



UNIVERSIDADE ESTADUAL PAULISTA

“JÚLIO DE MESQUITA FILHO”

Programa de Pós-Graduação em Ciência da Computação

Giovani Candido

**Avaliação da Deterioração Interna de Árvores
Urbanas Através de Algoritmos de Aprendizado
de Máquina**

Bauru – SP
Agosto de 2024

Giovani Candido

Avaliação da Deterioração Interna de Árvores Urbanas Através de Algoritmos de Aprendizado de Máquina

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Faculdade de Ciências da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de Bauru, como parte dos requisitos para a obtenção do título de Mestre, com área de concentração Computação Aplicada e linha de pesquisa Inteligência Computacional.

Fomento: FAPESP - Processo nº 2022/16562-7

Orientador: Prof. Dr. João Paulo Papa
Coorientador: Dr. Danilo Samuel Jodas

Bauru – SP
Agosto de 2024

C217a Candido, Giovani
Avaliação da Deterioração Interna de Árvores Urbanas Através de
Algoritmos de Aprendizado de Máquina / Giovani Candido. -- Bauru, 2024
107 f. : il., tabs., fotos

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP),
Faculdade de Ciências, Bauru
Orientador: João Paulo Papa
Coorientador: Danilo Samuel Jodas

1. Arborização Urbana. 2. Gestão de Riscos de Árvores. 3. Avaliação de
Deterioração Interna. 4. Aprendizado de Máquina. 5. Otimização
Meta-heurística. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Universidade Estadual
Paulista (UNESP), Faculdade de Ciências, Bauru. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE GIOVANI CANDIDO, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO, DA FACULDADE DE CIÊNCIAS - CÂMPUS DE BAURU.

Aos 03 dias do mês de julho do ano de 2024, às 09:00 horas, por meio de Videoconferência, realizou-se a defesa de DISSERTAÇÃO DE MESTRADO de GIOVANI CANDIDO, intitulada **Avaliação da Deterioração Interna de Árvores Urbanas Através de Algoritmos de Aprendizado de Máquina**. A Comissão Examinadora foi constituída pelos seguintes membros: Prof. Dr. JOÃO PAULO PAPA (Orientador - Participação Virtual) do FC/UNESP/Bauru - SP, Prof. Dr. KELTON AUGUSTO PONTARA DA COSTA (Participação Virtual) do FC/UNESP/Bauru - SP, Prof. Dr. SÉRGIO BRAZOLIN (Participação Virtual) do Centro de Tecnologia de Recursos Florestais / Instituto de Pesquisas Tecnológicas do Estado de São Paulo. Após a exposição pelo mestrando e arguição pelos membros da Comissão Examinadora que participaram do ato, de forma presencial e/ou virtual, o discente recebeu o conceito final: **APROVADO**. Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo Presidente da Comissão Examinadora.

Documento assinado digitalmente
 JOAO PAULO PAPA
Data: 01/08/2024 19:17:18-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. JOÃO PAULO PAPA

Giovani Candido

Avaliação da Deterioração Interna de Árvores Urbanas Através de Algoritmos de Aprendizado de Máquina

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Faculdade de Ciências da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de Bauru, como parte dos requisitos para a obtenção do título de Mestre, com área de concentração Computação Aplicada e linha de pesquisa Inteligência Computacional.

Fomento: FAPESP - Processo nº 2022/16562-7

Banca Examinadora

Prof. Dr. João Paulo Papa

Universidade Estadual Paulista “Júlio de Mesquita Filho” - Câmpus de Bauru
Orientador

Prof. Dr. Kelton Augusto Pontara da Costa

Universidade Estadual Paulista “Júlio de Mesquita Filho” - Câmpus de Bauru

Dr. Sérgio Brazolin

Instituto de Pesquisas Tecnológicas do Estado de São Paulo

Bauru – SP
03 de julho de 2024

Dedico esta dissertação de mestrado a minha querida família, a minha amada noiva, aos meus estimados amigos e a todos que, de diversas formas, contribuíram para o êxito deste projeto.

Agradecimentos

Agradeço, em primeiro lugar, a Deus por acompanhar cada um dos meus passos, renovando minhas forças e proporcionando clareza nos momentos de dúvida.

A minha família, em especial aos meus pais, Elaine Cristina Rufino Candido e Luiz Fabiano Candido, e aos meus avós, Luiz Carlos Rufino e Conceição Aparecida Segantin Rufino, por guiarem meus passos com seu amor incondicional e constante apoio ao longo dos anos.

A minha noiva, Laiz Fernanda Alves Ferreira, por suavizar minha jornada com sua companhia, paciência e amor, especialmente nos momentos mais desafiadores.

Aos meus professores do ensino médio e da graduação pelos conselhos e pelas palavras de incentivo que motivaram a minha decisão de prosseguir com os estudos.

Aos meus professores da pós-graduação pelos ensinamentos e pelas orientações que colaboraram significativamente para o meu aprimoramento como pesquisador.

Ao meu orientador, Prof. Dr. João Paulo Papa, pelas oportunidades promovidas, e ao meu coorientador, Dr. Danilo Samuel Jodas, por toda a assistência no decorrer do projeto.

Aos amigos que conheci no ensino médio e na graduação, os quais permaneceram presentes durante todo o mestrado. Em especial, expresso minha gratidão a Davi Augusto Neves Leite, Luis Henrique Morelli e Luiz Fernando Merli de Oliveira Sementille.

Aos colegas do Laboratório Recogna por todo conhecimento compartilhado.

A equipe do Instituto de Pesquisas Tecnológicas do Estado de São Paulo (IPT), por confiar a mim o projeto de pesquisa e por auxiliar em seu desenvolvimento com sua experiência.

Agradeço também ao apoio financeiro concedido pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) por intermédio do processo nº 2022/16562-7, e esclareço que as opiniões, hipóteses, conclusões ou recomendações expressas neste trabalho são de exclusiva responsabilidade do autor e não refletem necessariamente a visão da FAPESP.

E, por fim, agradeço a todos que cooperaram, de alguma forma, com meu projeto.

"Those who have a 'why' to live, can bear with almost any 'how'."

Viktor Emil Frankl

Resumo

Embora as florestas urbanas ofereçam benefícios como a melhoria da qualidade do ar e a mitigação de enchentes, a queda de árvores pode causar sérios problemas. Este estudo propõe uma nova abordagem para estimar a deterioração interna do tronco de árvores urbanas e, assim, auxiliar na previsão do risco de queda. A pesquisa utilizou uma base de dados com variáveis intrínsecas e extrínsecas contendo árvores de sete espécies localizadas em São Paulo, Brasil. Para a estimativa, o problema foi modelado como duas tarefas distintas: regressão e classificação. Nesse cenário, diferentes modelos de aprendizado de máquina, incluindo uma versão inicial do *Optimum-Path Forest* (OPF) para regressão, foram empregados em um fluxo de trabalho que inclui a seleção de características e a otimização de hiperparâmetros por meio de uma promissora meta-heurística denominada *Slime Mold Algorithm* (SMA). Para avaliar as estimativas de forma prática, um método de três etapas foi utilizado. Na primeira etapa, os modelos foram treinados para estimar a deterioração interna do tronco; na segunda, os modelos foram treinados para avaliar o risco de queda utilizando a mesma base de dados, considerando os valores reais de deterioração e outros atributos; na terceira, as estimativas de deterioração foram utilizadas na previsão do risco de queda, em vez dos valores reais, validando a abordagem empregada. Além disso, visando melhorar o desempenho dos modelos, foi realizada a inferência por espécie, considerando *Caesalpinia peltophoroides* e *Tipuana tipu*, e a junção das demais espécies. No entanto, a análise demonstrou que um modelo geral, treinado com amostras de todas as espécies, apresentou melhor desempenho. No geral, a estimativa via regressão, que previu o percentual de área deteriorada, teve um erro médio mínimo próximo de 10% e um R-quadrado (R^2) máximo de 0,23. Já na classificação, que previu o nível de deterioração interna, obteve-se uma acurácia máxima próxima de 80%, com uma acurácia balanceada máxima de cerca de 56%. Ao analisar as acurácias por classes, constatou-se que o desempenho dos modelos em amostras com baixos níveis de deterioração é um destaque, pois permite que os modelos sejam utilizados para complementar a análise visual de sinais externos de deterioração, reforçando a decisão de arboristas e, potencialmente, reduzindo a necessidade de investigações com equipamentos não destrutivos. Contudo, o uso das estimativas para prever o risco indicou que o método ainda não gera estimativas de deterioração suficientemente precisas, comprometendo a previsão de risco, com uma redução de no mínimo 10% da acurácia balanceada ao utilizar os valores previstos de deterioração em vez dos reais.

Palavras-chave: Arborização Urbana, Gestão de Riscos de Árvores, Avaliação de Deterioração Interna, Aprendizado de Máquina, Otimização Meta-heurística.

Abstract

Although urban forests provide benefits such as improved air quality and flood mitigation, tree failures can pose serious issues. This study proposes a new approach for estimating the internal deterioration of urban tree trunks to help predict the risk of tree failure. The research used a database with intrinsic and extrinsic variables from trees of seven species in São Paulo, Brazil. The problem was modeled for estimation as two distinct tasks: regression and classification. In this scenario, different machine learning models, including an initial version of the Optimum-Path Forest (OPF) for regression, were employed in a workflow that includes feature selection and hyperparameter optimization through a promising meta-heuristic called Slime Mold Algorithm (SMA). To evaluate the estimates practically, a three-step method was used. In the first step, the models were trained to estimate the internal deterioration of the trunk; in the second, the models were trained to assess the risk of failure using the same database, considering actual deterioration values and other attributes; in the third, deterioration estimates were used to predict the risk of failure instead of actual values, validating the approach used. Additionally, to improve model performance, the inference was made by species, considering *Caesalpinia peltophoroides* and *Tipuana tipu* separately and grouping the remaining species. However, the analysis showed that a general model trained with samples from all species performed better. Overall, the regression estimate, which predicted the percentage of the deteriorated area, had a minimum mean error close to 10% and a maximum R-squared (R^2) of 0.23. In classification, which predicted the level of internal deterioration, the maximum accuracy achieved was around 80%, with a maximum balanced accuracy of about 56%. However, using estimates to predict risk pointed out that the method still does not provide sufficiently accurate deterioration estimates, compromising risk prediction, with at least a 10% reduction in balanced accuracy when using predicted deterioration values instead of actual ones.

Keywords: Urban Forestry, Tree Risk Management, Internal Deterioration Assessment, Machine Learning, Meta-heuristic Optimization.

Lista de Figuras

Figura 1 – Inspeção de um tronco de acácia-negra com região oca central de 10 cm de diâmetro através de um tomógrafo sônico Arbotom® com 24 sensores.	22
Figura 2 – Podridão parda no cerne de uma conífera.	26
Figura 3 – Achatamento da seção transversal do tronco.	27
Figura 4 – Divisão axial do tronco.	28
Figura 5 – Representação visual das velocidades de propagação das ondas de estresse, registradas por meio de um tomógrafo sônico Arbotom®.	37
Figura 6 – Uso do penetrômetro Digital Micro Probe® da Sibtec para avaliar a perda de resistência mecânica em um tronco de <i>Tipuana tipu</i>	38
Figura 7 – Gráfico da distribuição de árvores por espécie.	42
Figura 8 – Representação dos aspectos físicos de uma árvore.	43
Figura 9 – Representação do ângulo de inclinação de uma árvore.	44
Figura 10 – Representação visual da razão raio/parede sadia.	46
Figura 11 – Gráfico da distribuição de árvores por porcentagem de área deteriorada.	46
Figura 12 – Gráfico da distribuição de árvores por nível de deterioração.	47
Figura 13 – Gráfico da distribuição de árvores por nível de deterioração agrupado por espécie.	47
Figura 14 – Gráfico da distribuição de árvores por nível binário de deterioração.	48
Figura 15 – Gráfico da distribuição de árvores por risco de queda.	49
Figura 16 – Gráfico da distribuição de árvores por risco de queda agrupado por espécie.	49
Figura 17 – Representação dos dados via t-SNE.	50
Figura 18 – Estimativa do <i>cluster</i> de uma amostra de teste com o OPF não supervisionado.	55
Figura 19 – Gráfico de resíduo por valor ajustado de um modelo com $R^2 = 0,97$	58
Figura 20 – Gráfico de resíduo por valor ajustado de um modelo com $R^2 = 0,45$	58
Figura 21 – Pipeline da abordagem proposta.	61
Figura 22 – Fluxograma com a estrutura dos experimentos.	62
Figura 23 – Esquema da divisão dos dados.	62
Figura 24 – Fluxograma do pré-processamento pós-divisão dos dados.	63
Figura 25 – Representação do mecanismo de forrageamento do bolor limoso.	66
Figura 26 – Fluxograma da otimização de hiperparâmetros.	69
Figura 27 – Fluxograma da formação de <i>ensemble</i>	71
Figura 28 – Representação do treinamento do método <i>stacking</i>	72
Figura 29 – Matriz de confusão da DT obtido com a previsão do risco de queda com base nos valores estimados de porcentagem de área com deterioração.	89

Lista de Quadros

Quadro 1 – Relação dos atributos seleccionados.	64
Quadro 2 – Espaços de busca para o ajuste dos hiperparâmetros dos modelos.	70

Lista de Tabelas

Tabela 1 – Medidas descritivas das variáveis contínuas.	43
Tabela 2 – Densidade da madeira de cada espécie de árvore.	45
Tabela 3 – Métricas de avaliação para a estimativa do percentual de área deteriorada.	74
Tabela 4 – Métricas de avaliação para a inferência do risco de queda das árvores com base nos verdadeiros percentuais de área deteriorada.	74
Tabela 5 – Métricas de avaliação para a inferência do risco de queda das árvores com base nos percentuais estimados de área deteriorada.	75
Tabela 6 – Métricas de avaliação para a estimativa do percentual de área deteriorada de árvores da espécie <i>Caesalpinia peltophoroides</i>	75
Tabela 7 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie <i>Caesalpinia peltophoroides</i> com base nos verdadeiros percentuais de área deteriorada.	76
Tabela 8 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie <i>Caesalpinia peltophoroides</i> com base nos percentuais estimados de área deteriorada.	76
Tabela 9 – Métricas de avaliação para a estimativa do percentual de área deteriorada de árvores da espécie <i>Tipuana tipu</i>	77
Tabela 10 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie <i>Tipuana tipu</i> com base nos verdadeiros percentuais da área deteriorada.	77
Tabela 11 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie <i>Tipuana tipu</i> com base nos percentuais estimados de área deteriorada.	78
Tabela 12 – Métricas de avaliação para a estimativa do percentual de área deteriorada de árvores das espécies minoritárias.	78
Tabela 13 – Métricas de avaliação para a inferência do risco de queda de árvores das espécies minoritárias com base nos verdadeiros percentuais da área deteriorada.	79
Tabela 14 – Métricas de avaliação para a inferência do risco de queda de árvores das espécies minoritárias com base nos percentuais estimados de área deteriorada.	79
Tabela 15 – Métricas de avaliação para a classificação do nível de deterioração.	80
Tabela 16 – Métricas de avaliação para a inferência do risco de queda das árvores com base nos verdadeiros níveis de deterioração.	80
Tabela 17 – Métricas de avaliação para a inferência do risco de queda das árvores com base nas estimativas do nível de deterioração.	81
Tabela 18 – Métricas de avaliação para a classificação do nível de deterioração de árvores da espécie <i>Caesalpinia peltophoroides</i>	81

Tabela 19 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie <i>Caesalpinia peltophoroides</i> com base nos verdadeiros níveis de deterioração.	82
Tabela 20 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie <i>Caesalpinia peltophoroides</i> com base nas estimativas do nível de deterioração.	82
Tabela 21 – Métricas de avaliação para a classificação do nível de deterioração de árvores da espécie <i>Tipuana tipu</i>	83
Tabela 22 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie <i>Tipuana tipu</i> com base nos verdadeiros níveis de deterioração. . . .	83
Tabela 23 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie <i>Tipuana tipu</i> com base nas estimativas do nível de deterioração. . .	83
Tabela 24 – Métricas de avaliação para a classificação do nível de deterioração de árvores das espécies minoritárias.	84
Tabela 25 – Métricas de avaliação para a inferência do risco de queda de árvores das espécies minoritárias com base nos verdadeiros níveis de deterioração. . . .	84
Tabela 26 – Métricas de avaliação para a inferência do risco de queda de árvores das espécies minoritárias com base nas estimativas do nível de deterioração. . .	85
Tabela 27 – Métricas de avaliação para a classificação binária do nível de deterioração.	85
Tabela 28 – Métricas de avaliação para a inferência do risco de queda das árvores com base nos verdadeiros níveis binários de deterioração.	86
Tabela 29 – Métricas de avaliação para a inferência do risco de queda das árvores com base nas estimativas binárias do nível de deterioração.	86

Lista de Abreviaturas e Siglas

AdaBoost	<i>Adaptive Boosting</i>
Bal.	Balanceada
CatBoost	<i>Category Boosting</i>
CRP	<i>Close-Range Photogrammetry</i>
CV	<i>Computer Vision</i>
DAP	Diâmetro à Altura do Peito
DL	<i>Deep Learning</i>
DT	<i>Decision Tree</i>
EFB	<i>Exclusive Feature Bundling</i>
EM	Expectativa-Maximização
FAPESP	Fundação de Amparo à Pesquisa do Estado de São Paulo
FBR	Função de Base Radial
FN	Falsos Negativos
g	Grama
GB	Gigabyte
GBM	<i>Gradient Boosting Machine</i>
GCP	<i>Ground Control Point</i>
GHz	Gigahertz
GOSS	<i>Gradient-based One-Side Sampling</i>
GreedyTS	<i>Greedy Target-based Statistics</i>
HPO	<i>Hyperparameter Optimization</i>
IA	Inteligência Artificial
IoT	<i>Internet of Things</i>

IPT	Instituto de Pesquisas Tecnológicas do Estado de São Paulo
<i>k</i> -CV	<i>k-Fold Cross-Validation</i>
<i>k</i> -NN	<i>k-Nearest Neighbors</i>
LiDAR	<i>Light Detection and Ranging</i>
LightGBM	<i>Light Gradient Boosting Machine</i>
m	Metro
MAE	<i>Mean Absolute Error</i>
MI	<i>Mutual Information</i>
MLP	<i>Multilayer Perceptron</i>
MSE	<i>Mean Squared Error</i>
MST	<i>Minimum Spanning Tree</i>
nº	Número
OPF	<i>Optimum-Path Forest</i>
PDF	<i>Probability Density Function</i>
PDIP	Plano de Desenvolvimento Institucional em Pesquisa
pH	Potencial Hidrogeniônico
PSO	<i>Particle Swarm Optimization</i>
RF	<i>Random Forest</i>
RNA	Rede Neural Artificial
RNC	Rede Neural Convolucional
RNFBR	Rede Neural com Função de Base Radial
RNH	Rede Neural Heterogênea
RNM	Rede Neural Multicamadas
RNR	Rede Neural Recorrente
RSS	<i>Residual Sum of Squares</i>
SIBGRAPI	Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens

SMA	<i>Slime Mold Algorithm</i>
SMOTENC	<i>Synthetic Minority Over-sampling Technique for Nominal and Continuous</i>
SVM	<i>Support Vector Machine</i>
TB	Terabyte
TLS	<i>Terrestrial Laser Scanning</i>
t-SNE	<i>t-Distributed Stochastic Neighbor Embedding</i>
TSP	<i>Travelling Salesman Problem</i>
TSS	<i>Total Sum of Squares</i>
UNESP	Universidade Estadual Paulista “Júlio de Mesquita Filho”
UTHI	<i>Urban Tree Health Index</i>
VE	<i>Voting Ensemble</i>
VP	Verdadeiros Positivos
XGBoost	<i>Extreme Gradient Boosting</i>
YOLO	<i>You Only Look Once</i>

Sumário

1	INTRODUÇÃO	19
1.1	Contexto	20
1.2	Problema	21
1.3	Solução Proposta	22
1.4	Objetivo Geral	23
1.5	Objetivos Específicos	23
1.6	Contribuições Específicas do Trabalho	23
1.7	Organização do Trabalho	24
2	REFERENCIAL TEÓRICO	25
2.1	Indicadores de Queda de Árvores Urbanas	25
2.2	Processo de Deterioração das Árvores	25
2.3	Mecanismos de Ruptura de Árvores Deterioradas	27
3	REVISÃO DE LITERATURA	29
3.1	IA na Gestão de Riscos de Florestas Urbanas	29
3.2	Otimização da Coleta de Aspectos Externos	33
3.3	Desafios da Avaliação da Deterioração Interna	36
4	MATERIAL E MÉTODOS	40
4.1	Base de Dados	40
4.1.1	Origem e Coleta de Dados	40
4.1.2	Preparação dos Dados	41
4.1.3	Estrutura e Características dos Dados	42
4.1.4	Visualização dos Dados	49
4.2	Modelos de Aprendizado de Máquina	51
4.2.1	Floresta de Caminhos Ótimos	51
4.2.2	k -Vizinhos Mais Próximos	51
4.2.3	Máquina de Vetores de Suporte	52
4.2.4	Árvore de Decisão	52
4.2.5	Floresta Aleatória	52
4.2.6	<i>Boosting</i>	52
4.2.6.1	<i>AdaBoost</i>	53
4.2.6.2	<i>Gradient Boosting</i>	53
4.2.6.3	<i>XGBoost</i>	53
4.2.6.4	<i>LightGBM</i>	54

4.2.6.5	<i>CatBoost</i>	54
4.2.7	<i>Perceptron Multicamadas</i>	54
4.3	Versão Inicial do OPF para Regressão	54
4.4	Métricas de Avaliação	56
4.4.1	Métricas para Regressão	56
4.4.1.1	Erro Médio Absoluto	56
4.4.1.2	Erro Médio Quadrático	57
4.4.1.3	Coeficiente de Determinação	57
4.4.2	Métricas para Classificação	59
4.4.2.1	Acurácia	59
4.4.2.2	Revocação	59
4.4.2.3	Acurácia Balanceada	59
4.5	Abordagem Proposta	60
4.6	Protocolo Experimental	61
4.6.1	Divisão dos Dados	62
4.6.2	Pré-Processamento	63
4.6.3	Otimização de Hiperparâmetros	65
4.6.3.1	Funcionamento do SMA	66
4.6.3.2	Etapas da Otimização	68
4.6.4	Formação de <i>Ensembles</i>	71
5	RESULTADOS	73
5.1	Estimativa do Percentual de Área Deteriorada	73
5.1.1	<i>Caesalpinia peltophoroides</i>	75
5.1.2	<i>Tipuana tipu</i>	76
5.1.3	Espécies Minoritárias	78
5.2	Classificação do Nível de Deterioração	79
5.2.1	Classificação Multiclasse	79
5.2.1.1	<i>Caesalpinia peltophoroides</i>	81
5.2.1.2	<i>Tipuana tipu</i>	82
5.2.1.3	Espécies Minoritárias	84
5.2.2	Classificação Binária	85
6	DISCUSSÃO	87
6.1	Estimativa do Percentual da Área Deteriorada	87
6.1.1	<i>Caesalpinia peltophoroides</i>	89
6.1.2	<i>Tipuana tipu</i>	90
6.1.3	Espécies Minoritárias	91
6.2	Classificação do Nível de Deterioração	91
6.2.1	Classificação Multiclasse	91

6.2.1.1	<i>Caesalpinia peltophoroides</i>	92
6.2.1.2	<i>Tipuana tipu</i>	93
6.2.1.3	Espécies Minoritárias	93
6.2.2	Classificação Binária	94
6.3	Considerações Finais	95
7	CONCLUSÃO	99
	REFERÊNCIAS	101

1 Introdução

A presença de árvores no ambiente urbano acarreta uma série de impactos positivos para a qualidade de vida da população. Estudos realizados por Donovan (2017) e Pataki et al. (2021) apontam que florestas urbanas são capazes de: i) mitigar a poluição, o que, por conseguinte, resulta na melhoria da qualidade do ar; ii) aumentar a absorção da água pluvial, reduzindo o número de inundações; iii) atenuar o efeito estufa, resultando no resfriamento das áreas urbanas; e iv) reduzir os gastos de energia com aparelhos domésticos de ventilação. Ademais, os autores citam a influência positiva na qualidade de vida e saúde da população mesmo em regiões que possuem poucas árvores. Entre essas vantagens, encontram-se a redução de estresse, a rápida recuperação em casos de enfermidade, a melhoria da fadiga mental, estímulo aos exercícios físicos e o incentivo a atividades de socialização.

No entanto, Pataki et al. (2021) indica que árvores urbanas podem resultar em transtornos em caso de planejamento inadequado ou falta de manejo. Roman et al. (2021) evidencia que a queda de árvores ou de seus elementos constituintes tem ocasionado danos à infraestrutura municipal, quedas de energia, danos a propriedades e bens privados dos residentes, além de lesões físicas e eventuais fatalidades. Em decorrência desses impactos negativos, o autor revela a necessidade de comprometimento dos governos locais em promover o uso de técnicas eficientes para a gestão e o monitoramento de árvores em ecossistemas urbanos.

Conforme Haaften et al. (2021), cidades europeias e norte-americanas possuem artifícios legais que preveem a existência de programas de gestão que têm como intuito a identificação de falhas na estrutura de árvores urbanas para evitar possíveis colapsos, bem como suas eventuais consequências. O autor descreve a importância de tais programas tanto na identificação de aspectos dendrométricos da árvore quanto no estudo de fatores extrínsecos, como aspectos ambientais e antrópicos, que contribuam para a potencial queda. Por meio da avaliação desses fatores, pode-se tomar as medidas de manutenção necessárias ou, em cenários de perigo iminente para a população, optar por ações extremas, como a retirada do espécime.

Ainda de acordo com Haaften et al. (2021), que analisou 161 estudos em sua revisão sistemática, a deterioração é um dos principais fatores associados à ruptura de árvores urbanas. Porém, Brazolin (2009) e Haaften et al. (2021) salientam que uma queda pode ser, de modo geral, indicada por múltiplas variáveis, sendo estas, deterioração da madeira, causado pela presença de xilófagos, como fungos e cupins; características dendrométricas da árvore, como o Diâmetro à Altura do Peito (DAP), diâmetro medido a uma altura de 1,30 metros do solo; injúrias mecânicas ou estruturais; presença de oco aberto; situações inadequadas de plantio, como colo soterrado; e condições climáticas adversas, tais como ventanias e fortes tempestades.

Nesse sentido, Brazolin (2009) descreve duas abordagens para a avaliação de risco em

árvores urbanas: a análise visual externa e a análise estrutural. Esses instrumentos, por meio dos fatores supracitados, visam embasar decisões de manejo. Segundo o autor, a análise externa é amplamente utilizada para determinar as condições de conservação das árvores, embora não apresente critérios bem definidos para a tomada de decisão. Dessa forma, o autor enfatiza que a inspeção estrutural complementa a externa, investigando a perda da resistência mecânica através da análise quantitativa da deterioração interna do tronco e, então, estabelecendo critérios concretos para a decisão do manejo adequado diante das condições avaliadas.

Não obstante as abordagens existentes e consolidadas para o monitoramento de árvores urbanas, Haaften et al. (2021) alegam a escassez de técnicas que permitam a predição do risco de queda de árvores precisamente. Segundo os autores, os programas de gestão têm empregado modelos mecanísticos ou estatísticos para automatizar as análises realizadas. Todavia, os autores observam que modelos mecanísticos são custosos devido à necessidade de coleta de informações detalhadas acerca de cada árvore, enquanto os estatísticos apresentam altos níveis de incerteza. Nesse cenário, Araújo et al. (2021) apontam que as metodologias baseadas em Inteligência Artificial (IA) e aprendizado de máquina destacam-se como alternativas para a avaliação dos riscos associados aos aspectos e às condições de árvores urbanas.

1.1 Contexto

O presente trabalho está inserido no âmbito do “Plano de Desenvolvimento Institucional em Pesquisa (PDIP) na Área de Transformação Digital: Manufatura Avançada e Cidades Inteligentes”, uma iniciativa promovida pelo Instituto de Pesquisas Tecnológicas do Estado de São Paulo (IPT) com o apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP)¹. Vale ressaltar que o PDIP em questão se beneficia com a participação de pesquisadores, entre os quais se inclui o autor, afiliados ao Laboratório Recogna², situado no câmpus de Bauru da Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP).

Nesse contexto, este estudo aborda a avaliação do risco de queda de árvores urbanas mediante algoritmos de aprendizado de máquina, os quais são treinados considerando fatores internos e externos, tais como os indicados por Brazolin (2009), como a área deteriorada do tronco e o DAP. Entretanto, o foco do projeto está na redução do trabalho de campo associado à coleta de dados. Nielsen, Östberg e Delshammar (2014) ressaltam que a abordagem mais comum para o inventário de árvores urbanas consiste em análises visuais e medições de aspectos da árvore por uma equipe de campo, embora seja uma atividade dispendiosa e extensa.

Contudo, novas abordagens têm surgido para otimizar o processo de aquisição de dados. De acordo com Nielsen, Östberg e Delshammar (2014), é possível utilizar até mesmo fotografias digitais para realizar o inventário de árvores. Nesse cenário, o trabalho de Jodas

¹ Processo nº 2017/50343-2.

² Site do laboratório: <https://recogna.tech/>.

et al. (2022) propõe o uso de redes neurais convolucionais para a detecção de árvores e seus elementos constituintes em imagens capturadas a partir da perspectiva do solo, a fim de estimar a altura das árvores com base em uma haste adjacente de tamanho conhecido. Analogamente, outros aspectos visíveis podem ser determinados via visão computacional, também denominada *Computer Vision* (CV), que extraem informações de imagens de modo automático.


1.2 Problema

Em contrapartida, no que diz respeito às condições internas das árvores, ainda são necessárias técnicas que otimizem o processo de avaliação durante as pesquisas de campo. Embora a inspeção visual seja comumente empregada em um estágio inicial para identificar possíveis sinais de alerta, como indícios de estresse mecânico excessivo, corpos de frutificação de fungos e galhos mortos, quando esses sinais são encontrados, uma investigação adicional deve ser realizada para determinar a extensão da deterioração da madeira com o uso de ferramentas de suporte (DOLWIN; BARNETT, 1999; MATTHECK, 1998). A título de exemplo, o estudo de Espinosa et al. (2017) empregou um dispositivo de tomografia sônica Arbotom^{®3} para a detecção das regiões internas do tronco que se encontravam deterioradas.

Segundo Li et al. (2022), ao utilizar equipamentos não destrutivos para conduzir uma análise do estado interno do tronco, é necessário considerar o custo e o tempo de medição. Embora o tomógrafo sônico seja robusto, seu uso implica na instalação de sensores ao redor do tronco para analisar a velocidade de propagação de ondas de estresse em diferentes direções e mapear as áreas deterioradas, como ilustrado pela Figura 1. Sendo assim, essa técnica requer um esforço considerável, dificultando a avaliação de extensas áreas arborizadas. Além disso, a abordagem negligencia a propriedade anisotrópica da madeira, que possibilita distintas velocidades de propagação mesmo na ausência de deterioração (ESPINOSA et al., 2017).

³ Site do fabricante: <https://rinntech.info/products/arbotom/>.

Figura 1 – Inspeção de um tronco de acácia-negra com região oca central de 10 cm de diâmetro através de um tomógrafo sônico Arbotom® com 24 sensores.



Fonte: Extraída de Espinosa et al. (2017).

1.3 Solução Proposta

Sendo assim, este estudo propõe uma alternativa eficiente para a estimativa da deterioração interna, visando auxiliar arboristas como uma ferramenta de apoio na tomada de decisões, complementando a análise visual externa do tronco. Além disso, a solução confirma a decisão do arborista de não realizar investigações adicionais com equipamentos não destrutivos quando sinais de alerta, como corpos de frutificação de fungos, estão ausentes e há congruência entre as deliberações do profissional e do modelo. Em síntese, a proposta envolve o treinamento de diferentes algoritmos de aprendizado de máquina em aspectos relacionados às árvores. Para tal, aborda-se o problema tanto como classificação quanto como regressão. Além disso, são empregadas técnicas de *ensembles*, ou, em português, agrupamento de modelos (DONG et al., 2020), visando aprimorar os resultados através da combinação das saídas de vários algoritmos. Para a validação da abordagem proposta, realiza-se a comparação da qualidade das previsões de risco de queda, obtidas com os valores reais de deterioração e com os valores estimados.

Nessa perspectiva, o presente trabalho tem em vista contribuir para a investigação de metodologias que visam acelerar o monitoramento de árvores urbanas e reduzir a necessidade de alocação de recursos humanos para a extração de medidas em trabalhos de campo. Além disso, analisa a relação entre os fatores internos do tronco e os aspectos externos relacionados a árvores urbanas, ainda pouco explorada no contexto de aprendizado de máquina.

1.4 Objetivo Geral

Esta pesquisa visa modelar a estimativa da deterioração interna do tronco de árvores urbanas por meio de técnicas de aprendizado de máquina treinadas com base em características registradas por equipes de campo. Busca-se, assim, gerar uma ferramenta de suporte que minimize a necessidade de inspeções adicionais do tronco mediante equipamentos não destrutivos, reduzindo consequentemente o trabalho de campo necessário para monitorar o risco de queda.

1.5 Objetivos Específicos

No que se refere às metas específicas, este projeto almeja:

- Comparar o desempenho de diferentes algoritmos de aprendizado de máquina na relação entre aspectos estipulados por equipes de campo e a deterioração interna da madeira;
- Analisar como a avaliação do risco de queda de árvores urbanas é afetada pelo emprego das estimativas de deterioração interna obtidas com o método proposto, comparando-a com a avaliação baseada nos valores de deterioração mensurados por equipes de campo;
- Propor um modelo de aprendizado de máquina para tarefas de regressão tendo como base o *framework* Floresta de Caminhos Ótimos, também denominado *Optimum-Path Forest* (OPF) em inglês (PAPA; FALCÃO; SUZUKI, 2009);
- Contribuir para futuros estudos focados na otimização do trabalho de campo envolvido na avaliação de risco de árvores urbanas;
- Divulgar a pesquisa em eventos científicos por meio da escrita de artigos.

