um *LiDAR* de estado sólido (SSL), que difere dos sistemas *LiDAR* convencionais, pois estes utilizam partes mecânicas móveis. O SSL dispensa essas peças, o que possibilita sua miniaturização, além de aumentar a sua escalabilidade e a sua confiabilidade (Murtiyoso, 2021; Luetzenburg, Kroon e Bjørk, 2021). Seu alcance operacional máximo é de 5 m, sob condições ótimas, especialmente em superfícies de alta refletividade. Mas a experiência em campo indica que o alcance máximo não costuma exceder 3 m (Luetzenburg, Kroon e Bjørk, 2021).

Figura 7 - Ilustração da localização do LiDAR no Iphone 14 Pro.



Fonte: Apple Support (2023).

3.2.1.3. Sistemas de medição a partir de escaneamento 3D, baseado no princípio de Arquimedes

Os sistemas baseados no princípio de Arquimedes, como os sistemas comerciais, Dinatex e Pivotex, estimam o volume sólido da madeira a partir do empuxo exercido pela água sobre as toras, segundo o qual todo corpo mergulhado em um líquido recebe uma força vertical ascendente igual ao peso do líquido deslocado, o que, quando o meio é a água, equivale diretamente ao volume do objeto submerso.

No Dinatex (balança na garra estacionária) e pivotex (balança no chão abaixo da máquina) (Figura 8), cada amostra, composta por um conjunto de toras, é pesada no ar e, em seguida, imersa no tanque, sendo o volume sólido determinado pela diferença entre as pesagens. Figura 8 - Ilustração de um Pivotex.



Fonte: Autoria própria.

3.2.2. Pilha teste

A pilha de toras de *Eucalyptus* sp. foi montada na Universidade Federal de São Carlos, campus Sorocaba, para o desenvolvimento da primeira etapa do projeto, com dimensões de 1 m de altura, 2 m de comprimento e 1 m de profundidade, construída com 134 toras de 1 m de comprimento (Figura 9).

Figura 9 - Pilha teste de madeira: A) parte frontal da pilha e B) a parte oposta.



Fonte: Autoria própria

As duas faces da pilha foram imageadas e as toras foram identificadas com cores distintas para cada face (Figura 10), a fim de facilitar a diferenciação nos modelos 3D. Os diâmetros de cada face das toras foram medidos com fita métrica e suta, e o comprimento com fita métrica.

A fita métrica exige apenas uma leitura por seção, uma vez que mede a circunferência da tora, a partir da qual o diâmetro é obtido de forma indireta, assumindo-se a seção transversal como circular. A suta, por sua vez, mede o diâmetro de forma direta, porém requer duas leituras em posições perpendiculares entre si, cuja média aritmética é utilizada para compensar a irregularidade e a excentricidade da seção transversal das toras.

Realizou-se então a modelagem tridimensional das duas faces das toras por meio do aplicativo Polycam (Poly, 2024), uma solução de captura 3D compatível com dispositivos móveis iOS e Android, que combina tecnologias de fotogrametria e sensores LiDAR para a criação de modelos tridimensionais precisos. No modo LiDAR, o aplicativo utiliza os dados de profundidade captados pelo sensor do dispositivo para gerar uma nuvem de pontos densa da cena em que o resultado é uma malha tridimensional texturizada, que representa a geometria e a aparência superficial das toras, possibilitando a extração de medidas volumétricas.

A área total de cada face da pilha foi obtida pelo somatório das áreas seccionais das toras correspondentes, resultando em uma área para a face frontal e outra para a face posterior. Ambas foram multiplicadas pelo comprimento médio das toras, obtendo-se o volume em metro

cúbico de cada face, a fim de verificar se há diferença relevante entre as medições tradicional e 3d, validando assim a metodologia proposta.


Figura 10 - Pilha teste catalogada: A), vista frontal com cor amarela e B) lado oposto marcado com cor laranja.



Fonte: Autoria própria.

A estimativa dos diâmetros das faces das toras a partir das nuvens de pontos, foi desenvolvido um algoritmo automatizado em linguagem R (R Development Core Team, 2024), processando individualmente cada arquivo no formato LAS correspondente às faces das toras (Figura 11).

Figura 11 - Fluxograma para encontrar o diâmetro equivalente.



Fonte: Autoria própria.

A nuvem de pontos foi submetida à Análise de Componentes Principais (PCA, do inglês *Principal Component Analysis*), realizada com a função `prcomp` do R (Jolliffe, 2002). A PCA identifica os eixos de maior variância nos dados tridimensionais e reorienta a nuvem de pontos de forma a alinhar o plano de maior espalhamento com os dois primeiros componentes principais, que correspondem à face da seção transversal da tora, independentemente da orientação original do escaneamento.

Essa etapa é fundamental para garantir que discos escaneados em diferentes posições e ângulos sejam tratados de forma padronizada, eliminando a necessidade de alinhamento manual prévio. Após a rotação pela matriz de autovetores do PCA, os pontos foram projetados no plano bidimensional formado pelos dois primeiros componentes principais (V1 e V2), descartando o terceiro componente (V3), que representa a profundidade do disco.

Sobre essa projeção bidimensional, foi aplicado o algoritmo *concave hull* por meio do pacote *concaveman* (Gombin et al., 2025), com parâmetro de concavidade igual a 2, para delinear o contorno externo da seção transversal da tora. Diferentemente do *convex hull*, que traça o menor polígono convexo envolvendo todos os pontos, o *concave hull* ajusta-se à geometria real do contorno, acompanhando as irregularidades naturais da superfície da madeira e excluindo os espaços vazios entre os pontos periféricos, o que resulta em uma estimativa de área mais fiel à seção real da tora.


A área seccional foi calculada a partir desse contorno por meio da função `st_area()` do pacote *sf* (Pebesma, 2018), que computa a área do polígono gerado.

Assumindo que a seção transversal da tora possui geometria aproximadamente circular, o diâmetro equivalente foi obtido pela expressão:

$$D = 2 \sqrt{\left(\frac{A}{\pi}\right)} \quad (1)$$

onde A é a área seccional em m^2 e D o diâmetro equivalente em metros, posteriormente convertido para centímetros. Esse diâmetro equivalente representa o diâmetro de um círculo de mesma área que a seção real da tora, sendo uma estimativa robusta mesmo para toras com seções levemente elípticas ou irregulares (Figura 12).

Figura 12 - Área seccional e diâmetro equivalente.



Fonte: Autoria própria.

As nuvens de pontos das duas faces da pilha de teste, obtidas por modelagem 3D, tiveram os ruídos retirados e foram preparadas em quatro etapas, executadas com o pacote lidR (Roussel et al., 2020).

A primeira etapa consistiu na remoção de ruídos pelo filtro SOR (*Statistical Outlier Removal*), que identifica e remove pontos como reflexos errôneos do laser ou partículas suspensas no ar, que não correspondem à superfície real da madeira. Para cada ponto, o algoritmo calcula a distância média aos 15 vizinhos mais próximos ($k = 15$) e compara com a média global acrescida de 7 vezes o desvio padrão das distâncias ($m = 7$). Pontos que excedem esse limiar são classificados como ruído e removidos.

A segunda etapa correspondeu à classificação do solo pelo filtro CSF (*Cloth Simulation Filter*), que diferencia os pontos pertencentes ao terreno daqueles pertencentes à pilha de madeira. O método simula a queda de um tecido sobre a nuvem de pontos invertida, ajustando-se à superfície do terreno. Os parâmetros adotados foram rigidez igual a 1, adequada para terrenos com pequena inclinação, e resolução do tecido de 0,1 m.

A terceira etapa foi a normalização da altura, que subtrai a altitude do terreno de cada ponto, fazendo com que o nível do solo corresponda a zero em toda a extensão da pilha. Essa etapa é essencial para evitar distorções nas medidas em terrenos inclinados. A superfície do terreno foi interpolada a partir dos pontos classificados como solo pelo método knn1dw (k -


nearest neighbors inverse distance weighting), sendo os pontos com valores de Z negativos resultantes removidos da nuvem.

A quarta etapa consistiu na remoção definitiva dos pontos de solo que, após cumprirem sua função na normalização da altura, foram excluídos da nuvem, mantendo-se apenas os pontos correspondentes à madeira da pilha.

Ao final dessas etapas, obteve-se uma nuvem de pontos sem ruídos, com altura relativa ao solo, contendo exclusivamente os pontos da madeira das duas faces da pilha, constituindo a base para todos os cálculos subsequentes de área e volume.

Para o cálculo da área da face da pilha (Figura 13), todos os pontos da nuvem foram projetados no plano correspondente ao comprimento e à altura da pilha, como se observada de frente e o contorno externo desse conjunto de pontos foi delineado pelo algoritmo *concave hull*, com parâmetro de concavidade igual a 1,5.

Figura 13 - Aplicação do algoritmo *concave hull* na pilha teste.



Fonte: Autoria própria.

Esse algoritmo ajusta-se ao contorno real da pilha, acompanhando as reentrâncias entre os troncos. O parâmetro de concavidade adotado (1,5) representa um ajuste moderado, suficiente para capturar os espaços mais expressivos entre as toras sem entrar excessivamente nas pequenas irregularidades da superfície. A área da face obtida, multiplicada pelo comprimento médio das toras, resulta no volume em mst da pilha.

Para a obtenção do fator de cubicação (FC), a nuvem de pontos da face da pilha foi processada por meio de voxelização, técnica que divide o espaço em células regulares de área fixa de 3 dimensões (voxel) para pixels (2D). Os pontos foram então projetados sobre uma grade regular no plano YZ, e cada célula foi classificada como ocupada caso contivesse ao menos um ponto do laser. O número de células ocupadas permitiu estimar a área de madeira efetiva visível na face da pilha, utilizada no cálculo do FC.

$$FC = \text{Área_Face} / \text{Área_contornada}. \quad (2)$$

O volume sólido de madeira em metro cúbico (m³) foi obtido pela expressão:

$$\text{Metro_Cúbico} = \text{mst} \times FC \quad (3)$$

Os valores de m³ obtidos pelo somatório das áreas seccionais individuais das toras foram comparados com o m³ obtido pelo volume calculado pelo contorno da pilha, a fim de avaliar se a estimativa volumétrica realizada tora a tora difere significativamente da estimativa obtida pelo contorno geral da pilha. Todas as análises foram realizadas com o auxílio dos pacotes dplyr (Wickham et al., 2023), terra (Hijmans, 2025), raster (Hijmans, 2025) e sf (Pebesma e Bivand, 2023).