1.6 Contribuições Específicas do Trabalho

Este projeto de pesquisa apresenta diversas contribuições específicas. Para a área de computação, destaca-se a primeira tentativa de adaptar o OPF ao contexto de regressão, aplicando-o em um cenário real e comparando seu desempenho com diferentes modelos já consolidados na literatura de aprendizado de máquina. Além disso, na otimização dos hiperparâmetros dos modelos, foi empregada uma meta-heurística relativamente recente e, portanto, ainda pouco explorada nesse contexto: o Algoritmo do Bolor Limoso, mais conhecido por *Slime Mold Algorithm* (SMA) em inglês Li et al. (2020). Para a gestão de árvores urbanas, a contribuição principal é a abordagem proposta para estimar a deterioração interna de árvores urbanas, representando o primeiro trabalho a treinar algoritmos de aprendizado de máquina com variáveis relacionadas às árvores. Ademais, outra importante contribuição é a disponibilização da base de dados à comunidade científica, visando fomentar pesquisas futuras.

1.7 Organização do Trabalho

Esta dissertação está organizada da seguinte forma:

- **Capítulo 2:** Fornece uma base teórica sobre os indicadores de queda de árvores urbanas, o processo de deterioração e os mecanismos de ruptura de árvores deterioradas;
- **Capítulo 3:** Apresenta uma revisão da literatura sobre o uso de IA na gestão de risco de árvores urbanas, a otimização da coleta de dados e a avaliação da deterioração interna;
- **Capítulo 4:** Descreve a base de dados, os modelos de aprendizado de máquina, a abordagem proposta para resolver o problema e o protocolo experimental;
- **Capítulo 5:** Apresenta os resultados dos experimentos realizados;
- **Capítulo 6:** Analisa os resultados e discute suas implicações;
- **Capítulo 7:** Sumariza os principais pontos do trabalho, destaca suas contribuições para a gestão de árvores urbanas e sugere possíveis direções para pesquisas futuras.

2 Referencial Teórico

Este capítulo tem como objetivo fornecer uma base teórica para a compreensão da queda de árvores urbanas. Nesse contexto, a seção 2.1 detalha os fatores que podem indicar uma queda iminente quando avaliados em conjunto, tais como a ação do vento e a deterioração interna. Em seguida, a seção 2.2 explora o processo de deterioração da madeira, destacando os agentes deterioradores e o sistema de defesa natural das árvores. Por fim, a seção 2.3 discute os mecanismos de ruptura específicos de árvores ocas devido à deterioração interna.

2.1 Indicadores de Queda de Árvores Urbanas

Em sua revisão sistemática, que contemplou 161 estudos, Haaften et al. (2021) observou que a principal causa relatada de ruptura do lenho em árvores urbanas foi o vento, seguido pelo apodrecimento interno causado por fungos e, paralelamente, a perda de vigor devido à idade avançada. Essa conclusão está alinhada com o estudo realizado por IPT (2004), que identificou a deterioração provocada por fungos e cupins em árvores urbanas do município de São Paulo, Brasil, como uma causa significativa de quedas. Contudo, a avaliação do risco de queda de árvores urbanas, de modo geral, requer a análise conjunta de diversos fatores.

Brazolin (2009) e Haaften et al. (2021) ressaltam que a análise do risco de queda pode abranger fatores como a presença de agentes deterioradores, discutidos na seção 2.2; a existência de ocos abertos; características dendrométricas que podem influenciar a resistência mecânica da árvore, tais como altura, diâmetro da copa e DAP; injúrias mecânicas e estruturais, como rachaduras, inclinação e galhos desalinhados; condições de plantio inadequadas, como colo soterrado e raízes expostas; má execução ou ausência de podas; compactação do solo; deficiências nutricionais do solo; excesso ou falta de água; intervenções de engenharia civil que afetem as árvores; poluição; e condições climáticas adversas, como ventos fortes e tempestades.

Além disso, é importante destacar que propriedades intrínsecas à espécie podem afetar o risco de queda. De acordo com Clausen (2010), cada espécie de árvore possui uma capacidade inerente de resistir aos ataques de agentes deterioradores, o que é conhecido como resistência natural. Além disso, a densidade específica da madeira do tronco influencia a resistência mecânica das árvores, ou seja, sua capacidade de resistir à ação de forças externas (IPT, 2004).

2.2 Processo de Deterioração das Árvores

A deterioração é um processo biológico de decomposição dos componentes estruturais da madeira, como celulose e lignina, que resulta na perda da resistência estrutural da árvore,

enfraquecendo-a (SHORTLE; DUDZIK, 2012). Esse fenômeno é causado principalmente pela ação enzimática de fungos e bactérias, que digerem as paredes celulares da árvore. Um exemplo desse processo é ilustrado na Figura 2, que mostra uma conífera com a região do cerne deteriorada por podridão parda, causada por várias espécies de fungos. Segundo Shortle e Dudzik (2012), esse tipo de deterioração é considerado o mais perigoso, pois a madeira perde sua força rapidamente antes que sinais externos se manifestem. De modo geral, esses micro-organismos, isto é, fungos e bactérias, invadem as árvores a partir de feridas, como tocos resultantes da queda de galhos e cicatrizes decorrentes da remoção da casca por insetos, animais de diferentes portes ou seres humanos (SHIGO, 1979; SHORTLE; DUDZIK, 2012).

Figura 2 – Podridão parda no cerne de uma conífera.



Fonte: Extraída de Downer e Perry (2019).

Além disso, outros agentes podem se aliar aos fungos e bactérias no processo de biodeterioração. Ebeling (1975) explica que algumas ordens de insetos podem atuar na deterioração da madeira das árvores. Entre essas ordens de insetos estão: Isoptera (cupins), sendo este o grupo mais destrutivo para a madeira; Coleoptera (besouros); e Hymenoptera (formigas, abelhas e vespas). Vale ressaltar que os ataques desses insetos, através da ação mecânica da mastigação, podem estar relacionados tanto à alimentação quanto à construção de túneis. As formigas carpinteiras, por exemplo, danificam a madeira das árvores apenas para a construção de ninhos, enquanto os cupins são capazes de se alimentar da madeira mastigada.


É importante destacar que, como consequência da deterioração, a árvore aciona um sistema de defesa natural denominado compartimentalização. Segundo Shigo e Marx (1977), este mecanismo consiste na formação de barreiras protetoras que visam isolar a região do lenho infectada pelo fungo, em processo de deterioração, da madeira saudável resultante do crescimento da árvore. Ao conter a madeira velha e deteriorada da árvore, esse mecanismo justifica a existência de árvores com regiões ocas no interior (SHORTLE; DUDZIK, 2012).

2.3 Mecanismos de Ruptura de Árvores Deterioradas

Uma árvore pode quebrar de diversas maneiras, independentemente de estar deteriorada ou saudável. A título de exemplo, em condições extremas, como fortes ventanias, a seção transversal do tronco de uma árvore pode ceder devido a uma fratura causada pela flexão resultante das forças do vento. No entanto, de acordo com Mattheck, Bethge e West (1994), árvores internamente deterioradas e, portanto, ocas, têm menor resistência estrutural e são mais suscetíveis a rupturas por flexão quando expostas à ação do vento ou ao próprio peso.


Em árvores ocas, a ruptura da seção transversal do tronco pode ser desencadeada por um achatamento semelhante ao observado numa mangueira de água quando flexionada, conforme representado na Figura 3. Esse processo de achatamento resulta na divisão axial do tronco, como evidenciado na Figura 4, e consequentemente leva ao colapso do tronco (MATTHECK; BETHGE; WEST, 1994). Ademais, quando a parede do tronco é fina, a ruptura pode ocorrer devido à flambagem. Nesse segundo mecanismo de falha, Mattheck (1998) explica que a seção transversal do tronco sofre uma compressão tão intensa ao ser flexionada que as fibras se deformam espontaneamente, sem que o achatamento da seção transversal ocorra.

Figura 3 – Achatamento da seção transversal do tronco.



Fonte: Adaptada de Mattheck, Bethge e West (1994).

Figura 4 – Divisão axial do tronco.



Fonte: Adaptada de Mattheck, Bethge e West (1994).

3 Revisão de Literatura

A arborização de ambientes urbanos tem sido uma prática adotada por muitos governos locais devido aos inúmeros benefícios ecológicos proporcionados pelas árvores (ROMAN et al., 2021). Contudo, segundo Li et al. (2022), as condições adversas às quais as árvores urbanas são expostas têm sido preocupantes, uma vez que a queda de árvores ou de seus membros pode danificar bens materiais, assim como lesionar os munícipes. Por conseguinte, as autoridades locais têm implementado programas de gestão que visam a constante avaliação do estado das árvores urbanas com o intuito de antecipar acidentes (LI et al., 2022). Em meio a esse cenário, a aplicação de métodos baseados em IA e aprendizado de máquina, que possibilitam a análise eficiente de extensos conjuntos de dados, tem-se demonstrado promissora na avaliação dos riscos associados aos aspectos e às condições de árvores urbanas (ARAÚJO et al., 2021).

Esta revisão de literatura tem como objetivo discutir estudos que recorrem à IA e algoritmos de aprendizado de máquina para inferir o risco de queda, assim como o estado de saúde e conservação de árvores urbanas, levando em consideração fatores intrínsecos e extrínsecos. Ademais, este capítulo apresenta metodologias eficientes baseadas em sensoriamento e CV, que têm sido utilizadas para otimizar o processo de obtenção de variáveis externas que indiquem o risco de queda. Por último, são abordadas as dificuldades na avaliação da deterioração interna do tronco, ressaltando a importância do presente projeto de pesquisa.

3.1 IA na Gestão de Riscos de Florestas Urbanas

Esta seção aborda os estudos relacionados ao uso de IA, assim como técnicas de aprendizado de máquina, para a tarefa de estimar o risco de queda de árvores em ambientes urbanos. Além de discutir os aspectos das árvores que são considerados nesses trabalhos, são apresentadas as diferentes abordagens propostas para o monitoramento automatizado como uma ferramenta de suporte ao manejo realizado por especialistas em arborização urbana.

Nesse contexto, Rust e Stoinski (2022) propuseram o uso do Dylogos, um sistema comercial de IA para tomada de decisões, como uma ferramenta de suporte para que arboristas inexperientes possam ter acesso a uma segunda opinião. Com os dados de treinamento, um arborista experiente cria regras por meio de expressões lógicas. Tais regras formam árvores de decisões para a classificação do risco de queda em níveis como baixo, médio, alto ou extremo. Essas regras são fundamentadas nas possíveis combinações de categorias, de baixo a extremo, de seis aspectos: (i) exposição ao vento, que se refere à intensidade do vento na região; (ii) braço de alavanca, que diz respeito à distância entre a base do tronco e o ponto de aplicação da força do vento; (iii) área de superfície, correspondente à área total exposta ao vento; (iv) gravidade do ponto de estresse, que considera a presença de pontos de fraqueza, como

rachaduras e bifurcações malformadas; (v) arquitetura excurrente — quanto mais excurrente, maior é a dominância de um tronco principal; (vi) exposição real, que representa a intensidade do vento que de fato atinge a árvore, considerando a presença de obstruções. Além disso, esse sistema consegue otimizar as regras e ajustar suas saídas por meio de observações fornecidas pelo operador. De acordo com os autores, arboristas inexperientes podem utilizar o sistema para orientar suas avaliações. Ademais, o Dylogos é um software de IA do tipo “caixa branca”, já que os resultados podem ser explicados por meio das regras estabelecidas, ao contrário de modelos considerados “caixa preta”, tais como a Rede Neural Artificial (RNA).

No estudo de Ramírez et al. (2022), o problema foi modelado com base na construção de conjuntos *fuzzy* para os aspectos de 260 árvores analisadas, assim como para os fatores relacionados ao ambiente. Para a altura da árvore, por exemplo, foram criados conjuntos para alturas baixas, médias e altas. Os autores empregaram as seguintes características: (i) altura da árvore, (ii) DAP, (iii) proximidade de cabos elétricos, (iv) presença de pestes, (v) porcentagem de umidade relativa do ar, (vi) tipo de clima, (vii) temperatura máxima do ambiente e (viii) velocidade do vento. Com os conjuntos dos atributos já definidos, os pesquisadores propuseram o uso de modelos de aprendizado de máquina para, com os níveis de cada característica das árvores, prever o risco de queda das árvores em diferentes graus, tais como baixo, médio ou alto. Outrossim, os autores propuseram a criação de uma aplicação web na qual os usuários possam registrar os dados das árvores e obter as respectivas indicações de risco em tempo real.

Por outro lado, Jahani e Saffariha (2022) propuseram a comparação de três técnicas de aprendizado de máquina para a previsão de risco de queda de árvores urbanas. Os modelos selecionados pelos pesquisadores foram a Rede Neural Multicamadas (RNM), a Rede Neural com Função de Base Radial (RNFBR) e a Máquina de Vetores de Suporte, ou *Support Vector Machine* (SVM) em inglês. Nesse estudo, os autores agruparam 12 características de 500 árvores urbanas de províncias do Irã, todas da espécie plátano-oriental, as quais foram acompanhadas por cinco anos para o registro de eventuais falhas. Tais aspectos foram categorizados em (1) variáveis da árvore e (2) defeitos ou distúrbios da árvore. Do primeiro grupo, foram selecionadas as variáveis: (i) altura da árvore, (ii) idade, (iii) diâmetro da base, (iv) DAP, (v) espalhamento da copa baseado na média do diâmetro da copa em duas dimensões, (vi) comprimento vertical da copa, (vii) profundidade do solo e (viii) proteção contra o vento. Do segundo grupo, foram selecionadas as condições: (i) grau de inclinação, (ii) porcentagem de deterioração interna, (iii) comprimento de rachaduras, e (iv) porcentagem de desfolhamento da copa. Com os registros, seis classes foram formadas: (1) Extremamente Perigosa, que agrupa árvores que apresentaram falhas após um ano; (2) Muito Perigosa, árvores que apresentaram falhas em dois anos; (3) Perigosa, em três anos; (4) Relativamente Perigosa, em quatro anos; (5) Pouco Perigosa, em cinco anos; e (6) Não Perigosa, árvores que não apresentaram falhas. Por meio de experimentos, demonstrou-se a eficácia da abordagem, salientando a performance da SVM.

O trabalho de Kabir, Guikema e Kane (2018) apresentou uma metodologia para a

previsão da probabilidade de falha em árvores urbanas durante tempestades, baseada em aprendizado de máquina. Para isso, os autores utilizaram uma base de dados com 1.258 árvores de diferentes espécies, localizadas no Parque Estadual Nickerson, em Massachusetts, nos Estados Unidos. Essa base registra as quedas ocorridas durante uma tempestade que ocorreu em dezembro de 2005, além de apresentar variáveis relacionadas às árvores. Os autores agruparam essas variáveis em (1) binárias, (2) categóricas multiníveis e (3) contínuas. Do primeiro grupo, selecionaram: (i) poda realizada antes da tempestade, (ii) presença de árvores removidas nas proximidades e (iii) presença de defeitos graves, tais como rachaduras, raízes cortadas, galhos com fraca fixação e deterioração. Do segundo grupo, escolheram: (i) número do setor do parque no qual a árvore está plantada e (ii) espécie da árvore. Do último grupo, separaram: (i) DAP e (ii) altura da árvore. Nesse estudo, a estimativa da probabilidade de queda foi modelada como uma classificação binária com as classes “ocorrência de queda” e “não ocorrência”. Assim, a probabilidade de as árvores pertencerem à classe “ocorrência de queda” foi tomada como a probabilidade de falha. Com seus experimentos, os autores demonstraram que essa abordagem resultou em bons resultados para a tempestade analisada, especialmente com a formação de um *ensemble* com os modelos *boosting* e Floresta Aleatória.

Analisando sob outra perspectiva, Wang et al. (2018) propuseram estabelecer o relacionamento entre fatores ambientais e o estado de conservação das árvores, uma vez que árvores em mau estado de conservação tendem a apresentar estruturas instáveis e, portanto, serem mais propensas a quedas. Nesse contexto, a avaliação da conservação das árvores orienta a tomada de decisão dos gestores da arborização urbana. No estudo, os autores propuseram, inicialmente, a instalação de sensores nas proximidades das árvores para a obtenção de seis características relacionadas com o desenvolvimento saudável das árvores: temperatura, umidade, nível de água no solo, concentração de dióxido de carbono, intensidade luminosa e acidez do solo. Tais características foram medidas 5.000 vezes para cada uma das 14 árvores selecionadas. Posteriormente, os autores sugerem uma inspeção visual do tronco, dos galhos, das folhas e das raízes, a fim de realizar classificações manuais das árvores em: saudáveis e não saudáveis. Para o aprendizado da relação entre os fatores e a saúde das árvores, os autores propõem o uso de um modelo de regressão logística. Embora o estudo tenha lidado com poucas árvores e a inspeção visual possa ser imprecisa, os resultados obtidos com a abordagem foram satisfatórios.

Em um trabalho derivado, Wu et al. (2019) sugerem que um sistema de Internet das Coisas, ou *Internet of Things* (IoT) em inglês, pode ser empregado para a aquisição de características dinâmicas mediante sensores, com o intuito de combinar esses fatores com características estáticas predeterminadas e realizar a classificação do estado da árvore. No que se refere aos valores dinâmicos, os autores empregaram sete fatores: temperatura, umidade, concentração de gás carbônico, intensidade luminosa, umidade do solo, nível de potencial hidrogeniônico (pH) do solo e ângulo de inclinação da árvore. Por outro lado, usaram sete fatores estáticos: características de crescimento da árvore, localização, idade, direção da fonte de luz, exposição ao vento, condições de plantio, e área de raízes e profundidade. Em síntese, os

autores propuseram uma Rede Neural Heterogênea (RNH) formada pela junção de uma RNA, para lidar com os fatores estáticos, com uma Rede Neural Recorrente (RNR), para lidar com os fatores dinâmicos. O intuito dessa arquitetura é estimar o *Urban Tree Health Index* (UTHI), um indicador de saúde proposto pelos pesquisadores para avaliar a condição das árvores. Esse índice assume valores contínuos em $[0, 5]$, sendo dividido em níveis de intervalos, tais como nível 1, $[0, 1]$; nível 2, $(1, 2]$; nível 3, $(2, 3]$; nível 4, $(3, 4]$; e nível 5, $(4, 5]$. Quanto maior o nível, melhor o estado, com cinco representando uma árvore em excelentes condições e um, em péssimas condições. Segundo os autores, o modelo atingiu altos valores de acurácia.

Outrossim, a revisão de Araújo et al. (2021) reúne um total de 67 estudos que propõem o uso de IA para tarefas relacionadas à arboricultura urbana em 23 países, incluindo o Brasil. Além da avaliação de risco de queda de árvores urbanas, os autores identificaram outras atividades associadas ao manejo das árvores, tais como estimativas de crescimento, análise da vulnerabilidade a surtos de insetos e avaliação de aspectos socioeconômicos da arborização urbana. No que tange às demais aplicações, os autores também apontaram trabalhos com foco na avaliação remota da cobertura do dossel — a camada superior formada pelas copas das árvores, classificação remota de espécies de árvores, classificação do uso do solo ou de florestas, identificação remota de árvores individuais e avaliação de serviços ecossistêmicos das árvores.

No que diz respeito às potenciais limitações dos trabalhos mencionados, a metodologia de Rust e Stoinski (2022) baseia-se na experiência de especialistas em arborização urbana, uma vez que não existem regras universalmente aplicáveis que tenham sido comprovadas por meio do método científico. Em contrapartida, na abordagem proposta por Ramírez et al. (2022), a sobreposição da função de pertinência dos conjuntos *fuzzy* pode resultar em amostras de treinamento inconsistentes. No estudo de Jahani e Saffariha (2022), todas as árvores examinadas possuíam mais de 100 anos, o que gera um viés no modelo e impede sua aplicação na análise de árvores mais jovens. O método utilizado por Kabir, Guikema e Kane (2018) fundamentou-se em dados de uma única tempestade, restringindo sua aplicabilidade apenas a esse evento específico. Por sua vez, Wang et al. (2018) treinaram o modelo com uma base de dados desbalanceada, já que das 14 árvores analisadas por sensores, apenas duas não apresentavam saúde adequada, o que pode sugerir que a alta acurácia do modelo não represente sua real capacidade de generalização. Por fim, Wu et al. (2019) propuseram um modelo de desempenho satisfatório, mas que requer a instalação de sensores em cada árvore, o que ocasiona um custo elevado e pode apresentar desafios em zonas urbanas.

É relevante destacar que os estudos analisados nesta seção empregaram fatores comuns em suas avaliações de risco, tais como a exposição ao vento, a dendrometria da árvore, os defeitos externos e a presença de deterioração. Porém, entre os fatores, apenas a deterioração, por ser um fator interno, exige uma investigação mais robusta para sua identificação, como será discutido na seção 3.3. Além disso, esse aspecto está diretamente relacionado ao estado de conservação da árvore, indicando o enfraquecimento da estrutura da árvore, que acarreta a

perda de sua resistência mecânica. Portanto, justifica-se a ênfase na estimativa desse atributo.

3.2 Otimização da Coleta de Aspectos Externos

Segundo Nielsen, Östberg e Delshammar (2014), o inventário de árvores individuais é essencial para os municípios manterem o controle dos espécimes em locais públicos, como parques e passagens, e realizem atividades rotineiras como avaliação de risco. Em sua revisão, a qual incluiu 57 estudos realizados em vários países, os autores concluem que o método de coleta de dados mais utilizado para esse propósito consiste em inspeções visuais e pesquisas de campo com equipamentos para a extração de medidas. Entretanto, os autores destacam abordagens mais recentes nas quais a coleta de dados ocorre por meio de imagens obtidas por satélite, veículos aéreos e escaneamento ou fotografia digital ao nível do solo, a fim de agilizar o inventário. De acordo com os pesquisadores, esses métodos não convencionais têm sido empregados não só na identificação de árvores urbanas mas também na extração de algumas características, tais como espécie, altura total da árvore, diâmetro da copa e DAP.

Nesse contexto, tanto as abordagens convencionais de processamento de imagens quanto as técnicas baseadas em aprendizado profundo, também conhecido como *Deep Learning* (DL) em inglês, têm sido amplamente utilizadas. Os algoritmos convencionais realizam a detecção das árvores com base em cor, textura e forma, além de outros atributos relevantes das imagens (TENG; CHEN; HSU, 2005; WANG; HUANG; FU, 2009). Por outro lado, as Redes Neurais Convolucionais (RNCs) têm se destacado pela eficiência na detecção de objetos em ambientes urbanos, incluindo árvores. Tais redes aprendem a reconhecer padrões complexos nas imagens e mapear características relevantes, fornecendo resultados precisos e robustos.

O estudo de Kwak et al. (2007) teve como objetivo a estimativa da altura de árvores coníferas e caducifólias localizadas em florestas da Coreia do Sul. Para isso, os autores utilizaram um sensor *Light Detection and Ranging* (LiDAR) que emite lasers pulsados para calcular a distância do sensor à superfície do terreno ou aos objetos presentes no terreno com base no tempo de retorno do feixe de luz. O sensor foi empregado em um sobrevoo da floresta a 1.500 metros de altura e produziu uma nuvem de pontos tridimensionais, a qual foi utilizada para a construção de uma representação virtual da floresta por meio do software TerraScan^{TM4}. A partir do modelo digital criado, a técnica de segmentação *watershed*, que particiona imagens topográficas por meio de linhas que se assemelham a divisores de água (HUANG; CHEN, 2004), foi empregada para obter 153 árvores individuais e extrair seus pontos de maior altura. Para validar a abordagem proposta, Kwak et al. (2007) compararam as alturas obtidas com as alturas reais das árvores e concluíram que a metodologia resultou em altos valores de coeficiente de determinação, indicando uma proximidade considerável entre os valores estimados e os medidos.

Birdal, Avdan e Türk (2017) propuseram a utilização de uma câmera fotográfica

⁴ Site da desenvolvedora: <https://terrasolid.com/products/terrascan/>.

convencional ao invés de um sensor LiDAR, uma vez que a primeira apresenta um custo mais baixo. No estudo realizado pelos autores, utilizou-se um drone eBee⁵ equipado com uma câmera Canon IXUS 127 HS, com uma resolução máxima de 4.608 por 3.456. Antes do voo, os autores marcaram pontos de coordenadas geográficas conhecidas, denominados *Ground Control Points* (GCPs), ao longo da região de análise, para que fossem capturados nas fotografias. Durante o voo, foram obtidas 133 fotografias aéreas, que receberam informações geoespaciais, como as coordenadas da câmera, em seus metadados. Posteriormente, as imagens passaram por um processo de ortorretificação utilizando o software Postflight Terra 3D⁶, tendo como base os GCPs definidos. Esse processo corrige as distorções geométricas das imagens para que elas possam ser utilizadas para medir distâncias reais. A partir das ortofotos, os autores utilizaram o software para a construção de modelos digitais da região. Para a estimativa da altura das árvores, empregaram um algoritmo de determinação de máximos locais que identificou os topos das árvores e permitiu a obtenção da coordenada de altura desses pontos. A fim de validar a abordagem, um laser medidor de distância foi utilizado para medir as alturas reais de 53 árvores, visando a comparação com as alturas estimadas pelo modelo. Essa comparação resultou em um coeficiente de determinação de 0,94, indicando uma equivalência entre os resultados obtidos e os dados reais, sendo que 1,0 representa uma correspondência perfeita entre os dados.

Sob outra perspectiva, Cabo et al. (2018) sugerem o uso de imagens ao nível do solo, em oposição às imagens aéreas, a fim de permitir a obtenção não apenas da altura mas também de outros atributos como o DAP, capturando informações do tronco das árvores, além das copas. Em síntese, os autores empregaram três bases de dados com informações obtidas por meio do sensoriamento via *Terrestrial Laser Scanning* (TLS), uma versão terrestre do LiDAR. Tais bases apresentam dados de 207 árvores de diferentes espécies localizadas na Espanha e no México. Com base nas nuvens de pontos, os autores elaboraram modelos virtuais das florestas e realizaram uma planificação do terreno desses modelos mediante um processo de normalização das alturas. Posteriormente, obtiveram as árvores individuais através do isolamento dos troncos para estimar as alturas e os DAPs. Para a validação da metodologia, calcularam a diferença entre os dados reais e os aproximados, verificando um baixo erro de estimativa.

Nesse cenário, Pires et al. (2022) empregaram um dispositivo móvel de sensoriamento TLS, acoplado a um carro, visando realizar uma varredura de florestas boreais próximas a pistas no sul da Suécia. Após o mapeamento, os autores utilizaram a nuvem de pontos para a detecção individual das árvores e segmentação de seus troncos, a fim de extrair atributos como DAP, volume e perfil do tronco. Apesar dos erros de estimativa, os autores comprovaram que a abordagem é uma alternativa eficiente para o inventário das árvores. No entanto, observaram que, à medida que a distância dos espécimes em relação à pista aumenta, a acurácia da identificação das árvores e a qualidade da estimativa do volume diminuem, demonstrando a

⁵ Site do fabricante: <https://www.sensefly.com/>.

⁶ Esse software deixou de ser mantido pela desenvolvedora, sendo substituído pelo PIX4Dmapper, que disponível em: <https://www.pix4d.com/product/pix4dmapper-photogrammetry-software/>.

ineficiência do método diante de árvores distantes do dispositivo de captura.

Teng, Chen e Hsu (2005) propuseram um método de três etapas para a detecção de árvores em imagens coloridas. A primeira etapa consiste em uma segmentação preliminar das imagens por meio do algoritmo de Expectativa-Maximização (EM). Em seguida, na segunda fase, a estrutura do tronco é extraída das regiões obtidas na segmentação. Em síntese, mediante a análise de propriedades como cor, direção e largura, os elementos que não pertencem ao tronco são removidos. Por fim, a terceira etapa consiste em analisar os componentes oriundos da segmentação, assim como a estrutura do tronco, a fim de identificar as regiões de folhagem mediante fatores como proximidade do tronco e cor. Embora não tenham sido apresentadas métricas de desempenho, os autores relataram resultados promissores ao testar a técnica em imagens com uma ou duas árvores. Além disso, os autores sugerem que a estrutura do tronco, extraída por meio do algoritmo, pode ser utilizada para a obtenção de características da árvore.

Por outro lado, Wang, Huang e Fu (2009) propuseram uma abordagem para a detecção individual de árvores fundamentada nas variações de cores da imagem. Em síntese, o método é composto pelas seguintes etapas: (i) ajuste de brilho e contraste; (ii) eliminação de ruído; (iii) conversão do espaço de cores da imagem; (iv) segmentação com base nas cores; e, por fim, (v) correção morfológica. Os dois primeiros passos são correções realizadas nas imagens originais. Por sua vez, a terceira realiza a conversão da imagem para o espaço de cores $L^*a^*b^*$, o qual é mais próximo da percepção humana das cores. A quarta etapa compreende a segmentação das imagens por meio das diferenças de cores, levando em conta as cores presentes nas árvores de interesse. Por fim, a última etapa reforça a estrutura da árvore identificada. Em relação aos resultados, os autores apresentaram exemplos, demonstrando o bom desempenho do algoritmo, mas evidenciaram que objetos similares em cor podem ser erroneamente detectados. Entretanto, o trabalho não abordou o potencial do algoritmo para a extração de características das árvores.

O estudo conduzido por Jodas et al. (2022) utilizou uma base de dados contendo fotografias convencionais de árvores situadas em diversas regiões da cidade de São Paulo, juntamente com informações dendrométricas coletadas em campo. Dos dados disponíveis, os autores utilizaram 1.434 imagens em seus experimentos, empregando, para a detecção individual das árvores, a terceira versão da arquitetura de RNC denominada YOLO (*You Only Look Once*), que foi proposta por Redmon e Farhadi (2018). Em seguida, foi realizado um processo de refinamento das caixas delimitadoras, também conhecidas como *bounding boxes*, determinadas pelo modelo. Com base nessas caixas, os autores estimaram a altura das árvores nas imagens, utilizando a relação entre o tamanho de um bastão posicionado próximo às árvores e as dimensões das caixas delimitadoras. Para validar a metodologia, os autores selecionaram 336 árvores e compararam as alturas estimadas com as medidas manuais, identificando um erro considerável em nove árvores apenas. Essa pequena inconsistência motivou uma nova medição das alturas desses nove espécimes, resultando em valores mais próximos aos estimados. Dessa forma, concluiu-se que as incongruências observadas nos experimentos podem ser justificadas

pelos eventuais erros de medição cometidos na etapa de coleta de dados.

No que se refere aos aspectos positivos e negativos dos trabalhos expostos, a abordagem de Kwak et al. (2007) possibilita a análise de extensas regiões arborizadas, uma vez que propõe o uso do LiDAR em sobrevoos. No entanto, os autores ressaltam que a baixa densidade de pontos do dispositivo pode afetar a acurácia da detecção das árvores, assim como da estimativa da altura. Por sua vez, Birdal, Avdan e Türk (2017) propuseram uma abordagem de baixo custo que também permite a cobertura de áreas amplas por meio de sobrevoos. Entretanto, como essa abordagem falha na identificação de árvores em regiões de alta densidade, as medições realizadas pelos autores não foram distribuídas de forma homogênea na floresta de estudo, mas com preferência pelas árvores próximas a clareiras. No estudo de Cabo et al. (2018), a metodologia proposta elimina a necessidade de sobrevoos e garante a cobertura de extensas áreas com boa acurácia na detecção e na estimativa. Contudo, há uma incerteza quanto à visibilidade dos topos das árvores ao utilizar o TLS, o que pode resultar na subestimação da altura. Além disso, árvores cercadas por espécimes maiores podem ser superestimadas.

Quanto ao trabalho de Pires et al. (2022), o método proposto permite a medição de áreas extensas por meio do contorno com um veículo, como um carro, alcançando além do efeito de borda. Todavia, a qualidade das estimativas diminui à medida que as árvores se distanciam do dispositivo de captura. A abordagem de Teng, Chen e Hsu (2005) aparenta ser promissora e tem potencial para a extração de características, mas a obtenção não foi efetivamente realizada. Ademais, segundo os autores, árvores nas quais o tronco é coberto por galhos e folhagem foram excluídas, pois o método não consegue lidar com esses espécimes. Wang, Huang e Fu (2009) apresentaram um método simples baseado em cor, mas capaz de identificar apenas uma única árvore na imagem, com as demais podendo ser erroneamente identificadas como partes de uma mesma árvore. Além disso, os autores evidenciam que a aplicabilidade do método depende da complexidade da cena. Por fim, o método de Jodas et al. (2022) baseia-se em um modelo robusto para a criação de caixas delimitadoras das partes constituintes da árvore, apresentando bons resultados, mas com dificuldade em cenas complexas. Outrossim, a estimativa da altura depende do posicionamento de uma haste de tamanho fixo, uma vez que o tamanho do pixel das imagens utilizadas não é conhecido.


3.3 Desafios da Avaliação da Deterioração Interna

Embora a inspeção visual permita identificar sinais de deterioração interna, a avaliação de risco das árvores não se limita à análise de aspectos externos. Para avaliar o estado interno do tronco, é necessária uma investigação adicional (DOLWIN; BARNETT, 1999; MATTHECK, 1998). Nesse contexto, diversas técnicas tradicionais podem ser empregadas, desde as mais simples, como percutir áreas do tronco para identificar variações no som gerado, até as mais complexas, como a inserção de uma microcâmera no tronco para visualizar seu interior.

Entretanto, Li et al. (2022) ressaltam que esses métodos são imprecisos na identificação de regiões deterioradas e podem agredir a árvore, eventualmente agravando sua deterioração. Diante dessas limitações, destacam-se novas técnicas não destrutivas, como a tomografia de ondas de estresse, também conhecida como tomografia acústica (ESPINOSA et al., 2017). Essa abordagem tem sido utilizada para evidenciar as diferenças físicas entre as regiões deterioradas e as saudáveis por meio de variações na velocidade de propagação de ondas de estresse, uma vez que áreas deterioradas apresentam menor velocidade de propagação.

Para examinar internamente as condições de troncos de acácia-negra, Espinosa et al. (2017) empregam um tomógrafo sônico Arbotom® em duas configurações, uma com 12 e outra com 24 sensores. Em síntese, o operador do dispositivo aplica uma série de marteladas em cada um dos sensores para medir a velocidade de propagação do estresse em diferentes direções. Após registrar as velocidades, o software do Arbotom® gera uma imagem tomográfica invertida, evidenciando as regiões nas quais a propagação ocorreu normalmente em tons verdes, e as regiões nas quais as velocidades diminuíram em amarelo, laranja ou vermelho, sendo que o vermelho indica as regiões que resultaram em velocidades mais baixas, conforme ilustrado na Figura 5. Para automatizar a identificação das áreas deterioradas, Espinosa et al. (2017) recorreram a um modelo de regressão logística para rotular os pixels como zero, caso pertencessem a áreas saudáveis, ou como um, se pertencessem a regiões deterioradas. Contudo, um desafio da abordagem foi definir um limiar para a decisão entre as classes, já que o valor é influenciado pelo tamanho do defeito, sua localização no tronco e pela quantidade de sensores.

Figura 5 – Representação visual das velocidades de propagação das ondas de estresse, registradas por meio de um tomógrafo sônico Arbotom®.



Fonte: Extraída de Lin e Yang (2015).

Em sua análise do problema, Espinosa et al. (2017) apontaram que os aparelhos comerciais utilizados para realizar tomografias em árvores partem da suposição de que a madeira das árvores seja isotrópica, quando, na verdade, esse material é anisotrópico. Isso

resulta em variações da velocidade de propagação das ondas de estresse em diferentes regiões da superfície, mesmo quando o tronco está saudável. Segundo os autores, algumas pesquisas têm se empenhado em ajustar os resultados obtidos nos tomogramas, considerando a anisotropia da madeira. Nesse quadro, outras metodologias, citadas por Li et al. (2022), tais como a tomografia de impedância elétrica, que se fundamenta em discrepâncias nos níveis de condutividade elétrica, também assumem erroneamente a isotropia da madeira das árvores.

Brazolin (2009) empregou como método não destrutivo de inspeção interna um penetrômetro Digital Micro Probe® da Sibtec, para verificar a perda da resistência mecânica através da perfuração do tronco de árvores da espécie *Tipuana tipu* por uma broca de aço de 0,9 mm de diâmetro, como demonstrado na Figura 6. Após a penetração, um software gera um gráfico com os diferentes níveis de resistência, revelando as áreas do lenho com deterioração mais intensa, pois essas apresentam uma menor resistência. Embora seja uma alternativa viável, a técnica compartilha um obstáculo comum às mencionadas anteriormente: a escalabilidade, dado o tempo de operação exigido e o número de árvores em regiões urbanas.

Figura 6 – Uso do penetrômetro Digital Micro Probe® da Sibtec para avaliar a perda de resistência mecânica em um tronco de *Tipuana tipu*.



Fonte: Extraída de Brazolin (2009).

Ciente dessa adversidade, o estudo de Hrdina e Surový (2023) partiu da premissa de que as propriedades tridimensionais do tronco poderiam revelar mudanças morfológicas decorrentes de um apodrecimento interno. Utilizando um iPhone 12 Pro, aplicou-se a fotogrametria de curto alcance, denominada *Close-Range Photogrammetry* (CRP) em inglês, para a reconstrução tridimensional por meio de fotografias de diferentes perspectivas, e também realizou-se o escaneamento dos troncos com LiDAR. Então, foi empregado o modelo PointNet (CHARLES et al., 2017), que classifica objetos com base em nuvens de pontos, para distinguir árvores saudáveis das deterioradas. A validação dos resultados foi realizada com um tomógrafo acústico

ArborSonic 3D⁷, equipado com dez sensores. No entanto, a melhor acurácia alcançada foi de 65,5% para árvores coníferas, considerando um treinamento com 69 árvores saudáveis e 111 deterioradas, e uma avaliação com 35 árvores. Importante notar que a análise permitiu apenas a detecção da presença de deterioração, sem fornecer informações sobre a gravidade.

Diante do exposto, retoma-se a proposta deste projeto, que sugere a estimativa da deterioração interna do tronco com base nos aspectos externos da árvore. Essa proposição pode ser respaldada pela existência de estudos que já apresentaram propostas similares, realizando a estimativa de certos atributos da árvore com base em um conjunto de atributos mensurados em campo. Um exemplo é o trabalho de Ercanlı (2020), que modelou a previsão da altura da árvore como uma tarefa de regressão, empregando várias arquiteturas de RNAs profundas. Por meio de um teste de equivalência em amostras de teste, o autor concluiu que as redes previram, satisfatoriamente, a altura da árvore a partir do DAP e demais atributos dendrométricos.

Todavia, a predição de atributos internos com base em características externas ainda é uma área a ser explorada, embora a relação entre a deterioração interna e características externas tenha sido apontada há muito tempo. Lavallée e Lortie (1968) analisaram a ocorrência de fatores externos em 255 árvores da espécie bétula amarela e registraram a frequência com que esses aspectos estavam associados a um real apodrecimento, indicando que tais fatores têm relativa importância na determinação da presença de decaimento. Dentre os traços analisados, pode-se citar galhos quebrados, lesões mecânicas, cancrios no tronco, nós cegos, rachaduras de geadas e na base do tronco, e corpos de frutificação de fungos. Nesse cenário, as rachaduras basais destacam-se como o indicador mais relevante, visto que em 72,7% dos casos nos quais foram observadas rachaduras na base do tronco, havia uma deterioração associada.

⁷ Site do fabricante: <https://fakopp.com/en/product/arborsonic/>.

4 Material e Métodos

Este capítulo descreve a metodologia adotada na avaliação da deterioração interna do tronco de árvores urbanas. Inicialmente, a base de dados utilizada neste projeto é descrita na seção 4.1. Posteriormente, os modelos de aprendizado de máquina empregados na inferência são abordados na seção 4.2. Logo após, uma primeira tentativa de adaptar o OPF ao contexto de regressão é exposta na seção 4.3. Então, são apresentadas as métricas selecionadas para avaliar o desempenho dos modelos na seção 4.4. Em seguida, a abordagem proposta é discutida na seção 4.5. Finalmente, aspectos da configuração experimental são tratados na seção 4.6.

4.1 Base de Dados

Esta seção oferece uma visão geral do conjunto de dados considerado para este estudo. A subseção 4.1.1 aborda a origem e o protocolo seguido pela equipe de campo responsável pela coleta dos dados. Em seguida, a subseção 4.1.2 descreve o processo de preparação dos dados, que inclui a correção de inconsistências e a codificação de informações categóricas que ainda não foram discretizadas. Então, a subseção 4.1.3 evidencia o número de árvores e as espécies selecionadas para o estudo, além de descrever as características contínuas e categóricas da base de dados e apresentar a distribuição das variáveis-alvo. Por fim, a subseção 4.1.4 fornece uma visualização dos dados através do mapeamento dos atributos para um espaço bidimensional.

4.1.1 Origem e Coleta de Dados

Os dados empregados neste estudo foram concedidos pelo IPT e provêm de um sistema interno de gestão de árvores urbanas mantido pela prefeitura municipal de São Paulo, Brasil. Esse sistema, desenvolvido pelo IPT no âmbito do Projeto Árvore Saudável, registra dados coletados por equipes de campo para fins de monitoramento do risco de queda (IPT, 2004). Durante o projeto, o sistema foi alimentado com registros de 7.050 árvores situadas em vias urbanas do município de São Paulo, abrangendo bairros como Cerqueira César, Pacaembu, Sumaré, Alto de Pinheiros, Alto da Lapa, Vila Nova Conceição, Paraíso e Alto da Boa Vista, pertencentes à região do centro expandido. Essa região central foi selecionada devido à presença de árvores antigas e uma maior incidência de cupins subterrâneos (ROMAGNANO, 2004).

Para a coleta de dados, foram conduzidos trabalhos de campo, nos quais técnicos registraram a localização e a espécie das árvores. Em seguida, uma haste de referência de três metros foi posicionada verticalmente próxima às árvores, e registros fotográficos delas foram obtidos. Para complementar, foram medidas a distância do observador à árvore, juntamente com os ângulos zenitais da base e do topo da haste, os quais indicam a declividade do terreno.

Então, utilizando as fotografias e medidas obtidas, foram realizados cálculos trigonométricos para determinar características dendrométricas da árvore. Ademais, a equipe de campo conduziu uma inspeção externa para identificar sinais de estresse mecânico, avaliar as condições de plantio e verificar a presença de xilófagos, como cupins e fungos. Quando xilófagos foram encontrados, a equipe coletou amostras para posterior identificação em laboratórios.

Além da análise externa, a equipe realizou a prospecção interna por meio de um teste não destrutivo de resistência à microperfuração utilizando um penetrômetro Digital Micro Probe® da Sibtec. Este teste foi efetuado na região do colo, que representa a transição entre a raiz e o tronco, e, quando indicada a presença de oco aberto, definido como um espaço vazio aparente, na região do tronco. Em síntese, uma pequena broca com 0,9 mm de diâmetro perfura a madeira, registrando as variações de resistência em um gráfico. Essa análise possibilitou a quantificação da intensidade da deterioração causada por organismos xilófagos, uma vez que áreas deterioradas demonstram menor resistência mecânica, facilitando a perfuração.

Após as pesquisas de campo, as árvores inspecionadas foram categorizadas quanto ao respectivo risco de queda: baixo, médio ou alto, utilizando o modelo de cálculo estrutural desenvolvido pelo IPT. Conforme destacado por IPT (2004), trata-se de um modelo probabilístico sujeito a incertezas inerentes. Em suma, o modelo se baseia em princípios biomecânicos para avaliar e categorizar o potencial de queda das árvores, considerando três possíveis mecanismos de queda: arrancamento da raiz do solo, ruptura na região do colo e ruptura na região do tronco. Para tal avaliação, o modelo analisa múltiplos fatores, tais como as características dendrométricas das árvores; as informações sobre sua saúde biológica; as propriedades físicas da espécie da árvore, como a densidade da madeira; o tipo de solo em que estão inseridas; e os esforços solicitantes, os quais são esforços internos gerados pela resistência do tronco a forças externas, como as forças resultantes do peso da própria árvore e da influência do vento.

4.1.2 Preparação dos Dados

A preparação dos dados concedidos pelo IPT consistiu na eliminação de dados impróprios e na codificação de variáveis nominais. O arquivo de dados inicial continha 2.028 amostras, as quais foram combinadas com um conjunto de dados adicionais contendo 990 amostras, totalizando 3.018 amostras. A princípio, foram removidas as amostras duplicadas, as quais foram identificadas por meio do código da árvore ou pela análise de valores idênticos de suas variáveis contínuas. Posteriormente, também foi excluída uma amostra com valor incoerente de DAP (0,00). Como resultado, o número total de árvores na base foi reduzido para 2.878.

Além disso, foram excluídos atributos duplicados ou com informações equivalentes, como a largura e o diâmetro da copa, ou o ângulo de inclinação expresso em graus e em radianos, sendo a variável em graus mantida. O atributo “árvore morta” foi desconsiderado, uma vez que não apresentava variação nos valores, já que todas as árvores da base estavam vivas, não contribuindo com informações úteis para o treino dos modelos. Ademais, a variável-alvo


que media a razão entre o raio e a parede sadia ao nível do tronco foi excluída. Isso se deve ao fato de que os pesquisadores só coletaram essa informação durante os estudos de campo quando havia sinais visíveis de deterioração no tronco, resultando em uma variável enviesada.

Outrossim, o atributo “espécie da árvore”, que é nominal, precisava de tratamento. Optou-se por discretizá-lo, uma vez que os modelos de aprendizado de máquina requerem entradas numéricas. No entanto, ao invés de simplesmente atribuir um valor numérico a cada espécie, o que poderia introduzir uma ordem arbitrária (HANCOCK; KHOSHGOFTAAR, 2020), foi escolhida a codificação via *one-hot*, também conhecida como *one-hot encoding*. Nessa abordagem, uma variável binária é criada para cada possível espécie, de modo que a variável correspondente à espécie de uma amostra receba o valor “1” e as outras variáveis recebam “0”.

4.1.3 Estrutura e Características dos Dados

A base de dados final contém informações sobre um total de 2.878 árvores de sete espécies distintas, como evidenciado na Figura 7, que ilustra a distribuição das árvores por espécie, destacando a predominância de algumas em relação a outras no município. É importante ressaltar que as espécies selecionadas estão entre as mais frequentes nas regiões consideradas para a coleta de dados, além de estarem entre as mais suscetíveis à infestação por organismos xilófagos e à deterioração interna, como observado em estudos anteriores (IPT, 2004).

Figura 7 – Gráfico da distribuição de árvores por espécie.



Fonte: Elaborada pelo autor.

No total, o conjunto de dados inclui 39 atributos, dos quais sete são contínuos e 32 são

categóricos. Os atributos categóricos são representados por valores ordinais, exceto a espécie, que segue a codificação *one-hot*. Esta base está disponível no GitHub do autor, onde é possível encontrar a lista completa dos atributos⁸. Entre as variáveis contínuas, destacam-se medidas dendrométricas, tais como DAP, largura e altura da copa, altura do tronco e da árvore, ângulo de inclinação em graus e excentricidade. A excentricidade é uma medida que está relacionada ao ângulo de inclinação da árvore e pode ser calculada pela seguinte equação:

$$e = h \cdot \operatorname{tg}(\theta), \quad (1)$$


onde h é a altura da árvore e $\operatorname{tg}(\theta)$ é a tangente do ângulo de inclinação θ . Ademais, as variáveis contínuas estão descritas estatisticamente na Tabela 1 e ilustradas nas Figuras 8 e 9.

Tabela 1 – Medidas descritivas das variáveis contínuas.

Variável	Média	Desvio Padrão	Mínimo	Mediana	Máximo
DAP (m)	0,4591	0,1782	0,1080	0,4390	1,1460
Largura da Copa (m)	8,0317	2,7380	0,7580	7,8695	19,1830
Altura da Copa (m)	8,0443	2,9195	1,3020	7,8700	18,2010
Altura do Tronco (m)	2,9354	1,1134	0,0350	2,8430	11,0020
Altura da Árvore (m)	10,9796	3,0832	4,0410	10,7640	22,0230
Ângulo (°)	8,4247	6,3932	0,0740	6,8250	65,6940
Excentricidade (m)	1,6680	1,5057	0,0129	1,2381	29,7735

Fonte: Elaborada pelo autor.

Figura 8 – Representação dos aspectos físicos de uma árvore.




Fonte: Elaborada pelo autor.⁹

⁸ Repositório da base de dados: <https://github.com/giovcandido/urban-tree-decay-dataset>.

⁹ A ilustração da árvore foi disponibilizada por brgfx no Freepik e pode ser acessada pelo link: https://br.freepik.com/vetores-gratis/arvore-isolada-no-fundo-branco_4382376.htm.

Figura 9 – Representação do ângulo de inclinação de uma árvore.



Fonte: Adaptada de Boschetti et al. (2015).

Por outro lado, entre as variáveis categóricas da base de dados, encontram-se atributos como o formato da copa, que está indicado na Figura 8 e pode ser classificado em:

- **Esférico:** a diferença entre a altura e a largura da copa é menor ou igual a dois metros;
- **Elíptico 1:** a largura da copa excede dois metros em relação à altura da copa;
- **Elíptico 2:** a altura da copa excede dois metros em relação à largura da copa.

Além disso, outras variáveis categóricas incluídas na base de dados são: a codificação da espécie da árvore; a densidade da madeira, conforme apresentado na Tabela 2; a presença de injúria mecânica na raiz, colo, tronco e copa; o nível de ataque de fungos e cupins subterrâneos, de madeira seca e de solo; a presença de corpos de frutificação; e a presença de protuberâncias ou rachaduras. No que diz respeito à seleção dos atributos para o treinamento dos modelos de aprendizado de máquina, o critério utilizado para a escolha é abordado na subseção 4.6.2.

Tabela 2 – Densidade da madeira de cada espécie de árvore.

Espécies	Densidade (g/m^3)
<i>Caesalpinia ferrea</i> var. <i>leiostachya</i>	1,12
<i>Caesalpinia peltophoroides</i>	0,91
<i>Holocalyx balansae</i>	0,92
<i>Jacaranda mimosaefolia</i>	0,52
<i>Ligustrum lucidum</i>	0,63
<i>Tibouchina granulosa</i>	0,63
<i>Tipuana tipu</i>	0,63


Fonte: Elaborada pelo autor.

O conjunto de dados também inclui variáveis-alvo contínuas relacionadas à deterioração interna no nível do colo, que é a região de transição entre a raiz e o tronco. A partir da prospecção interna da árvore com o penetrômetro, conforme detalhado na subseção 4.1.1, foi possível analisar a perda de resistência mecânica e quantificar tanto a espessura da porção deteriorada do lenho quanto a espessura da parede sadia residual. Com essas medidas, foram definidos dois atributos-alvo: a razão entre o raio do lenho e a parede sadia remanescente, e a porcentagem da área com deterioração considerando a seção transversal do lenho. O primeiro atributo, definido por uma razão, pode ser calculado através da seguinte expressão:

$$r = \frac{R}{t} \quad (2)$$


onde R é o raio do lenho e t é a espessura da parede sadia remanescente, medidas ilustradas na Figura 10. Com base nessa representação visual, também se torna compreensível o cálculo da porcentagem da área com deterioração, pois trata-se da razão entre a área deteriorada e a área total da seção transversal do lenho. Essas áreas são calculadas, respectivamente, a partir da espessura da parede deteriorada e do raio do lenho. Desse modo, é possível afirmar que as duas variáveis de deterioração interna presentes na base quantificam informações equivalentes. Ademais, a Figura 11 retrata a distribuição das árvores em relação à deterioração, evidenciando a predominância de espécimes com baixas porcentagens de área deteriorada.

Figura 10 – Representação visual da razão raio/parede sadia.



Fonte: Elaborada pelo autor.

Figura 11 – Gráfico da distribuição de árvores por porcentagem de área deteriorada.




Fonte: Elaborada pelo autor.

A fim de modelar o problema como uma classificação, foi necessário criar uma variável categórica para representar níveis de deterioração. Nesse sentido, a Figura 12 ilustra a distribuição das árvores em relação aos níveis de deterioração definidos, revelando um desbalanceamento considerável. Por sua vez, a Figura 13, que apresenta a distribuição organizada por espécie, destaca a contribuição das espécies majoritárias, *Caesalpinia peltophoroides* e *Tipuana tipu*, para os níveis de deterioração. Ademais, para simplificar a classificação, foi proposta uma divisão binária na qual os níveis “médio” e “alto” foram combinados em uma única classe, denominada “significativo”, e o nível “baixo” foi renomeado para “mínimo”, conforme ilustrado na Figura 14, que apresenta a distribuição dos dados segundo essa divisão. É importante destacar que a decisão de unir os níveis de deterioração “médio” e “alto” para compor o


nível “significativo”, em vez de unir os níveis “baixo” e “médio”, foi fundamentada em testes empíricos que demonstraram que a junção escolhida resultava em melhores resultados. Isso pode ter ocorrido porque a combinação dos dois níveis minoritários cria uma classe com um número maior de amostras, proporcionando uma melhor representatividade. Por outro lado, a junção dos níveis “baixo” e “médio” apenas acentua a predominância do nível majoritário.

Figura 12 – Gráfico da distribuição de árvores por nível de deterioração.




Fonte: Elaborada pelo autor.

Figura 13 – Gráfico da distribuição de árvores por nível de deterioração agrupado por espécie.



Fonte: Elaborada pelo autor.

Figura 14 – Gráfico da distribuição de árvores por nível binário de deterioração.




Fonte: Elaborada pelo autor.

É importante ressaltar que, para a definição dos níveis de deterioração, adotou-se a divisão proposta por Brazolin (2009), que se baseia na porcentagem de área deteriorada na seção transversal da árvore: baixo (até 11% de área afetada), médio (11% a 44% de área afetada) e alto (acima de 44% de área afetada). Essa classificação fundamenta-se na conhecida “regra do 1/3”, derivada dos resultados experimentais do estudo de Mattheck, Bethge e Erb (1993). Nesse estudo, os autores analisaram 400 árvores de diferentes espécies, demonstrando graficamente que árvores ocas devido à deterioração interna estão mais propensas a falhas por achatamento transversal quando a razão entre a parede sadia remanescente (t) e o raio do lenho (R) é menor que $1/3$, equivalendo a uma área deteriorada superior a 44%.


Há ainda uma variável-alvo categórica que expressa o risco de queda associado a cada árvore, conforme determinado pelo modelo de cálculo estrutural proposto por IPT (2004), descrito previamente na subseção 4.1.1. Essa variável classifica as amostras em três classes de risco: baixo, médio e alto. A distribuição das árvores em relação ao risco de queda é ilustrada na Figura 15, que revela um desbalanceamento significativo entre as classes. Outrossim, a Figura 16, que apresenta a distribuição agrupada por espécie, evidencia a contribuição das espécies majoritárias para as três classes de risco, como observado para os níveis de deterioração.

Figura 15 – Gráfico da distribuição de árvores por risco de queda.



Fonte: Elaborada pelo autor.

Figura 16 – Gráfico da distribuição de árvores por risco de queda agrupado por espécie.



Fonte: Elaborada pelo autor.


4.1.4 Visualização dos Dados

Para compreender a disposição do espaço de atributos e identificar padrões presentes nos dados, empregou-se uma técnica de redução de dimensionalidade denominada Incorporação Estocástica de Vizinhança Distribuída em t , mais conhecido como *t-Distributed Stochastic Neighbor Embedding* (t-SNE) em inglês. Essa técnica de visualização projeta os dados em

um espaço de baixa dimensão, mantendo o agrupamento global presente no espaço original de alta dimensão, bem como a estrutura local das amostras (MAATEN; HINTON, 2008). Para realizar a projeção, o algoritmo visa corresponder a similaridade entre pares de pontos no espaço original com a similaridade no espaço de menor dimensão, onde a similaridade entre um par de pontos é definida por uma distribuição de probabilidades condicional, sendo alta quando os pontos são próximos e relativamente baixa quando estão mais distantes. Além disso, a quantidade efetiva de vizinhos considerados para o cálculo dos pares de similaridade de uma amostra de dados é controlada por um hiperparâmetro denominado perplexidade.

A Figura 17 ilustra o espaço bidimensional gerado pelo *t*-SNE com uma perplexidade de $p = 5$ vizinhos, ajustada empiricamente. Os testes que resultaram na escolha basearam-se na observação de que, segundo Maaten e Hinton (2008), os valores típicos de perplexidade variam entre 5 e 50. Ao examinar essa representação, torna-se evidente que os dados não formam agrupamentos bem definidos, não havendo uma separação clara entre as classes, uma vez que amostras com diferentes níveis de deterioração compartilham frequentemente a mesma região do espaço, resultando em sobreposições. Portanto, a disposição dos dados sugere que o problema pode representar um desafio para os modelos de aprendizado de máquina, uma vez que estes aprendem a realizar estimativas a partir da identificação de padrões nos dados.

Figura 17 – Representação dos dados via *t*-SNE.



Fonte: Elaborada pelo autor.

4.2 Modelos de Aprendizado de Máquina

Como discutido no Capítulo 3, diversos modelos de aprendizado têm sido empregados na gestão de florestas urbanas para tarefas como a previsão do risco de queda. Os modelos utilizados neste projeto para estimar a deterioração interna do tronco de árvores em ambientes urbanos, nos contextos de regressão e classificação, estão descritos nas subseções abaixo.

4.2.1 Floresta de Caminhos Ótimos

O OPF é um *framework* que viabiliza a criação de classificadores baseados em grafo, permitindo a modificação da lógica de 1) relação de adjacência, 2) seleção de protótipos e 3) função de custo. De acordo com Papa, Falcão e Suzuki (2009), as amostras de treinamento formam um grafo com conexões estabelecidas por uma relação de adjacência, podendo ser um grafo completo, onde todos os nós estão conectados entre si. O algoritmo, então, identifica as amostras de classes diferentes que estão mais próximas, utilizando-as como protótipos.

Essa seleção dos protótipos pode ocorrer mediante a construção de uma árvore geradora mínima, também conhecida como *Minimum Spanning Tree* (MST). A MST permite a identificação de arestas entre amostras de classes distintas e, através dessas arestas, a marcação dos protótipos. Em seguida, utilizando um algoritmo guloso semelhante ao algoritmo de Dijkstra, o grafo inicial é particionado para formar árvores de caminho ótimo enraizadas pelos protótipos. Esse processo de conquista é orientado por uma função de custo, como a F_{max} , que considera o máximo entre o custo do nó e a distância até o nó de interesse.

Após a construção da floresta, a classificação de uma amostra de teste ocorre ao testar sua inclusão em cada uma das árvores. Assim, a amostra é incorporada à árvore que apresenta o menor custo, adotando, portanto, a classe do protótipo como uma estimativa para a amostra. Como se pode notar, o *framework* não lida com problemas de regressão. Portanto, para utilizá-lo na previsão da porcentagem de área deteriorada, foi realizada uma primeira tentativa de adaptar o OPF para o contexto de regressão, conforme será discutido na seção 4.3.

4.2.2 k -Vizinhos Mais Próximos

O modelo k -vizinhos mais próximos, ou *k-Nearest Neighbors* (k -NN), é um algoritmo de aprendizado não paramétrico que se baseia na premissa de que amostras próximas tendem a ter saídas semelhantes (SONG et al., 2017). Para estimar a saída de uma amostra de teste, o algoritmo calcula a distância entre a amostra e as observações de treinamento. Em seguida, seleciona as k amostras mais próximas e determina a classe mais frequente entre esses vizinhos, no caso de classificação, ou a média aritmética de suas saídas, no caso de regressão. Enfim, o resultado é considerado uma estimativa da saída esperada para aquela amostra de teste.

4.2.3 Máquina de Vetores de Suporte

Quando aplicada a tarefas de classificação, a SVM determina um hiperplano de separação que maximize a margem entre diferentes classes de dados. Por outro lado, em problemas de regressão, a SVM visa encontrar um hiperplano que descreva as amostras de treinamento com a menor margem de erro possível (SMOLA; SCHÖLKOPF, 2004). Para modelar dados não lineares por meio de hiperplanos, Smola e Schölkopf (2004) evidenciam a necessidade de uma fase de pré-processamento das amostras. Em síntese, utilizam-se *kernels* de transformação, como os polinomiais ou de função de base radial (FBR), para modelar as relações não lineares das amostras por meio de um mapeamento para espaços de alta dimensão.

4.2.4 Árvore de Decisão

A árvore de decisão, denominada *Decision Tree* (DT) em inglês, é uma técnica que emprega uma estrutura similar à de um fluxograma, iniciando com um único nó e se ramificando segundo as condições estabelecidas (COSTA; PEDREIRA, 2023). Os nós internos, conhecidos como *split* em inglês, contêm testes lógicos. Para valores contínuos, esses testes verificam se o valor não ultrapassa um limiar, enquanto para valores nominais, verifica-se se os valores são iguais a uma das possíveis opções. Como as verificações são binárias, um *split* possui duas ramificações. Tais bifurcações podem, por sua vez, conter outros testes lógicos, particionando a árvore novamente, ou nós folhas, que apresentam as estimativas do modelo.

Dessa forma, o treinamento das DT pode ser compreendido como um processo de particionamento do espaço de características. Ao passar uma amostra de teste pela estrutura da árvore, determina-se a partição do espaço a qual essa amostra pertence. A predição é então realizada adotando como valor do nó folha a classe mais frequente entre as amostras da partição, no caso de classificação, ou a média aritmética das amostras, no caso de regressão.

4.2.5 Floresta Aleatória

O modelo de floresta aleatória, conhecido como *Random Forest* (RF) em inglês, fundamenta-se na combinação de árvores de decisão (LI et al., 2018), formando um *ensemble*, conceito abordado na subseção 4.6.4. Cada árvore de decisão, conforme explicado por Li et al. (2018), é construída com base em um subconjunto aleatório de amostras de treinamento e um subconjunto aleatório de atributos. Durante a etapa de previsões, cada árvore da floresta produz uma estimativa individual. Em seguida, o resultado é determinado pela classe mais frequente no caso de classificação ou pela média aritmética das saídas no caso de regressão.

4.2.6 Boosting

Os métodos de *boosting* envolvem o treinamento sequencial de aprendizes fracos, conhecidos como *weak learners* em inglês, para produzir um aprendiz forte, denominado *strong*

learner em inglês. Esse processo naturalmente resulta na formação de um *ensemble*. Durante o treinamento, cada aprendiz fraco, geralmente uma árvore de decisão, aprende com os erros de seu antecessor, atribuindo maior peso às amostras incorretamente previstas, ou aprendendo os residuais no caso de regressão. Entre os algoritmos de *boosting*, destacam-se o *Adaptive Boosting* (AdaBoost) e o *Gradient Boosting*, também referido por *Gradient Boosting Machine* (GBM). Essas abordagens, em conjunto com variantes da GBM, são abordadas a seguir, conforme explanado por González et al. (2020) e Mienye e Sun (2022).

4.2.6.1 AdaBoost

O AdaBoost é um algoritmo que, a cada iteração, ajusta os pesos das amostras de treinamento para o aprendiz atual com base nas previsões realizadas pelo aprendiz da etapa antecedente. Nesse processo, os pesos atribuídos são maiores para as amostras classificadas incorretamente, ou proporcionais ao residual em problemas de regressão. Isso assegura que o aprendiz subsequente dedique mais atenção às amostras com maior peso, visando corrigir as classificações inadequadas ou reduzir os resíduos em casos de problemas de regressão.

4.2.6.2 Gradient Boosting

Diferentemente do AdaBoost, que atribui pesos às amostras de treinamento, a GBM emprega, a cada iteração, um aprendiz fraco que aprende o pseudo-residual calculado com base na função de perda, também denominada *loss function* em inglês. Em suma, a partir de uma estimativa inicial, os pseudo-resíduos são calculados e, em seguida, um aprendiz fraco é treinado com base nesses residuais. Novos pseudo-resíduos são então calculados, e esse processo é repetido iterativamente. Assim, a cada nova iteração, um aprendiz tenta reduzir o erro global, diminuindo os resíduos da etapa anterior. Esse processo pode ser compreendido como uma minimização por meio do método do gradiente. Devido à sua eficácia, a GBM serviu de base para a criação de outros algoritmos de *boosting*, tais como *Extreme Gradient Boosting* (XGBoost), *Light Gradient Boosting Machine* (LightGBM) e *Category Boosting* (CatBoost).

4.2.6.3 XGBoost

Para mitigar o risco de sobreajuste, também conhecido como *overfitting* em inglês, que ocorre quando o modelo descreve de maneira muito precisa o conjunto de treinamento, mas é incapaz de generalizar adequadamente, o XGBoost introduz um termo de regularização na função de perda da GBM. Além disso, o modelo consegue lidar com valores ausentes e pode ser utilizado para calcular a importância das características, o que é útil para a seleção de atributos. Adicionalmente, o XGBoost viabiliza o paralelismo e o processamento de dados em memória externa, melhorando sua eficiência e possibilitando sua aplicação em bases extensas.

4.2.6.4 *LightGBM*

Desenvolvido por pesquisadores da Microsoft, a LightGBM apresenta duas principais novidades em relação à GBM convencional: a técnica de amostragem *Gradient-based One-Side Sampling* (GOSS) e a técnica de seleção de atributos denominada *Exclusive Feature Bundling* (EFB). O GOSS exclui estrategicamente amostras de treinamento que possuem gradientes pequenos, empregando as amostras restantes para calcular ganho de informação, uma métrica que orienta a construção das árvores de decisão. Esse método acelera e simplifica o processo de aprendizado. Em contrapartida, o EFB realiza a seleção de características ao agrupar atributos esparsos e mutuamente exclusivos, reduzindo a dimensionalidade do espaço de características.

4.2.6.5 *CatBoost*

Por sua vez, o CatBoost, criado por pesquisadores da Yandex, apresenta duas novidades significativas em relação à GBM. Em primeiro lugar, o modelo realiza uma estimativa não enviesada do gradiente da função de perda ao excluir um exemplo de treinamento do aprendiz em cada iteração do algoritmo de *boosting*, visando mitigar o *overfitting*. Em segundo lugar, o CatBoost utiliza uma versão melhorada da técnica *Greedy Target-based Statistics* (GreedyTS), que converte os atributos categóricos da base de dados em variáveis numéricas, substituindo os valores categóricos pela média da variável-alvo das amostras correspondentes.

4.2.7 *Perceptron Multicamadas*

As RNAs são modelos inspirados na rede neural humana e em sua habilidade para resolver problemas de reconhecimento de padrões. Segundo Singh e Banerjee (2019), o perceptron multicamadas, também conhecido como *Multilayer Perceptron* (MLP) em inglês, é um dos tipos de redes neurais mais amplamente empregados. Em síntese, sua arquitetura é composta por uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída. Nesse contexto, a ideia central é propagar a entrada através da estrutura da rede, permitindo que cada camada oculta processe a saída da camada anterior, contribuindo assim para a saída final. No caso de classificação, a rede aprende a definir um hiperplano para separar os dados, enquanto na regressão, busca-se encontrar um hiperplano que melhor se ajuste aos dados.


4.3 Versão Inicial do OPF para Regressão

Como o *framework* não foi originalmente concebido para lidar com problemas de regressão, este projeto propõe uma adaptação baseada na versão do OPF para clusterização. Assim como outros modelos não supervisionados, essa variação do OPF, criada por Rocha, Cappabianco e Falcão (2009), baseia-se na função de densidade de probabilidade, ou *Probability Density Function* (PDF) em inglês, estimada a partir das amostras de treinamento, para identificar possíveis agrupamentos, ou seja, regiões populadas por amostras com altos valores

de densidades. Os máximos desses potenciais agrupamentos são selecionados como protótipos, os quais representam as árvores que comporão a floresta, sendo rotulados com números inteiros consecutivos. A partir dos protótipos, as amostras são atribuídas às árvores, de modo que uma amostra seja associada a uma árvore se estiver mais fortemente conectada ao seu protótipo do que aos máximos das demais árvores, ou seja, se estiver na zona de influência definida por este máximo específico. Portanto, para incorporar uma nova amostra, a função de conectividade verifica o mínimo entre a PDF dessa amostra e o menor valor de PDF ao longo do caminho já estabelecido pela árvore, incluindo a amostra se este valor de conectividade for o mais alto entre os valores obtidos ao considerar a inclusão da amostra em outras árvores.

Em síntese, o algoritmo criado neste projeto realiza o agrupamento dos dados de treino, resultando na formação de *clusters* que constituem uma floresta de árvores de caminho ótimo. Durante a fase de estimativa, determina-se a árvore à qual a amostra de teste pertenceria, com base no protótipo ao qual essa amostra está mais fortemente conectada, conforme ilustrado na Figura 18. Nessa representação, destacam-se três árvores, em vermelho, verde e azul, com seus protótipos indicados por tons mais escuros. Após o cálculo da função de conectividade para cada árvore, conclui-se que a amostra de teste, em cinza, seria atribuída ao *cluster* verde.