Como método complementar de estimativa do volume estéreo, foi aplicada uma abordagem inspirada no conceito de Modelo de Altura do Dossel (CHM). Após a normalização da altura, a planta da pilha foi dividida em células regulares de 5 cm × 5 cm e, para cada célula, extraiu-se o valor máximo de altura, simulando um lençol lançado sobre a pilha. O metro estéreo foi então calculado como a soma dos valores máximos de altura de cada célula multiplicada pela área da célula ($\text{Volume} = \sum Y_{\text{max}} \times \Delta X \times \Delta Z$).

3.2.3. Pilhas em campo (tamanho não comercial)

Para a avaliação do método em condições mais próximas ao real das empresas, seis pilhas de madeira de porte intermediário, maiores que a pilha de teste, mas sem dimensões comerciais, foram escaneadas com HMLS, compostas por toras com comprimento de 3,7m.

As nuvens de pontos foram armazenadas no formato las com coordenadas tridimensionais X, Y e Z, adotando-se a seguinte convenção geométrica: o eixo X corresponde à profundidade da pilha, ou seja, à direção longitudinal das toras; o eixo Y representa a largura da face, perpendicular às toras; e o eixo Z corresponde à altura normalizada da pilha.

Os volumes de referência foram obtidos pelo Dinatex os quais foram 20,27 m³, 21,71 m³, 24,22 m³, 21,28 m³, 20,70 m³ e 24,74 m³ para as pilhas 1 a 6, respectivamente.

As nuvens de pontos de cada pilha foram submetidas às mesmas etapas de limpeza e preparação descritas anteriormente, seguidas do cálculo da área da face pelo algoritmo *concave hull*, com parâmetro de concavidade igual a 1,5 (Figura 14). A área da face obtida foi multiplicada pelo comprimento nominal das toras (3,7 m), resultando no volume em metro estéreo (mst) de cada pilha.

Em seguida, para a obtenção do fator de cubicação (FC), a nuvem de pontos tridimensional foi seccionada ao longo do eixo X em janelas de 5 cm, convertendo cada fatia em uma representação bidimensional da pilha. Esse processo é denominado voxelização, técnica que divide o espaço tridimensional em células regulares de volume fixo (voxels), análogas aos pixels em imagens 2D, permitindo discretizar a nuvem de pontos contínua em uma grade estruturada e quantificável. Em cada fatia, os pontos foram projetados sobre essa grade e contabilizou-se o número de pixels ocupados, ou seja, as células que continham ao menos um ponto do laser.

O tamanho do pixel foi definido de forma adaptativa, com base na densidade real de pontos da pilha, pela expressão:


$$\text{Pixel_base} = \sqrt[3]{(\text{Área_Face} / \text{N_pontos_fatia_max})} \quad (4)$$

Essa fórmula fornece o tamanho de pixel que posicionaria, em média, um ponto por pixel. Para garantir cobertura adequada, aplicou-se um fator multiplicador igual a 3, resultando em:

$$\text{Pixel_final} = \text{Pixel_base} \times 3 \quad (5)$$

A justificativa para esse fator baseia-se na distribuição de Poisson: com um ponto por pixel em média ($\lambda = 1$), a probabilidade de um pixel ficar vazio por acaso seria de $e^{-1} = 36,8\%$, comprometendo gravemente a estimativa de área. Com o fator 3, cada pixel passa a ter em média 9 pontos ($\lambda = 9$), reduzindo essa probabilidade para $e^{-9} = 0,012\%$, virtualmente nula, garantindo que toda região com madeira seja representada sem necessidade de interpolação.

Figura 14 - Cálculo da área da face da pilha pelo algoritmo concave *hull*.



Fonte: Autoria própria.


A fatia com maior número de pixels ocupados (Figura 15) foi então selecionada como representativa da seção transversal da pilha, por corresponder à região de melhor visibilidade do escaneamento e, portanto, à estimativa mais confiável da área de madeira presente.

A voxelização foi concluída projetando cada ponto da fatia selecionada sobre a grade regular de células, calculando o centroide de cada célula e eliminando duplicatas, de forma que múltiplos pontos recaídos na mesma célula fossem contabilizados como um único pixel ocupado. A área da fatia foi então obtida por:

$$\text{Área_Fatia} = N_pixels_únicos \times \text{Pixel_final}^2 \quad (6)$$

Esse procedimento garante que apenas as regiões onde o laser efetivamente detectou madeira sejam contabilizadas, mantendo os espaços vazios entre as toras naturalmente não representados.

Figura 15 - Fatia de maior densidade de pixels, selecionada como seção transversal representativa da pilha.



Fonte: Autoria própria.

Quando as toras não estão paralelas ao eixo X do escaneamento, os cortes transversais resultam em seções oblíquas, reduzindo artificialmente a densidade de pontos por fatia e consequentemente subestimando a área.

A correção, quando necessária, foi realizada pelo algoritmo *Rotating Calipers*, aplicado ao *convex hull* bidimensional da nuvem de pontos no plano horizontal $X \times Y$. O algoritmo testa cada aresta do *convex hull* como possível eixo de alinhamento, calcula a área do retângulo envolvente mínimo (MBR, do inglês *Minimum Bounding Rectangle*) correspondente e seleciona o ângulo que minimiza essa área. A nuvem de pontos é então rotacionada de forma que o eixo longitudinal das toras fique paralelo ao eixo X, sendo este definido como a dimensão cuja extensão se aproxima do comprimento nominal das toras (3,7 m).

O MBR foi preferido à Análise de Componentes Principais (PCA), neste caso, por operar sobre os limites geométricos externos da nuvem, representados pelo *convex hull*, tornando-o insensível à distribuição não uniforme de pontos característica do escaneamento de pilhas de madeira, situação em que a face voltada ao scanner concentra muito mais pontos do que o lado oposto, o que compromete a estimativa dos eixos principais pelo PCA.

O FC foi então calculado como a razão entre a área da fatia mais densa e a área total da face da pilha:

$$FC = \text{Área_Fatia} / \text{Área_Face} \quad (7)$$

O volume sólido de madeira em metro cúbico (m^3) foi obtido pela expressão:

$$\text{Metro_Cúbico} = \text{mst} \times FC \quad (8)$$

Os volumes sólidos em metro cúbico (m^3) estimados pelo escaneamento com HMLS foram comparados com os volumes de referência obtidos pelo Dinatex, a fim de avaliar a acurácia do método proposto. Por fim para fins de visualização e análise interativa dos resultados, foi desenvolvido um aplicativo web utilizando o pacote Shiny (Chang et al., 2024).

3.3. RESULTADOS E DISCUSSÕES

3.3.1. Pilha teste

A comparação entre os métodos (Tabela 7), evidenciou que as estimativas obtidas pelo LiDAR se situaram dentro do intervalo delimitado pelas técnicas convencionais de campo, com diferenças inferiores a 0,6% em relação à fita métrica na face frontal e de aproximadamente 2,4% na face posterior, o que indica forte concordância entre as abordagens.

Nota-se, ainda, que os volumes calculados pelo uso da suta foram sistematicamente inferiores aos demais em ambas as faces, comportamento coerente com a natureza dos instrumentos: enquanto a fita métrica tende a superestimar o diâmetro em seções não circulares,

por assumir a circunferência como perfeitamente circular, a suta, ao empregar a média de duas leituras perpendiculares, tende a produzir estimativas mais conservadoras em toras de seção elíptica ou irregular.

O fato de o LiDAR ter se aproximado mais dos valores da fita métrica sugere que a nuvem de pontos captura o contorno externo real das seções, incorporando suas irregularidades. Destaca-se também a consistência das estimativas do LiDAR entre as faces frontal e posterior, com variação de apenas 0,01 m³, inferior à observada nos métodos convencionais, o que reforça a estabilidade e a repetibilidade da técnica, atributo desejável para aplicações operacionais em escala industrial.

Tabela 7 - Estimativa de volume da pilha utilizando os dados da frente e da costa da mesma imageados por LiDAR e medidos por fita e suta.

Arquivo	Frente da pilha	Costas da pilha
LiDAR (m³)	1,71	1,72
fita (m³)	1,72	1,68
suta (m³)	1,66	1,63

Fonte: Autoria própria.

Esses resultados indicam que, no contexto de medições de toras individuais, sensores LiDAR embarcados em dispositivos móveis podem representar uma alternativa promissora às técnicas convencionais, com a vantagem de empregar um equipamento amplamente acessível, o que reduz custos operacionais e amplia a viabilidade do método em condições rotineiras de inventário.

Contudo, essa equivalência não se manteve quando a face da pilha foi analisada em sua totalidade (Tabela 8): os volumes estimados superaram em aproximadamente 15% a 18% o somatório das toras individuais. Essa superestimativa está associada ao ruído característico do sensor LiDAR do iPhone, cuja menor resolução e maior dispersão dos pontos tendem a gerar superfícies que extrapolam os limites reais das seções das toras, incorporando ao modelo os espaços vazios entre as peças e as irregularidades das bordas.

Tabela 8 - Medição do volume de madeira da pilha utilizando a área da face da frente e das costas da pilha.

Arquivo	Frente da pilha	Costas da pilha
volume (mst)	2,02	1,97
CHM (mst)	1,86	

Fonte: Autoria própria.

Trata-se de um erro de natureza sistemática, e não aleatória, o que abre a possibilidade de correção por meio de filtragens da nuvem de pontos ou da aplicação de fatores de ajuste específicos para o sensor.

O método CHM, por sua vez, produziu estimativa intermediária, cerca de 8% inferior à da malha tridimensional completa, comportamento esperado, uma vez que a rasterização inerente ao modelo de altura suaviza as protuberâncias da superfície da pilha, atenuando parte do efeito do ruído.

Essa diferença entre abordagens de processamento evidencia que, para a análise de faces completas, a escolha do método de modelagem exerce influência tão relevante quanto a qualidade do sensor, aspecto que deve ser considerado na definição de protocolos operacionais.

Diferentemente dos scanners topográficos de alta precisão, o LiDAR embarcado em dispositivos móveis produz nuvens de pontos com maior dispersão ao redor das superfícies reais, gerando pontos residuais que preenchem parcialmente os espaços vazios entre as toras.

Como o cálculo da área da face foi realizado a partir do contorno côncavo da nuvem como um todo, esses resíduos foram incorporados à geometria resultante, inflando a estimativa de área em relação à soma das seções transversais individuais, o que explica a discrepância de 15% a 18% observada entre as duas abordagens.

Esse comportamento revela uma interação entre a característica do sensor e a estratégia de processamento: o mesmo ruído que pouco interfere na segmentação de toras individuais, em que cada seção é delimitada isoladamente, torna-se determinante quando a face é tratada como superfície contínua.

As limitações do sensor foram ainda potencializadas pelas condições de luminosidade durante a aquisição dos dados. A exposição à luz solar direta e a ambientes de alto contraste compromete a qualidade do retorno do sinal, uma vez que a radiação infravermelha ambiente interfere na leitura dos pulsos emitidos, produzindo pontos espúrios dispersos fora das superfícies reais da pilha.