Figura 18 – Estimativa do *cluster* de uma amostra de teste com o OPF não supervisionado.



Fonte: Elaborada pelo autor.

Após determinar o grupo adequado para a amostra de teste, cada amostra do grupo contribui para a estimativa do valor alvo. Inicialmente, são calculados pesos com base nas

distâncias euclidianas entre as amostras da árvore e a de teste, conforme a seguinte equação:

$$w_i = \frac{1}{d_i + \varepsilon}, \quad (3)$$

onde w_i indica o peso da amostra i , d_i a distância euclidiana da amostra i à amostra de teste, normalizada pelo máximo das distâncias, e ε representa o valor 10^{-6} somado para evitar a divisão por zero. Em seguida, o valor de saída da amostra de teste é estimado pela média ponderada das saídas das amostras contidas na árvore, conforme a equação:

$$\hat{y} = \frac{\sum_{i=1}^{N_a} (y_i \cdot w_i)}{\sum_{i=1}^{N_a} w_i}, \quad (4)$$

onde $\hat{y}$ indica a estimativa da saída da amostra de teste, N_a denota o número de amostras na árvore, y_i a saída da amostra i e w_i o peso da amostra i . Vale ressaltar que a finalidade da ponderação é priorizar as contribuições das amostras mais próximas à amostra de teste.

4.4 Métricas de Avaliação

Para quantificar o desempenho dos modelos, foram selecionadas três métricas específicas para cada tipo de tarefa. A subseção 4.4.1 aborda as medidas empregadas na regressão, ao passo que a subseção 4.4.2 discute as métricas consideradas para as tarefas de classificação.

4.4.1 Métricas para Regressão

Na avaliação das previsões obtidas por meio de regressão, foram utilizadas as seguintes medidas: erro médio absoluto, ou *Mean Absolute Error* (MAE) em inglês; erro médio quadrático, ou *Mean Squared Error* (MSE) em inglês; e coeficiente de determinação. Em síntese, essas métricas fundamentam-se no cálculo dos erros de predição, os quais são definidos como a diferença (e_i) entre o valor real (y_i) e o valor previsto ($\hat{y}_i$) pelo modelo, conforme a Equação 5.

$$e_i = |y_i - \hat{y}_i| \quad (5)$$

4.4.1.1 Erro Médio Absoluto

O MAE mede a diferença média entre os valores observados e as previsões do modelo, acumulando o erro de estimativa de todas as amostras. O cálculo é apresentado pela Equação 6, na qual n indica o número de amostras analisadas. Essa medida assume valores iguais ou maiores que zero, sendo que valores próximos a zero indicam um baixo erro de estimativa.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

4.4.1.2 Erro Médio Quadrático

Por outro lado, o MSE calcula a média dos quadrados da diferença entre os valores reais e os estimados, conforme a Equação 7. James et al. (2021) evidencia que o MSE atribui pesos proporcionais aos erros de predição. Com isso, erros graves são fortemente penalizados, fazendo com que o algoritmo de aprendizado se concentre nas amostras mais desafiadoras. Assim como o MAE, essa medida também assume valores iguais ou maiores que zero.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

4.4.1.3 Coeficiente de Determinação

Segundo James et al. (2021), o coeficiente de determinação, ou R^2 (R -quadrado), varia de zero a um e indica o quanto da variabilidade dos dados é explicada pelo modelo. Em suma, quanto maior o valor, maior a correlação entre os valores reais e os previstos, com $R^2 = 1$ sugerindo um regressor perfeito. Essa medida é definida pela soma dos quadrados dos resíduos, conhecida como *Residual Sum of Squares* (RSS) em inglês, e pela soma total dos quadrados, denominada *Total Sum of Squares* (TSS) em inglês, conforme a Equação 8.

$$R^2 = 1 - \frac{RSS}{TSS} \quad (8)$$

O RSS calcula o quadrado da diferença entre os valores reais e as estimativas, como pode ser observado na Equação 9. Em contrapartida, o cálculo do TSS é baseado na média dos valores reais das n amostras de teste, obtida por meio da Equação 10. Em síntese, o TSS computa o quadrado da diferença entre cada valor e a média, conforme a Equação 11.

$$RSS = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$


$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (10)$$

$$TSS = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (11)$$

Em síntese, um modelo que consegue capturar adequadamente o comportamento dos dados é capaz de descrever sua variabilidade de forma satisfatória, como pode ser observado na Figura 19, que ilustra os resíduos - diferença entre as estimativas e os valores reais - obtidos pelo modelo em cada estimativa. Nesse exemplo, os resíduos tendem a estar mais próximos de zero, refletindo um coeficiente de determinação (R^2) de 0,97. No entanto, um modelo que não descreve bem a variabilidade dos dados apresenta um gráfico de resíduos por estimativa mais


próximo ao da Figura 20, com um R^2 de 0,45. Como evidenciado, o R^2 tende a ser menor quando os resíduos estão mais distantes de zero, indicando previsões menos confiáveis.

Figura 19 – Gráfico de resíduo por valor ajustado de um modelo com $R^2 = 0,97$.



Fonte: Elaborada pelo autor.

Figura 20 – Gráfico de resíduo por valor ajustado de um modelo com $R^2 = 0,45$.



Fonte: Elaborada pelo autor.

Entretanto, um R^2 baixo não necessariamente indica que o modelo seja inaceitável. Em certos cenários, uma margem de erro relativamente maior pode ser tolerada. Além disso, é

possível aprimorar a capacidade do modelo de explicar a variabilidade dos dados posteriormente, mediante a inclusão de outros fatores ainda não considerados. Para mais, em todos os campos de estudo, existe uma quantidade inerente de variabilidade inexplicável. Por exemplo, nas ciências sociais, onde se tenta prever o comportamento humano, o qual é intrinsecamente complexo, é comum que estudos apresentem valores de R^2 inferiores a 0,5 (FROST, c2024).

4.4.2 Métricas para Classificação

Em contrapartida, a performance dos modelos em tarefas de classificação foi avaliada mediante as métricas: acurácia; revocação, ou *recall* em inglês; e acurácia balanceada. Em linhas gerais, tais medidas apresentam modos distintos de quantificar os acertos dos classificadores.

4.4.2.1 Acurácia

A acurácia mensura a proporção de amostras corretamente classificadas em relação ao total de amostras, como demonstrado na Equação 12. Essa métrica assume valores entre zero, indicando a ausência de acertos, e um, indicando que todas as previsões foram corretas. Contudo, sua interpretação pode ser enganosa quando há desbalanceamento dos dados, pois o modelo aprende mais sobre a classe majoritária do que sobre as demais (HOSSIN; M.N, 2015).

$$\text{Acurácia} = \frac{\text{Número de Previsões Corretas}}{\text{Número Total de Previsões}} \quad (12)$$

4.4.2.2 Revocação

A revocação, por sua vez, representa a proporção de amostras de uma classe que foram corretamente classificadas em relação ao total de amostras dessa mesma classe. Nesse sentido, essa métrica possibilita uma análise por classe do desempenho dos modelos. Por se tratar de uma acurácia individual, essa medida também assume valores entre zero e um. Considerando uma classe arbitrária c , a revocação pode ser calculada com base na seguinte expressão:

$$R_c = \frac{VP_c}{VP_c + FN_c}, \quad (13)$$

onde VP_c denota o número de Verdadeiros Positivos (VP) da classe c , indicando as amostras da classe que foram corretamente classificadas, e FN_c representa o número de Falsos Negativos (FN) da classe c , indicando as amostras da classe que foram erroneamente classificadas.

4.4.2.3 Acurácia Balanceada

Por fim, a acurácia balanceada pode ser calculada através da média aritmética da revocação de todas as classes, conforme a seguinte equação:

$$\text{Acurácia Bal.} = \frac{1}{N_c} \sum_{i=1}^{N_c} R_i, \quad (14)$$

onde N_c denota o número total de classes e R_i , a revocação da classe i . Ao considerar a média das acurácias por classe, proporciona uma avaliação mais imparcial do desempenho dos modelos, revelando-se especialmente informativa em bases de dados desbalanceadas (BRODERSEN et al., 2010). Ademais, a acurácia balanceada também assume valores entre zero e um.

4.5 Abordagem Proposta


Conforme evidenciado por Roman et al. (2021), a falta de monitoramento adequado das árvores urbanas pode resultar em transtornos. Nesse contexto, a análise de risco de queda de árvores urbanas tornou-se uma prática comum em programas de gestão de arborização urbana de muitos municípios, visando proteger os residentes, seus bens privados e a infraestrutura urbana. No entanto, o monitoramento das árvores requer a coleta de dados por meio de pesquisas de campo, o que pode demandar tempo e recursos financeiros. Para otimizar esse processo, trabalhos recentes, como o de Jodas et al. (2022), têm explorado o uso de técnicas de CV para a obtenção de atributos externos das árvores. Além disso, estudos como o de Jahani e Saffariha (2022) sugerem a utilização de algoritmos de aprendizado de máquina para facilitar a previsão do risco de queda das árvores. Sendo assim, este projeto visa preencher uma lacuna importante no desenvolvimento de um sistema automatizado de monitoramento das árvores urbanas, apresentando um método eficiente para a estimativa das condições internas do tronco, que complementa a análise visual externa e pode, possivelmente, dispensar testes não destrutivos quando há congruência entre a decisão do arborista e do modelo.

O presente trabalho propõe a inferência da deterioração interna das árvores urbanas por meio de diversos algoritmos de aprendizado de máquina, os quais são treinados utilizando variáveis contínuas e categóricas da base de dados. Essa inferência é modelada de duas formas distintas: como uma tarefa de regressão, que visa estimar o percentual de área deteriorada, e como uma tarefa de classificação multiclasse, que visa determinar o nível de deterioração. As duas modelagens são utilizadas para estipular a deterioração interna do lenho considerando todas as espécies presentes na base de dados, assim como considerando isoladamente as espécies majoritárias *Caesalpinia peltophoroides* e *Tipuana tipu*, e a junção das demais espécies, dado o baixo número de amostras. É importante destacar que a inferência por espécie permite avaliar os modelos de forma individual e, por conseguinte, analisar se é mais vantajoso utilizar modelos gerais, que abrangem todas as espécies, ou modelos específicos. Ademais, realiza-se uma tarefa de classificação binária para simplificar a estimativa dos níveis de deterioração.

Independentemente da modelagem, o método proposto neste projeto pode ser dividido em três etapas distintas, conforme ilustrado pelo pipeline na Figura 21. Na primeira fase, os modelos são ajustados para a estimativa da deterioração interna do tronco. Na segunda

fase, esses mesmos modelos são aplicados na avaliação do risco associado às amostras, sendo treinados a partir dos valores reais de deterioração, bem como dos demais atributos da base. Por fim, a terceira etapa visa validar as estimativas de deterioração, verificando o impacto na previsão do risco de queda. Para isso, os modelos treinados na segunda fase são usados para avaliar o risco de queda considerando as estimativas de deterioração obtidas na primeira fase.

Figura 21 – Pipeline da abordagem proposta.




Fonte: Elaborada pelo autor.

4.6 Protocolo Experimental

Esta seção descreve a configuração utilizada para a realização dos experimentos. Nesse contexto, é importante ressaltar que os experimentos foram conduzidos em um computador pessoal com o sistema operacional Ubuntu 23.10, baseado no núcleo Linux, considerando 25 execuções independentes. Esse equipamento possui um processador Intel i5-6200U de 2,30 gigahertz (GHz), uma memória principal de 8 gigabytes (GB) e um disco rígido de 1 terabyte (TB). Ademais, os códigos foram elaborados em Python 3.11.5, utilizando a biblioteca scikit-learn 1.2.2, que agrega modelos de aprendizado de máquina e métodos auxiliares.

No que diz respeito à estrutura dos experimentos, com exceção da terceira fase da abordagem proposta, cujo propósito é validar a estimativa do risco de queda por meio de modelos já treinados e dos valores de deterioração interna previamente estimados, as fases anteriores do método podem ser organizadas segundo o fluxograma apresentado na Figura 22. As subseções seguintes fornecem detalhes sobre cada elemento dessa estrutura.

Figura 22 – Fluxograma com a estrutura dos experimentos.



Fonte: Elaborada pelo autor.

4.6.1 Divisão dos Dados

A base de dados foi dividida em três subconjuntos, seguindo o esquema 80/10/10, que aloca 80% dos dados para o treinamento, 10% para a validação e os 10% restantes para o teste, conforme indicado pelo esquema presente na Figura 23. Nesse cenário, o conjunto de validação é utilizado para avaliar a performance do modelo com uma configuração específica de hiperparâmetros durante o processo de otimização, que será discutido na subseção 4.6.3. Em contrapartida, o conjunto de teste é reservado para avaliar o desempenho final dos modelos.

Figura 23 – Esquema da divisão dos dados.




Fonte: Elaborada pelo autor.

4.6.2 Pré-Processamento

O pré-processamento seguiu os passos delineados na Figura 24. Inicialmente, realizou-se o escalonamento das variáveis contínuas por meio da padronização, também denominada normalização *z-score* ou escalonamento da variância. Esse processo envolve a subtração da média das observações ($\hat{x}$) de cada observação individual (x) e a divisão do resultado obtido pelo desvio padrão dos dados (s), conforme a Equação 15. Após a aplicação da técnica, os atributos resultantes ($\tilde{x}$) apresentam uma média zero e uma variância unitária, assumindo uma escala padronizada. Segundo Zheng e Casari (2018), essa escala impede que modelos sensíveis sejam influenciados desproporcionalmente pelas entradas, acelerando a convergência.

Figura 24 – Fluxograma do pré-processamento pós-divisão dos dados.



Fonte: Elaborada pelo autor.

$$\tilde{x} = \frac{x - \hat{x}}{s} \quad (15)$$

Em seguida, procedeu-se à seleção dos 80% principais atributos de cada subconjunto,

organizando-os pela Informação Mútua, ou *Mutual Information* (MI) em inglês, em relação à variável-alvo. A MI avalia a dependência entre variáveis, quantificando a informação que uma contém sobre a outra e, assim, permite a classificação das características conforme sua relevância (VERGARA; ESTÉVEZ, 2014). Os valores de MI podem variar de $[0, \infty)$, onde zero indica variáveis estatisticamente independentes, e valores acima de zero refletem o grau de dependência entre as variáveis. Essa medida pode ser definida pela seguinte equação:

$$I(X; Y) = \sum_{x \in X} \sum_{y \in Y} P(x, y) \log \left(\frac{P(x, y)}{P(x)P(y)} \right), \quad (16)$$

onde $P(x, y)$ é a probabilidade conjunta do atributo x com a variável-alvo y , e $P(x)$ e $P(y)$ são, respectivamente, as probabilidades marginais do atributo x e da variável-alvo y . Considerando as variáveis-alvo relacionadas à deterioração interna do lenho, o Quadro 1 apresenta resumidamente a relação das características selecionadas por meio da MI.

Quadro 1 – Relação dos atributos selecionados.

Atributo	Descrição
Altura da copa, do tronco e da árvore	m
Ângulo de inclinação	$^\circ$
Área permeável insuficiente	Sim/Não
Ataque de cupim-subterrâneo e cupim-de-solo	Ausente/Leve/Intenso
Ataque de fungo	Ausente/Leve/Moderado/Intenso
Casca inclusa no tronco	Sim/Não
Codificação <i>one-hot</i> da espécie	Vetor binário
Corpos de frutificação de fungos	Sim/Não
Dano aparente no colo	Sim/Não
Densidade da madeira	g/m^3
Diâmetro à altura do peito	m
Epífitas, erva de passarinho e figueira mata-pau na copa	Sim/Não
Formato da copa	Esférico/Elíptico 1/Elíptico 2
Injúria mecânica na raiz, no colo, no tronco e na copa	Sim/Não
Levantamento do pavimento	Sim/Não
Presença de fendas no tronco	Sim/Não
Presença de formiga no colo	Sim/Não
Presença de interferência na raiz	Sim/Não
Presença de poda	Sim/Não
Raiz cortada, dobrada/enovelada e exposta	Sim/Não

Fonte: Elaborada pelo autor.

Por último, no contexto de classificação, os dados de treino foram submetidos a um processo de sobreamostragem através da geração de dados sintéticos para as classes minoritárias,

a fim de mitigar o impacto negativo do desbalanceamento entre as classes. Para essa finalidade, foi empregada a Técnica de Sobreamostragem Minoritária Sintética, ou *Synthetic Minority Over-sampling Technique for Nominal and Continuous* (SMOTENC) em inglês. Esse algoritmo cria amostras suplementares ao realizar interpolação entre amostras de treinamento e um vizinho selecionado aleatoriamente entre os k mais próximos, neste trabalho, $k = 5$, no caso de atributos contínuos, ou escolher o valor mais frequente entre os vizinhos no caso de atributos nominais (CHAWLA et al., 2002). Em síntese, o SMOTENC aprimora a representação das classes minoritárias ao introduzir instâncias sintéticas no espaço de características.

4.6.3 Otimização de Hiperparâmetros

A otimização de hiperparâmetros, denominada *Hyperparameter Optimization* (HPO) em inglês, é um processo no qual diferentes combinações de hiperparâmetros, que são variáveis externas de configuração dos modelos, como o número de vizinhos (k) do k -NN, são testadas visando selecionar um conjunto que proporcione os melhores resultados no problema em questão, considerando o critério de avaliação adotado. Esse processo pode ocorrer de várias formas.


Nesse contexto, ressalta-se que as meta-heurísticas de otimização têm se mostrado eficientes em encontrar soluções satisfatórias para problemas complexos, em detrimento de métodos tradicionais (YANG, 2014), inclusive em problemas de HPO (PASSOS; RODRIGUES; PAPA, 2018). Em geral, tais técnicas incorporam comportamentos presentes na natureza para orientar seus mecanismos de busca, bem como utilizam aleatoriedade. Assim, ao longo de um certo número de iterações, uma população de potenciais soluções é guiada pelo espaço de busca por meio de uma lógica bioinspirada, visando a obtenção da melhor solução.

Dentre as inúmeras meta-heurísticas, opta-se pelo SMA, que se inspira no forrageamento de fungos gelatinosos. A escolha da técnica é justificada por sua novidade, sendo relativamente recente, e por seus resultados promissores, superando meta-heurísticas tradicionais, como o Algoritmo de Otimização por Enxame de Partículas, ou *Particle Swarm Optimization* (PSO) em inglês (KENNEDY; EBERHART, 1995), conforme constatado por Li et al. (2020), que realizou comparações utilizando diferentes funções de *benchmark*. Além disso, o bolor limoso tem sido bem-sucedido na resolução de problemas complexos reais, incluindo o Problema do Caixeiro-Viajante, referido como *Travelling Salesman Problem* (TSP) em inglês (ZHU et al., 2018). Durante sua busca por alimento, o fungo se propaga em várias regiões, movendo-se gradualmente em direção à área com maior concentração de alimento. Embora o fungo gelatinoso seja um único organismo, o SMA emprega uma população de agentes inicializados aleatoriamente, que se propagam em direção a possíveis soluções, conduzindo a população para a melhor solução através de equações matemáticas que abstraem o comportamento natural desses fungos. Esse processo é detalhado na subseção seguinte, conforme Li et al. (2020).

4.6.3.1 Funcionamento do SMA

Em síntese, o SMA emprega pesos adaptativos para simular o feedback positivo e negativo da propagação do bolor limoso durante a busca por alimento. Dessa maneira, atribui-se maior peso a regiões com altas concentrações de alimento, ou seja, soluções promissoras, e menor peso a áreas com menores concentrações, ou seja, soluções menos atrativas. Isso resulta em uma rede diversificada de veias alimentares com espessuras variadas, conforme ilustrado na Figura 25. Além disso, durante seu processo iterativo, o algoritmo alterna entre dois padrões principais de comportamento: exploração, que busca novas fontes de alimento (novas soluções), e exploração, que se concentra em uma fonte específica de alimentação (solução específica).

Figura 25 – Representação do mecanismo de forrageamento do bolor limoso.



Fonte: Extraída de Li et al. (2020).

A modelagem matemática utilizada pelo algoritmo pode ser compreendida através do Algoritmo 1, que descreve o passo a passo desse método de otimização. Em cada iteração, os valores de aptidão, ou seja, o desempenho dos agentes, são recalculados, e o melhor agente X_b é identificado. Esses valores são obtidos por meio da função de aptidão S , que é definida de acordo com o problema e indica, na abstração do método, a concentração de odor de alimento no ar. Assim, quanto maior o odor, melhor é o agente, pois ele está mais próximo de uma alta concentração de alimento, sugerindo uma boa solução. Em seguida, os pesos são calculados com base na Equação 17, que utiliza *SmellIndex*, uma lista com os índices dos agentes ordenados de forma decrescente de acordo com os valores de aptidão:

$$W(\text{SmellIndex}(i)) = \begin{cases} 1 + r \cdot \log_{10} \left(\frac{bF - S(i)}{bF - wF} + 1 \right), & \text{cond} \\ 1 - r \cdot \log_{10} \left(\frac{bF - S(i)}{bF - wF} + 1 \right), & \neg \text{cond} \end{cases}, \quad (17)$$

onde n é o número de agentes, $\text{SmellIndex}(i)$ é a posição do agente X_i ($i \in 1, 2, \dots, n$) na lista ordenada de valores de aptidão, cond indica que $S(i)$ corresponde à metade superior da população, r é um valor aleatório no intervalo $[0, 1]$, $\log_{10}$ é o logaritmo na base 10, $S(i)$ é a aptidão do agente X_i , e bF e wF referem-se aos melhores e piores valores de aptidão da iteração atual, respectivamente. Após o cálculo dos pesos, itera-se pelos agentes da população.

No laço de repetição, inicialmente, o valor de p é determinado pela Equação 18:

$$p = \tanh|S(i) - DF|, \quad (18)$$

na qual $S(i)$ representa o valor de aptidão do agente X_i e DF denota o melhor valor de aptidão obtido entre todas as iterações. Em seguida, as variáveis v_b e v_c são atualizadas. A variável v_c decresce linearmente de 1 a 0 ao longo das iterações, conforme a Equação 19:

$$v_c = 1 - \left(\frac{t}{\text{max_iters}} \right), \quad (19)$$

onde t representa a iteração atual e max_iters é o número total de iterações. Por sua vez, v_b é selecionado do intervalo $[-a, a]$, no qual o valor de a é determinado pela Equação 20:

$$a = \arctg \left(1 - \left(\frac{t}{\text{max_t}} \right) \right), \quad (20)$$

na qual $\arctg$ denota a função trigonométrica inversa arco tangente. Após a atualização dessas variáveis, a nova posição do agente X_i é calculada conforme a Equação 21:

$$X^* = \begin{cases} \text{rand} \cdot (UB - LB) + LB, & \text{rand} < z \\ X_b(t) + v_b \cdot (W \cdot X_A(t) - X_B(t)), & r < p \\ v_c \cdot X(t), & r \geq p \end{cases}, \quad (21)$$

onde LB e UB são os limites inferiores e superiores do espaço de busca, respectivamente. As variáveis rand e r correspondem a valores aleatórios no intervalo $[0, 1]$. $X_b(t)$ representa o agente com melhor valor de aptidão na iteração t , enquanto $X_A(t)$ e $X_B(t)$ denotam dois agentes selecionados aleatoriamente da população da iteração t , e $X(t)$ indica a posição atual do agente sendo atualizado. Já o hiperparâmetro z geralmente recebe o valor 0,03, definido por testes empíricos. Ao término da atualização das variáveis p , v_b , v_c e da posição X_i para todos os agentes, o processo é repetido até que o número total de iterações max_iters seja atingido. Por fim, o melhor agente encontrado durante a execução é retornado como solução.

Algoritmo 1: Pseudocódigo do SMA

Entradas: n, max_iters, z
Saída: X_b

```

1 Inicializa aleatoriamente a população de agentes  $X_i \mid i = 1, 2, \dots, n$ ;
2  $t \leftarrow 0$ ;
3 Enquanto  $t < max\_iters$  faça
4   | Calcula o valor de aptidão de cada agente;
5   | Atualiza o melhor valor de aptidão e o melhor agente  $X_b$ ;
6   | Calcula o peso  $W$  pela Equação 17;
7   | Enquanto  $i < n$  faça
8   |   | Atualiza  $p, v_b, v_c$ ;
9   |   | Atualiza a posição do agente  $X_i$  pela Equação 21;
10  |   |  $i \leftarrow i + 1$ ;
11  |  $t \leftarrow t + 1$ ;

```


4.6.3.2 Etapas da Otimização

As etapas do procedimento de ajuste dos hiperparâmetros mediante o emprego do SMA estão esquematizadas na Figura 26. Nessa abordagem, cada agente da população codifica um potencial conjunto de hiperparâmetros. Sendo assim, em cada iteração da meta-heurística, um modelo foi treinado utilizando os hiperparâmetros codificados por cada agente e os dados de treinamento, e sua eficácia avaliada no conjunto de validação. A avaliação do desempenho obtido com os agentes foi realizada por meio do MSE no caso de regressão e da acurácia balanceada no caso de classificação. Ao final da execução, o modelo final foi treinado considerando o melhor conjunto de hiperparâmetros encontrado, assim como a combinação dos dados de treinamento e validação. Posteriormente, esse modelo foi avaliado no conjunto de teste.

A meta-heurística foi executada com um total de $n = 10$ agentes, considerando um número máximo de $max = 50$ iterações e um mecanismo de parada precoce com uma paciência de $p = 10$ iterações. A execução utilizou a versão original do algoritmo, disponível na biblioteca MEALPY¹⁰. Além disso, o Quadro 2 delimita os espaços de busca considerados para cada hiperparâmetro ajustado durante o processo de otimização, tanto para regressão quanto para classificação. No contexto do OPF, o espaço de busca apresentado na tabela corresponde à versão não supervisionada do algoritmo, que serviu como base para o OPF em problemas de regressão, uma vez que o classificador OPF não possui hiperparâmetros sintonizáveis.

¹⁰ Repositório da biblioteca: <https://github.com/thieu1995/mealpy>.

Figura 26 – Fluxograma da otimização de hiperparâmetros.



Fonte: Elaborada pelo autor.

Quadro 2 – Espaços de busca para o ajuste dos hiperparâmetros dos modelos.


Modelo	Hiperparâmetros	Espaço de Busca
OPF	max_k	[5, 30]
k-NN	n_neighbors weights algorithm p	[5, 100] uniform, distance ball_tree, kd_tree, brute [1, 2]
SVM	C gamma kernel degree	[0.001, 30.0) [0.0, 1.0) linear, poly, rbf, sigmoid [1, 5]
DT	max_depth max_leaf_nodes min_samples_leaf min_samples_split	[2, 10] [2, 10] [2, 10] [2, 10]
RF	n_estimators max_depth min_samples_split min_samples_leaf	[5, 1000] [2, 10] [2, 10] [2, 10]
AdaBoost	n_estimators learning_rate	[5, 1000] [0.001, 1.]
GBM	n_estimators min_samples_split min_samples_leaf learning_rate	[5, 1000] [2, 10] [2, 10] [0.001, 1.0]
XGBoost	n_estimators max_depth min_child_weight gamma	[5, 1000] [2, 10] [2, 10] [0.0, 30.0)
LightGBM	n_estimators num_leaves min_data_in_leaf max_depth	[5, 1000] [2, 1024] [1, 100] [2, 10]
CatBoost	n_estimators learning_rate max_depth l2_leaf_reg	[5, 1000] [0.001, 1.0) [2, 10] [0.001, 30.0)
MLP	hidden_layer_sizes activation alpha learning_rate	(10,10,10), (20,20,20), (30,30,30) relu, logistic, tanh [0.0, 30.0) constant, adaptive

Fonte: Elaborado pelo autor.

4.6.4 Formação de *Ensembles*

Na etapa final, são formados *ensembles* de modelos, também designados agrupamentos de modelos. Nessa abordagem, diferentes algoritmos são combinados para fazer previsões mais confiáveis (DONG et al., 2020). O objetivo principal é explorar a diversidade desses modelos a fim de alcançar melhor desempenho geral, como denotado na Figura 27. Para compor os *ensembles*, foram selecionados os cinco melhores algoritmos de cada execução independente, tendo com base o MSE para o problema de regressão e a acurácia balanceada para as tarefas de classificação. Nesse contexto, dentre as diversas estratégias que podem ser empregadas para combinar as saídas de cada modelo, optou-se por duas abordagens: a votação e o *stacking*.

Figura 27 – Fluxograma da formação de *ensemble*.



Fonte: Elaborada pelo autor.


O método de votação, denominado *Voting Ensemble* (VE) em inglês, envolve a coleta de votos dos modelos do *ensemble*. Em outras palavras, na classificação, a classe mais frequente entre os modelos é escolhida como resultado. Por outro lado, em tarefas de regressão, calcula-se a média aritmética das previsões dos modelos para determinar a saída final (AN; MENG, 2010).

Já o método de *stacking*, também denominado *stacking generalization*, combina as saídas dos modelos do *ensemble* por meio de um segundo modelo (PAVLYSHENKO,

2018), conforme ilustrado na Figura 28. Em síntese, os modelos do nível 1, que compõem o *ensemble*, geram estimativas usadas como entrada para o modelo do segundo nível. Esse modelo subsequente aprende a combinar essas estimativas e, assim, produzir um resultado. Neste trabalho, utilizou-se o modelo de regressão logística como o modelo do segundo nível em problemas de classificação, e um modelo de regressão linear *ridge* em problemas de regressão.

Para mitigar o *overfitting* do modelo do segundo nível, adota-se a técnica de validação cruzada por meio do método *k-fold*, conhecida como *k-Fold Cross-Validation (k-CV)*. Segundo James et al. (2021), este método envolve a divisão aleatória dos dados de treinamento em k subconjuntos independentes de tamanho similar. Durante a validação cruzada, os modelos são treinados e avaliados k vezes, reservando um subconjunto diferente para validação em cada iteração, enquanto os outros $k - 1$ subconjuntos são utilizados no treinamento. Com essa abordagem, todas as previsões dos modelos do nível 1 obtidas nas k iterações do *k-CV*, neste trabalho, $k = 5$, são combinadas e utilizadas como entrada para o modelo do segundo nível.

Figura 28 – Representação do treinamento do método *stacking*.



Fonte: Adaptada de Raschka (2020).

5 Resultados

Este capítulo expõe os resultados obtidos a partir da execução dos experimentos. Inicialmente, a seção 5.1 apresenta os resultados encontrados ao modelar a estimativa da deterioração interna do tronco como uma regressão. Em seguida, a seção 5.2 discute os resultados obtidos ao abordar o problema como uma classificação. Ambas as seções incluem as métricas de avaliação de desempenho e os tempos de HPO e de treino, expressos em segundos (s). Essas medidas foram registradas por meio de 25 execuções independentes, visando destacar a performance média dos modelos e, por conseguinte, garantir a consistência dos resultados.

Quanto à margem de erro, foi adotado um intervalo de confiança de 95%. Ademais, as medidas destacadas em negrito nas tabelas apontam os melhores desempenhos entre todos os modelos. Para assegurar a reprodutibilidade dos resultados, foram utilizadas sementes aleatórias, ou *seeds* em inglês, para a inicialização do gerador de números pseudoaleatórios. É importante ressaltar também que o SMOTENC foi usado nas tarefas de classificação para lidar com o desbalanceamento dos dados por meio da sobreamostragem sintética das classes minoritárias.

Além disso, os resultados apresentados para as previsões do risco de queda foram obtidos a partir do treinamento dos modelos com todos os atributos selecionados durante a etapa de pré-processamento, acrescidos da variável referente à deterioração presente no tronco da árvore. Contudo, por simplicidade, as tabelas se referem à previsão do risco de queda com base nos valores reais ou estimados de deterioração, sem explicitar o uso dos demais atributos.

5.1 Estimativa do Percentual de Área Deteriorada

Inicialmente, esta seção aborda os resultados da previsão da porcentagem de área deteriorada ao nível do colo, considerando todas as espécies contempladas pela base de dados. A Tabela 3 apresenta os resultados da previsão do percentual de área deteriorada. Por sua vez, na Tabela 4, encontram-se os resultados da inferência do risco de queda com base nos valores reais da porcentagem de deterioração. Então, na Tabela 5, são apresentados os achados da estimativa do risco utilizando os valores preditos do percentual de deterioração, a fim de validar a aplicabilidade do método. Posteriormente, os resultados são relatados individualmente para as espécies *Caesalpinia peltophoroides* (subseção 5.1.1) e *Tipuana tipu* (subseção 5.1.2), as quais são mais predominantes na base, e para a união das espécies minoritárias (subseção 5.1.3).

Tabela 3 – Métricas de avaliação para a estimativa do percentual de área deteriorada.

Modelo	MAE	MSE	R^2	Tempo de HPO	Tempo de Treino
OPF	11,4765 $\pm$ 0,2244	274,4895 $\pm$ 10,4435	0,0928 $\pm$ 0,0266	6.624,8949 $\pm$ 928,5413	34,3530 $\pm$ 3,7470
k -NN	10,4959 $\pm$ 0,1418	254,5210 $\pm$ 8,4474	0,1589 $\pm$ 0,0186	158,7684 $\pm$ 22,3612	0,0055 $\pm$ 0,0012
SVM	10,4703 $\pm$ 0,3107	271,4395 $\pm$ 11,2151	0,1023 $\pm$ 0,0335	2.586,8618 $\pm$ 866,8342	0,9529 $\pm$ 0,2528
DT	10,6104 $\pm$ 0,1900	239,1866 $\pm$ 8,3911	0,2083 $\pm$ 0,0274	111,2921 $\pm$ 14,2533	0,0084 $\pm$ 0,0006
RF	10,6037 $\pm$ 0,2146	237,4258 $\pm$ 8,6099	0,2143 $\pm$ 0,0273	970,1696 $\pm$ 234,9090	4,2059 $\pm$ 1,5608
AdaBoost	11,1857 $\pm$ 0,6952	253,3939 $\pm$ 29,4207	0,1660 $\pm$ 0,0842	326,0918 $\pm$ 93,5366	0,7250 $\pm$ 0,6135
GBM	10,8569 $\pm$ 0,4119	243,0572 $\pm$ 11,4965	0,1966 $\pm$ 0,0332	597,8723 $\pm$ 233,7230	1,6337 $\pm$ 1,0399
XGBoost	10,8365 $\pm$ 0,4679	242,9004 $\pm$ 14,7325	0,1978 $\pm$ 0,0425	199,8256 $\pm$ 25,2185	0,0371 $\pm$ 0,0273
LightGBM	10,3897 $\pm$ 0,1697	234,8014 $\pm$ 7,7746	0,2239 $\pm$ 0,0185	197,5326 $\pm$ 30,6962	0,0606 $\pm$ 0,0174
CatBoost	10,2775 $\pm$ 0,1536	232,6786 $\pm$ 7,6786	0,2302 $\pm$ 0,0227	546,1351 $\pm$ 244,8906	0,8130 $\pm$ 0,7345
MLP	10,7828 $\pm$ 0,3530	240,9344 $\pm$ 10,0564	0,2022 $\pm$ 0,0343	1.061,2392 $\pm$ 168,1360	4,4911 $\pm$ 0,6680
VE	10,6388 $\pm$ 0,1963	239,4612 $\pm$ 8,0077	0,2082 $\pm$ 0,0206	-	39,6342 $\pm$ 4,7611
Stacking	10,7381 $\pm$ 0,3237	239,2786 $\pm$ 11,6573	0,2083 $\pm$ 0,0371	-	187,6845 $\pm$ 23,8851

Fonte: Elaborada pelo autor.