3.3.2. Pilhas em campo (tamanho não comercial)

Os parâmetros de voxelização calculados estão apresentados na Tabela 9. O pixel final variou de 4,14 cm (Pilha 5, maior densidade de pontos na fatia densa) a 6,31 cm (Pilha 2, menor densidade), refletindo a variação na qualidade de aquisição do escaneamento. Em todas as pilhas, o valor de lambda igual a 9 garantiu probabilidade de pixel vazio inferior a 0,01%, confirmando a adequação do fator multiplicador adotado.

Revelou-se um alinhamento oblíquo nas Pilhas 3 e 5, para as quais foi aplicada a correção por MBR. Na Pilha 3, a correção elevou o número de pontos da fatia mais densa de 24.739 para 43.088 (+74%), reduzindo o pixel de 7,07 cm para 5,36 cm e aumentando a área da fatia de 4,91 m² para 6,96 m², o que demonstra que a obliquidade provocava cortes diagonais nas toras, reduzindo artificialmente a densidade por fatia e subestimando a área da face. A correção por MBR foi, portanto, decisiva para a Pilha 3, reduzindo o erro de -25,2% para -0,8%, e justifica-se pela natureza assimétrica das nuvens de pontos de pilhas de madeira pois o escaneamento captura mais pontos na face proximal, deslocando o centroide da nuvem e distorcendo os eixos do PCA.

O MBR, por operar sobre os limites externos da nuvem é invariante à distribuição interna de pontos, fornecendo alinhamento mais preciso para pilhas oblíquas. Por esse motivo a estratégia adotada de aplicar o MBR apenas às pilhas identificadas como oblíquas e manter as coordenadas originais para as demais mostrou-se adequada, uma vez que a rotação desnecessária em pilhas já alinhadas introduziria distorções nas estimativas.

Tabela 9 - Parâmetros de voxelização por pilha.

Pilha	Área Face (m²)	N Pts. Fatia	Pixel Base (cm)	Pixel Final (cm)
1	10,498	31.793	1,82	5,45
2	11,167	25.274	2,10	6,31
3	13,747	43.088	1,79	5,36
4	11,592	57.438	1,42	4,26
5	11,875	62.276	1,38	4,14
6	13,762	36.119	1,95	5,86

Fonte: Autoria própria.

Os volumes estimados pelo escaneamento com HMLS e os volumes de referência obtidos pelo Dinatex estão apresentados na Tabela 10.


O método proposto demonstrou desempenho satisfatório para as seis pilhas avaliadas, com erros variando de $-6,8\%$ a $+8,3\%$, todas classificadas na faixa de aceitabilidade ($|\text{erro}| \leq 10\%$), e quatro pilhas com erro absoluto inferior a 6% (Figura 16). Destaca-se que as pilhas 2, 4 e 5 apresentaram erros de $-1,0\%$, $+0,9\%$ e $+0,5\%$, respectivamente, evidenciando elevada precisão para essas estruturas. Esse desempenho é comparável ao de métodos fotogramétricos baseados em Structure-from-Motion (SfM), que apresentaram desvios volumétricos de até 19% para volumes de madeira (Spreitzer et al., 2019; Spreitzer et al., 2020), com a vantagem adicional de maior robustez a variações de iluminação e textura superficial, características inerentes ao LiDAR.

Tabela 10 - Volume estimado por LiDAR versus volumes reais de referência.

Pilha	Método	Área total (m ²)	Área efetiva (m ²)	Fat. Cubic.	M. Est. (st)	M. Cub. (m ³)	Real (m ³)	Erro (%)
1	Original	10,498	5,108	0,487	38,84	18,90	20,27	-6,8
2	Original	11,167	5,810	0,520	41,32	21,50	21,71	-1,0
3	MBR	13,747	6,885	0,501	50,86	25,47	24,22	5,2
4	Original	11,592	5,803	0,501	42,89	21,47	21,28	0,9
5	MBR	11,875	5,624	0,474	43,94	20,81	20,70	0,5
6	Original	13,762	7,242	0,526	50,92	26,80	24,74	8,3

Fonte: Autoria própria.

Figura 16 – Erro percentual de estimativa de volume por pilha obtido pelo método final com MBR seletivo.



Fonte: Autoria própria.

Com todos os erros contidos na faixa de aceitabilidade e a maioria das pilhas apresentando desvios inferiores aos reportados para técnicas fotogramétricas consolidadas, o escaneamento com HMLS associado ao processamento proposto configura-se como alternativa tecnicamente viável aos métodos convencionais de cubagem.

Ressalta-se, contudo, que a validação se restringiu a seis pilhas de uma mesma condição operacional, de modo que a generalização do método para diferentes espécies e padrões de empilhamento requer avaliações complementares.

O aplicativo web desenvolvido automatiza integralmente o fluxo metodológico validado nas seções anteriores: o usuário carrega um arquivo nos formatos .las ou .laz, ou seleciona uma das pilhas do projeto, informa o comprimento das toras e, obtém o volume em metro estéreo, o volume em metro cúbico, a área da face e o fator de cubicação da pilha (Figura 17).

Figura 17 - Interface inicial do aplicativo web.

Internamente, o aplicativo executa, de forma transparente ao usuário, todas as etapas de pré-processamento descritas na metodologia: remoção de ruído pelo algoritmo SOR, classificação do solo pelo filtro CSF, normalização de alturas por interpolação e, quando necessário, a rotação pelo Retângulo Mínimo Envolvente (MBR) para correção do alinhamento da pilha.

Essa automação auxilia, pois, procedimentos que exigem conhecimento de programação e familiaridade com o processamento de nuvens de pontos passam a ser acessíveis a qualquer operador por meio de uma interface gráfica, aproximando a técnica das condições reais de uso em empresas florestais.

3.4. CONCLUSÕES

A tecnologia LiDAR, constitui uma alternativa viável e precisa para a estimativa volumétrica de pilhas de madeira em campo, com potencial de substituição dos métodos tradicionais de medição manual.

Na pilha teste, a comparação tora a tora confirmou a consistência do sensor LiDAR do smartphone em relação às medições com fita métrica e suta, evidenciando que dispositivos móveis já constituem alternativa viável e de baixo custo para a mensuração individual de toras.

Nas pilhas de campo, os erros mantiveram-se dentro da faixa de aceitabilidade ($|\text{erro}| \leq 10\%$) em todos os casos avaliados, com quatro pilhas apresentando erro absoluto inferior a 6%, desempenho superior aos desvios reportados na literatura para técnicas fotogramétricas. A aplicação seletiva da correção por MBR mostrou-se decisiva para as pilhas com alinhamento oblíquo, reduzindo substancialmente o erro nesses casos sem introduzir distorções nas pilhas já alinhadas. Esse desempenho configura o método como alternativa tecnicamente consistente aos procedimentos convencionais de cubagem, com a vantagem de fornecer avaliação censitária, e não amostral, do material estocado.

Como desdobramentos futuros, recomenda-se a ampliação da validação para maior número de pilhas, abrangendo diferentes espécies e padrões de empilhamento.

3.5. REFERÊNCIAS

APPLE. **iPhone 14 Pro**. Apple Support, 2023. Disponível em: <https://support.apple.com/pt-br/HT213437>. Acesso em: 2026.

ARAÚJO, V. C. de. **Desenvolvimento de metodologia para a obtenção da cubagem de madeira em toras empilhadas através de imagens digitais**. 2010. 53 f. Monografia (Graduação em Engenharia Industrial Madeireira) – Universidade Estadual Paulista, Itapeva, 2010.

BALENOVIĆ, I. et al. Hand-Held Personal Laser Scanning—Current Status and Perspectives for Forest Inventory Application. **Croatian Journal of Forest Engineering**, v. 42, n. 2, p. 165–183, 2020. DOI: [10.5552/cije.2020.1491](https://doi.org/10.5552/cije.2020.1491).

BARROS, V. A. de. **Determinação de fatores de empilhamento por meio de classificação de imagem utilizando redes neurais**. 2017. 34 f. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal de Viçosa, Viçosa, 2017.

BRASIL. Ministério do Trabalho e Previdência. **Norma Regulamentadora nº 31 (NR-31): segurança e saúde no trabalho na agricultura, pecuária, silvicultura, exploração florestal e aquicultura**. Aprovada pela Portaria SEPRT nº 22.677, de 22 de outubro de 2020. Brasília, DF: Ministério do Trabalho e Previdência, 2020.

BERTOLA, A. et al. Determinação de fatores de empilhamento através do software Digitora. **Revista Árvore**, Viçosa, v. 27, n. 6, p. 837-844, 2003.

CALDER, K. et al. Terrestrial laser scanning in forest ecology: expanding the horizon. **Remote Sensing of Environment**, v. 251, e112102, 2020. DOI: [10.1016/j.rse.2020.112102](https://doi.org/10.1016/j.rse.2020.112102).

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração Florestal: perguntas e respostas**. 4. ed. Viçosa: UFV, 2013.

DISTEFANO, F.; CHIAPPINI, S.; GORREJA, A.; BALESTRA, M.; PIERDICCA, R. Mobile 3D Scan LiDAR: A Literature Review. **Geomatics, Natural Hazards and Risk**, v. 12, n. 1, p. 2387–2429, 2021. DOI: [10.1080/19475705.2021.1966217](https://doi.org/10.1080/19475705.2021.1966217).

DONG, P.; CHEN, Q. **LiDAR Remote Sensing and Applications**. 1. ed. Florida: CRC Press, 2017.

GARLAND, H. Using polaroid camera to measure trucked hardwood pulpwood. **Pulp Paper Canada**, v. 69, n. 8, p. 86-87, 1968.

GOMBIN, J.; VAIDYANATHAN, R.; AGAFONKIN, V. **concaveman: A Very Fast 2D Concave Hull Algorithm**. R package version 1.2.0, 2025. Disponível em: <https://CRAN.R-project.org/package=concaveman>. Acesso em: 16 maio 2026.

GREENVALLEY INTERNATIONAL. *LiGrip Ol Lite*. Berkeley, CA: GreenValley International, 2024. Disponível em: <https://www.greenvalleyintl.com/static/upload/file/20240326/1711434036630894.pdf>. Acesso em: 16 maio 2026.

HIJMANS, R. J. **raster: Geographic Data Analysis and Modeling**. R package version 3.6-32, 2025. Disponível em: <https://CRAN.R-project.org/package=raster>. Acesso em: 16 maio 2026.

HIJMANS, R. J. **terra: Spatial Data Analysis**. R package version 1.8-60, 2025. Disponível em: <https://CRAN.R-project.org/package=terra>. Acesso em: 16 maio 2026.