Tabela 4 – Métricas de avaliação para a inferência do risco de queda das árvores com base nos verdadeiros percentuais de área deteriorada.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,7844 $\pm$ 0,0096	0,8860 $\pm$ 0,0076	0,0264 $\pm$ 0,0161	0,6007 $\pm$ 0,0261	0,5044 $\pm$ 0,0114	-	19,8593 $\pm$ 0,1938
k -NN	0,8415 $\pm$ 0,0083	0,9735 $\pm$ 0,0044	0,0000 $\pm$ 0,0000	0,5803 $\pm$ 0,0288	0,5179 $\pm$ 0,0101	116,1390 $\pm$ 17,5545	0,0063 $\pm$ 0,0008
SVM	0,6786 $\pm$ 0,0487	0,6991 $\pm$ 0,0685	0,4193 $\pm$ 0,0837	0,6654 $\pm$ 0,0412	0,5946 $\pm$ 0,0227	184,8861 $\pm$ 23,4990	0,8604 $\pm$ 0,3808
DT	0,7546 $\pm$ 0,0214	0,8026 $\pm$ 0,0252	0,4187 $\pm$ 0,0788	0,6693 $\pm$ 0,0252	0,6302 $\pm$ 0,0259	71,5218 $\pm$ 3,4162	0,0123 $\pm$ 0,0010
RF	0,6549 $\pm$ 0,0365	0,6609 $\pm$ 0,0515	0,2235 $\pm$ 0,0685	0,7038 $\pm$ 0,0373	0,5294 $\pm$ 0,0266	169,6988 $\pm$ 19,1491	0,0699 $\pm$ 0,1152
AdaBoost	0,8387 $\pm$ 0,0135	0,9240 $\pm$ 0,0168	0,0418 $\pm$ 0,0303	0,7098 $\pm$ 0,0219	0,5585 $\pm$ 0,0098	141,7877 $\pm$ 14,2811	2,3514 $\pm$ 0,5771
GBM	0,8306 $\pm$ 0,0213	0,9288 $\pm$ 0,0154	0,0602 $\pm$ 0,0422	0,6629 $\pm$ 0,0557	0,5506 $\pm$ 0,0251	506,0691 $\pm$ 73,4560	7,2402 $\pm$ 3,4545
XGBoost	0,8600 $\pm$ 0,0074	0,9545 $\pm$ 0,0088	0,0106 $\pm$ 0,0119	0,7115 $\pm$ 0,0222	0,5589 $\pm$ 0,0071	105,1381 $\pm$ 13,9875	0,2493 $\pm$ 0,0843
LightGBM	0,7656 $\pm$ 0,0149	0,8114 $\pm$ 0,0175	0,3753 $\pm$ 0,0603	0,6949 $\pm$ 0,0240	0,6272 $\pm$ 0,0174	103,0458 $\pm$ 8,3491	0,0846 $\pm$ 0,0436
CatBoost	0,7867 $\pm$ 0,0233	0,8492 $\pm$ 0,0220	0,2579 $\pm$ 0,0755	0,6887 $\pm$ 0,0624	0,5986 $\pm$ 0,0270	208,9458 $\pm$ 27,8227	0,6184 $\pm$ 0,5422
MLP	0,7810 $\pm$ 0,0236	0,8707 $\pm$ 0,0350	0,0803 $\pm$ 0,0402	0,6217 $\pm$ 0,0460	0,5242 $\pm$ 0,0165	1.037,0733 $\pm$ 143,4571	5,5069 $\pm$ 0,4254
VE	0,8229 $\pm$ 0,0146	0,8910 $\pm$ 0,0188	0,2694 $\pm$ 0,0736	0,7089 $\pm$ 0,0215	0,6231 $\pm$ 0,0208	-	7,3621 $\pm$ 3,3860
Stacking	0,8661 $\pm$ 0,0076	0,9548 $\pm$ 0,0100	0,0000 $\pm$ 0,0000	0,7368 $\pm$ 0,0205	0,5639 $\pm$ 0,0063	-	38,0541 $\pm$ 17,2976

Fonte: Elaborada pelo autor.

Tabela 5 – Métricas de avaliação para a inferência do risco de queda das árvores com base nos percentuais estimados de área deteriorada.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.
		Baixo	Médio	Alto	
OPF	0,6747 ± 0,0130	0,7774 ± 0,0142	0,0498 ± 0,0256	0,4688 ± 0,0301	0,4320 ± 0,0129
<i>k</i> -NN	0,7321 ± 0,0086	0,8593 ± 0,0105	0,0000 ± 0,0000	0,4666 ± 0,0243	0,4420 ± 0,0088
SVM	0,5811 ± 0,0338	0,6147 ± 0,0571	0,2143 ± 0,0672	0,5418 ± 0,0419	0,4569 ± 0,0158
DT	0,1106 ± 0,0794	0,0833 ± 0,0956	0,8873 ± 0,1138	0,0709 ± 0,0595	0,3472 ± 0,0143
RF	0,5908 ± 0,0205	0,6224 ± 0,0319	0,1665 ± 0,0633	0,5613 ± 0,0330	0,4500 ± 0,0207
AdaBoost	0,6986 ± 0,0127	0,7693 ± 0,0172	0,0209 ± 0,0183	0,5915 ± 0,0243	0,4605 ± 0,0118
GBM	0,7143 ± 0,0144	0,8274 ± 0,0184	0,0219 ± 0,0182	0,4852 ± 0,0254	0,4448 ± 0,0119
XGBoost	0,7267 ± 0,0098	0,8353 ± 0,0171	0,0106 ± 0,0119	0,5157 ± 0,0255	0,4539 ± 0,0079
LightGBM	0,5974 ± 0,0173	0,6427 ± 0,0203	0,2604 ± 0,0581	0,5151 ± 0,0272	0,4727 ± 0,0209
CatBoost	0,6368 ± 0,0242	0,6949 ± 0,0308	0,1531 ± 0,0597	0,5376 ± 0,0269	0,4619 ± 0,0203
MLP	0,6994 ± 0,0161	0,7977 ± 0,0263	0,0504 ± 0,0219	0,5011 ± 0,0404	0,4497 ± 0,0127
VE	0,6751 ± 0,0142	0,7447 ± 0,0183	0,1493 ± 0,0632	0,5506 ± 0,0217	0,4815 ± 0,0203
Stacking	0,7319 ± 0,0103	0,8264 ± 0,0113	0,0000 ± 0,0000	0,5628 ± 0,0241	0,4630 ± 0,0093

Fonte: Elaborada pelo autor.

5.1.1 *Caesalpinia peltophoroides*

Nesta subseção, demonstra-se o desempenho dos modelos em árvores urbanas da espécie *Caesalpinia peltophoroides*. Primeiramente, a Tabela 6 aborda os resultados da previsão da porcentagem de área com deterioração. Em seguida, na Tabela 7, são apresentados os resultados da inferência do risco de queda com base nos valores reais da porcentagem de área deteriorada. Então, na Tabela 8, são expressos os achados da estimativa do risco utilizando os valores preditos da porcentagem de área deteriorada, visando validar o método proposto.

Tabela 6 – Métricas de avaliação para a estimativa do percentual de área deteriorada de árvores da espécie *Caesalpinia peltophoroides*.

Modelo	MAE	MSE	R^2	Tempo de HPO	Tempo de Treino
OPF	7,1490 ± 0,2353	141,7091 ± 9,9370	-0,0097 ± 0,0450	1.008,1468 ± 190,0623	5,1909 ± 1,1183
<i>k</i> -NN	6,5449 ± 0,1200	136,4431 ± 7,4705	0,0251 ± 0,0323	51,9738 ± 9,1341	0,0014 ± 0,0004
SVM	6,8219 ± 0,3410	141,4623 ± 10,2238	-0,0207 ± 0,0939	538,6627 ± 346,4484	0,4822 ± 0,3043
DT	7,3804 ± 0,2714	142,3496 ± 10,5808	-0,0185 ± 0,0708	41,5532 ± 5,8125	0,0027 ± 0,0002
RF	7,0004 ± 0,2123	126,8740 ± 7,4192	0,0920 ± 0,0403	264,3250 ± 95,9386	0,9394 ± 0,5906
AdaBoost	7,0089 ± 0,2086	125,5503 ± 8,0983	0,1039 ± 0,0383	141,7880 ± 54,3285	0,3666 ± 0,3972
GBM	7,3179 ± 0,2626	136,4840 ± 9,7801	0,0230 ± 0,0620	247,9553 ± 89,9237	0,8108 ± 0,4084
XGBoost	7,1692 ± 0,2076	129,9336 ± 7,7413	0,0679 ± 0,0504	69,9078 ± 9,5496	0,0541 ± 0,0280
LightGBM	7,0097 ± 0,3061	127,3890 ± 9,0308	0,0904 ± 0,0477	74,8607 ± 13,1007	0,0446 ± 0,0200
CatBoost	7,0118 ± 0,2240	125,3389 ± 7,3144	0,0969 ± 0,0615	242,5691 ± 81,3195	0,4738 ± 0,3061
MLP	7,7861 ± 0,8010	179,0919 ± 42,7118	-0,3006 ± 0,3234	527,4216 ± 66,7482	3,0629 ± 0,2635
VE	6,9496 ± 0,1937	131,7824 ± 6,5247	0,0511 ± 0,0562	-	6,6657 ± 1,4697
Stacking	7,0786 ± 0,1671	128,9869 ± 6,5154	0,0737 ± 0,0446	-	32,9518 ± 7,3938

Fonte: Elaborada pelo autor.

Tabela 7 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie *Caesalpinia peltophoroides* com base nos verdadeiros percentuais de área deteriorada.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,8373 ± 0,0162	0,9258 ± 0,0112	0,0240 ± 0,0303	0,4611 ± 0,0545	0,4703 ± 0,0206	-	2,7866 ± 0,0119
k-NN	0,8724 ± 0,0133	0,9933 ± 0,0034	0,0000 ± 0,0000	0,2695 ± 0,0442	0,4210 ± 0,0146	45,4968 ± 4,5952	0,0018 ± 0,0000
SVM	0,7143 ± 0,0388	0,7586 ± 0,0443	0,3990 ± 0,1439	0,5169 ± 0,0538	0,5582 ± 0,0497	74,0390 ± 11,3330	0,1460 ± 0,0822
DT	0,7280 ± 0,0423	0,7710 ± 0,0503	0,2779 ± 0,1264	0,5587 ± 0,0445	0,5359 ± 0,0386	37,9798 ± 2,5173	0,0050 ± 0,0005
RF	0,6392 ± 0,0566	0,6635 ± 0,0678	0,3963 ± 0,1296	0,5674 ± 0,0669	0,5424 ± 0,0401	81,5142 ± 8,7388	0,0312 ± 0,0310
AdaBoost	0,8590 ± 0,0222	0,9444 ± 0,0229	0,0133 ± 0,0270	0,5129 ± 0,0641	0,4902 ± 0,0228	66,0687 ± 4,8712	0,7326 ± 0,2988
GBM	0,8629 ± 0,0247	0,9483 ± 0,0252	0,0154 ± 0,0242	0,5146 ± 0,0696	0,4928 ± 0,0293	205,2674 ± 41,8832	1,9690 ± 1,0978
XGBoost	0,8888 ± 0,0121	0,9733 ± 0,0067	0,0100 ± 0,0202	0,5608 ± 0,0476	0,5147 ± 0,0187	49,8673 ± 4,3613	0,1499 ± 0,0646
LightGBM	0,7676 ± 0,0306	0,8128 ± 0,0354	0,3382 ± 0,1381	0,5947 ± 0,0495	0,5819 ± 0,0435	60,0093 ± 7,2936	0,0853 ± 0,0455
CatBoost	0,7505 ± 0,0370	0,7893 ± 0,0446	0,1679 ± 0,1201	0,6657 ± 0,0466	0,5410 ± 0,0437	153,0797 ± 17,8087	0,1580 ± 0,1963
MLP	0,8183 ± 0,0276	0,8975 ± 0,0306	0,0997 ± 0,0619	0,4717 ± 0,0728	0,4896 ± 0,0250	539,1564 ± 76,0258	2,9230 ± 0,1261
VE	0,8537 ± 0,0238	0,9199 ± 0,0260	0,2292 ± 0,1227	0,5790 ± 0,0471	0,5760 ± 0,0365	-	3,0641 ± 1,2304
Stacking	0,8933 ± 0,0123	0,9795 ± 0,0067	0,0000 ± 0,0000	0,5610 ± 0,0471	0,5135 ± 0,0148	-	16,3183 ± 5,9925

Fonte: Elaborada pelo autor.

Tabela 8 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie *Caesalpinia peltophoroides* com base nos percentuais estimados de área deteriorada.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.
		Baixo	Médio	Alto	
OPF	0,7771 ± 0,0119	0,8960 ± 0,0103	0,0460 ± 0,0395	0,1352 ± 0,0339	0,3591 ± 0,0196
k-NN	0,8290 ± 0,0131	0,9659 ± 0,0077	0,0000 ± 0,0000	0,0926 ± 0,0352	0,3528 ± 0,0106
SVM	0,6263 ± 0,0504	0,6892 ± 0,0592	0,1997 ± 0,1171	0,3163 ± 0,0633	0,4017 ± 0,0379
DT	0,3185 ± 0,1444	0,3476 ± 0,1766	0,6119 ± 0,1651	0,0493 ± 0,0437	0,3363 ± 0,0246
RF	0,5608 ± 0,0524	0,6034 ± 0,0647	0,3870 ± 0,1256	0,3269 ± 0,0686	0,4391 ± 0,0450
AdaBoost	0,7920 ± 0,0239	0,9111 ± 0,0299	0,0267 ± 0,0373	0,1722 ± 0,0482	0,3700 ± 0,0169
GBM	0,7749 ± 0,0277	0,8887 ± 0,0288	0,0221 ± 0,0270	0,1747 ± 0,0498	0,3618 ± 0,0218
XGBoost	0,8042 ± 0,0133	0,9229 ± 0,0146	0,0233 ± 0,0330	0,1896 ± 0,0450	0,3786 ± 0,0177
LightGBM	0,6484 ± 0,0263	0,7169 ± 0,0341	0,2918 ± 0,1205	0,2687 ± 0,0472	0,4258 ± 0,0429
CatBoost	0,6072 ± 0,0638	0,6569 ± 0,0818	0,1950 ± 0,1191	0,3834 ± 0,0645	0,4118 ± 0,0382
MLP	0,7375 ± 0,0335	0,8300 ± 0,0411	0,0797 ± 0,0591	0,2680 ± 0,0689	0,3926 ± 0,0285
VE	0,7604 ± 0,0226	0,8647 ± 0,0276	0,1122 ± 0,0770	0,2095 ± 0,0580	0,3955 ± 0,0287
Stacking	0,8145 ± 0,0145	0,9369 ± 0,0110	0,0000 ± 0,0000	0,1841 ± 0,0473	0,3736 ± 0,0158

Fonte: Elaborada pelo autor.

5.1.2 *Tipuana tipu*

Nesta subseção, relata-se a performance dos algoritmos considerando árvores da espécie *Tipuana tipu*. Nesse contexto, a Tabela 9 apresenta os resultados da estimativa do percentual de área deteriorada. Então, na Tabela 10, são exibidos os resultados da inferência do risco de queda com base nos valores reais da porcentagem de área deteriorada. Por fim, a Tabela 11 revela os achados da previsão do risco utilizando os valores preditos do percentual de deterioração.

Tabela 9 – Métricas de avaliação para a estimativa do percentual de área deteriorada de árvores da espécie *Tipuana tipu*.

Modelo	MAE	MSE	R^2	Tempo de HPO	Tempo de Treino
OPF	16,0774 ± 0,3573	402,3376 ± 21,5699	0,0059 ± 0,0394	886,3446 ± 162,8597	4,8314 ± 0,7525
k-NN	15,2459 ± 0,3124	370,2266 ± 16,7660	0,0846 ± 0,0292	51,2794 ± 7,6430	0,0016 ± 0,0004
SVM	14,2514 ± 0,3305	364,7411 ± 17,3625	0,0976 ± 0,0333	128,1565 ± 28,9393	0,1270 ± 0,0230
DT	14,1517 ± 0,3421	345,2733 ± 16,8730	0,1455 ± 0,0341	41,2606 ± 4,5110	0,0030 ± 0,0002
RF	14,1002 ± 0,2777	335,9760 ± 15,5048	0,1680 ± 0,0326	316,8382 ± 97,1873	1,2129 ± 0,5847
AdaBoost	14,1878 ± 0,3516	339,1517 ± 15,4503	0,1592 ± 0,0369	166,5919 ± 95,5638	0,5526 ± 0,4899
GBM	14,3210 ± 0,3365	341,9448 ± 18,9731	0,1540 ± 0,0394	282,8280 ± 98,2782	0,9974 ± 0,4796
XGBoost	14,4726 ± 0,3258	350,0633 ± 17,7720	0,1310 ± 0,0488	67,9091 ± 9,8878	0,0461 ± 0,0353
LightGBM	14,4227 ± 0,3610	341,8601 ± 19,2277	0,1540 ± 0,0407	70,8316 ± 11,4982	0,0206 ± 0,0078
CatBoost	14,3222 ± 0,3491	340,1081 ± 17,1501	0,1592 ± 0,0320	449,3902 ± 252,8360	1,4115 ± 1,2382
MLP	14,1113 ± 0,2909	339,5364 ± 16,6768	0,1608 ± 0,0295	636,4449 ± 111,4813	3,1940 ± 0,1253
VE	14,6068 ± 0,3211	346,5779 ± 15,4099	0,1428 ± 0,0266	-	7,2873 ± 1,3639
Stacking	14,1578 ± 0,3267	333,5800 ± 15,6480	0,1738 ± 0,0341	-	36,4872 ± 7,6189

Fonte: Elaborada pelo autor.

Tabela 10 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie *Tipuana tipu* com base nos verdadeiros percentuais da área deteriorada.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,7204 ± 0,0152	0,8028 ± 0,0194	0,0200 ± 0,0280	0,6906 ± 0,0287	0,5045 ± 0,0131	-	2,6910 ± 0,0267
k-NN	0,7744 ± 0,0337	0,9013 ± 0,0474	0,0000 ± 0,0000	0,6885 ± 0,0317	0,5299 ± 0,0210	49,1133 ± 6,3137	0,0020 ± 0,0003
SVM	0,7096 ± 0,0424	0,7437 ± 0,0592	0,3604 ± 0,1157	0,7096 ± 0,0452	0,6046 ± 0,0268	78,8599 ± 10,2117	0,1836 ± 0,0779
DT	0,6959 ± 0,0222	0,7331 ± 0,0377	0,4616 ± 0,1085	0,6763 ± 0,0379	0,6237 ± 0,0333	36,0624 ± 2,1988	0,0045 ± 0,0003
RF	0,6604 ± 0,0409	0,6912 ± 0,0536	0,2650 ± 0,0781	0,6692 ± 0,0610	0,5418 ± 0,0300	92,4247 ± 11,1049	0,0095 ± 0,0005
AdaBoost	0,7922 ± 0,0450	0,8603 ± 0,0755	0,0181 ± 0,0263	0,7982 ± 0,0311	0,5589 ± 0,0232	70,4752 ± 5,9250	0,7770 ± 0,3042
GBM	0,8115 ± 0,0132	0,8989 ± 0,0177	0,0270 ± 0,0258	0,7840 ± 0,0220	0,5700 ± 0,0139	196,9077 ± 30,2011	1,9344 ± 1,0787
XGBoost	0,8193 ± 0,0128	0,9095 ± 0,0167	0,0147 ± 0,0206	0,7921 ± 0,0200	0,5721 ± 0,0121	55,0371 ± 5,7396	0,2825 ± 0,1982
LightGBM	0,7619 ± 0,0210	0,8091 ± 0,0283	0,2663 ± 0,1009	0,7618 ± 0,0276	0,6124 ± 0,0328	60,7311 ± 6,8053	0,1337 ± 0,1084
CatBoost	0,7789 ± 0,0197	0,8293 ± 0,0251	0,1845 ± 0,0838	0,7847 ± 0,0251	0,5995 ± 0,0300	154,4391 ± 23,1077	0,2113 ± 0,2546
MLP	0,7274 ± 0,0260	0,7686 ± 0,0466	0,0511 ± 0,0459	0,7561 ± 0,0513	0,5253 ± 0,0218	573,1190 ± 63,2863	2,9639 ± 0,0645
VE	0,8081 ± 0,0201	0,8795 ± 0,0249	0,1901 ± 0,0867	0,7859 ± 0,0304	0,6185 ± 0,0271	-	2,1753 ± 1,0703
Stacking	0,8237 ± 0,0186	0,9021 ± 0,0191	0,0000 ± 0,0000	0,8164 ± 0,0291	0,5728 ± 0,0136	-	11,2010 ± 5,5535

Fonte: Elaborada pelo autor.

Tabela 11 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie *Tipuana tipu* com base nos percentuais estimados de área deteriorada.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.
		Baixo	Médio	Alto	
OPF	0,5444 ± 0,0185	0,6287 ± 0,0195	0,0200 ± 0,0404	0,4880 ± 0,0354	0,3789 ± 0,0147
k-NN	0,6078 ± 0,0220	0,7160 ± 0,0226	0,0000 ± 0,0000	0,5244 ± 0,0326	0,4134 ± 0,0151
SVM	0,4996 ± 0,0251	0,5201 ± 0,0399	0,1961 ± 0,0779	0,5027 ± 0,0423	0,4063 ± 0,0235
DT	0,3437 ± 0,0238	0,0000 ± 0,0000	0,0479 ± 0,0530	0,9144 ± 0,0605	0,3207 ± 0,0132
RF	0,5319 ± 0,0267	0,5522 ± 0,0334	0,2219 ± 0,0767	0,5450 ± 0,0602	0,4397 ± 0,0293
AdaBoost	0,5993 ± 0,0208	0,6102 ± 0,0352	0,0057 ± 0,0116	0,6667 ± 0,0370	0,4275 ± 0,0136
GBM	0,6193 ± 0,0175	0,6778 ± 0,0242	0,0213 ± 0,0240	0,6106 ± 0,0283	0,4366 ± 0,0164
XGBoost	0,6026 ± 0,0170	0,6514 ± 0,0193	0,0000 ± 0,0000	0,6092 ± 0,0267	0,4202 ± 0,0120
LightGBM	0,5311 ± 0,0250	0,5485 ± 0,0288	0,1135 ± 0,0576	0,5630 ± 0,0356	0,4083 ± 0,0180
CatBoost	0,5415 ± 0,0251	0,5567 ± 0,0259	0,1035 ± 0,0609	0,5802 ± 0,0363	0,4134 ± 0,0230
MLP	0,5922 ± 0,0197	0,6628 ± 0,0384	0,0080 ± 0,0162	0,5599 ± 0,0470	0,4102 ± 0,0156
VE	0,5789 ± 0,0202	0,6247 ± 0,0257	0,0447 ± 0,0387	0,5823 ± 0,0278	0,4172 ± 0,0173
Stacking	0,6181 ± 0,0164	0,6560 ± 0,0194	0,0000 ± 0,0000	0,6456 ± 0,0294	0,4339 ± 0,0127

Fonte: Elaborada pelo autor.

5.1.3 Espécies Minoritárias

Por fim, esta subseção concentra-se no desempenho dos modelos na junção das espécies minoritárias da base de dados, nomeadamente, *Caesalpinia ferrea* var. *leiostachya*, *Holocalyx balansae*, *Jacaranda mimosaefolia*, *Ligustrum lucidum* e *Tibouchina granulosa*. Inicialmente, a Tabela 12 relata os resultados da estimativa do percentual de área deteriorada. Por sua vez, na Tabela 13, são apresentados os resultados da inferência do risco de queda com base nos valores reais da porcentagem de área deteriorada. Posteriormente, a Tabela 14 mostra os achados da previsão do risco utilizando os valores preditos do percentual de deterioração.

Tabela 12 – Métricas de avaliação para a estimativa do percentual de área deteriorada de árvores das espécies minoritárias.

Modelo	MAE	MSE	R ²	Tempo de HPO	Tempo de Treino
OPF	10,4615 ± 0,4007	262,1062 ± 20,0894	-0,0241 ± 0,0438	578,6040 ± 145,8160	2,6765 ± 0,6695
k-NN	9,6838 ± 0,3191	241,7094 ± 18,6582	0,0540 ± 0,0503	41,7704 ± 5,1383	0,0011 ± 0,0002
SVM	9,8457 ± 0,5799	257,5690 ± 28,1351	0,0006 ± 0,0721	141,6540 ± 28,7697	0,1408 ± 0,0888
DT	9,5640 ± 0,3733	227,1050 ± 18,6740	0,1068 ± 0,0635	28,3100 ± 2,7549	0,0019 ± 0,0002
RF	9,7362 ± 0,4177	216,7483 ± 19,7894	0,1481 ± 0,0676	270,9095 ± 80,4894	1,2661 ± 0,5432
AdaBoost	9,3266 ± 0,6881	218,3913 ± 21,3197	0,1437 ± 0,0657	106,3481 ± 27,2685	0,1961 ± 0,2344
GBM	10,6445 ± 0,7312	242,6254 ± 27,5154	0,0435 ± 0,1026	194,1498 ± 62,2531	0,8084 ± 0,3314
XGBoost	10,1569 ± 0,4599	242,5965 ± 23,2488	0,0443 ± 0,0864	68,8032 ± 10,4964	0,1030 ± 0,0396
LightGBM	10,1966 ± 0,4867	229,6303 ± 20,6799	0,0946 ± 0,0782	70,2328 ± 13,9827	0,1243 ± 0,1133
CatBoost	10,0457 ± 0,5429	226,0089 ± 28,0431	0,1201 ± 0,0831	451,2786 ± 286,6671	2,1470 ± 1,6047
MLP	14,8302 ± 3,0942	689,6265 ± 296,4922	-1,6363 ± 0,9515	146,8612 ± 24,7181	2,1287 ± 0,1352
VE	10,2188 ± 0,4433	241,3854 ± 19,5006	0,0555 ± 0,0536	-	5,4553 ± 0,7953
Stacking	10,7139 ± 1,1182	248,4403 ± 40,7880	0,0350 ± 0,1247	-	26,7722 ± 4,0620

Fonte: Elaborada pelo autor.

Tabela 13 – Métricas de avaliação para a inferência do risco de queda de árvores das espécies minoritárias com base nos verdadeiros percentuais da área deteriorada.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,8179 ± 0,0165	0,9197 ± 0,0180	0,0267 ± 0,0373	0,5452 ± 0,0628	0,4972 ± 0,0231	-	1,4003 ± 0,0213
k-NN	0,8395 ± 0,0143	0,9829 ± 0,0061	0,0000 ± 0,0000	0,3921 ± 0,0479	0,4583 ± 0,0160	44,1895 ± 5,3137	0,0015 ± 0,0001
SVM	0,7816 ± 0,0380	0,8347 ± 0,0455	0,2980 ± 0,1304	0,6570 ± 0,0530	0,5966 ± 0,0421	66,1054 ± 12,0600	0,0447 ± 0,0146
DT	0,5442 ± 0,1273	0,5199 ± 0,1685	0,3533 ± 0,1700	0,7282 ± 0,0802	0,5338 ± 0,0626	33,3643 ± 2,5752	0,0031 ± 0,0003
RF	0,6032 ± 0,0692	0,5965 ± 0,0968	0,2527 ± 0,1460	0,6989 ± 0,0702	0,5160 ± 0,0393	76,3260 ± 10,1283	0,0800 ± 0,0670
AdaBoost	0,8516 ± 0,0260	0,9268 ± 0,0309	0,0400 ± 0,0809	0,6953 ± 0,0404	0,5540 ± 0,0355	66,7797 ± 8,9744	0,4545 ± 0,2511
GBM	0,8558 ± 0,0201	0,9357 ± 0,0204	0,0100 ± 0,0202	0,6794 ± 0,0527	0,5417 ± 0,0187	168,0843 ± 34,4661	1,6878 ± 0,8608
XGBoost	0,8663 ± 0,0188	0,9525 ± 0,0142	0,0000 ± 0,0000	0,6768 ± 0,0611	0,5431 ± 0,0214	43,5635 ± 4,5523	0,0526 ± 0,0236
LightGBM	0,7011 ± 0,0720	0,7172 ± 0,0944	0,3027 ± 0,1549	0,7232 ± 0,0509	0,5810 ± 0,0455	51,0091 ± 6,1646	0,0718 ± 0,0642
CatBoost	0,7174 ± 0,0775	0,7474 ± 0,0961	0,2680 ± 0,1412	0,7083 ± 0,0463	0,5746 ± 0,0472	145,3632 ± 22,5589	0,5128 ± 0,9807
MLP	0,7874 ± 0,0275	0,8782 ± 0,0271	0,0933 ± 0,0930	0,5360 ± 0,0678	0,5025 ± 0,0353	138,5276 ± 12,8783	2,2415 ± 0,0385
VE	0,8147 ± 0,0396	0,8719 ± 0,0569	0,2333 ± 0,1430	0,7013 ± 0,0469	0,6022 ± 0,0436	-	2,5196 ± 1,3034
Stacking	0,8758 ± 0,0137	0,9570 ± 0,0113	0,0000 ± 0,0000	0,7044 ± 0,0477	0,5538 ± 0,0163	-	12,9309 ± 6,9673

Fonte: Elaborada pelo autor.

Tabela 14 – Métricas de avaliação para a inferência do risco de queda de árvores das espécies minoritárias com base nos percentuais estimados de área deteriorada.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.
		Baixo	Médio	Alto	
OPF	0,7132 ± 0,0181	0,8471 ± 0,0179	0,0180 ± 0,0254	0,2685 ± 0,0445	0,3779 ± 0,0174
k-NN	0,7747 ± 0,0168	0,9215 ± 0,0123	0,0000 ± 0,0000	0,2923 ± 0,0380	0,4046 ± 0,0134
SVM	0,6363 ± 0,0337	0,6974 ± 0,0451	0,1367 ± 0,0784	0,4786 ± 0,0535	0,4376 ± 0,0317
DT	0,2200 ± 0,0807	0,1766 ± 0,1056	0,3913 ± 0,1734	0,3890 ± 0,1189	0,3189 ± 0,0426
RF	0,5542 ± 0,0620	0,5740 ± 0,0829	0,2280 ± 0,1299	0,5186 ± 0,0694	0,4402 ± 0,0392
AdaBoost	0,7500 ± 0,0446	0,8692 ± 0,0605	0,0080 ± 0,0162	0,4089 ± 0,0669	0,4287 ± 0,0213
GBM	0,7511 ± 0,0154	0,8617 ± 0,0204	0,0080 ± 0,0162	0,4179 ± 0,0453	0,4292 ± 0,0166
XGBoost	0,7589 ± 0,0200	0,8698 ± 0,0196	0,0400 ± 0,0809	0,4363 ± 0,0622	0,4487 ± 0,0372
LightGBM	0,6042 ± 0,0489	0,6263 ± 0,0606	0,3027 ± 0,1375	0,5738 ± 0,0557	0,5009 ± 0,0414
CatBoost	0,5742 ± 0,0426	0,6089 ± 0,0496	0,3327 ± 0,1595	0,4985 ± 0,0638	0,4800 ± 0,0525
MLP	0,6884 ± 0,0275	0,8117 ± 0,0298	0,1033 ± 0,0935	0,2824 ± 0,0747	0,3991 ± 0,0361
VE	0,7074 ± 0,0311	0,7918 ± 0,0387	0,1413 ± 0,1211	0,4739 ± 0,0555	0,4690 ± 0,0480
Stacking	0,7626 ± 0,0153	0,8647 ± 0,0158	0,0000 ± 0,0000	0,4761 ± 0,0505	0,4470 ± 0,0171

Fonte: Elaborada pelo autor.

5.2 Classificação do Nível de Deterioração

Em um primeiro momento, na subseção 5.2.1, são apresentados os resultados da classificação multiclasse do nível de deterioração interna na região do colo. Em seguida, na subseção 5.2.2, demonstra-se o desempenho dos modelos na classificação binária do nível de deterioração, que agrupa os níveis médio e alto em uma categoria denominada significativa.

5.2.1 Classificação Multiclasse

Nesta subseção, inicialmente, são apresentados os resultados da classificação do nível de deterioração interna na região do colo, considerando todas as espécies presentes na base de

dados. Logo, a Tabela 15 expõe os resultados da classificação do nível de deterioração. Em seguida, na Tabela 16, encontram-se os resultados da inferência do risco de queda com base nos níveis reais de deterioração. Então, na Tabela 17, são expressos os achados da estimativa do risco utilizando os níveis preditos de deterioração, a fim de validar a aplicabilidade do método. Em um segundo momento, os resultados da classificação são relatados individualmente para as espécies *Caesalpinia peltophoroides* (subseção 5.2.1.1) e *Tipuana tipu* (subseção 5.2.1.2), as quais são mais predominantes, e para a união das espécies minoritárias (subseção 5.2.1.3).

Tabela 15 – Métricas de avaliação para a classificação do nível de deterioração.

Modelo	Acurácia	Revocação por Nível de Deterioração			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,6001 ± 0,0137	0,7080 ± 0,0190	0,3667 ± 0,0253	0,2360 ± 0,0407	0,4369 ± 0,0150	-	93,2146 ± 1,3545
k-NN	0,5724 ± 0,0155	0,6427 ± 0,0212	0,3770 ± 0,0262	0,4720 ± 0,0615	0,4972 ± 0,0163	277,1001 ± 38,9548	0,0146 ± 0,0022
SVM	0,6594 ± 0,0151	0,7780 ± 0,0201	0,3528 ± 0,0312	0,4180 ± 0,0606	0,5162 ± 0,0150	751,7045 ± 83,7896	1,4174 ± 0,2941
DT	0,5699 ± 0,0187	0,6472 ± 0,0183	0,3179 ± 0,0747	0,5780 ± 0,0895	0,5144 ± 0,0124	227,3166 ± 24,5930	0,0209 ± 0,0022
RF	0,6243 ± 0,0211	0,7697 ± 0,0302	0,2034 ± 0,0665	0,4700 ± 0,0868	0,4811 ± 0,0171	374,8324 ± 49,8257	1,2218 ± 0,7962
AdaBoost	0,5863 ± 0,0225	0,6799 ± 0,0273	0,3019 ± 0,0958	0,5280 ± 0,1369	0,5033 ± 0,0161	358,3579 ± 29,4400	1,3345 ± 0,8838
GBM	0,6157 ± 0,0218	0,7480 ± 0,0380	0,2457 ± 0,0602	0,4340 ± 0,0843	0,4759 ± 0,0221	1.059,3913 ± 136,1779	8,2820 ± 6,7602
XGBoost	0,6383 ± 0,0142	0,7670 ± 0,0220	0,2814 ± 0,0530	0,4520 ± 0,0682	0,5001 ± 0,0210	351,7188 ± 52,2971	0,1283 ± 0,1008
LightGBM	0,7992 ± 0,0178	0,8546 ± 0,0262	0,0693 ± 0,0323	0,7461 ± 0,0284	0,5567 ± 0,0112	302,4804 ± 30,9268	0,1730 ± 0,1368
CatBoost	0,5904 ± 0,0137	0,6849 ± 0,0165	0,3019 ± 0,0499	0,5380 ± 0,0676	0,5083 ± 0,0135	409,2059 ± 33,8022	0,2188 ± 0,1967
MLP	0,6587 ± 0,0514	0,8277 ± 0,0746	0,2337 ± 0,0446	0,2760 ± 0,0951	0,4458 ± 0,0259	1.160,6974 ± 131,6287	3,4340 ± 1,0531
VE	0,6431 ± 0,0117	0,7611 ± 0,0184	0,3219 ± 0,0534	0,4520 ± 0,0762	0,5117 ± 0,0154	-	10,6310 ± 11,0518
Stacking	0,6536 ± 0,0130	0,7783 ± 0,0270	0,3672 ± 0,0471	0,2840 ± 0,0702	0,4765 ± 0,0174	-	53,7286 ± 54,0487

Fonte: Elaborada pelo autor.

Tabela 16 – Métricas de avaliação para a inferência do risco de queda das árvores com base nos verdadeiros níveis de deterioração.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,6979 ± 0,0142	0,7875 ± 0,0180	0,0657 ± 0,0351	0,5314 ± 0,0264	0,4615 ± 0,0175	-	97,0280 ± 1,3180
k-NN	0,6576 ± 0,0313	0,7204 ± 0,0459	0,1757 ± 0,0595	0,5460 ± 0,0239	0,4807 ± 0,0169	325,1339 ± 35,8089	0,0153 ± 0,0007
SVM	0,7839 ± 0,0214	0,8371 ± 0,0267	0,0781 ± 0,0410	0,7348 ± 0,0260	0,5500 ± 0,0124	565,8705 ± 57,4006	1,9616 ± 0,5632
DT	0,6814 ± 0,0734	0,6971 ± 0,0974	0,1915 ± 0,1030	0,7117 ± 0,0596	0,5334 ± 0,0183	217,2334 ± 15,0995	0,0241 ± 0,0027
RF	0,7417 ± 0,0404	0,7836 ± 0,0512	0,0800 ± 0,0424	0,7182 ± 0,0357	0,5273 ± 0,0205	412,2678 ± 51,5388	0,2110 ± 0,2884
AdaBoost	0,8111 ± 0,0107	0,8766 ± 0,0128	0,0642 ± 0,0444	0,7342 ± 0,0289	0,5584 ± 0,0147	318,1362 ± 16,2830	3,2078 ± 1,1151
GBM	0,6661 ± 0,0691	0,6886 ± 0,0926	0,1632 ± 0,0674	0,6770 ± 0,0577	0,5096 ± 0,0250	860,8670 ± 79,0478	0,3359 ± 0,0966
XGBoost	0,8115 ± 0,0152	0,8668 ± 0,0196	0,0451 ± 0,0282	0,7674 ± 0,0253	0,5597 ± 0,0123	350,7690 ± 39,0769	0,1675 ± 0,1133
LightGBM	0,7992 ± 0,0178	0,8546 ± 0,0262	0,0693 ± 0,0323	0,7461 ± 0,0284	0,5567 ± 0,0112	302,4804 ± 30,9268	0,1730 ± 0,1368
CatBoost	0,8049 ± 0,0153	0,8645 ± 0,0184	0,0293 ± 0,0278	0,7475 ± 0,0267	0,5471 ± 0,0140	409,9015 ± 48,4544	0,6362 ± 0,4444
MLP	0,7261 ± 0,0641	0,8106 ± 0,1034	0,0440 ± 0,0275	0,5837 ± 0,1095	0,4794 ± 0,0340	1.304,3091 ± 167,6854	4,2561 ± 1,4830
VE	0,8144 ± 0,0155	0,8669 ± 0,0193	0,0402 ± 0,0271	0,7778 ± 0,0193	0,5616 ± 0,0104	-	4,8626 ± 1,4155
Stacking	0,7987 ± 0,0172	0,8633 ± 0,0221	0,0803 ± 0,0508	0,7179 ± 0,0314	0,5538 ± 0,0158	-	25,7983 ± 7,6640

Fonte: Elaborada pelo autor.

Tabela 17 – Métricas de avaliação para a inferência do risco de queda das árvores com base nas estimativas do nível de deterioração.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.
		Baixo	Médio	Alto	
OPF	0,5949 ± 0,0184	0,6806 ± 0,0301	0,1045 ± 0,0481	0,4152 ± 0,0386	0,4001 ± 0,0180
k-NN	0,5499 ± 0,0216	0,5707 ± 0,0379	0,1766 ± 0,0608	0,5484 ± 0,0505	0,4319 ± 0,0221
SVM	0,6700 ± 0,0218	0,7256 ± 0,0304	0,0676 ± 0,0429	0,5957 ± 0,0302	0,4629 ± 0,0142
DT	0,5346 ± 0,0453	0,4991 ± 0,0674	0,1265 ± 0,0769	0,7005 ± 0,0383	0,4420 ± 0,0140
RF	0,6493 ± 0,0214	0,6920 ± 0,0304	0,0493 ± 0,0340	0,6127 ± 0,0371	0,4513 ± 0,0107
AdaBoost	0,6358 ± 0,0159	0,6616 ± 0,0324	0,0395 ± 0,0347	0,6562 ± 0,0614	0,4524 ± 0,0148
GBM	0,5322 ± 0,0614	0,5765 ± 0,0997	0,1779 ± 0,0974	0,4546 ± 0,0791	0,4030 ± 0,0190
XGBoost	0,6754 ± 0,0115	0,7365 ± 0,0254	0,0341 ± 0,0217	0,5928 ± 0,0502	0,4545 ± 0,0123
LightGBM	0,6582 ± 0,0224	0,7014 ± 0,0451	0,0360 ± 0,0329	0,6171 ± 0,0653	0,4515 ± 0,0143
CatBoost	0,6335 ± 0,0143	0,6447 ± 0,0194	0,0202 ± 0,0178	0,6932 ± 0,0224	0,4527 ± 0,0087
MLP	0,6422 ± 0,0609	0,7657 ± 0,1151	0,0394 ± 0,0267	0,3700 ± 0,1171	0,3917 ± 0,0211
VE	0,6746 ± 0,0155	0,7250 ± 0,0238	0,0343 ± 0,0265	0,6228 ± 0,0258	0,4607 ± 0,0124
Stacking	0,6675 ± 0,0157	0,7438 ± 0,0285	0,0433 ± 0,0292	0,5322 ± 0,0492	0,4398 ± 0,0136

Fonte: Elaborada pelo autor.

5.2.1.1 *Caesalpinia peltophoroides*

Esta subseção trata do desempenho dos modelos em árvores urbanas da espécie *Caesalpinia peltophoroides*. Primeiramente, a Tabela 18 aborda os resultados da classificação do nível de deterioração interna. Em seguida, na Tabela 19, são apresentados os resultados da inferência do risco de queda com base nos níveis reais de deterioração. Então, na Tabela 20, são relatados os achados da estimativa do risco utilizando os níveis preditos de deterioração.

Tabela 18 – Métricas de avaliação para a classificação do nível de deterioração de árvores da espécie *Caesalpinia peltophoroides*.

Modelo	Acurácia	Revocação por Nível de Deterioração			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,6472 ± 0,0184	0,7241 ± 0,0221	0,3025 ± 0,0363	0,0600 ± 0,0671	0,3622 ± 0,0286	-	15,6351 ± 0,3131
k-NN	0,5684 ± 0,0273	0,6166 ± 0,0321	0,3625 ± 0,0560	0,1200 ± 0,0881	0,3664 ± 0,0396	117,2109 ± 14,4504	0,0045 ± 0,0006
SVM	0,6552 ± 0,0383	0,7343 ± 0,0537	0,2800 ± 0,0762	0,2200 ± 0,1316	0,4114 ± 0,0392	181,0849 ± 23,4601	0,9481 ± 0,8578
DT	0,5223 ± 0,0425	0,5664 ± 0,0525	0,2750 ± 0,1274	0,5800 ± 0,1509	0,4738 ± 0,0333	101,8835 ± 11,7389	0,0080 ± 0,0009
RF	0,6350 ± 0,0376	0,7053 ± 0,0469	0,2925 ± 0,0442	0,3200 ± 0,1416	0,4393 ± 0,0429	158,9577 ± 23,3625	0,1271 ± 0,1355
AdaBoost	0,5234 ± 0,0632	0,5669 ± 0,0900	0,2900 ± 0,1343	0,5000 ± 0,1751	0,4523 ± 0,0465	173,5888 ± 17,7206	0,2118 ± 0,3067
GBM	0,6042 ± 0,0329	0,6607 ± 0,0455	0,3575 ± 0,0591	0,1200 ± 0,0881	0,3794 ± 0,0317	413,2461 ± 62,5945	0,7723 ± 0,7701
XGBoost	0,6213 ± 0,0327	0,6869 ± 0,0422	0,3100 ± 0,0529	0,2600 ± 0,1321	0,4190 ± 0,0484	148,1327 ± 17,3771	0,0714 ± 0,0620
LightGBM	0,5223 ± 0,0396	0,5554 ± 0,0520	0,3650 ± 0,0887	0,3400 ± 0,1622	0,4201 ± 0,0469	150,1233 ± 16,6990	0,0197 ± 0,0121
CatBoost	0,5832 ± 0,0321	0,6189 ± 0,0473	0,4225 ± 0,1110	0,3200 ± 0,1639	0,4538 ± 0,0448	249,6732 ± 28,2378	0,0961 ± 0,1164
MLP	0,6979 ± 0,0657	0,7867 ± 0,0794	0,2775 ± 0,0556	0,2000 ± 0,1305	0,4214 ± 0,0369	865,6969 ± 149,1295	3,8024 ± 0,7146
VE	0,6366 ± 0,0362	0,7076 ± 0,0516	0,2850 ± 0,0929	0,3600 ± 0,1491	0,4509 ± 0,0416	-	5,2653 ± 2,7495
Stacking	0,7070 ± 0,0294	0,7968 ± 0,0405	0,2825 ± 0,0575	0,2000 ± 0,1168	0,4264 ± 0,0393	-	26,6256 ± 13,5345

Fonte: Elaborada pelo autor.

Tabela 19 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie *Caesalpinia peltophoroides* com base nos verdadeiros níveis de deterioração.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,7097 ± 0,0215	0,7780 ± 0,0280	0,1127 ± 0,0661	0,4068 ± 0,0445	0,4325 ± 0,0277	-	16,0995 ± 0,0902
k-NN	0,5931 ± 0,0378	0,6351 ± 0,0443	0,2884 ± 0,1222	0,4219 ± 0,0609	0,4485 ± 0,0354	135,7355 ± 16,8883	0,0052 ± 0,0004
SVM	0,6770 ± 0,0613	0,7039 ± 0,0764	0,2867 ± 0,1384	0,5849 ± 0,0808	0,5252 ± 0,0393	180,3337 ± 22,0620	0,3363 ± 0,1070
DT	0,6918 ± 0,0642	0,7211 ± 0,0783	0,1553 ± 0,0907	0,6635 ± 0,0395	0,5133 ± 0,0269	83,2499 ± 4,3011	0,0093 ± 0,0009
RF	0,5653 ± 0,0682	0,5602 ± 0,0805	0,4436 ± 0,1266	0,6409 ± 0,0484	0,5482 ± 0,0395	172,3163 ± 16,4618	0,1601 ± 0,2274
AdaBoost	0,7314 ± 0,0696	0,7675 ± 0,0834	0,2045 ± 0,1223	0,6591 ± 0,0564	0,5437 ± 0,0361	151,3229 ± 15,3193	0,8004 ± 0,4987
GBM	0,6537 ± 0,0547	0,6762 ± 0,0674	0,2811 ± 0,1233	0,6307 ± 0,0549	0,5294 ± 0,0410	411,1574 ± 40,0086	1,1327 ± 1,1909
XGBoost	0,6213 ± 0,0327	0,6869 ± 0,0422	0,3100 ± 0,0529	0,2600 ± 0,1321	0,4190 ± 0,0484	148,1327 ± 17,3771	0,0714 ± 0,0620
LightGBM	0,6994 ± 0,0500	0,7194 ± 0,0580	0,3190 ± 0,1296	0,6721 ± 0,0486	0,5701 ± 0,0441	142,5811 ± 18,3741	0,0649 ± 0,0950
CatBoost	0,7291 ± 0,0619	0,7580 ± 0,0773	0,1920 ± 0,1152	0,6808 ± 0,0527	0,5436 ± 0,0343	227,6202 ± 23,2370	0,0250 ± 0,0146
MLP	0,7459 ± 0,0582	0,8107 ± 0,0757	0,1097 ± 0,0944	0,4694 ± 0,0924	0,4633 ± 0,0370	859,7969 ± 135,1629	3,2084 ± 0,5176
VE	0,7550 ± 0,0369	0,7911 ± 0,0471	0,1774 ± 0,1119	0,6875 ± 0,0439	0,5520 ± 0,0318	-	3,1927 ± 2,4181
Stacking	0,7509 ± 0,0306	0,8007 ± 0,0405	0,2135 ± 0,1280	0,5706 ± 0,0695	0,5283 ± 0,0464	-	15,9575 ± 11,6643

Fonte: Elaborada pelo autor.

Tabela 20 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie *Caesalpinia peltophoroides* com base nas estimativas do nível de deterioração.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.
		Baixo	Médio	Alto	
OPF	0,6316 ± 0,0294	0,7036 ± 0,0361	0,1765 ± 0,1053	0,2438 ± 0,0453	0,3746 ± 0,0417
k-NN	0,5253 ± 0,0413	0,5627 ± 0,0484	0,3038 ± 0,1223	0,3263 ± 0,0721	0,3976 ± 0,0354
SVM	0,5924 ± 0,0623	0,6295 ± 0,0832	0,2642 ± 0,1356	0,4007 ± 0,1017	0,4315 ± 0,0423
DT	0,4640 ± 0,0722	0,4648 ± 0,0986	0,2402 ± 0,1208	0,5329 ± 0,1225	0,4126 ± 0,0290
RF	0,4830 ± 0,0662	0,4934 ± 0,0849	0,4384 ± 0,1415	0,4234 ± 0,1098	0,4517 ± 0,0550
AdaBoost	0,5185 ± 0,0816	0,5316 ± 0,1055	0,2004 ± 0,1304	0,5247 ± 0,1199	0,4189 ± 0,0364
GBM	0,5368 ± 0,0696	0,5793 ± 0,0914	0,2501 ± 0,1244	0,3178 ± 0,0880	0,3824 ± 0,0359
XGBoost	0,5623 ± 0,0485	0,6014 ± 0,0669	0,2030 ± 0,1237	0,4215 ± 0,0970	0,4086 ± 0,0421
LightGBM	0,4766 ± 0,0651	0,4803 ± 0,0871	0,2785 ± 0,1369	0,5202 ± 0,1175	0,4263 ± 0,0379
CatBoost	0,5566 ± 0,0562	0,5789 ± 0,0765	0,1822 ± 0,1061	0,5055 ± 0,1279	0,4222 ± 0,0343
MLP	0,6480 ± 0,0676	0,7158 ± 0,0891	0,1461 ± 0,0987	0,2819 ± 0,1030	0,3813 ± 0,0384
VE	0,5669 ± 0,0680	0,5956 ± 0,0890	0,2390 ± 0,1222	0,4946 ± 0,1105	0,4431 ± 0,0487
Stacking	0,6084 ± 0,0542	0,6646 ± 0,0730	0,3149 ± 0,1321	0,3203 ± 0,1048	0,4332 ± 0,0417

Fonte: Elaborada pelo autor.

5.2.1.2 *Tipuana tipu*

Nesta subseção, aborda-se a performance dos algoritmos em árvores urbanas da espécie *Tipuana tipu*. Inicialmente, a Tabela 21 aborda os resultados da classificação do nível de deterioração interna. Então, na Tabela 22, são apresentados os resultados da inferência do risco de queda com base nos níveis reais de deterioração. Por último, na Tabela 23, são expostos os achados da estimativa do risco utilizando os níveis preditos de deterioração.

Tabela 21 – Métricas de avaliação para a classificação do nível de deterioração de árvores da espécie *Tipuana tipu*.

Modelo	Acurácia	Revocação por Nível de Deterioração			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,4630 ± 0,0273	0,5410 ± 0,0392	0,4078 ± 0,0415	0,2615 ± 0,0492	0,4034 ± 0,0277	-	6,6564 ± 0,0877
k-NN	0,4759 ± 0,0207	0,5288 ± 0,0348	0,4178 ± 0,0298	0,3969 ± 0,0755	0,4478 ± 0,0252	99,9585 ± 15,3406	0,0031 ± 0,0003
SVM	0,5530 ± 0,0213	0,6827 ± 0,0590	0,4300 ± 0,0797	0,3046 ± 0,0606	0,4724 ± 0,0289	147,2253 ± 19,7466	0,1762 ± 0,0752
DT	0,4981 ± 0,0224	0,5749 ± 0,0422	0,3689 ± 0,0915	0,5077 ± 0,1129	0,4838 ± 0,0250	79,2079 ± 9,3782	0,0061 ± 0,0005
RF	0,5193 ± 0,0228	0,6569 ± 0,0578	0,3789 ± 0,0688	0,2831 ± 0,0817	0,4396 ± 0,0263	145,8140 ± 15,6784	0,1459 ± 0,1736
AdaBoost	0,5141 ± 0,0275	0,6386 ± 0,0571	0,3378 ± 0,0567	0,4369 ± 0,0953	0,4711 ± 0,0232	135,5231 ± 17,6794	0,8448 ± 0,5037
GBM	0,5289 ± 0,0177	0,6285 ± 0,0338	0,4000 ± 0,0388	0,4338 ± 0,0827	0,4874 ± 0,0241	291,0682 ± 32,8220	1,0525 ± 1,2056
XGBoost	0,5378 ± 0,0193	0,6603 ± 0,0424	0,3722 ± 0,0513	0,4400 ± 0,0990	0,4909 ± 0,0300	119,6074 ± 16,8413	0,1055 ± 0,0692
LightGBM	0,5148 ± 0,0202	0,5688 ± 0,0361	0,4200 ± 0,0509	0,5323 ± 0,0777	0,5070 ± 0,0243	126,7625 ± 16,2073	0,0173 ± 0,0104
CatBoost	0,5111 ± 0,0225	0,5912 ± 0,0378	0,3722 ± 0,0430	0,5323 ± 0,0724	0,4986 ± 0,0237	217,1609 ± 24,4105	0,0408 ± 0,0359
MLP	0,5381 ± 0,0291	0,7227 ± 0,0994	0,3867 ± 0,1014	0,1200 ± 0,0467	0,4098 ± 0,0242	758,3823 ± 104,7701	2,9101 ± 0,5087
VE	0,5256 ± 0,0201	0,6034 ± 0,0378	0,3911 ± 0,0240	0,5446 ± 0,0735	0,5130 ± 0,0235	-	2,5097 ± 1,6189
Stacking	0,5530 ± 0,0190	0,6644 ± 0,0413	0,4433 ± 0,0511	0,3508 ± 0,0746	0,4862 ± 0,0265	-	13,2903 ± 8,4634

Fonte: Elaborada pelo autor.

Tabela 22 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie *Tipuana tipu* com base nos verdadeiros níveis de deterioração.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,6337 ± 0,0246	0,6977 ± 0,0308	0,1160 ± 0,0548	0,6087 ± 0,0365	0,4741 ± 0,0261	-	7,6960 ± 0,0767
k-NN	0,6289 ± 0,0286	0,6959 ± 0,0334	0,3123 ± 0,0955	0,5692 ± 0,0372	0,5258 ± 0,0366	114,4985 ± 14,4581	0,0035 ± 0,0001
SVM	0,7185 ± 0,0409	0,7654 ± 0,0392	0,1369 ± 0,0770	0,7246 ± 0,0639	0,5423 ± 0,0334	142,2581 ± 21,4621	0,4670 ± 0,5241
DT	0,6478 ± 0,0403	0,7414 ± 0,0372	0,4282 ± 0,0988	0,5344 ± 0,0786	0,5680 ± 0,0304	82,6740 ± 8,0382	0,0069 ± 0,0006
RF	0,7007 ± 0,0460	0,7743 ± 0,0552	0,1178 ± 0,0675	0,6639 ± 0,0666	0,5187 ± 0,0210	152,1463 ± 17,8443	0,2196 ± 0,2021
AdaBoost	0,7252 ± 0,0462	0,7737 ± 0,0501	0,1242 ± 0,0788	0,7354 ± 0,0734	0,5444 ± 0,0234	137,4644 ± 16,7469	0,7352 ± 0,3133
GBM	0,6993 ± 0,0251	0,7880 ± 0,0224	0,2593 ± 0,1195	0,6255 ± 0,0622	0,5576 ± 0,0408	293,1290 ± 27,0871	0,6926 ± 0,6728
XGBoost	0,7522 ± 0,0315	0,8139 ± 0,0320	0,1050 ± 0,0787	0,7481 ± 0,0571	0,5557 ± 0,0173	129,4929 ± 17,6246	0,0684 ± 0,0599
LightGBM	0,7407 ± 0,0309	0,8108 ± 0,0302	0,1035 ± 0,0748	0,7202 ± 0,0606	0,5448 ± 0,0201	131,3599 ± 16,3660	0,1273 ± 0,1339
CatBoost	0,7463 ± 0,0291	0,8023 ± 0,0282	0,0650 ± 0,0534	0,7599 ± 0,0538	0,5424 ± 0,0209	205,0078 ± 20,2002	1,0587 ± 1,2422
MLP	0,6756 ± 0,0705	0,7173 ± 0,1141	0,1587 ± 0,0942	0,6822 ± 0,0822	0,5194 ± 0,0380	621,2165 ± 90,4242	2,4125 ± 0,5545
VE	0,7526 ± 0,0243	0,8006 ± 0,0306	0,1753 ± 0,1079	0,7610 ± 0,0518	0,5789 ± 0,0285	-	3,9678 ± 1,7976
Stacking	0,7656 ± 0,0251	0,8061 ± 0,0325	0,1392 ± 0,0693	0,7946 ± 0,0333	0,5800 ± 0,0200	-	21,4912 ± 9,7571

Fonte: Elaborada pelo autor.

Tabela 23 – Métricas de avaliação para a inferência do risco de queda de árvores da espécie *Tipuana tipu* com base nas estimativas do nível de deterioração.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.
		Baixo	Médio	Alto	
OPF	0,4852 ± 0,0213	0,5444 ± 0,0448	0,0966 ± 0,0655	0,4494 ± 0,0513	0,3634 ± 0,0225
k-NN	0,4844 ± 0,0242	0,5146 ± 0,0446	0,1899 ± 0,0736	0,4730 ± 0,0606	0,3925 ± 0,0265
SVM	0,5385 ± 0,0254	0,6071 ± 0,0348	0,1312 ± 0,0920	0,4826 ± 0,0825	0,4069 ± 0,0323
DT	0,4830 ± 0,0332	0,5446 ± 0,0662	0,2024 ± 0,0841	0,4219 ± 0,1076	0,3896 ± 0,0331
RF	0,5393 ± 0,0262	0,6104 ± 0,0526	0,1540 ± 0,0904	0,4840 ± 0,0730	0,4161 ± 0,0246
AdaBoost	0,5393 ± 0,0313	0,5811 ± 0,0616	0,0400 ± 0,0357	0,5347 ± 0,0928	0,3853 ± 0,0214
GBM	0,5233 ± 0,0260	0,5756 ± 0,0514	0,1691 ± 0,0900	0,4917 ± 0,0793	0,4121 ± 0,0316
XGBoost	0,5452 ± 0,0392	0,6134 ± 0,0621	0,1069 ± 0,0888	0,4983 ± 0,0914	0,4062 ± 0,0279
LightGBM	0,5296 ± 0,0261	0,5866 ± 0,0637	0,0959 ± 0,0744	0,5032 ± 0,1042	0,3952 ± 0,0252
CatBoost	0,5489 ± 0,0259	0,5771 ± 0,0497	0,0160 ± 0,0224	0,5814 ± 0,0979	0,3915 ± 0,0264
MLP	0,5000 ± 0,0534	0,5875 ± 0,1161	0,1223 ± 0,0879	0,4038 ± 0,1141	0,3712 ± 0,0238
VE	0,5556 ± 0,0315	0,6041 ± 0,0650	0,0880 ± 0,0635	0,5539 ± 0,1014	0,4154 ± 0,0246
Stacking	0,5778 ± 0,0218	0,6563 ± 0,0389	0,0547 ± 0,0546	0,5210 ± 0,0794	0,4106 ± 0,0233

Fonte: Elaborada pelo autor.

5.2.1.3 Espécies Minoritárias

Por último, esta subseção concentra-se no desempenho dos modelos na união das espécies minoritárias, que são: *Caesalpinia ferrea* var. *leiostachya*, *Holocalyx balansae*, *Jacaranda mimosaeifolia*, *Ligustrum lucidum* e *Tibouchina granulosa*. A Tabela 24 relata os resultados da classificação do nível de deterioração. Em seguida, na Tabela 25, são apresentados os resultados da inferência do risco de queda com base nos níveis reais de deterioração. Então, a Tabela 26 mostra os achados da previsão do risco utilizando os níveis preditos de deterioração.

Tabela 24 – Métricas de avaliação para a classificação do nível de deterioração de árvores das espécies minoritárias.

Modelo	Acurácia	Revocação por Nível de Deterioração			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,6174 ± 0,0233	0,7127 ± 0,0299	0,2400 ± 0,0544	0,3200 ± 0,0745	0,4242 ± 0,0287	-	8,2712 ± 0,2199
k-NN	0,5653 ± 0,0401	0,6247 ± 0,0515	0,3567 ± 0,0712	0,3000 ± 0,1011	0,4271 ± 0,0335	346,7674 ± 54,7395	0,0034 ± 0,0003
SVM	0,6774 ± 0,0255	0,8013 ± 0,0337	0,1300 ± 0,0390	0,4600 ± 0,1420	0,4638 ± 0,0389	297,6884 ± 33,4009	0,1760 ± 0,0494
DT	0,5237 ± 0,0436	0,5313 ± 0,0675	0,5167 ± 0,1188	0,4300 ± 0,0991	0,4927 ± 0,0357	266,2312 ± 24,0256	0,0067 ± 0,0006
RF	0,6489 ± 0,0312	0,7520 ± 0,0484	0,1933 ± 0,0777	0,4700 ± 0,1142	0,4718 ± 0,0419	366,2275 ± 39,9630	0,2052 ± 0,2031
AdaBoost	0,6100 ± 0,0332	0,6727 ± 0,0508	0,3600 ± 0,0976	0,4200 ± 0,1120	0,4842 ± 0,0405	326,1101 ± 35,4881	0,7340 ± 0,4279
GBM	0,5889 ± 0,0301	0,6447 ± 0,0448	0,3767 ± 0,0797	0,3900 ± 0,0830	0,4704 ± 0,0285	545,0897 ± 97,3950	1,0540 ± 1,3758
XGBoost	0,6232 ± 0,0225	0,6887 ± 0,0365	0,3533 ± 0,0945	0,4500 ± 0,1130	0,4973 ± 0,0344	466,7761 ± 69,6101	0,7724 ± 0,4074
LightGBM	0,5721 ± 0,0331	0,6113 ± 0,0482	0,4200 ± 0,0775	0,4400 ± 0,1314	0,4904 ± 0,0428	369,1376 ± 43,8429	0,0434 ± 0,0498
CatBoost	0,6332 ± 0,0260	0,7133 ± 0,0382	0,2700 ± 0,0736	0,5200 ± 0,0919	0,5011 ± 0,0334	495,2784 ± 59,7084	0,2312 ± 0,3973
MLP	0,7111 ± 0,0348	0,8433 ± 0,0466	0,2200 ± 0,0607	0,2000 ± 0,0826	0,4211 ± 0,0345	812,2549 ± 110,9303	3,4500 ± 0,5471
VE	0,6574 ± 0,0210	0,7273 ± 0,0337	0,3767 ± 0,0815	0,4500 ± 0,0876	0,5180 ± 0,0334	-	4,1930 ± 1,6639
Stacking	0,6558 ± 0,0251	0,7260 ± 0,0467	0,3767 ± 0,0871	0,4400 ± 0,1064	0,5142 ± 0,0459	-	21,3233 ± 7,9782

Fonte: Elaborada pelo autor.

Tabela 25 – Métricas de avaliação para a inferência do risco de queda de árvores das espécies minoritárias com base nos verdadeiros níveis de deterioração.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,7026 ± 0,0172	0,7883 ± 0,0223	0,0833 ± 0,0653	0,4538 ± 0,0477	0,4418 ± 0,0279	-	7,9637 ± 0,1865
k-NN	0,6495 ± 0,0401	0,7179 ± 0,0577	0,1680 ± 0,1192	0,4616 ± 0,0625	0,4492 ± 0,0402	318,9080 ± 71,1177	0,0033 ± 0,0003
SVM	0,6800 ± 0,0484	0,7227 ± 0,0677	0,2747 ± 0,1254	0,5979 ± 0,0586	0,5318 ± 0,0398	283,7603 ± 54,7623	0,1119 ± 0,0136
DT	0,7742 ± 0,0349	0,8394 ± 0,0415	0,1927 ± 0,1058	0,6046 ± 0,0550	0,5456 ± 0,0292	203,7538 ± 32,7726	0,0068 ± 0,0006
RF	0,6758 ± 0,0644	0,7163 ± 0,0775	0,2447 ± 0,1357	0,5920 ± 0,0690	0,5177 ± 0,0508	325,7638 ± 58,1923	0,2462 ± 0,2196
AdaBoost	0,8247 ± 0,0249	0,8951 ± 0,0252	0,0813 ± 0,0708	0,6653 ± 0,0659	0,5473 ± 0,0236	277,4222 ± 61,4308	0,8951 ± 0,4344
GBM	0,7363 ± 0,0354	0,7975 ± 0,0439	0,1367 ± 0,0825	0,5898 ± 0,0678	0,5080 ± 0,0283	402,0206 ± 40,5245	1,1359 ± 1,2420
XGBoost	0,7595 ± 0,0423	0,8254 ± 0,0456	0,1647 ± 0,1077	0,5966 ± 0,0676	0,5289 ± 0,0442	382,6876 ± 58,0501	0,3011 ± 0,2303
LightGBM	0,7753 ± 0,0374	0,8375 ± 0,0465	0,1693 ± 0,1219	0,6396 ± 0,0693	0,5488 ± 0,0414	287,7519 ± 49,2184	0,0293 ± 0,0200
CatBoost	0,8011 ± 0,0241	0,8779 ± 0,0330	0,1293 ± 0,1004	0,6191 ± 0,0667	0,5421 ± 0,0372	362,4418 ± 60,0535	1,7257 ± 2,9157
MLP	0,7811 ± 0,0217	0,8721 ± 0,0288	0,0360 ± 0,0415	0,5417 ± 0,0588	0,4833 ± 0,0276	708,1178 ± 108,8349	3,0242 ± 0,5981
VE	0,8205 ± 0,0201	0,8947 ± 0,0211	0,1260 ± 0,0731	0,6324 ± 0,0603	0,5510 ± 0,0229	-	2,6240 ± 1,1524
Stacking	0,7958 ± 0,0264	0,8667 ± 0,0313	0,0867 ± 0,0936	0,6419 ± 0,0526	0,5318 ± 0,0359	-	13,5191 ± 5,6909

Fonte: Elaborada pelo autor.