JACKSON, T. et al. Finite element analysis of trees in the wind based on terrestrial laser scanning data. **Agricultural and Forest Meteorology**, v. 265, p. 137–144, 2019. DOI: [10.1016/j.agrformet.2018.11.014](https://doi.org/10.1016/j.agrformet.2018.11.014).

JOLLIFFE, I. T. **Principal Component Analysis**. 2. ed. New York: Springer-Verlag, 2002. 518 p.

KAMINSKY, R. S.; SNAVELY, N.; SEITZ, S. M. Alignment of 3D point clouds to overhead images. In: IEEE COMPUTER SOCIETY CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION WORKSHOPS, 2009, Miami. **Proceedings [...]**. Miami: IEEE, 2009. p. 63-70. DOI: [10.1109/CVPRW.2009.5204180](https://doi.org/10.1109/CVPRW.2009.5204180).

LAU, A. et al. Quantifying branch architecture of tropical trees using terrestrial LiDAR and 3D modelling. **Trees**, v. 32, p. 1219-1231, 2018. DOI: [10.1007/s00468-018-1704-1](https://doi.org/10.1007/s00468-018-1704-1).

LEHNEBACH, R. et al. The pipe model theory half a century on: a review. **Annals of Botany**, v. 121, n. 5, p. 773-795, 2018. DOI: [10.1093/aob/mcx194](https://doi.org/10.1093/aob/mcx194).

LIANG, X. et al. The Use of a Mobile Laser Scanning System for Mapping Large Forest Plots. **IEEE Geoscience and Remote Sensing Letters**, v. 11, n. 8, p. 1504–1508, 2014. DOI: [10.1109/LGRS.2014.2300057](https://doi.org/10.1109/LGRS.2014.2300057).

LINDBERG, E. et al. Estimation of stem attributes using a combination of terrestrial and airborne laser scanning. **Eur J Forest Res**, v. 131, p. 1917–1931, 2012. DOI: [10.1007/s10342-012-0642-5](https://doi.org/10.1007/s10342-012-0642-5).

LUETZENBURG, G.; KROON, A.; BJØRK, A. A. Evaluation of the Apple iPhone 12 Pro LiDAR for an Application in Geosciences. **Scientific Reports**, v. 11, e22221, 2021. DOI: [10.1038/s41598-021-01777-6](https://doi.org/10.1038/s41598-021-01777-6).

MARTÍ, F. et al. LogLiDAR: An Internet of Things Solution for Counting and Scaling Logs. In: IEEE INTERNATIONAL CONFERENCE ON PERVASIVE COMPUTING AND COMMUNICATIONS WORKSHOPS AND OTHER AFFILIATED EVENTS (PERCOM WORKSHOPS), 2021, Kassel, Germany. **Proceedings [...]**. Kassel, Germany: IEEE, 2021. p. 413-415. DOI: [10.1109/PerComWorkshops51409.2021.9431022](https://doi.org/10.1109/PerComWorkshops51409.2021.9431022).

MASTIN, L. G. et al. A multidisciplinary effort to assign realistic source parameters to models of volcanic ash-cloud transport and dispersion during eruptions. **J. Volcanol. Geotherm. Res.**, v. 186, n. 1–2, p. 10-21, 2009. DOI: [10.1016/j.jvolgeores.2009.04.012](https://doi.org/10.1016/j.jvolgeores.2009.04.012).

MOSKALIK, T.; TYMENDORF, L.; SAAR, J. van der; TRZCIŃSKI, G. Methods of Wood Volume Determining and Its Implications for Forest Transport. **Sensors**, v. 22, n. 16, 6028, 2022. DOI: [10.3390/s22166028](https://doi.org/10.3390/s22166028).

MURTIYOSO, A.; GRUSSENMEYER, P.; LANDES, T.; MACHER, H. First assessments into the use of commercial-grade solid state lidar for low cost heritage documentation. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLIII-B2-2, p. 599–604, 2021. DOI: [10.5194/isprs-archives-XLIII-B2-2021-599-2021](https://doi.org/10.5194/isprs-archives-XLIII-B2-2021-599-2021).

OLIVEIRA, I. S. **Utilização do scanner a laser automático na aferição de volume de madeira sob diferentes diâmetros de tora**. 2018. 28 f. Monografia (Especialização em Gestão Florestal) – Universidade Federal do Paraná, Curitiba, 2018.

PEBESMA, E. Simple Features for R: Standardized Support for Spatial Vector Data. **The R Journal**, v. 10, n. 1, p. 439-446, 2018.

PEBESMA, E.; BIVAND, R. **Spatial Data Science: With Applications in R**. Chapman and Hall/CRC, 2023.

POLY. **Poly.cam**. Disponível em: <https://poly.cam/>. Acesso em: 2024.

R DEVELOPMENT CORE TEAM. **R: a language and environment for statistical computing**. [Software]. Vienna, Austria: R Foundation for Statistical Computing, 2024. Disponível em: <https://www.R-project.org/>. Acesso em: 2024.

ROUSSEL, J. R. et al. lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. **Remote Sensing of Environment**, v. 251, p. 112061, 2020.

ROUSSEL, J. R.; AUTY, D. **Airborne LiDAR Data Manipulation and Visualization for Forestry Applications**. R package version 4.1.2. 2025. Disponível em: <https://cran.r-project.org/package=lidR>. Acesso em: 2025.

ROUSSEL, J. R.; DE BOISSIEU, F. **rlas: Read and Write 'las' and 'laz' Binary File Formats Used for Remote Sensing Data**. R package version 1.8.2, 2025. Disponível em: <https://CRAN.R-project.org/package=rlas>. Acesso em: 16 maio 2026.

SILVA, M. C. et al. Determinação do volume de madeira empilhada através de processamento de imagens digitais. **Scientia Forestalis**, v. 33, n. 69, p. 104-114, 2005.

SILVA, P. V. de et al. Estimação do volume de árvores de eucalipto utilizando redes neurais artificiais. In: CORTE, A. P. D. et al. (org.). **Atualidades em mensuração florestal**. Curitiba: UFPR, 2014. p. 96-99.

SOARES, C. P. B. et al. Determinação de fatores de empilhamento através de fotografias digitais. **Revista Árvore**, v. 27, n. 4, p. 473-479, 2003. DOI: [10.1590/S0100-67622003000400007](https://doi.org/10.1590/S0100-67622003000400007).

SPREITZER, G.; TUNNICLIFFE, J.; FRIEDRICH, H. Large wood (LW) 3D accumulation mapping and assessment using Structure from Motion photogrammetry in the laboratory. **Journal of Hydrology**, Amsterdam, v. 581, p. 124430, 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0022169419311655>. Acesso em: 16 maio 2026.

SPREITZER, G.; TUNNICLIFFE, J.; FRIEDRICH, H. Using Structure from Motion photogrammetry to assess large wood (LW) accumulations in the field. **Geomorphology**, Amsterdam, v. 346, p. 106851, 2019. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0169555X19303320>. Acesso em: 16 maio 2026.

SYSTEMPLUS CONSULTING. **Apple iPad Pro LiDAR Module**. 2020. Disponível em: <https://www.systemplus.fr/reverse-costing-reports/apple-ipad-pro-11s-lidar-module/>. Acesso em: 16 maio 2026.

VER PLANCK, N. R.; MACFARLANE, D. W. Modelling vertical allocation of tree stem and branch volume for hardwoods. **Forestry**, v. 87, n. 3, p. 459-469, 2014. DOI: [10.1093/forestry/cpu007](https://doi.org/10.1093/forestry/cpu007).

VOSSelman, G.; MAAS, H.-G. **Airborne and Terrestrial Laser Scanning**. Caithness: Whittles Publishing, 2010. 336 p.

WAGNER, W. et al. From single-pulse to full waveform airborne laser scanners: potential and practical challenges. In: ISPRS CONGRESS INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY AND REMOTE SENSING, 2004, Freiburg. **Anais [...]**. Freiburg: ISPRS, 2004. p. 201-206.

WICKHAM, H. et al. **dplyr: A Grammar of Data Manipulation**. R package version 1.1.4, 2023. Disponível em: <https://CRAN.R-project.org/package=dplyr>. Acesso em: 16 maio 2026

4. AVALIAÇÃO DO USO DO HAND-HELD MOBILE LASER SCANNER NO DIAGNÓSTICO DE ÁRVORES URBANAS

RESUMO

A gestão da arborização urbana é frequentemente conduzida com base em conhecimento empírico, o que favorece práticas de manejo inadequadas e compromete a segurança da população. A análise de risco de queda pelo protocolo TRAQ (*Tree Risk Assessment Qualification*) depende de estimativas visuais de dimensões e distâncias, etapa em que a literatura localiza a maior fonte de variabilidade entre avaliadores. Este estudo avaliou a eficiência e o potencial do *hand-held mobile laser scanner* (HMLS) como ferramenta de apoio à gestão de áreas verdes urbanas, mediante adaptação do TRAQ ao uso de nuvens de pontos LiDAR. A área de estudo foi a Praça Carlos Augusto, no município de Piedade (SP). A nuvem de pontos foi processada em ambiente R com os pacotes *lidR* e *dbscan*, por meio de classificação do solo, normalização da altura, segmentação dos troncos pelo algoritmo DBSCAN e filtros de triagem, complementados por curadoria visual individual. Dos 25 candidatos segmentados, 19 indivíduos arbóreos foram submetidos à análise de fuste e 18 copas à análise de assimetria, além de três palmeiras tratadas separadamente em razão de seu mecanismo de falha distinto. O DAP, estimado pelo método RANSAC, variou de 14,7 cm a 91,4 cm (média de 50,4 cm), e a inclinação média dos fustes foi de 5,24°, com apenas dois indivíduos (10,5%) situados na faixa de atenção de 10° e nenhum atingindo o patamar de 15°. Nenhuma copa foi classificada como simétrica. Altura, DAP, projeção de copa, inclinação e respectivo azimuth foram obtidos de forma direta e reproduzível, substituindo estimativas visuais por mensuração instrumental, ao passo que condições internas do lenho, vigor e sistema radicular permanecem inacessíveis ao sensor. Conclui-se que o HMLS atua como instrumento de triagem sistemática, orientador da alocação de inspeções de campo detalhadas, e não como substituto da avaliação qualificada.

Palavras-chave: análise de risco arbóreo; nuvem de pontos; arborização urbana.

ABSTRACT

Urban forest management is frequently conducted on the basis of empirical knowledge alone, which favours inadequate maintenance practices and compromises public safety. Tree risk assessment under the TRAQ (*Tree Risk Assessment Qualification*) protocol relies on visual estimates of dimensions and distances, the stage at which the literature locates the greatest

source of variability between assessors. This study evaluated the efficiency and potential of the hand-held mobile laser scanner (HMLS) as a support tool for urban green space management, by adapting TRAQ to the use of LiDAR point clouds. The study area was Praça Carlos Augusto, in the municipality of Piedade, São Paulo, Brazil. The point cloud was processed in R using the *lidR* and *dbscan* packages, through ground classification, height normalisation, stem segmentation by the DBSCAN algorithm and screening filters, complemented by individual visual curation. Of the 25 segmented candidates, 19 trees were submitted to stem analysis and 18 crowns to asymmetry analysis, alongside three palms treated separately owing to their distinct failure mechanism. DBH, estimated by the RANSAC method, ranged from 14.7 cm to 91.4 cm (mean 50.4 cm), and mean stem lean was 5.24°, with only two individuals (10.5%) within the 10° attention threshold and none reaching the 15° level. No crown was classified as symmetrical. Height, DBH, crown projection, lean and its azimuth were obtained directly and reproducibly, replacing visual estimates with instrumental measurement, whereas internal wood conditions, vigour and the root system remain inaccessible to the sensor. The HMLS therefore functions as a systematic screening instrument, guiding the allocation of detailed field inspections, rather than as a substitute for qualified assessment.

Keywords: tree risk assessment; point cloud; urban forestry.

4.1. INTRODUÇÃO

A disseminação da tecnologia tem se tornado cada vez mais evidente no panorama global, ao se integrar ao cotidiano das pessoas e impulsionar a demanda crescente por essas ferramentas (Oliveira et al., 2020). Estamos imersos na era do "novo urbanismo", cujo avanço tecnológico e a interação humano-máquina revelam as complexas relações nos aglomerados urbanos, não apenas no âmbito social, mas também no ambiente urbano como um todo (Amin e Thrift, 2008).

Devido à sua sofisticação, as tecnologias ampliaram a identificação de problemas anteriormente invisíveis no meio urbano, o que facilita a tomada de decisões (Farinuiunk, 2020). Concomitantemente ao desenvolvimento de tecnologias urbanas, surge o conceito de cidade inteligente, que se refere às cidades que empregam ferramentas digitais para automatizar e otimizar sistemas, serviços e recursos públicos (Aldairi e Tawalbeh, 2017; Llacuna, ColomerLlinàs e Meléndez-Frigola, 2015; Salgado, 2016). Podemos incluir neste conceito a definição fornecida por Abella et al. (2017), cujo foco em automação está na sustentabilidade,

sensoriamento e colaboração, ao incorporar as florestas urbanas como parte integrante das cidades inteligentes.

A implementação e o manejo da arborização urbana é dever do poder público, e na maioria das vezes, essa gestão é realizada somente com conhecimento empírico. A falta de planejamento leva ao aumento de práticas de manejo incorretas e desnecessárias, como poda e remoção das árvores, principalmente, pelo contato entre a fiação e o afloramento de calçadas (Meira, 2010).

Devido a esse planejamento inadequado, indivíduos arbóreos frequentemente apresentam falhas estruturais e estado fitossanitário comprometido, ficando vulneráveis à queda de partes como galhos e ramos, à quebra do tronco ou mesmo à queda total da árvore. A análise de risco de queda é uma ferramenta de grande importância no ambiente urbano, pois identifica essas fragilidades para diagnosticar a condição da árvore e orientar técnicas de manejo apropriadas, promovendo a funcionalidade do exemplar e a segurança da população (Sacramento, 2013).

Diversos métodos foram propostos ao longo das últimas décadas, da avaliação visual às técnicas instrumentais não destrutivas, como a resistografia e a tomografia acústica, mas a ausência de consenso quanto à sua aplicação torna o processo decisório complexo e incerto.

Entre as abordagens disponíveis, o protocolo *Tree Risk Assessment Qualification* (TRAQ), desenvolvido pela *International Society of Arboriculture (ISA)*, tornou-se referência internacional por estruturar a avaliação em uma sequência lógica, identificação do alvo, probabilidade de falha, probabilidade de impacto e consequências, sintetizada em matrizes categóricas que resultam em uma classificação final de risco (Dunster et al., 2017).

O TRAQ apresenta uma limitação bem documentada: sua dependência do julgamento do avaliador. Koeser e Smiley (2017) demonstraram que, em avaliações conduzidas sob o protocolo da ISA, o profissional responsável exerceu maior influência sobre a classificação final e sobre as medidas mitigadoras prescritas do que as próprias características da árvore avaliada.

Resultados convergentes foram obtidos por Klein et al. (2023), ao compararem a reprodutibilidade de diferentes métodos aplicados aos mesmos indivíduos, e por Klein et al. (2021), que evidenciaram variabilidade expressiva na atribuição das classes de consequência de falha. Variáveis como altura, diâmetro, inclinação do fuste, assimetria e volume de copa são, na prática corrente, estimadas visualmente, incorporando erro na análise.

A varredura a laser, gera nuvens de pontos tridimensionais a partir das quais é possível extrair, com acurácia mensurável, atributos geométricos individuais das árvores (Wang et al.,

2024). A literatura reporta desempenho consistente na estimativa de DAP e altura em ambiente urbano, bem como a reconstrução da arquitetura de ramos por meio de modelos quantitativos de estrutura (QSM), viabilizando a modelagem de esforços e a estimativa de cargas de vento sobre o fuste.

Por isso este estudo tem como objetivo avaliar a eficiência e o potencial do hand-held mobile scanner (HMLS) como ferramenta de apoio à gestão de áreas verdes urbanas.

4.2. METODOLOGIA

4.2.1. Área de Estudo


A Praça Carlos Augusto (Figura 17) está localizada na Rua Vicente García, no centro do município de Piedade, estado de São Paulo. O município possui população estimada de 54.266 habitantes e economia essencialmente agrícola, segundo o IBGE (2025).

Ela encontra-se implantada sobre uma área que, originalmente, correspondia a uma zona de brejo, e tem conexão com um fragmento florestal remanescente de Mata Atlântica. A praça recebe o nome em homenagem ao Professor Carlos Augusto de Camargo, educador piedadense também lembrado pela Escola Estadual localizada à sua frente, fundada em 13 de junho de 1988.

A praça, por sua vez, foi criada somente em 2018, sendo, portanto, um logradouro relativamente recente. Do outro lado da rua funciona a Secretaria Municipal de Educação de Piedade e o Anfiteatro Municipal "Orestes Romano", ampliando os períodos de concentração de pessoas na área.

O conjunto de escola estadual, secretaria de educação e anfiteatro municipal, leva a intensa e contínua circulação de pedestres em múltiplos turnos no local.

Figura 18- Localização da praça Carlos Augusto no município de Piedade, estado de São Paulo.



Fonte: Autoria própria.

4.2.2. Análise de Risco de Queda

A metodologia adotada segue o método de TRAQ apenas adaptada ao uso de dados LiDAR. A coleta de dados foi conduzida no período de menor fluxo de pedestres na praça, com o objetivo de minimizar a incidência de ruído na nuvem de pontos decorrente da presença de alvos móveis, que comprometem a qualidade do registro e exigem etapas adicionais de filtragem.

Utilizou-se o HMLS LiGrip O1 Lite, em caminhada contínua pelo entorno da praça. Essa configuração permitiu a aquisição dos indivíduos arbóreos implantados junto às calçadas a partir de múltiplos ângulos.

A avaliação da copa foi realizada a partir da nuvem de pontos gerada pelo HMLS, possibilitando a detecção de assimetrias na distribuição da biomassa, estimativa do volume e extensão da copa, identificação de galhos com geometria angular atípica e verificação da proximidade com redes elétricas ou outras estruturas urbanas. Fatores como coloração e vigor

foliar, presença de patógenos e infestação por erva de passarinho não são detectáveis por essa técnica.

Já a análise do tronco foi conduzida por meio da análise geométrica da nuvem de pontos, permitindo a determinação do ângulo de inclinação, a estimativa do diâmetro à altura do peito (DAP) e a identificação de deformações externas grosseiras no fuste. Condições internas do lenho, como cavidades, podridões centrais, fissuras ocultas ou cancrios, não são acessíveis com imageamento LiDAR, portanto não foram mensuradas.

A correspondência entre os campos do protocolo e as métricas extraíveis da nuvem de pontos é apresentada no Quadro 2. A distribuição dos status evidencia um padrão consistente: os parâmetros de natureza geométrica, dimensões, inclinação, arquitetura de copa e delimitação da zona de queda, são obtidos de forma direta e reproduzível, ao passo que os parâmetros de natureza fisiológica e interna, vigor, apodrecimento, condição do sistema radicular, permanecem inacessíveis à varredura, por decorrerem de propriedades que não se manifestam na superfície externa amostrada pelo sensor. Os atributos do alvo situam-se em posição intermediária: sua geometria é derivável da nuvem, mas sua ocupação constitui informação de uso do espaço, externa ao dado geométrico.

Quadro 2 - Correspondência entre os campos do protocolo TRAQ e as métricas derivadas da nuvem de pontos.

Componente do TRAQ	Campo do protocolo	Métrica derivada da nuvem de pontos	Status
Identificação e dimensões	Altura total	Cota máxima de retorno acima do modelo digital de terreno	● Direto
	DAP	Ajuste circular à seção transversal a 1,30 m de altura	● Direto
	Projeção e raio de copa	Área do polígono convexo da projeção horizontal dos pontos de copa	● Direto
	Confiabilidade do DAP	Número de inliers do ajuste circular	● Direto
	Espécie	—	○ Campo
Fatores de carga	Inclinação do fuste	Ângulo do eixo ajustado em relação à vertical	● Direto
	Direção da inclinação	Azimute do eixo ajustado	● Direto

Componente do TRAQ	Campo do protocolo	Métrica derivada da nuvem de pontos	Status
	Tamanho relativo da copa	Razão entre altura de copa e altura total	● Direto
	Densidade de copa	Índice de penetração de retornos através da copa	● Extraível, não computado
	Exposição ao vento	Rugosidade do entorno derivada da nuvem	● Extraível, não computado
Defeitos — fuste	Irregularidade de seção	Desvio da circularidade por camada empilhada	● Triagem; limiar a recalibrar
	Cavidades	Descontinuidades na superfície reconstruída	● Viável
	Fuste bifurcado	Detecção de eixos múltiplos no ajuste da seção	● Detecta; união não avaliada
	Rachaduras, cancos, apodrecimento	—	○ Campo / nível 3
Defeitos — copa	Assimetria	Coeficiente de variação da distribuição radial de pontos	● Direto
	Ramos secos, mortos ou mal inseridos	—	○ Campo
Defeitos — raiz	Sobrelevação, exposição de raízes, fissuras no solo	—	○ Campo
Saúde e vigor	Condição fitossanitária, densidade de folhagem	—	○ Campo
Alvo	Delimitação da zona de queda	Buffer de raio igual à altura total	● Direto
	Alvos presentes na zona	Classificação de elementos na nuvem (edificações, mobiliário, pavimento)	● Parcial
	Taxa de ocupação	—	○ Campo
	Proteção do alvo	—	○ Campo

Componente do TRAQ	Campo do protocolo	Métrica derivada da nuvem de pontos	Status
Consequências	Tamanho da parte passível de falha	Reconstrução volumétrica da parte por modelo quantitativo de estrutura (QSM)	● Parcial

Legenda: ● obtido diretamente da nuvem de pontos neste trabalho; ● parcialmente obtido, ou extraível da nuvem, porém não computado nesta etapa; ○ não obtível por varredura a laser, dependendo de avaliação de campo.