Tabela 26 – Métricas de avaliação para a inferência do risco de queda de árvores das espécies minoritárias com base nas estimativas do nível de deterioração.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.
		Baixo	Médio	Alto	
OPF	0,6000 ± 0,0321	0,6879 ± 0,0424	0,1367 ± 0,0992	0,3223 ± 0,0490	0,3823 ± 0,0455
k-NN	0,5258 ± 0,0438	0,5725 ± 0,0656	0,1600 ± 0,0992	0,4030 ± 0,0724	0,3785 ± 0,0361
SVM	0,6063 ± 0,0335	0,6510 ± 0,0487	0,2427 ± 0,1157	0,5034 ± 0,0621	0,4657 ± 0,0389
DT	0,4932 ± 0,0486	0,4709 ± 0,0595	0,3180 ± 0,1683	0,6267 ± 0,0771	0,4719 ± 0,0499
RF	0,6095 ± 0,0557	0,6503 ± 0,0803	0,1580 ± 0,0889	0,5285 ± 0,0706	0,4456 ± 0,0360
AdaBoost	0,6289 ± 0,0323	0,6692 ± 0,0532	0,0613 ± 0,0543	0,5799 ± 0,0939	0,4368 ± 0,0254
GBM	0,5637 ± 0,0465	0,6017 ± 0,0683	0,1213 ± 0,1022	0,4949 ± 0,0844	0,4060 ± 0,0433
XGBoost	0,6042 ± 0,0288	0,6480 ± 0,0466	0,0900 ± 0,0708	0,5396 ± 0,0968	0,4259 ± 0,0361
LightGBM	0,5805 ± 0,0465	0,6044 ± 0,0729	0,1633 ± 0,1221	0,5752 ± 0,1158	0,4477 ± 0,0493
CatBoost	0,6632 ± 0,0302	0,7088 ± 0,0364	0,1367 ± 0,0992	0,5549 ± 0,0800	0,4668 ± 0,0413
MLP	0,6879 ± 0,0335	0,8099 ± 0,0467	0,0333 ± 0,0477	0,2939 ± 0,0896	0,3790 ± 0,0286
VE	0,6658 ± 0,0254	0,7151 ± 0,0416	0,1233 ± 0,1180	0,5709 ± 0,0777	0,4698 ± 0,0450
Stacking	0,6542 ± 0,0274	0,7153 ± 0,0501	0,0400 ± 0,0560	0,5320 ± 0,1054	0,4291 ± 0,0344

Fonte: Elaborada pelo autor.

5.2.2 Classificação Binária

Esta subseção apresenta os resultados da classificação binária do nível de deterioração, realizada através do agrupamento dos níveis “médio” e “alto” da tarefa multiclasse em uma classe denominada “significativo”. A Tabela 27 aborda os resultados da classificação do nível de deterioração. Em seguida, na Tabela 28, são apresentados os resultados da inferência do risco de queda com base nos níveis reais de deterioração. Posteriormente, na Tabela 29, são expressos os achados da estimativa do risco utilizando os níveis preditos de deterioração.

Tabela 27 – Métricas de avaliação para a classificação binária do nível de deterioração.

Modelo	Acurácia	Revocação por Nível de Deterioração		Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Mínimo	Significativo			
OPF	0,6757 ± 0,0126	0,7488 ± 0,0173	0,4966 ± 0,0258	0,6227 ± 0,0136	-	40,4722 ± 1,2171
k-NN	0,7033 ± 0,0128	0,7467 ± 0,0172	0,5972 ± 0,0310	0,6719 ± 0,0153	226,2416 ± 24,4000	0,0089 ± 0,0008
SVM	0,7312 ± 0,0117	0,8204 ± 0,0327	0,5131 ± 0,0762	0,6667 ± 0,0252	479,1509 ± 63,3637	0,7725 ± 0,2964
DT	0,7244 ± 0,0157	0,7737 ± 0,0280	0,6041 ± 0,0632	0,6889 ± 0,0246	186,0719 ± 28,6171	0,0137 ± 0,0017
RF	0,7279 ± 0,0105	0,8295 ± 0,0285	0,4798 ± 0,0663	0,6546 ± 0,0221	297,5781 ± 40,4769	0,5455 ± 0,4061
AdaBoost	0,7319 ± 0,0113	0,7887 ± 0,0261	0,5927 ± 0,0563	0,6907 ± 0,0194	259,0821 ± 18,5824	1,1840 ± 0,7276
GBM	0,7453 ± 0,0111	0,8456 ± 0,0209	0,4994 ± 0,0534	0,6725 ± 0,0203	346,4125 ± 31,8871	1,2256 ± 1,1330
XGBoost	0,7406 ± 0,0092	0,8212 ± 0,0223	0,5432 ± 0,0558	0,6822 ± 0,0195	290,2832 ± 36,9108	0,0413 ± 0,0271
LightGBM	0,7329 ± 0,0094	0,7691 ± 0,0198	0,6440 ± 0,0369	0,7066 ± 0,0129	228,5397 ± 24,9971	0,0236 ± 0,0083
CatBoost	0,7364 ± 0,0099	0,7668 ± 0,0166	0,6619 ± 0,0279	0,7144 ± 0,0116	321,8008 ± 39,0284	0,3058 ± 0,3046
MLP	0,7424 ± 0,0122	0,8476 ± 0,0280	0,4846 ± 0,0557	0,6661 ± 0,0189	835,7949 ± 108,4311	1,9401 ± 0,3893
VE	0,7424 ± 0,0091	0,7834 ± 0,0162	0,6418 ± 0,0229	0,7126 ± 0,0091	-	3,5962 ± 3,4201
Stacking	0,7449 ± 0,0117	0,8148 ± 0,0181	0,5738 ± 0,0285	0,6943 ± 0,0130	-	18,5493 ± 16,4358

Fonte: Elaborada pelo autor.

Tabela 28 – Métricas de avaliação para a inferência do risco de queda das árvores com base nos verdadeiros níveis binários de deterioração.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.	Tempo de HPO	Tempo de Treino
		Baixo	Médio	Alto			
OPF	0,7004 ± 0,0123	0,7880 ± 0,0163	0,0720 ± 0,0271	0,5382 ± 0,0295	0,4661 ± 0,0126	-	98,7154 ± 2,5530
k-NN	0,6299 ± 0,0398	0,6840 ± 0,0577	0,1770 ± 0,0517	0,5413 ± 0,0352	0,4674 ± 0,0195	326,7484 ± 38,3770	0,0150 ± 0,0004
SVM	0,7764 ± 0,0256	0,8197 ± 0,0332	0,0884 ± 0,0449	0,7618 ± 0,0278	0,5566 ± 0,0151	606,1853 ± 95,7291	1,4826 ± 0,4537
DT	0,7411 ± 0,0434	0,7667 ± 0,0659	0,1196 ± 0,0672	0,7690 ± 0,0480	0,5518 ± 0,0160	220,5550 ± 20,5161	0,0216 ± 0,0027
RF	0,7392 ± 0,0457	0,7784 ± 0,0547	0,1095 ± 0,0515	0,7248 ± 0,0515	0,5376 ± 0,0257	398,8835 ± 47,0754	0,3106 ± 0,2704
AdaBoost	0,7910 ± 0,0337	0,8457 ± 0,0459	0,0600 ± 0,0440	0,7468 ± 0,0324	0,5508 ± 0,0172	338,4242 ± 26,1013	4,6197 ± 1,2350
GBM	0,7181 ± 0,0514	0,7406 ± 0,0699	0,1449 ± 0,0598	0,7442 ± 0,0280	0,5432 ± 0,0158	975,9939 ± 97,7207	0,8660 ± 1,1676
XGBoost	0,8064 ± 0,0187	0,8612 ± 0,0231	0,0392 ± 0,0329	0,7662 ± 0,0384	0,5556 ± 0,0147	330,1663 ± 40,5335	0,1568 ± 0,0930
LightGBM	0,8092 ± 0,0173	0,8676 ± 0,0234	0,0221 ± 0,0192	0,7619 ± 0,0404	0,5505 ± 0,0129	290,1171 ± 24,9772	0,1971 ± 0,1287
CatBoost	0,8021 ± 0,0260	0,8597 ± 0,0374	0,0613 ± 0,0390	0,7535 ± 0,0523	0,5582 ± 0,0170	389,9059 ± 40,0246	0,8413 ± 0,7022
MLP	0,7849 ± 0,0281	0,8681 ± 0,0364	0,0755 ± 0,0359	0,6446 ± 0,0640	0,5294 ± 0,0211	1.138,7351 ± 142,8423	4,6797 ± 0,9142
VE	0,8313 ± 0,0093	0,8850 ± 0,0095	0,0180 ± 0,0175	0,8002 ± 0,0184	0,5678 ± 0,0098	-	5,0984 ± 1,6065
Stacking	0,8154 ± 0,0165	0,8714 ± 0,0192	0,0674 ± 0,0424	0,7678 ± 0,0267	0,5689 ± 0,0111	-	26,7343 ± 8,2207

Fonte: Elaborada pelo autor.

Tabela 29 – Métricas de avaliação para a inferência do risco de queda das árvores com base nas estimativas binárias do nível de deterioração.

Modelo	Acurácia	Revocação por Risco de Queda			Acurácia Bal.
		Baixo	Médio	Alto	
OPF	0,6122 ± 0,0217	0,6987 ± 0,0354	0,0709 ± 0,0430	0,4381 ± 0,0339	0,4025 ± 0,0188
k-NN	0,5610 ± 0,0335	0,6029 ± 0,0488	0,1740 ± 0,0459	0,4991 ± 0,0219	0,4253 ± 0,0207
SVM	0,6754 ± 0,0171	0,7540 ± 0,0331	0,0986 ± 0,0454	0,5273 ± 0,0755	0,4600 ± 0,0191
DT	0,5915 ± 0,0494	0,6273 ± 0,0709	0,1251 ± 0,0716	0,5632 ± 0,0681	0,4386 ± 0,0261
RF	0,6482 ± 0,0357	0,7263 ± 0,0510	0,0920 ± 0,0510	0,5011 ± 0,0691	0,4398 ± 0,0222
AdaBoost	0,6568 ± 0,0258	0,7260 ± 0,0432	0,0579 ± 0,0450	0,5469 ± 0,0621	0,4436 ± 0,0177
GBM	0,5785 ± 0,0605	0,6448 ± 0,0859	0,1672 ± 0,0843	0,4495 ± 0,0635	0,4205 ± 0,0257
XGBoost	0,6879 ± 0,0163	0,7780 ± 0,0215	0,0295 ± 0,0301	0,5251 ± 0,0393	0,4442 ± 0,0133
LightGBM	0,6651 ± 0,0251	0,7256 ± 0,0402	0,0169 ± 0,0167	0,5919 ± 0,0480	0,4448 ± 0,0163
CatBoost	0,6685 ± 0,0230	0,7240 ± 0,0384	0,0144 ± 0,0142	0,6094 ± 0,0430	0,4493 ± 0,0126
MLP	0,6957 ± 0,0284	0,8232 ± 0,0445	0,0225 ± 0,0211	0,4167 ± 0,0555	0,4208 ± 0,0161
VE	0,6907 ± 0,0117	0,7486 ± 0,0181	0,0182 ± 0,0253	0,6246 ± 0,0272	0,4638 ± 0,0091
Stacking	0,6974 ± 0,0186	0,7843 ± 0,0257	0,0242 ± 0,0191	0,5436 ± 0,0295	0,4507 ± 0,0101

Fonte: Elaborada pelo autor.

6 Discussão

Este capítulo discute o desempenho dos modelos de aprendizado de máquina utilizados nos experimentos relacionados à inferência da deterioração interna do lenho de árvores urbanas. Neste contexto, as seções 6.1 e 6.2 abordam, respectivamente, os resultados da previsão da porcentagem de área deteriorada e da classificação do nível de deterioração. Para encerrar as discussões, a seção 6.3 apresenta as considerações finais acerca dos resultados.

6.1 Estimativa do Percentual da Área Deteriorada

A presente subseção aborda, inicialmente, os resultados da modelagem por regressão do percentual de área deteriorada na seção transversal de árvores urbanas, considerando todas as espécies da base de dados. Conforme evidenciado na Tabela 3, que apresenta os resultados da estimativa do percentual de área deteriorada, o CatBoost demonstrou o melhor desempenho entre os modelos, apresentando os melhores valores de MAE, MSE e R^2 . No entanto, é importante observar que os modelos, de maneira geral, apresentaram um MAE em torno de 10%, indicando uma margem de erro relativamente alta. Além disso, o R^2 máximo alcançado foi cerca de 0,23, sugerindo que as variáveis de entrada não capturam completamente a variação na porcentagem de área deteriorada e evidenciando a importância de futuras pesquisas para validar a agregação de outros aspectos que aprimorem a capacidade de inferência dos modelos utilizados. No que diz respeito ao tempo de HPO, a DT destacou-se entre os modelos. Já em relação ao tempo de treinamento, observou-se que o k -NN apresentou o menor valor.

Outrossim, é notável que a versão do OPF para regressão proposta neste projeto obteve resultados próximos aos de alguns modelos clássicos já consolidados na literatura de aprendizado de máquina, embora tenha demonstrado valores de MAE e MSE moderadamente superiores. Entretanto, um diferencial do OPF para regressão é o fato de requerer o ajuste de apenas um hiperparâmetro, o k_{max} , que regula o agrupamento dos dados em *clusters* de amostras similares, enquanto outros modelos exigem o ajuste de um conjunto maior de hiperparâmetros. Ademais, para avaliar melhor o potencial desta versão inicial, são necessários testes empíricos adicionais em diferentes tarefas de regressão que possam destacar as forças e fraquezas da técnica, identificando possíveis áreas de aperfeiçoamento e aplicações específicas do método.


Por outro lado, a Tabela 4, responsável por apresentar os resultados da inferência do risco de queda das árvores com base nos percentuais verdadeiros de área com deterioração, revela que a maior acurácia foi atingida pelo *stacking*, com aproximadamente 0,87, apesar desse modelo ter negligenciado a classe “médio”, obtendo uma taxa de acerto de 0,00. Na classe “baixo”, o k -NN apresentou a melhor revocação, em torno de 0,97, enquanto, para a classe “alto”, o *stacking* destacou-se com um valor aproximado de 0,74. Em relação à classe

“médio”, a SVM mostrou-se o modelo mais eficaz, com uma revocação em torno de 0,42. No geral, os modelos tiveram dificuldade nesta classe, o que pode ser justificado pela baixa quantidade de amostras, visto que apenas 122 árvores da base possuem um risco de queda moderado. Ademais, o modelo que melhor equilibrou o desempenho entre as classes foi a DT, com uma acurácia balanceada de cerca de 0,63. Vale ressaltar que a DT também obteve o menor tempo de HPO, enquanto o menor tempo de treino foi alcançado pelo *k*-NN.

Já a Tabela 5, que contém os resultados da inferência do risco com base nas estimativas do percentual de área deteriorada, evidencia que a maior acurácia foi alcançada pelo *k*-NN, aproximadamente 0,73, apesar de ter negligenciado a classe “médio”, com uma taxa de acerto de 0,00. Para a classe “baixo”, o *k*-NN também apresentou a melhor revocação, em torno de 0,86, enquanto, para a classe “médio”, a DT destacou-se com um valor aproximado de 0,89, e para a classe “alto”, o destaque foi do AdaBoost, em torno de 0,59. No geral, o modelo que melhor equilibrou o desempenho foi o VE, com uma acurácia balanceada de cerca de 0,48.

Embora a DT tenha alcançado um resultado excelente na classe “médio”, com uma revocação aproximada de 0,89, diferenciando-se dos demais modelos que obtiveram baixa acurácia nesta classe, seu desempenho nas outras classes foi comprometido. A Figura 29 apresenta a matriz de confusão da DT na previsão do risco de queda com os valores estimados de porcentagem de área com deterioração, considerando todas as previsões realizadas no conjunto de teste entre as 25 execuções independentes. Essa matriz expressa a relação entre as classes reais e as previstas pela DT, evidenciando que as previsões pouco coincidiram com a realidade. Como se pode notar, a DT previu a classe “médio” para aproximadamente 85% das amostras, apesar desta classe representar apenas 3,7% das amostras observadas nos testes.

Figura 29 – Matriz de confusão da DT obtido com a previsão do risco de queda com base nos valores estimados de porcentagem de área com deterioração.



Fonte: Elaborada pelo autor.

Nas subseções a seguir, os resultados são analisados individualmente, considerando as espécies majoritárias *Caesalpinia peltophoroides* (subseção 6.1.1) e *Tipuana tipu* (subseção 6.1.2), e para a junção das espécies minoritárias (subseção 6.1.3).

6.1.1 *Caesalpinia peltophoroides*

A Tabela 6, que registra o desempenho da estimativa da porcentagem de área com deterioração, destaca que o k -NN obteve o menor MAE entre os modelos avaliados, atingindo aproximadamente 6,55, estabelecendo uma margem de erro das previsões. Por outro lado, o CatBoost demonstrou a melhor performance em termos de MSE, alcançando um valor aproximado de 125,34. Em relação ao R^2 , o AdaBoost se sobressaiu, registrando em torno de 0,10, indicando uma baixa capacidade de explicar a variabilidade da variável-alvo. No que diz respeito aos tempos de HPO e de treino, a DT e o k -NN se destacaram, respectivamente.

Em seguida, a Tabela 7, que resume os resultados da inferência do risco de queda das árvores com base nos percentuais verdadeiros de área deteriorada, indica que o *stacking* se destacou com a melhor acurácia, atingindo em torno de 0,89. Enquanto isso, o k -NN demonstrou a melhor revocação para a classe “baixo”, com aproximadamente 0,99. Por outro lado, o SVM obteve a maior revocação para a classe “médio”, registrando cerca de 0,40. Já na classe “alto”, o CatBoost se sobressaiu em termos de revocação, com um valor aproximado de

0,67. Quanto ao equilíbrio da performance entre as diferentes classes, a LightGBM alcançou a melhor acurácia balanceada, com aproximadamente 0,58. Além disso, a DT obteve destaque em relação ao tempo de HPO e o k -NN, em relação ao tempo de treinamento.

Por último, a Tabela 8, que apresenta os resultados da inferência do risco com base nas estimativas do percentual de área deteriorada, aponta que o k -NN conquistou a melhor acurácia, atingindo aproximadamente 0,83. Além disso, o k -NN demonstrou a maior revocação para a classe “baixo”, com um valor em torno de 0,97. Por outro lado, a DT obteve a melhor revocação na categoria “médio”, registrando cerca de 0,61., e o CatBoost, a melhor revocação na categoria “alto”, com um valor próximo de 0,38. No que se refere ao equilíbrio do desempenho entre as classes, a RF alcançou a melhor acurácia balanceada, com aproximadamente 0,44.

6.1.2 *Tipuana tipu*

Os resultados presentes na Tabela 9, que apresenta os resultados da estimativa do percentual de área deteriorada, revelam que a RF se destacou ao apresentar o menor MAE, registrando aproximadamente 14,10. Em contrapartida, o *stacking* demonstrou a melhor performance em termos de MSE, atingindo em torno de 333,58. Quanto ao R^2 , o *stacking* se sobressaiu, alcançando um valor aproximado de 0,17, sugerindo uma baixa capacidade de explicar a variabilidade da variável de saída. No contexto do tempo de HPO, a DT obteve destaque, enquanto no caso do tempo de treinamento, foi o k -NN que se destacou.

Por sua vez, a Tabela 10, que detalha os resultados da inferência do risco de queda das árvores com base nos percentuais verdadeiros de área deteriorada, evidencia que o *stacking* se destacou pela maior acurácia geral, alcançando em torno de 0,82. Além disso, o XGBoost obteve a maior revocação na categoria “baixo”, atingindo cerca de 0,91, enquanto a DT se destacou pela melhor revocação na categoria “médio”, com aproximadamente 0,46, e o *stacking*, pela melhor revocação na categoria “alto”, registrando cerca de 0,82. Em relação à acurácia balanceada, a DT se sobressaiu com um valor próximo de 0,62. Além disso, a DT obteve destaque quanto ao tempo de HPO e o k -NN, quanto ao tempo de treino.

Por fim, a Tabela 11, que contém os resultados da inferência do risco com base nas estimativas da porcentagem de área com deterioração, aponta que a GBM se destacou com a maior acurácia, atingindo aproximadamente 0,62. Por sua vez, o k -NN demonstrou a melhor revocação na classe “baixo”, com um valor em torno de 0,72. Na classe “médio”, a RF obteve a maior revocação, registrando aproximadamente 0,22. Já na classe “alto”, a DT conquistou a melhor revocação, com um valor aproximado de 0,91. Quanto ao equilíbrio entre as diferentes classes, a RF se distinguiu, alcançando uma acurácia balanceada próxima de 0,44.

6.1.3 Espécies Minoritárias

Os resultados da Tabela 12, que registra a estimativa do percentual de área deteriorada, revelam que o AdaBoost demonstrou o melhor MAE, registrando aproximadamente 9,33. Por outro lado, a RF se destacou ao apresentar a melhor performance em termos de MSE, atingindo em torno de 216,75. Em relação ao R^2 , a RF se sobressaiu, alcançando cerca de 0,15, o que indica que uma pequena parcela da variabilidade da variável de saída é explicada pelo modelo. Ademais, a DT conquistou o menor tempo de HPO e o k -NN, o menor tempo de treinamento.

Em seguida, a Tabela 13, que resume os resultados da inferência do risco de queda das árvores com base nos percentuais verdadeiros de área deteriorada, indica que o *stacking* se sobressaiu com a melhor acurácia geral, atingindo aproximadamente 0,88. Em termos de revocação, o k -NN demonstrou o maior desempenho na classe “baixo”, com cerca de 0,98, enquanto a DT obteve destaque nas classes “médio” e “alto”, registrando em torno de 0,35 e 0,73, respectivamente. Quanto ao equilíbrio do desempenho entre as diferentes classes, o VE alcançou a melhor acurácia balanceada, com valor próximo de 0,60. Além disso, a DT demonstrou o menor tempo de HPO, enquanto o k -NN, o menor tempo de treino.

Por último, a Tabela 14, que quantifica o desempenho da inferência do risco com base nas estimativas do percentual de área deteriorada, evidencia que o k -NN obteve destaque em termos de acurácia, alcançando aproximadamente 0,78. Ademais, em termos de revocação, o k -NN demonstrou a melhor performance na classe “baixo”, com um valor de cerca de 0,92. Por outro lado, a DT apresentou a maior revocação na categoria “médio”, com aproximadamente 0,39, enquanto a LightGBM se destacou na categoria “alto”, registrando em torno de 0,57. Quanto à acurácia balanceada, a LightGBM alcançou um valor aproximado de 0,50.

6.2 Classificação do Nível de Deterioração

Nesta seção, são discutidos inicialmente os resultados referentes à classificação da deterioração interna em três níveis de intensidade na subseção 6.2.1. Em seguida, na subseção 6.2.2, são analisados os achados da classificação binária dos níveis de deterioração.

6.2.1 Classificação Multiclasse

A presente subseção examina os resultados da modelagem por classificação multiclasse dos níveis de deterioração das árvores urbanas, considerando, em um primeiro momento, todas as espécies presentes na base de dados. Segundo a Tabela 15, que exhibe os resultados da estimativa do nível de deterioração, a LightGBM alcançou a maior acurácia, aproximadamente 0,80. Ademais, esse modelo apresentou os maiores valores de revocação para as classes “baixo” e “alto”, respectivamente, cerca de 0,86 e 0,75. Apesar de negligenciar a classe “médio”, com revocação em torno de 0,07, obteve a melhor acurácia balanceada, aproximadamente 0,56. Isso

se deve aos altos valores de revocação apresentados nas outras classes. Para a classe “médio”, a maior revocação foi obtida pelo k -NN, com cerca de 0,38. Em relação ao tempo de HPO, a DT destacou-se entre os modelos. Quanto ao tempo de treino, o destaque foi do k -NN.

A Tabela 16, que contém os resultados da previsão do risco de queda das árvores com base nas classes reais de deterioração, evidencia que a maior acurácia foi alcançada pelo VE, aproximadamente 0,81. Na classe “baixo”, o AdaBoost obteve a maior revocação, cerca de 0,88, enquanto na classe “médio”, a DT destacou-se, com uma revocação em torno de 0,19, e na classe “alto”, o VE alcançou a maior revocação, em torno de 0,78. Apesar de negligenciar a classe “médio”, o VE contou com a melhor acurácia balanceada, aproximadamente 0,56. Além disso, a DT teve um melhor tempo de HPO, enquanto o k -NN se destacou no tempo de treino.

Por último, a Tabela 17, que apresenta os resultados da inferência do risco de queda das árvores com base nas estimativas do nível de deterioração, revela que o XGBoost apresentou a melhor acurácia, aproximadamente 0,68. Na classe “baixo”, o MLP obteve a melhor revocação, cerca de 0,77, enquanto na classe “médio”, a GBM sobressaiu-se com uma revocação em torno de 0,18, e na classe “alto”, o modelo que se destacou foi a DT, com uma revocação de aproximadamente 0,70. Apesar de negligenciar a classe “médio”, com uma revocação próxima de 0,07, o modelo que alcançou a melhor acurácia balanceada foi a SVM, com cerca de 0,46.

Nas subseções a seguir, a análise dos resultados é realizada individualmente para as espécies majoritárias *Caesalpinia peltophoroides* (subseção 6.2.1.1) e *Tipuana tipu* (subseção 6.2.1.2), e para a combinação das espécies minoritárias (subseção 6.2.1.3).

6.2.1.1 *Caesalpinia peltophoroides*

Nesta subseção, os resultados da modelagem por classes de deterioração são discutidos para a espécie *Caesalpinia peltophoroides*. A partir da Tabela 18, que apresenta os resultados da estimativa do nível de deterioração, observa-se que o *stacking* demonstrou a melhor acurácia, alcançando aproximadamente 0,71, bem como a maior revocação para a classe “baixo”, atingindo cerca de 0,80. Por outro lado, o Catboost se destacou ao apresentar a melhor revocação para a classe “médio”, com aproximadamente 0,42. Quanto à classe “alto”, a DT obteve a maior revocação, em torno de 0,58. Além disso, a DT foi o modelo que melhor equilibrou o desempenho entre as classes, com uma acurácia balanceada de cerca de 0,47, e demonstrou o melhor tempo de HPO. Por fim, o k -NN obteve o menor tempo de treino.

Por sua vez, a Tabela 19, que contém os resultados da previsão do risco de queda das árvores com base nas classes reais de deterioração, evidencia que o VE alcançou a melhor acurácia geral, com aproximadamente 0,76. Na classe “baixo”, MLP obteve a melhor revocação, atingindo cerca de 0,81, enquanto na classe “médio”, a RF se destacou ao apresentar a melhor revocação, com aproximadamente 0,44, e, por fim, na classe “alto”, o VE demonstrou a maior revocação, registrando cerca de 0,69. Quanto ao equilíbrio da acurácia entre as diferentes classes, a LightGBM se destacou, alcançando uma acurácia balanceada em torno de 0,57.

Ademais, a DT se destacou pelo tempo de HPO e k -NN, pelo tempo de treinamento.

Já a Tabela 20, que resume os resultados da inferência do risco de queda das árvores com base nas estimativas do nível de deterioração, revela que o MLP alcançou a melhor acurácia, registrando aproximadamente 0,65, bem como a melhor revocação para a classe “baixo”, atingindo cerca de 0,72. Por outro lado, a RF se destacou ao apresentar a maior revocação na classe “médio”, com aproximadamente 0,44, e a DT demonstrou a maior revocação na classe “alto”, registrando em torno de 0,53. No que diz respeito ao equilíbrio da acurácia entre as três classes, a RF se sobressaiu, alcançando uma acurácia balanceada de aproximadamente 0,45.

6.2.1.2 *Tipuana tipu*

Esta subseção discute, individualmente, os resultados da modelagem por classes de deterioração para a espécie *Tipuana tipu*. A Tabela 21, que contém os resultados da estimativa do nível de deterioração, indica que o *stacking* demonstrou a melhor acurácia, registrando aproximadamente 0,55. Na classe “baixo”, destaca-se que o MLP que obteve a melhor revocação, atingindo cerca de 0,72. Por outro lado, o *stacking* se destacou pela maior revocação para a classe “médio”, com aproximadamente 0,44. Já na classe “alto”, o VE demonstrou a maior revocação, registrando cerca de 0,55. Quanto ao equilíbrio da acurácia entre as classes, o VE se sobressaiu com uma acurácia balanceada de aproximadamente 0,51. Ademais, a DT demonstrou o menor tempo de HPO e o k -NN, o menor tempo de treinamento.

Em seguida, a Tabela 22, que resume os resultados da previsão do risco de queda das árvores com base nas classes reais de deterioração, indica que o *stacking* demonstrou a maior acurácia, registrando aproximadamente 0,77. Ademais, o XGBoost obteve a melhor revocação para a classe “baixo”, atingindo cerca de 0,81. Por outro lado, DT se destacou pela melhor revocação na classe “médio”, com aproximadamente 0,43. Já na classe “alto”, o *stacking* demonstrou a maior revocação, registrando cerca de 0,80. Quanto ao equilíbrio do desempenho entre as classes, o *stacking* conquistou uma acurácia balanceada de aproximadamente 0,58. Além disso, a DT se sobressaiu pelo tempo de HPO e o k -NN, tempo de treino.

Por fim, a Tabela 23, que detalha os resultados da inferência do risco de queda das árvores com base nas estimativas do nível de deterioração, evidencia que o *stacking* demonstrou a melhor acurácia global, registrando aproximadamente 0,58, bem como obteve a melhor revocação na classe “baixo”, atingindo cerca de 0,66. Por outro lado, a DT se destacou ao apresentar a maior revocação na classe “médio”, com aproximadamente 0,20. Na classe “alto”, o CatBoost demonstrou a maior revocação, registrando em torno de 0,58. Outrossim, a RF obteve destaque com a maior acurácia balanceada, alcançando aproximadamente 0,42.

6.2.1.3 Espécies Minoritárias

Na presente subseção, discorre-se sobre os resultados da modelagem por classes de deterioração para a combinação das espécies minoritárias da base de dados. Nesse contexto,

os resultados apresentados na Tabela 24, que aborda a estimativa do nível de deterioração interna, apontam que o MLP se destacou ao alcançar a melhor acurácia geral, registrando aproximadamente 0,71, e a melhor revocação para a classe “baixo”, atingindo cerca de 0,84. Por outro lado, a DT demonstrou a maior revocação para a classe “médio”, com aproximadamente 0,52, e o CatBoost para a classe “alto”, também com aproximadamente 0,52. No que diz respeito ao equilíbrio da acurácia entre as diferentes classes, o VE se sobressaiu entre os modelos, alcançando uma acurácia balanceada de aproximadamente 0,52. Além disso, DT alcançou o menor tempo de HPO, enquanto o k -NN, o menor tempo de treinamento.

Por sua vez, a Tabela 25, que contém os resultados da previsão do risco de queda das árvores com base nas classes reais de deterioração, evidencia que o AdaBoost se sobressaiu ao atingir a melhor acurácia, registrando aproximadamente 0,83, bem como a maior revocação para a classe “baixo”, com cerca de 0,90. Por outro lado, o SVM se sobressaiu ao apresentar a melhor revocação para a classe “médio”, alcançando aproximadamente 0,28, e o AdaBoost, para a classe “alto”, registrando em torno de 0,67. No que diz respeito ao equilíbrio da acurácia entre as classes, o VE se destacou, alcançando uma acurácia balanceada próxima de 0,55. Ademais, a DT se distinguiu pelo tempo de HPO, enquanto o k -NN, pelo tempo de treino.

Então, a Tabela 26, que resume os resultados da inferência do risco de queda das árvores com base nas estimativas do nível de deterioração, aponta que o MLP alcançou a melhor acurácia, registrando cerca de 0,69, e a melhor revocação para a classe “baixo”, atingindo em torno de 0,81. Por outro lado, a DT demonstrou a maior revocação para a classe “médio”, com aproximadamente 0,32, e para a classe “alto”, com aproximadamente 0,63. Quanto à acurácia balanceada, a DT obteve destaque, alcançando um valor próximo de 0,47.

6.2.2 Classificação Binária

Finalmente, os resultados da modelagem por classificação binária dos níveis de deterioração interna, delineados na Tabela 27, revelam que a GBM se destacou ao alcançar a melhor acurácia, registrando aproximadamente 0,75. Notavelmente, o MLP demonstrou a maior revocação para a classe “mínimo”, atingindo cerca de 0,85. Por outro lado, o Catboost apresentou a melhor revocação para a classe “significativo”, com aproximadamente 0,66. No que diz respeito ao equilíbrio do desempenho, novamente o Catboost se sobressaiu, alcançando uma acurácia balanceada de aproximadamente 0,71. Além disso, a DT obteve o menor tempo de HPO, enquanto o k -NN se destacou pelo menor tempo de treinamento.

Em seguida, a Tabela 28, que descreve os resultados da previsão do risco de queda das árvores com base nas classes reais de deterioração, destaca que o VE obteve a melhor acurácia, registrando em torno de 0,83, assim como a melhor revocação na classe “baixo”, atingindo cerca de 0,89, e na classe “alto”, com aproximadamente 0,80. No entanto, o k -NN demonstrou a maior revocação na classe “médio”, atingindo em torno de 0,18. Quanto ao equilíbrio da acurácia, o *stacking* se sobressaiu, alcançando uma acurácia balanceada próxima de 0,57. Para

mais, a DT se distinguiu pelo tempo de HPO e o k -NN, pelo tempo de treino.

Por último, a Tabela 29, que detalha os resultados da inferência do risco de queda das árvores com base nas estimativas do nível de deterioração, ressalta que o *stacking* se destacou ao alcançar a maior acurácia, registrando um valor próximo de 0,70. O MLP demonstrou a melhor revocação para a classe “baixo”, atingindo cerca de 0,82, enquanto o k -NN obteve a melhor revocação para a classe “médio”, com aproximadamente 0,17, e, para a classe “alto”, o VE demonstrou a maior revocação, registrando cerca de 0,63. Quanto ao equilíbrio da acurácia entre as classes, o VE se destacou, alcançando uma acurácia balanceada em torno de 0,46.

6.3 Considerações Finais

No que diz respeito à estimativa da deterioração interna via regressão, o R^2 , no geral, indica que os modelos explicam somente uma parcela da variação da variável-alvo, o que é reforçado por um MAE de aproximadamente 10% da área deteriorada. Como pode ser inferido a partir da subseção 4.1.4, amostras com valores similares de atributos, e, portanto, que ocupam uma região próxima no espaço gerado pelo t-SNE, apresentam valores bastante distintos de porcentagem de área deteriorada. Isso demonstra uma alta variabilidade entre os valores de saída, sem um padrão aparente, tornando o problema difícil para os modelos de aprendizado de máquina, o que resulta em valores baixos de R^2 . Tal fato pode indicar a existência de fatores não contemplados na base de dados que justificam a variabilidade não explicada. Porém, como evidenciado por Frost (c2024), toda área de estudo possui uma variabilidade inexplicável inerente, sendo que algumas áreas podem ser intrinsecamente mais complexas. Além disso, a distribuição desigual dos valores de porcentagem de área com deterioração pode ter impactado o aprendizado dos modelos, contribuindo para a baixa variabilidade explicada.