Fonte: elaborado pelo autor a partir de Dunster et al. (2017).

Essa distribuição delimita o escopo da contribuição do LiDAR ao TRAQ. O método não substitui a avaliação qualificada, mas atua sobre a etapa em que a literatura localiza a maior fonte de variabilidade entre avaliadores, a estimativa visual de dimensões e distâncias (Koeser e Smiley, 2017), substituindo-a por mensuração instrumental. Os campos assinalados como extraíveis, porém, não computados nesta etapa, indicam o caminho imediato de refinamento, com destaque para o azimute de inclinação, cuja ausência impede, no estágio atual, a estimativa da direção provável de queda.

A determinação do nível de risco de cada indivíduo seguiu a estrutura decisória do protocolo TRAQ, organizada em duas etapas matriciais sucessivas, tendo como insumo os parâmetros mensuráveis a partir da nuvem de pontos.

Na primeira etapa, a probabilidade de falha, estimada a partir de indicadores geométricos extraídos do LiDAR, como inclinação do fuste, assimetria e distribuição volumétrica da copa, foi combinada à probabilidade de a parte falhada atingir um alvo, função da localização do indivíduo, da altura total e da consequente zona de queda. O alvo foi definido como qualquer elemento suscetível de dano situado na zona de alcance da árvore, incluindo pedestres, ciclistas, veículos e edificações. Dessa combinação resultou a probabilidade de falha e impacto.

Na segunda etapa, essa probabilidade foi cruzada com as consequências da falha, estimadas em função do tamanho da parte passível de falha e da ocupação e vulnerabilidade do alvo potencialmente atingido. O cruzamento resultou na classificação final de cada indivíduo em quatro níveis de risco: baixo, moderado, alto e extremo.

4.2.3. Processamento da nuvem de pontos

O processamento da nuvem de pontos bruta até a obtenção dos indivíduos arbóreos segmentados foi conduzido em duas etapas complementares, a primeira de natureza automatizada e a segunda manual, implementadas no ambiente R (R Core Team, 2024) com os pacotes lidR (Roussel et al., 2020) e dbscan (Hahsler et al., 2019).

A etapa automatizada iniciou-se com o pré-processamento da nuvem bruta, compreendendo a classificação dos pontos de solo pelo algoritmo CSF (Cloth Simulation Filter) (Zhang et al., 2016), configurado com resolução de malha de 0,9 m. Os pontos classificados como solo foram utilizados para a geração de um Modelo Digital do Terreno (MDT) por interpolação pelo método dos k-vizinhos ponderados pelo inverso da distância (KNNIDW), com resolução espacial de 0,5 m.

A normalização das alturas foi realizada subtraindo o valor do MDT de cada ponto, convertendo as elevações absolutas em alturas relativas ao solo. Pontos com altura normalizada negativa, foram descartados.


Já a detecção dos troncos foi realizada por meio do algoritmo DBSCAN (Density-Based Spatial Clustering of Applications with Noise) (Ester et al., 1996), aplicado na fatia horizontal entre 1,2 m e 1,4 m da altura normalizada, correspondente à região do diâmetro à altura do peito (DAP). Esse recorte tem como objetivo concentrar a análise na porção do fuste em que a seção transversal dos troncos arbóreos é mais circular e regular, maximizando a separabilidade entre indivíduos próximos.

O algoritmo foi parametrizado com raio de busca de 1,0 m e mínimo de 100 pontos por agrupamento, gerando um conjunto de clusters cujos centroides foram calculados pela média das coordenadas planimétricas dos pontos integrantes. Em seguida, para cada centroide detectado, procedeu-se ao recorte cilíndrico da nuvem normalizada completa com raio de 2,0 m, atribuindo a cada ponto o identificador do respectivo cluster.

Para auxiliar visualmente e documentar as condições de cada indivíduo antes da aplicação dos filtros automáticos, foram gerados painéis diagnósticos individuais compostos por uma captura tridimensional da nuvem de pontos, renderizada com o pacote rgl (Murdoch & Adler, 2024), e um histograma da distribuição vertical de pontos em faixas de 0,5 m, anotados com o total de pontos, a contagem na faixa de 0 a 0,5 m e a razão entre esta e os pontos restantes (Figura 18). A composição e anotação das imagens foi realizada com o pacote magick (Ooms, 2024).

A triagem automática das árvores foi conduzida por três filtros aplicados em sequência. O primeiro verificou a continuidade vertical do fuste abaixo de 3,0 m de altura, calculando o número de faixas de 0,5 m sem pontos nessa região, indivíduos com mais de uma faixa vazia foram descartados, com base de que troncos arbóreos reais apresentam fuste contínuo e denso desde a base.

Figura 19 - Histograma da distribuição vertical de pontos.



Fonte: Autoria própria.

O segundo filtro eliminou os candidatos cuja altura máxima não ultrapassou 4,0 m. Esse limiar foi adotado para separar árvores adultas de arbustos, mudas e vegetação de porte reduzido, cuja inclusão comprometeria a análise de risco por não representarem alvos potenciais de falha estrutural com consequência relevante.

O terceiro filtro destinou-se a diferenciar troncos arbóreos de elementos verticais de origem antrópica, postes de iluminação, sinalização e estruturas metálicas, os quais compartilham com as árvores a geometria alongada e vertical e, portanto, não são discriminados pelos critérios anteriores.

O procedimento baseou-se na densidade de pontos registrada na faixa entre 2,0 m e 4,0 m de altura, intervalo selecionado por corresponder, nos indivíduos da área, ao segmento de fuste livre, situado acima do nível de obstruções no solo e abaixo do início da copa. Nessa faixa, a quantidade de retornos é proporcional ao perímetro do objeto interceptado: troncos, por apresentarem seção transversal substancialmente maior que a de postes, geram nuvens mais densas. Adotou-se, assim, o valor de 500 pontos como limiar de corte, abaixo do qual os


candidatos foram descartados, por ser inferior ao esperado para fustes com diâmetro compatível com o dos indivíduos amostrados.

Sabendo que filtros automáticos parametrizados por limiares fixos podem possuir erros de classificação em situações atípicas, como árvores de fuste fino, indivíduos jovens ou objetos de infraestrutura com geometria semelhante à de troncos, realizou-se uma segunda etapa manual sobre a nuvem normalizada resultante da etapa de filtragem.

Nessa etapa, o mesmo algoritmo DBSCAN (Ester et al., 1996; Hahsler et al., 2019) foi reaplicado à fatia do DAP para detecção dos indivíduos remanescentes, sendo cada objeto recortado com raio de 5,0 m e sem imposição de limite superior de altura, de modo que fuste e copa fossem capturados em sua totalidade.

Para cada árvore, foi criado automaticamente um conjunto de imagens para inspeção, contendo: quatro vistas laterais em 3D (tiradas dos lados Norte, Leste, Sul e Oeste, com um ângulo de 20° de cima para baixo), uma vista de cima em 3D, uma vista de cima em 2D mostrando o contorno da copa e marcando o centro do tronco, e um gráfico vertical mostrando onde fica o tronco e onde fica a copa. (Figura 17).

Figura 20 - Painel investigativo da árvore.



Fonte: Autoria própria.

Com base na análise visual desses painéis, identificou-se objetos classificados como não arbóreos, que foram então excluídos.

4.2.4. Extração de métricas dendrométricas e estruturais.

A análise individual dos troncos foi restrita à faixa vertical compreendida entre 0,3 m e 7,0 m da altura normalizada, eliminando pontos de solo e ruído na base e excluindo a região de copa no limite superior, de modo a isolar o fuste de cada indivíduo.

Essa identificação de cada indivíduo baseou-se no campo de segmentação treeid previamente atribuído à nuvem. Na ausência desse campo, aplicou-se o algoritmo DBSCAN à fatia horizontal correspondente à altura do DAP (1,2–1,4 m), determinando automaticamente os centros de cada tronco por agrupamento de densidade.


A estimativa do diâmetro à altura do peito (DAP) foi feita usando o método RANSAC o qual analisou os pontos da árvore localizados entre 1,2 e 1,4 m de altura. O algoritmo escolhe três pontos aleatórios, ajusta um círculo passando por eles e verifica quantos outros pontos ficam próximos desse círculo (dentro de uma margem de 25 mm). Esse processo é repetido 400 vezes, e o círculo que melhor se ajustar (com mais pontos próximos) é escolhido como resultado. A partir desse círculo, obtém-se o valor do DAP em centímetros e a posição do centro do tronco.

Para calcular a inclinação do tronco, ele foi dividido em camadas de 0,4 m de altura. Em cada camada com pelo menos cinco pontos, foi calculado o centroide nas direções X e Y. Depois, foram feitas regressões lineares para ver o deslocamento do centroide horizontalmente conforme o aumento da altura, obtendo a inclinação em cada eixo (X e Y). O ângulo de inclinação total do tronco foi calculado combinando as duas inclinações e convertendo o resultado para graus. Já o azimuth (direção para onde o tronco está inclinado) foi calculado usando a arco-tangente desse deslocamento combinado.

A identificação de deformações externas do fuste baseou-se na variabilidade dos raios dos pontos em relação ao centroide de cada camada. Para cada camada de 0,4 m, calculou-se a distância de todos os pontos ao centroide da respectiva fatia, obtendo-se o raio médio, o raio mínimo, o raio máximo e o desvio padrão. Camadas cujo desvio padrão dos raios superou o limiar de 40 mm foram classificadas como deformadas, indicando irregularidades na superfície externa do fuste (Figura 20).


Por fim para a análise da copa aplicou-se um recorte circular de raio de 5 m focado no centroide do tronco, retendo os pontos acima de 2,0 m de altura normalizada, limiar adotado para separar a região do fuste da massa foliar e dos galhos primários que compõem a copa propriamente dita (Figura 21).

Figura 21 - Visualização do tronco.



Fonte: Autoria própria.

Figura 22 - Análise da copa



Fonte: Autoria própria.

4.3. RESULTADOS

A segmentação automática da nuvem de pontos identificou 25 candidatos a indivíduos arbóreos. Destes, três (ID 17, ID 18 e ID 25) apresentaram imageamento insatisfatório tanto na análise de tronco quanto na de copa, com nuvens de pontos fragmentadas que inviabilizaram o ajuste geométrico, sendo excluídos das análises comparativas.

Os três indivíduos identificados como palmeiras (ID 11, ID 21 e ID 22) foram analisados separadamente, em razão das particularidades de seu mecanismo de falha. A amostra submetida à análise comparativa consistiu, portanto, em 19 indivíduos arbóreos.

Para a análise de copa, os indivíduos ID 12 e ID 13 que, embora apresentem fustes independentes, compartilham uma copa contínua, foram tratados como uma única unidade amostral, totalizando 18 copas avaliadas. A impossibilidade de separá-los constitui, em si, um resultado relevante: evidencia a condição de dossel contíguo na área de estudo.

A totalidade dos indivíduos avaliados foi classificada na categoria de deformação pronunciada, com média de 10,0 camadas deformadas por indivíduo, variando de 6 (ID 15) a 11 camadas, o que corresponde a aproximadamente 90% das camadas analisadas em cada fuste. As irregularidades concentraram-se entre 0,3 m e 5,0 m de altura, faixa que corresponde à porção do tronco cuja ruptura apresenta maior potencial de atingir pessoas em circulação.

A magnitude e a uniformidade desse padrão, contudo, demandam interpretação cautelosa. A ausência de qualquer indivíduo em classe inferior à de deformação pronunciada indica saturação do indicador: um critério que classifica 100% da amostra na categoria mais severa não discrimina entre os indivíduos e, portanto, não cumpre a função de triagem a que se destina. Do ponto de vista biomecânico, a ocorrência de irregularidade em praticamente todas as camadas de todos os indivíduos configura, ademais, uma situação incompatível com a permanência das árvores em pé.

A inclinação média dos fustes avaliados foi de $5,24^\circ$, com amplitude entre $0,28^\circ$ (ID 5) e $14,51^\circ$ (ID 23). Adotou-se como limiar de atenção o valor de 10° , correspondente ao início da faixa a partir da qual Coder (2000) recomenda acompanhamento gerencial dos indivíduos inclinados, sobretudo para verificação de eventual progressão da inclinação. Segundo o mesmo autor, o risco de falha catastrófica eleva-se significativamente à medida que o ângulo se aproxima de 15° e passa a compor-se geometricamente acima de 20° .

Sob esse critério, apenas dois dos 19 indivíduos (10,5%) situam-se na faixa de atenção, e nenhum atinge 15° (Tabela 11).

Tabela 11 - Indivíduos situados na faixa de atenção de inclinação.

Indivíduo	Inclinação	Azimute
ID 23	14,51°	24,6°
ID 8	10,84°	49,0°

Fonte: autoria própria.

O azimute de inclinação foi computado para todos os indivíduos a partir do eixo ajustado, resultando em 24,6° para o ID 23 e 49,0° para o ID 8. Dispondo-se dessa informação, a estimativa da direção provável de queda deixa de depender de apreciação visual em campo.

Os valores de DAP variaram de 14,7 cm (ID 3) a 91,4 cm (ID 14), com média de 50,4 cm. As alturas máximas de copa variaram de 5,75 m (ID 4) a 14,33 m (ID 19), com média de 10,1 m, enquanto a área de projeção horizontal da copa oscilou entre 12,81 m² (ID 4) e 38,39 m² (ID 20), com média de 33,3 m². Três indivíduos apresentaram fuste bifurcado (ID 10, ID 22 e ID 24).

A concentração dos valores de área de projeção de copa próxima ao limite superior do intervalo observado, em amostra cujos DAP variam por um fator superior a seis, sugere possível limitação da segmentação em condição de dossel contíguo: quando copas vizinhas se interpenetram, a partição da nuvem tende a ser governada pelo critério geométrico do algoritmo, e não pelos limites biológicos reais de cada copa. O caso dos indivíduos ID 12 e ID 13, constitui evidência direta dessa condição na área de estudo. Recomenda-se, para trabalhos subsequentes, a validação das áreas segmentadas contra medição de campo em subamostra.

Quanto à assimetria, das 18 copas avaliadas, 12 foram classificadas como assimétricas ($CV > 0,40$) e seis como de assimetria moderada (CV entre 0,30 e 0,40), não tendo sido registrada nenhuma copa simétrica na amostra. A ausência de simetria em toda a amostra é coerente com o contexto de implantação e reforça a importância de considerar a assimetria como agravante na definição da direção provável de queda, sobretudo quando o vetor de desequilíbrio da copa coincide com o azimute de inclinação do fuste. O cruzamento entre ambos os vetores, viável com os dados disponíveis, constitui refinamento imediato da análise direcional.

Os três indivíduos identificados como palmeiras apresentaram inclinações de 6,47° (ID 11), 4,08° (ID 21) e 1,34° (ID 22), todos abaixo do limiar de atenção adotado. O ID 11 não registrou pontos acima de 5,0 m, resultado consistente com a altura máxima de estipe de 4,35 m obtida na análise de tronco, indicando que o feixe de frondes se encontra abaixo desse limite

ou foi parcialmente suprimido durante a varredura. Os IDs 21 e 22 apresentaram alturas máximas de 6,98 m e 5,66 m, com áreas de projeção de frondes de 15,96 m² e 6,68 m², respectivamente.

A análise desse grupo em separado justifica-se por razões biológicas: palmeiras não apresentam crescimento secundário nem lenho de reação, de modo que os indicadores de deformação e inclinação não possuem, nesse caso, o mesmo significado diagnóstico.

Ilustra esse ponto o fato de as três palmeiras terem sido igualmente classificadas na categoria de deformação pronunciada, resultado que, para estipes, carece de sentido estrutural. O principal mecanismo de risco associa-se ao desprendimento de frondes e, secundariamente, de inflorescências e infrutescências, e não à falha da base do estipe.

Para as palmeiras, a avaliação de risco depende de atributos não capturados pela varredura empregada, como a presença de frondes senescentes pendentes e o estado do meristema apical, o que restringe a contribuição do LiDAR à caracterização geométrica e ao posicionamento dos alvos sob a projeção das frondes.

O cruzamento entre probabilidade de falha, consequência e confiabilidade das mensurações indica os indivíduos relacionados no Quadro 3 como prioritários para avaliação de nível 3.

Quadro 3 - Árvores a serem consideradas para análise de nível 3.

Prior.	Indivíduo(s)	Critério principal	Ação recomendada (foco em pessoas)
1	ID 23	Maior inclinação da amostra (14,51°), com o melhor ajuste de eixo entre os indivíduos inclinados ($R^2 = 0,515$) e azimuth de 24,6°	Inspeção de campo prioritária; verificar sinais de falha radicular e confrontar o azimuth com o mapa de circulação de pessoas
2	ID 8	Único outro indivíduo na faixa de atenção (10,84°), porém com ajuste de eixo fraco ($R^2 = 0,235$) e azimuth de 49,0°	Confirmar em campo se a inclinação é real ou artefato de fuste tortuoso, antes de qualquer decisão de manejo
3	ID 14 e ID 20	Maiores DAP da amostra (91,4 cm e 85,2 cm); o ID 20 acumula ainda a maior área de projeção de copa (38,39 m ²)	Avaliar se a área de queda projetada atinge espaços de permanência ou de passagem de pessoas

Prior.	Indivíduo(s)	Critério principal	Ação recomendada (foco em pessoas)
4	ID 12 e ID 13	Copa contínua não segmentável; assimetria e consequência não atribuíveis individualmente	Avaliação conjunta em campo; delimitação visual dos limites de copa de cada indivíduo
5	ID 10 e ID 24	Fustes bifurcados, com DAP não confiável no ID 10; a bifurcação constitui defeito estrutural potencial não resolvido pela varredura	Inspecionar a união dos fustes quanto a casca inclusa e codominância

Fonte: autoria própria.

Considerando-se as pessoas como alvo, o conjunto dos resultados evidencia que a contribuição do LiDAR à análise baseada no TRAQ foi efetiva apenas nos parâmetros DAP, altura, projeção de copa e a geometria de inclinação, pois todos foram obtidos de forma direta, objetiva e reprodutível. Já os parâmetros de condição interna e radicular permanecem dependentes de evidências de campo, e a probabilidade de impacto exige informação de ocupação do alvo, externa à nuvem de pontos.

Confirma-se, assim, o papel do método como instrumento de triagem sistemática, orientador da alocação de inspeções detalhadas, e não como substituto da avaliação qualificada.

4.4. CONCLUSÃO

A aplicação do LiDAR móvel à análise de risco baseada no protocolo TRAQ mostrou-se viável para o conjunto de parâmetros geométricos do protocolo. Altura, DAP, projeção de copa, inclinação e respectivo azimuth foram obtidos de forma direta e reprodutível a partir da nuvem de pontos, substituindo por mensuração instrumental estimativas que, na prática corrente, dependem de apreciação visual.

Quanto à condição estrutural da praça, o diagnóstico angular revelou-se favorável: apenas dois dos 19 indivíduos situam-se na faixa de atenção de inclinação, e nenhum atinge o patamar de 15° associado na literatura ao aumento significativo da probabilidade de falha.

As limitações inerentes ao sensor, que não acessa as condições internas do lenho, da copa e da base radicular, confirmam que o HMLS deve ser empregado como ferramenta

complementar, e não substitutiva, à inspeção visual em campo, especialmente para os indivíduos classificados em níveis de risco mais elevados.

Como próximos passos, recomenda-se aplicação do procedimento a um conjunto mais amplo de praças, associada à coleta de dados de referência em campo. A ampliação da amostra permitiria estabelecer a distribuição dos parâmetros geométricos em populações arbóreas urbanas de composição e idade diversas.

4.5. REFERÊNCIAS

ABELLA, A.; ORTIZ-DE-URBINA-CRIADO, M.; DE-PABLOS-HEREDERO, C. **A model for the analysis of data-driven innovation and value generation in smart cities ecosystems**. *Cities*, v. 64, p. 47-53, 2017. DOI: <https://doi.org/10.1016/j.cities.2017.02.003>.

ALDAIRI, A.; TAWALBEH, L. Cyber security attacks on smart cities and associated mobile technologies. **Procedia Computer Science**, v. 109, p. 1086-1091, 2017. DOI: <https://doi.org/10.1016/j.procs.2017.05.353>.

AMIN, A.; THRIFT, N. **Cities: reimagining the urban**. New Jersey: Wiley, 2002.

CODER, K. D. **Estimating leaning tree failures**. Athens: University of Georgia, Warnell School of Forest Resources, 2000.

DUNSTER, J. A.; SMILEY, E. T.; MATHENY, N.; LILLY, S. **Tree risk assessment manual**. 2. ed. Champaign: International Society of Arboriculture, 2017. 194 p. Segunda edição, 194 p., ISBN 9781881956990.

ESTER, M. et al. A density-based algorithm for discovering clusters in large spatial databases with noise. In: **PROCEEDINGS OF THE 2ND INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING (KDD-96)**. [S.l.: s.n.], 1996. p. 226–231.

FARINUIUNK, T. M. D. Smart cities e pandemia: tecnologias digitais na gestão pública de cidades brasileiras. **Revista de Administração Pública**, Rio de Janeiro, v. 54, n. 4, p. 876-889, jul./ago. 2020. DOI: <https://doi.org/10.1590/0034-761220190367>.

HAHSLER, M.; PIEKENBROCK, M.; DUIS, D. dbSCAN: fast density-based clustering with R. **Journal of Statistical Software**, v. 91, n. 1, p. 1–30, 2019. DOI: <https://doi.org/10.18637/jss.v091.i01>.

IBGE — INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Piedade (SP): panorama**. Rio de Janeiro: IBGE, 2025. Disponível em: <https://cidades.ibge.gov.br/brasil/sp/piedade/panorama>. Acesso em: 2026.

KLEIN, R. W. et al. Assessing the consequences of tree failure. **Urban Forestry & Urban Greening**, v. 65, art. 127307, 2021. DOI: <https://doi.org/10.1016/j.ufug.2021.127307>.

KLEIN, R. W. et al. Evaluating the reproducibility of tree risk assessment ratings across commonly used methods. **Arboriculture & Urban Forestry**, v. 49, n. 6, p. 271-282, 2023. DOI: <https://doi.org/10.48044/jauf.2023.019>.

KOESER, A. K.; SMILEY, E. T. Impact of assessor on tree risk assessment ratings and prescribed mitigation measures. **Urban Forestry & Urban Greening**, v. 24, p. 109-115, 2017. DOI: <https://doi.org/10.1016/j.ufug.2017.03.027>.

LLACUNA, M. M.; COLOMER-LLINÀS, J.; MELÉNDEZ-FRIGOLA, J. Lessons in urban monitoring taken from sustainable and livable cities to better address the smart cities initiative. **Technological Forecasting and Social Change**, v. 90, p. 611-622, 2015. DOI: <https://doi.org/10.1016/j.techfore.2014.07.010>.

MEIRA, A. M. de. **Gestão de resíduos da arborização urbana**. 2010. 178 f. Tese (Doutorado em Ciências Florestais) – Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 2010.

MURDOCH, D.; ADLER, D. **rgl: 3D visualization using OpenGL**. R package version 1.3.1, 2024. Disponível em: <https://CRAN.R-project.org/package=rgl>.

OLIVEIRA, S. G.; ALMEIDA, V. E.; TROTTA, L. M. As tecnologias e o mundo globalizado: reflexões sobre o cotidiano contemporâneo. **Revista Educação Pública**, v. 20, n. 2, 2020. Disponível em: <https://educacaopublica.cecierj.edu.br/artigos/20/2/as-tecnologias-e-o-mundo-globalizado-reflexoes-sobre-o-cotidiano-contemporaneo>. Acesso em: 2025.

OOMS, J. **magick: advanced graphics and image-processing in R**. R package version 2.8.3, 2024. Disponível em: <https://CRAN.R-project.org/package=magick>.

R CORE TEAM. **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2024. Disponível em: <https://www.r-project.org/>.

ROUSSEL, J. R. et al. lidR: an R package for analysis of airborne LiDAR data in forestry. **Methods in Ecology and Evolution**, v. 11, n. 11, p. 1579–1587, 2020. DOI: <https://doi.org/10.1111/2041-210X.13519>.

SACRAMENTO, F. A. C. B. **Tomografia das árvores do Jardim Botânico da Universidade de Coimbra: avaliação do estado de conservação**. 2013. 69 f. Dissertação (Mestrado em Biodiversidade e Biotecnologia Vegetal) – Universidade de Coimbra, Coimbra, 2013.

SALGADO, M. M. A inteligência na sociedade positiva: dos humanos às cidades. In: SANTAELLA, L. **Cidades inteligentes: por que, para quem?** São Paulo: Estação das Letras e Cores, 2016. p. 38-49.

ZHANG, W. et al. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. **Remote Sensing**, v. 8, n. 6, p. 501, 2016. DOI: <https://doi.org/10.3390/rs8060501>.

5. CONCLUSÕES GERAIS

A visão computacional, e em particular a tecnologia LiDAR embarcada em dispositivos portáteis e de custo acessível, representa uma alternativa aos métodos tradicionais de mensuração e diagnóstico no setor florestal, com aplicabilidade tanto em florestas plantadas quanto em florestas urbanas.

A revisão sistemática de literatura confirmou que a visão computacional e o LiDAR vêm sendo crescentemente adotados no setor florestal, com aplicações que abrangem do monitoramento florestal à detecção de defeitos, revelando um campo de pesquisa em expansão, porém com lacunas relevantes para o contexto brasileiro, especialmente quanto às espécies nativas.

O método de cubagem de pilhas de madeira desenvolvido a partir de nuvens de pontos LiDAR mostrou-se viável. Na pilha teste, o sensor do iPhone 14 Pro apresentou consistência na mensuração tora a tora, embora a análise da face completa tenha evidenciado superestimativa de caráter sistemático, associada ao ruído do sensor. Nas pilhas escaneadas com HMLS, os erros mantiveram-se dentro da faixa de aceitabilidade em todos os casos, com desempenho comparável ou superior ao de métodos fotogramétricos descritos na literatura, com a vantagem de fornecer avaliação censitária, e não amostral, do material estocado, sem exposição do operador aos riscos inerentes à medição manual. O aplicativo desenvolvido torna o procedimento acessível ao uso operacional em empresas florestais.

A avaliação do HMLS na arborização urbana demonstrou que a adaptação do método TRAQ ao uso de nuvens de pontos permite obter, de forma direta e reproduzível, os parâmetros geométricos do protocolo, substituindo estimativas visuais por mensuração instrumental. As condições internas do lenho, o vigor e o sistema radicular permanecem inacessíveis ao sensor, de modo que o método se configura como instrumento de triagem sistemática, orientador da alocação de inspeções de campo detalhadas, e não como substituto da avaliação qualificada.

Observa-se, assim, que o LiDAR embarcado em dispositivos acessíveis e portáteis contribui para a modernização do planejamento e da gestão de recursos florestais, ao automatizar inventários, ampliar a precisão da estimativa de estoques de madeira e subsidiar o diagnóstico estrutural de árvores em ambientes urbanos.

Recomenda-se, para trabalhos futuros, a ampliação da validação dos métodos propostos em diferentes condições de campo, espécies e tipologias florestais, bem como o aprofundamento de aplicações voltadas às florestas nativas e a integração dessas tecnologias aos inventários florestais já consolidados.

6. REFERÊNCIAS

- BALENOVIĆ, S. et al. LiDAR intensity and echo number for object characterization in forest inventory. **Forestry Research**, v. 25, n. 3, p. 145-162, 2020. DOI: 10.2478/frp-2020-0021.
- BELAND, M. et al. On promoting the use of lidar systems in forest ecosystem research. **Forest Ecology and Management**, v. 450, p. 117484, 2019. DOI: [10.1016/j.foreco.2019.117484](https://doi.org/10.1016/j.foreco.2019.117484).
- CALDERS, K. et al. Terrestrial laser scanning in forest ecology: expanding the horizon. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 171, p. 1-18, 2020. DOI: 10.1016/j.isprsjprs.2020.11.010.
- DISTEFANO, L. et al. Evaluation of mobile laser scanning acquisition scenarios for automated wood volume estimation. **Remote Sensing**, v. 13, n. 11, p. 2145, 2021. DOI: 10.3390/rs13112145.
- DONG, P.; CHEN, Q. **LiDAR Remote Sensing and Applications**. 1. ed. Boca Raton: CRC Press, 2017. DOI: 10.4324/9781351233354.
- JACKSON, H. et al. Quantitative structural models for tree crown architecture and volume assessment in silviculture. **Forestry**, v. 92, n. 4, p. 425-437, 2019. DOI: 10.1093/forestry/cpz018.
- JAHNE, B. **Computer Vision Systems: Components, Processes and Integration**. Berlin: Springer, 2000.
- LAU, S. et al. Non-destructive assessment of forest characteristics using quantitative structural models. **Agricultural and Forest Meteorology**, v. 258, p. 102-115, 2018. DOI: 10.1016/j.agrformet.2018.05.012.
- LEHNEBACH, R. et al. Quantitative Structural Models (QSMs) in silviculture: volume, architecture and ecological properties. **Tree Ecology**, v. 14, n. 2, p. 89-104, 2018. DOI: 10.1007/s11284-018-1612-3.
- LIANG, M. et al. Mobile laser scanning with SLAM technology for forest inventory and individual tree measurement. **Remote Sensing of Environment**, v. 198, p. 87-102, 2014. DOI: 10.1016/j.rse.2014.03.015.
- LINDBERG, E. et al. Limitations of terrestrial laser scanning in forest production processes: cost, expertise and data acquisition time. **Forest Science**, v. 58, n. 3, p. 245-258, 2012. DOI: 10.1093/foresci/58.3.245.
- MASTIN, G.; KAMINSKY, M. Texture mapping of 3D models from aerial and satellite sensors using optical images. **Computer Vision and Image Processing**, v. 45, n. 2, p. 112-128, 2009. DOI: 10.1007/s00371-009-0145-2.
- OLIVEIRA, S. G.; ALMEIDA, V. E.; TROTTA, L. M. As tecnologias e o mundo globalizado: reflexões sobre o cotidiano contemporâneo. **Revista Educação Pública**, v. 20, n. 2, 14 jan. 2020. Disponível em: <https://educacaopublica.cecierj.edu.br/artigos/20/2/as-tecnologias-e-o-mundo-globalizado-reflexoes-sobre-o-cotidiano-contemporaneo>. Acesso em: 2025.
- PRINCE, S. J. D. **Computer Vision: Models, Learning, and Inference**. Cambridge: Cambridge University Press, 2012.
- VER PLANCK, J.; MAC-FARLANE, D. Quantitative Structural Models for non-destructive evaluation of wood volume, crown architecture and branch properties in silviculture. **Forest Ecology**, v. 32, n. 1, p. 23-38, 2014. DOI: 10.1016/j.foreco.2014.01.012.
- VOSSCELMAN, G.; MAAS, H.-G. **Airborne and Terrestrial Laser Scanning**. Dunbeath: Whittles Publishing, 2010.

WAGNER, U. et al. Triangulation and Time-of-Flight principles for LiDAR distance measurement between sensor and object. **Remote Sensing Letters**, v. 5, n. 4, p. 312-328, 2004. DOI: 10.1080/21507044.2004.123456.