Por outro lado, em relação à classificação dos níveis de deterioração, a acurácia geral apresenta valores satisfatórios, com um máximo em torno de 0,80. Isso se deve à influência da classe 'baixo', que é majoritária e apresenta uma excelente revocação, cerca de 0,86. Esse desempenho elevado na classe majoritária é um ponto forte do modelo, pois pode auxiliar arboristas na tomada de decisão na ausência de sinais de alerta de deterioração, uma vez que o modelo é especialmente eficaz para árvores saudáveis ou com baixos níveis de deterioração interna. No entanto, ao considerar as demais classes, a revocação é ainda limitada para a classe “médio” e regular para a classe “alto”, o que reduz a taxa de acerto ao realizar uma análise balanceada por classe. Consequentemente, a acurácia balanceada é insatisfatória, atingindo um valor máximo de aproximadamente 0,56. Como se pode notar, o desbalanceamento entre as classes, assim como a distribuição desigual dos percentuais de área deteriorada, pode ter impactado o aprendizado do modelo, contribuindo para a baixa acurácia balanceada. Ademais, a sobreposição de amostras com atributos similares e classes distintas de deterioração no espaço de visualização também pode ter contribuído para a baixa acurácia balanceada.

Quanto à estimativa do risco de queda das árvores, tanto com os valores reais de porcentagem de área com deterioração quanto com os níveis de deterioração, pode-se afirmar que, de modo geral, a acurácia é satisfatória. Contudo, a acurácia balanceada é insatisfatória, uma vez que os modelos apresentam uma excelente revocação para a classe “baixo”, mas uma revocação baixa para a classe “médio” e moderada para a classe “alto”. Ao empregar as estimativas do percentual de área deteriorada ou do nível de deterioração, a acurácia dos modelos na previsão do risco, de maneira geral, decresce, tornando-se razoável. Ao analisar tanto a acurácia balanceada quanto as revocações, evidencia-se um baixo desempenho de inferência para este cenário, com a acurácia individual para a classe “baixo” destacando-se em relação às outras, e a classe “médio” sendo a mais negligenciada de todas as classes.

Para comparar a qualidade das estimativas de deterioração, realizadas tanto por regressão quanto por classificação, é pertinente analisar a taxa de acerto da previsão do risco de queda com base nessas duas abordagens distintas. Ao empregar as estimativas do percentual de área deteriorada, observa-se que o VE alcança a maior acurácia balanceada na previsão do risco de queda, com um valor em torno de 0,48, enquanto com as porcentagens reais, a acurácia balanceada máxima foi próxima de 0,63 com a DT. Em contraste, ao empregar os níveis previstos de deterioração, a SVM apresentou a melhor acurácia balanceada, aproximadamente 0,46, enquanto com os níveis reais, a acurácia balanceada ficou em torno de 0,56 com o LightGBM. Assim, observa-se uma redução mínima de 10% na acurácia balanceada da previsão do risco de queda ao utilizar as estimativas. Porém, é evidente que a modelagem por regressão resulta em um desempenho ligeiramente superior. Essa semelhança no desempenho das duas abordagens sugere que um indicador categórico do grau de deterioração pode ser tão informativo quanto um contínuo, como a porcentagem de área deteriorada, para a previsão do risco.

Além disso, a análise da estimativa do percentual de área deteriorada por espécie revela que, embora os modelos treinados para cada espécie individual demonstrem certo grau de explicação da variabilidade da variável-alvo, o uso conjunto de todas as espécies resulta em uma maior compreensão dessa variabilidade. O R^2 máximo alcançado pelos modelos foi de 0,10 com o AdaBoost para a espécie *Caesalpinia peltophoroides*, 0,17 com o *stacking* para a espécie *Tipuana tipu* e 0,15 com a RF para as espécies minoritárias. Ao considerar todas as espécies, o R^2 máximo foi de 0,23 com o CatBoost. No que se refere à classificação do nível de deterioração por espécie, observa-se que a acurácia balanceada apresenta valores superiores quando todas as espécies são consideradas em conjunto. A maior acurácia balanceada registrada pelos modelos foi de 0,47 com a DT para a espécie *Caesalpinia peltophoroides*, 0,51 com o VE para a espécie *Tipuana tipu* e 0,52 com o VE para as espécies minoritárias. Em comparação, ao considerar todas as espécies, a maior acurácia balanceada foi de 0,56 com a LightGBM. No contexto da previsão de risco de queda, tanto com as estimativas de percentual de área deteriorada quanto com os níveis de deterioração, a previsão do risco ao considerar somente as espécies minoritárias apresentou uma acurácia balanceada muito próxima, mas ligeiramente superior, em comparação com o resultado ao incluir todas as espécies. Isso pode ser justificado

pelo menor tamanho do conjunto de teste ao considerar apenas as espécies minoritárias.

Ao analisar as espécies *Caesalpinia peltophoroides* e *Tipuana tipu* isoladamente, esperava-se que o desempenho dos modelos fosse superior ao observado quando todas as espécies são consideradas em conjunto, em vez de serem ligeiramente inferiores. Esse resultado pode ser atribuído à representatividade das classes, que se torna menos eficaz com um menor número de amostras, como ocorre no tratamento individual das espécies. Como mostrado na Figura 13, cada espécie contribui de maneira distinta para a representatividade das classes. Assim, utilizar todas as amostras para treinar o modelo proporciona uma melhor representatividade geral. Embora o modelo pareça aprender adequadamente com as espécies isoladas e em conjunto, são necessários testes adicionais com novos dados para avaliar o desempenho do modelo para cada espécie específica. Quando analisadas isoladamente, espécies minoritárias têm menor representação, principalmente nas classes minoritárias, e, portanto, os modelos aprendem menos sobre elas. Além disso, não se pode garantir que modelos treinados com sete espécies generalizem bem para todas as espécies encontradas em um município. Testes empíricos são necessários para validar o desempenho dos modelos para espécies não contempladas na base de dados. Ademais, para garantir um bom desempenho em outras espécies, uma possível solução seria retrainar os modelos com dados dessas novas espécies seguindo a mesma abordagem.

Em relação à classificação do nível de deterioração, constatou-se um desempenho superior em termos de acurácia balanceada na classificação binária, em comparação com a classificação multiclasse. Isso se deve ao fato de que, no problema binário, a classe “médio”, que apresenta valores de revocação relativamente baixos, é combinada com a classe “alto”, formando assim a classe “significativo”, que possui uma representatividade melhor. Como resultado, a acurácia balanceada máxima passa de cerca de 0,56 com o modelo LightGBM na classificação multiclasse, para aproximadamente 0,71 com o CatBoost na classificação binária. Todavia, ao considerar a acurácia geral, a abordagem multiclasse exibe um desempenho superior, atingindo cerca de 0,80 com o LightGBM, enquanto a abordagem binária registra aproximadamente 0,75 com a GBM. Ademais, ao prever o risco de queda com base nos níveis estimados de deterioração, tanto a abordagem multiclasse, utilizando o VE, quanto a binária, utilizando a SVM, alcançaram uma acurácia balanceada máxima em torno de 0,46. Isso sugere que, embora a acurácia balanceada seja superior na classificação binária, a perda de informação decorrente da união de duas classes pode ter afetado a previsão do risco de queda, fazendo com que a abordagem binária não ofereça uma vantagem significativa em relação à multiclasse.

Dado o desbalanceamento entre as classes e as variáveis empregadas, conclui-se que os resultados são plausíveis. Entretanto, as estimativas de deterioração interna do tronco ainda não são suficientes para substituir os valores reais sem comprometer a acurácia da previsão do risco de queda das árvores. Sendo assim, é necessário aprimorar o método proposto neste projeto de pesquisa para tornar viável sua aplicação em cenários reais. No entanto, o método apresentado neste trabalho para a estimativa da deterioração interna do tronco destaca-se em relação

ao método empregado no estudo de Hrdina e Surový (2023), que adotou uma abordagem mais complexa, envolvendo a construção de modelos tridimensionais para capturar os aspectos morfológicos dos troncos. Em síntese, Hrdina e Surový (2023) utilizaram os modelos criados para alimentar uma rede profunda, a fim de identificar a presença ou ausência de deterioração interna, alcançando uma acurácia máxima de apenas 65,5%. Por outro lado, o presente trabalho alcançou uma acurácia máxima de aproximadamente 80% com a LightGBM, a qual foi treinada em variáveis contínuas e categóricas, permitindo a classificação do nível de deterioração como “baixo”, “médio” e “alto”. Ademais, ao contrário do estudo de Hrdina e Surový (2023), este trabalho considerou o desbalanceamento, apresentando a acurácia balanceada, que também atingiu seu máximo com o LightGBM, apresentando um valor em torno de 56%.

7 Conclusão

Este estudo explorou a aplicação de técnicas de IA e aprendizado de máquina na gestão da arborização urbana, mais especificamente no monitoramento do risco de queda. Além de destacar os atributos frequentemente associados à ruptura de árvores urbanas, discutiu novas tecnologias de CV que têm facilitado o inventário arbóreo. Ademais, enfatizou as dificuldades inerentes à análise da deterioração interna, crucial para estipular o risco de queda, propondo a estimativa desse aspecto por meio de técnicas de aprendizado de máquina.

Neste contexto, a presente pesquisa aplicou diversos métodos de aprendizado de máquina para estimar a deterioração interna do tronco, abordando o problema tanto como uma tarefa de regressão quanto de classificação. Para tal, realizou-se a categorização do percentual de área deteriorada em três níveis de deterioração: “baixo”, “médio” e “alto”, criando uma tarefa de classificação multiclasse. Visando simplificar a tarefa, propôs-se também a divisão binária dos níveis através da junção das classes “médio” e “alto” em uma única classe denominada “significativo”, criando assim uma tarefa de classificação binária. Além disso, realizaram-se as estimativas isoladamente considerando três grupos de árvores: pertencentes à espécie *Caesalpinia peltophoroides*, à espécie *Tipuana tipu* e à união das espécies minoritárias.

Ademais, antes de proceder às estimativas, os dados foram preparados e um algoritmo de regressão baseado no OPF foi desenvolvido. Durante a fase de estimativas, realizou-se o pré-processamento dos dados; o processo de HPO dos modelos utilizando uma meta-heurística promissora baseada no forrageamento de bolor limoso, conhecida como SMA; e a formação de *ensembles* de modelos com as estratégias de votação e *stacking*. Então, para validar a eficácia do método desenvolvido, os riscos de queda foram previstos, utilizando tanto as estimativas da deterioração interna quanto os valores mensurados por equipes de campo.

Ao comparar as previsões do risco de queda, constatou-se que o método, no geral, ainda não gera estimativas de deterioração interna suficientemente precisas para não comprometer a qualidade geral da previsão de risco, sugerindo a necessidade de aprimoramento. No entanto, os resultados indicaram um desempenho satisfatório para amostras com baixos níveis de deterioração, possibilitando o uso do método como uma ferramenta de suporte aliada à análise de sinais externos de deterioração. Assim, ao identificar sinais de alerta, um especialista pode optar por realizar um teste não destrutivo, independentemente das saídas dos modelos. Quanto à capacidade de generalização dos modelos, observou-se um melhor desempenho ao trabalhar com todas as espécies da base, mas são necessários testes adicionais para avaliar o desempenho em espécies não vistas durante o treinamento, devido às particularidades de cada espécie.

Apesar dessa limitação, este trabalho oferece uma contribuição significativa para estudos que visam reduzir a necessidade de pesquisa de campo na gestão de risco de árvores. Como

perspectivas para pesquisas futuras, destaca-se a necessidade de lidar com o desbalanceamento entre as classes, uma vez que os dados são predominantemente compostos por amostras com níveis baixos de deterioração interna. Sendo assim, o acréscimo de amostras com valores maiores de deterioração pode melhorar a representatividade das demais classes e, conseqüentemente, o aprendizado dos modelos. Além disso, é possível incorporar outros aspectos não contemplados na base de dados, visando aprimorar a correlação entre os atributos de entradas e a variável-alvo.

Em relação ao OPF adaptado para regressão, embora seus resultados tenham sido ligeiramente inferiores aos de outros algoritmos bem estabelecidos na literatura, é importante notar que esta é uma versão inicial do modelo, com apenas um hiperparâmetro a ser ajustado. Além disso, serão necessários testes adicionais para validar o potencial do modelo em diferentes contextos e para identificar possíveis ajustes que possam aprimorar seu desempenho geral.

Referências

- AN, K.; MENG, J. Voting-averaged combination method for regressor ensemble. In: HUANG, D.-S.; ZHAO, Z.; BEVILACQUA, V.; FIGUEROA, J. C. (Ed.). **Advanced Intelligent Computing Theories and Applications**. Heidelberg, Berlin: Springer Berlin Heidelberg, 2010. p. 540–546. ISBN 978-3-642-14922-1. Disponível em: https://doi.org/10.1007/978-3-642-14922-1_67. Acesso em: 20 maio 2023.
- ARAÚJO, H. C. de L.; MARTINS, F. S.; CORTESE, T. T. P.; LOCOSSELLI, G. M. Artificial intelligence in urban forestry - a systematic review. **Urban Forestry & Urban Greening**, v. 66, artigo 127410, p. 1–11, 2021. ISSN 1618-8667. Disponível em: <https://doi.org/10.1016/j.ufug.2021.127410>. Acesso em: 30 mar. 2023.
- BIRDAL, A. C.; AVDAN, U.; TÜRK, T. Estimating tree heights with images from an unmanned aerial vehicle. **Geomatics, Natural Hazards and Risk**, Taylor & Francis, v. 8, n. 2, p. 1144–1156, 2017. Disponível em: <https://doi.org/10.1080/19475705.2017.1300608>. Acesso em: 9 maio 2023.
- BOSCHETTI, W. T. N.; PAES, J. B.; VIDAURRE, G. B.; ARANTES, M. D. C.; LEITE, F. P. Parâmetros dendrométricos e excentricidade da medula em árvores inclinadas de eucalipto. **Scientia Forestalis**, Instituto de Pesquisa e Estudos Florestais (IPEF), Piracicaba, v. 43, n. 108, p. 781–789, dec 2015. ISSN 1413-9324. Disponível em: <http://dx.doi.org/10.18671/scifor.v43n108.4>. Acesso em: 22 abr. 2024.
- BRAZOLIN, S. **Biodeterioração, anatomia do lenho e análise de risco de queda de árvores de tipuana, Tipuana tipu (Benth.) O. Kuntze, nos passeios públicos da cidade de São Paulo, SP**. 2009. Tese (Doutorado em Recursos Florestais) — Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2009. Disponível em: <https://doi.org/10.11606/T.11.2009.tde-20042010-092326>. Acesso em: 27 mar. 2023.
- BRODERSEN, K. H.; ONG, C. S.; STEPHAN, K. E.; BUHMANN, J. M. The balanced accuracy and its posterior distribution. In: **Proceedings of the 2010 20th International Conference on Pattern Recognition**. USA: IEEE Computer Society, 2010. (ICPR '10), p. 3121–3124. ISBN 9780769541099. Disponível em: <https://doi.org/10.1109/ICPR.2010.764>. Acesso em: 17 jan. 2024.
- CABO, C.; ORDÓÑEZ, C.; LÓPEZ-SÁNCHEZ, C. A.; ARMESTO, J. Automatic dendrometry: Tree detection, tree height and diameter estimation using terrestrial laser scanning. **International Journal of Applied Earth Observation and Geoinformation**, v. 69, p. 164–174, 2018. ISSN 1569-8432. Disponível em: <https://doi.org/10.1016/j.jag.2018.01.011>. Acesso em: 9 maio 2023.
- CHARLES, R.; SU, H.; KAICHUN, M.; GUIBAS, L. J. Pointnet: Deep learning on point sets for 3d classification and segmentation. In: **2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. Los Alamitos, CA, USA: IEEE Computer Society, 2017. p. 77–85. ISSN 1063-6919. Disponível em: <https://doi.ieeecomputersociety.org/10.1109/CVPR.2017.16>. Acesso em: 20 jan. 2024.

CHAWLA, N. V.; BOWYER, K. W.; HALL, L. O.; KEGELMEYER, W. P. Smote: Synthetic minority over-sampling technique. **J. Artif. Int. Res.**, AI Access Foundation, El Segundo, CA, USA, v. 16, n. 1, p. 321–357, jun 2002. ISSN 1076–9757. Disponível em: <https://dl.acm.org/doi/10.5555/1622407.1622416>. Acesso em: 17 jan. 2024.

CLAUSEN, C. A. Biodeterioration of wood. In: ROSS, R. J. (Ed.). **Wood handbook**: wood as an engineering material. 100. ed. Madison, WI, USA: U.S. Forest Service, 2010. p. 14.1–14.16. General Technical Report FPL-GTR-190. Disponível em: <https://doi.org/10.2737/FPL-GTR-190>. Acesso em: 22 jul. 2024.

COSTA, V. G.; PEDREIRA, C. E. Recent advances in decision trees: An updated survey. **Artificial Intelligence Review**, v. 56, n. 5, p. 4765–4800, maio 2023. ISSN 1573-7462. Disponível em: <https://doi.org/10.1007/s10462-022-10275-5>. Acesso em: 18 jan. 2024.

DOLWIN, D. L. J. A.; BARNETT, J. Detection of decay in trees. **Arboricultural Journal**, Taylor & Francis, v. 23, n. 2, p. 139–149, 1999. Disponível em: <https://doi.org/10.1080/03071375.1999.9747234>. Acesso em: 15 abr. 2024.

DONG, X.; YU, Z.; CAO, W.; SHI, Y.; MA, Q. A survey on ensemble learning. **Frontiers of Computer Science**, v. 14, n. 2, p. 241–258, abr 2020. ISSN 2095-2236. Disponível em: <https://doi.org/10.1007/s11704-019-8208-z>. Acesso em: 28 mar. 2023.

DONOVAN, G. H. Including public-health benefits of trees in urban-forestry decision making. **Urban Forestry & Urban Greening**, v. 22, p. 120–123, 2017. ISSN 1618-8667. Disponível em: <https://doi.org/10.1016/j.ufug.2017.02.010>. Acesso em: 21 mar. 2023.

DOWNER, A. J.; PERRY, E. J. Wood decay fungi in landscape trees. **UC ANR Publication**, Oakland, CA, USA, artigo 74109, p. 1–6, ago 2019. UC IPM Pest Notes. Disponível em: <https://ipm.ucanr.edu/home-and-landscape/wood-decay-fungi-in-landscape-trees/pest-notes/>. Acesso em: 26 jul. 2024.

EBELING, W. Wood-destroying insects and fungi. In: _____. **Urban entomology**. Berkeley, CA, USA: Division of Agricultural Sciences, University of California, Berkeley, 1975. p. 128–216. ISBN 0-931876-19-2. Disponível em: <https://entomology.ucr.edu/ebeling>. Acesso em: 16 jul. 2024.

ERCANLI, İ. Innovative deep learning artificial intelligence applications for predicting relationships between individual tree height and diameter at breast height. **Forest Ecosystems**, v. 7, n. 1, artigo 12, p. 1–18, abr 2020. ISSN 2197-5620. Disponível em: <https://doi.org/10.1186/s40663-020-00226-3>. Acesso em: 23 abr. 2023.

ESPINOSA, L.; ARCINIEGAS, A.; CORTES, Y.; PRIETO, F.; BRANCHERIAU, L. Automatic segmentation of acoustic tomography images for the measurement of wood decay. **Wood Science and Technology**, v. 51, n. 1, p. 69–84, jan 2017. ISSN 1432-5225. Disponível em: <https://doi.org/10.1007/s00226-016-0878-1>. Acesso em: 27 mar. 2023.

FROST, J. How to interpret regression models that have significant variables but a low r-squared. **Statistics by Jim**, c2024. Disponível em: <https://statisticsbyjim.com/regression/low-r-squared-regression/>. Acesso em: 7 maio 2024.

GONZÁLEZ, S.; GARCÍA, S.; DEL SER, J.; ROKACH, L.; HERRERA, F. A practical tutorial on bagging and boosting based ensembles for machine learning: Algorithms, software tools, performance study, practical perspectives and opportunities. **Information Fusion**, v. 64, p.

205–237, 2020. ISSN 1566-2535. Disponível em: <https://doi.org/10.1016/j.inffus.2020.07.007>. Acesso em: 18 jan. 2024.

HAAFTEN, M. van; LIU, Y.; WANG, Y.; ZHANG, Y.; GARDEBROEK, C.; HEIJMAN, W.; MEUWISSEN, M. Understanding tree failure—a systematic review and meta-analysis. **PLOS ONE**, Public Library of Science, v. 16, n. 2, artigo e0246805, p. 1–23, fev 2021. Disponível em: <https://doi.org/10.1371/journal.pone.0246805>. Acesso em: 21 mar. 2023.

HANCOCK, J. T.; KHOSHGOFTAAR, T. M. Survey on categorical data for neural networks. **Journal of Big Data**, v. 7, n. 1, artigo 28, p. 1–41, abr 2020. ISSN 2196-1115. Disponível em: <https://doi.org/10.1186/s40537-020-00305-w>. Acesso em: 10 fev. 2024.

HOSSIN, M.; M.N, S. A review on evaluation metrics for data classification evaluations. **International Journal of Data Mining & Knowledge Management Process**, v. 5, n. 2, p. 1–11, mar 2015. Disponível em: <https://www.airconline.com/ijdkp/V5N2/5215ijdkp01.pdf>. Acesso em: 17 jan. 2024.

HRDINA, M.; SUROVÝ, P. Internal tree trunk decay detection using close-range remote sensing data and the pointnet deep learning method. **Remote Sensing**, v. 15, n. 24, artigo 5712, p. 1–18, 2023. ISSN 2072-4292. Disponível em: <https://doi.org/10.3390/rs15245712>. Acesso em: 20 jan. 2024.

HUANG, Y.-L.; CHEN, D.-R. Watershed segmentation for breast tumor in 2-d sonography. **Ultrasound in Medicine & Biology**, v. 30, n. 5, p. 625–632, 2004. ISSN 0301-5629. Disponível em: <https://doi.org/10.1016/j.ultrasmedbio.2003.12.001>. Acesso em: 19 maio 2023.

INSTITUTO DE PESQUISAS TECNOLÓGICAS DO ESTADO DE SÃO PAULO. **Relatório técnico do diagnóstico e análise de risco de queda das árvores de vias públicas da cidade de São Paulo**: Projeto árvore saudável. São Paulo: IPT, Divisão de Produtos Florestais, 2004. v. 1. 45 p. Disponível em: https://www.prefeitura.sp.gov.br/cidade/secretarias/upload/arquivos/secretarias/meio_ambiente/projetos_acoes/Projeto_Arvore_Saudavel_Volume1.pdf. Acesso em: 17 abr. 2024.

JAHANI, A.; SAFFARIHA, M. Tree failure prediction model (tfpm): machine learning techniques comparison in failure hazard assessment of platanus orientalis in urban forestry. **Natural Hazards**, v. 110, n. 2, p. 881–898, jan 2022. ISSN 1573-0840. Disponível em: <https://doi.org/10.1007/s11069-021-04972-7>. Acesso em: 28 abr. 2023.

JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An introduction to statistical learning an introduction to statistical learning**. 2. ed. New York, NY: Springer, 2021. (Springer texts in statistics). ISBN 978-1-0716-1418-1. Disponível em: <https://www.statlearning.com/>. Acesso em: 20 maio 2023.

JODAS, D. S.; YOJO, T.; BRAZOLIN, S.; VELASCO, G. D. N.; PAPA, J. P. Detection of trees on street-view images using a convolutional neural network. **International Journal of Neural Systems**, v. 32, n. 01, artigo 2150042, p. 1–20, 2022. Disponível em: <https://doi.org/10.1142/S0129065721500428>. Acesso em: 27 mar. 2023.

KABIR, E.; GUIKEMA, S.; KANE, B. Statistical modeling of tree failures during storms. **Reliability Engineering & System Safety**, v. 177, p. 68–79, 2018. ISSN 0951-8320. Disponível em: <https://doi.org/10.1016/j.ress.2018.04.026>. Acesso em: 28 abr. 2023.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: **Proceedings of ICNN'95 - International Conference on Neural Networks**. Perth, Australia: IEEE, 1995. v. 4, p. 1942–1948. ISBN 0-7803-2768-3. Disponível em: <https://ieeexplore.ieee.org/document/488968>. Acesso em: 31 jul. 2024.

KWAK, D.-A.; LEE, W.-K.; LEE, J.-H.; BIGING, G. S.; GONG, P. Detection of individual trees and estimation of tree height using lidar data. **Journal of Forest Research**, Taylor & Francis, v. 12, n. 6, p. 425–434, 2007. Disponível em: <https://doi.org/10.1007/s10310-007-0041-9>. Acesso em: 9 maio 2023.

LAVALLÉE, A.; LORTIE, M. Relationships between external features and trunk rot in living yellow birch. **The Forestry Chronicle**, v. 44, n. 2, p. 5–10, 1968. Disponível em: <https://doi.org/10.5558/tfc44005-2>. Acesso em: 23 abr. 2023.

LI, H.; ZHANG, X.; LI, Z.; WEN, J.; TAN, X. A review of research on tree risk assessment methods. **Forests**, v. 13, n. 10, artigo 1556, p. 1–20, 2022. ISSN 1999-4907. Disponível em: <http://doi.org/10.3390/f13101556>. Acesso em: 23 abr. 2023.

LI, S.; CHEN, H.; WANG, M.; HEIDARI, A. A.; MIRJALILI, S. Slime mould algorithm: A new method for stochastic optimization. **Future Generation Computer Systems**, v. 111, p. 300–323, 2020. ISSN 0167-739X. Disponível em: <https://doi.org/10.1016/j.future.2020.03.055>. Acesso em: 17 jan. 2024.

LI, Y.; ZOU, C.; BERECHIBAR, M.; NANINI-MAURY, E.; CHAN, J. C.-W.; BOSSCHE, P. van den; VAN MIERLO, J.; OMAR, N. Random forest regression for online capacity estimation of lithium-ion batteries. **Applied Energy**, v. 232, p. 197–210, 2018. ISSN 0306-2619. Disponível em: <https://doi.org/10.1016/j.apenergy.2018.09.182>. Acesso em: 20 maio 2023.

LIN, C.-J.; YANG, T.-H. Detection of acoustic velocity and electrical resistance tomographies for evaluation of peripheral-inner wood demarcation in urban royal palms. **Urban Forestry & Urban Greening**, v. 14, n. 3, p. 583–589, 2015. ISSN 1618-8667. Disponível em: <https://doi.org/10.1016/j.ufug.2015.05.010>. Acesso em: 17 jan. 2024.

MAATEN, L. van der; HINTON, G. Visualizing data using t-sne. **Journal of Machine Learning Research**, v. 9, n. 86, p. 2579–2605, 2008. Disponível em: <http://jmlr.org/papers/v9/vandermaaten08a.html>. Acesso em: 7 maio 2024.

MATTHECK, C. How does a tree break? In: _____. **Design in Nature: Learning from Trees**. Heidelberg, Berlin: Springer Berlin Heidelberg, 1998. p. 141–162. ISBN 978-3-642-58747-4. Disponível em: https://doi.org/10.1007/978-3-642-58747-4_9. Acesso em: 15 abr. 2024.

MATTHECK, C.; BETHGE, K.; ERB, D. Failure criteria for trees. **Arboricultural Journal**, Taylor & Francis, v. 17, n. 2, p. 201–209, 1993. Disponível em: <https://doi.org/10.1080/03071375.1993.9746963>. Acesso em: 22 abr. 2024.

MATTHECK, C.; BETHGE, K.; WEST, P. W. Breakage of hollow tree stems. **Trees**, v. 9, n. 1, p. 47–50, nov 1994. ISSN 1432-2285. Disponível em: <https://doi.org/10.1007/BF00197869>. Acesso em: 26 abr. 2024.

MIENYE, I. D.; SUN, Y. A survey of ensemble learning: Concepts, algorithms, applications, and prospects. **IEEE Access**, v. 10, p. 99129–99149, 2022. Disponível em: <https://ieeexplore.ieee.org/document/9893798>. Acesso em: 18 jan. 2024.

NIELSEN, A. B.; ÖSTBERG, J.; DELSHAMMAR, T. Review of urban tree inventory methods used to collect data at single-tree level. **Arboriculture & Urban Forestry**, v. 40, n. 2, p. 96–111, 2014. Disponível em: <https://doi.org/10.48044/jauf.2014.011>. Acesso em: 27 mar. 2023.

PAPA, J. P.; FALCÃO, A. X.; SUZUKI, C. T. N. Supervised pattern classification based on optimum-path forest. **International Journal of Imaging Systems and Technology**, v. 19, n. 2, p. 120–131, 2009. Disponível em: <https://doi.org/10.1002/ima.20188>. Acesso em: 18 jan. 2024.

PASSOS, L. A.; RODRIGUES, D. R.; PAPA, J. P. Fine tuning deep boltzmann machines through meta-heuristic approaches. In: **2018 IEEE 12th International Symposium on Applied Computational Intelligence and Informatics (SACI)**. [s.n.], 2018. p. 000419–000424. Disponível em: <https://doi.org/10.1109/SACI.2018.8440959>. Acesso em: 17 jan. 2024.

PATAKI, D. E.; ALBERTI, M.; CADENASSO, M. L.; FELSON, A. J.; MCDONNELL, M. J.; PINCETL, S.; POUYAT, R. V.; SETÄLÄ, H.; WHITLOW, T. H. The benefits and limits of urban tree planting for environmental and human health. **Frontiers in Ecology and Evolution**, v. 9, artigo 603757, p. 1–9, 2021. ISSN 2296-701X. Disponível em: <https://doi.org/10.3389/fevo.2021.603757>. Acesso em: 21 mar. 2023.

PAVLYSHENKO, B. Using stacking approaches for machine learning models. In: **2018 IEEE Second International Conference on Data Stream Mining & Processing (DSMP)**. [s.n.], 2018. p. 255–258. Disponível em: <https://doi.org/10.1109/DSMP.2018.8478522>. Acesso em: 17 jan. 2024.

PIRES, R. de P.; OLOFSSON, K.; PERSSON, H. J.; LINDBERG, E.; HOLMGREN, J. Individual tree detection and estimation of stem attributes with mobile laser scanning along boreal forest roads. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 187, p. 211–224, 2022. ISSN 0924-2716. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2022.03.004>. Acesso em: 10 maio 2023.

RAMÍREZ, G.; SALAZAR, K.; BARRIA, V.; PINTO, O.; MARTIN, L. S.; CARRASCO, R.; FUENTEALBA, D.; GATICA, G. Accident risk detection in urban trees using machine learning and fuzzy logic. **Procedia Computer Science**, v. 203, p. 471–475, 2022. ISSN 1877-0509. Disponível em: <https://doi.org/10.1016/j.procs.2022.07.064>. Acesso em: 28 abr. 2023.

RASCHKA, S. **STAT 451: Machine Learning Lecture Notes**. 2020. 22 p. Notas de aula. Universidade de Wisconsin-Madison. Disponível em: https://sebastianraschka.com/pdf/lecture-notes/stat451fs20/07-ensembles__notes.pdf. Acesso em: 10 fev. 2024.

REDMON, J.; FARHADI, A. YOLOv3: An incremental improvement. **arXiv preprint**, artigo arXiv:1804.02767, p. 1–6, 2018. Disponível em: <https://doi.org/10.48550/arXiv.1804.02767>. Acesso em: 30 maio 2023.

ROCHA, L. M.; CAPPABIANCO, F. A. M.; FALCÃO, A. X. Data clustering as an optimum-path forest problem with applications in image analysis. **International Journal of Imaging Systems and Technology**, v. 19, n. 2, p. 50–68, 2009. Disponível em: <https://doi.org/10.1002/ima.20191>. Acesso em: 18 jan. 2024.

ROMAGNANO, L. F. T. di. **Instrumentos de gestão ambiental integrada**: diretrizes para o controle de cupins-subterrâneos em ambientes construídos. 2004. 126 p. Dissertação

(Mestrado em Tecnologia Ambiental) — Instituto de Pesquisas Tecnológicas do Estado de São Paulo, São Paulo, 2004. Disponível em: https://sapiens.ipt.br/Teses/2004_TA_Ligia_Torella_Romagnano.pdf. Acesso em: 17 abr. 2024.

ROMAN, L. A.; CONWAY, T. M.; EISENMAN, T. S.; KOESER, A. K.; BARONA, C. O.; LOCKE, D. H.; JENERETTE, G. D.; ÖSTBERG, J.; VOGT, J. Beyond 'trees are good': Disservices, management costs, and tradeoffs in urban forestry. **Ambio**, v. 50, n. 3, p. 615–630, mar 2021. ISSN 1654-7209. Disponível em: <https://doi.org/10.1007/s13280-020-01396-8>. Acesso em: 21 mar. 2023.

RUST, S.; STOINSKI, B. Using artificial intelligence to assist tree risk assessment. **Arboriculture & Urban Forestry**, v. 48, n. 2, p. 138–146, 2022. Disponível em: <https://doi.org/10.48044/jauf.2022.011>. Acesso em: 28 abr. 2023.

SHIGO, A. L. **Tree decay**: An expanded concept. Washington, DC, USA: U.S. Forest Service, 1979. 73 p. Agriculture Information Bulletin No. 419. Disponível em: <https://hardwoodbuckingham.mtu.edu/pdf/shigo.pdf>. Acesso em: 26 jul. 2024.

SHIGO, A. L.; MARX, H. G. **Compartmentalization of decay in trees**. Washington, DC, USA: U.S. Forest Service, 1977. 73 p. Agriculture Information Bulletin No. 405. Disponível em: <https://mntca.umn.edu/sites/mntca.umn.edu/files/2021-01/CODIT%20Booklet.pdf>. Acesso em: 25 abr. 2024.

SHORTLE, W. C.; DUDZIK, K. R. **Wood decay in living and dead trees**: A pictorial overview. Newtown Square, PA, USA: U.S. Forest Service, 2012. 26 p. General Technical Report NRS-97. Disponível em: <http://dx.doi.org/10.2737/NRS-GTR-97>.

SINGH, J.; BANERJEE, R. A study on single and multi-layer perceptron neural network. In: **2019 3rd International Conference on Computing Methodologies and Communication (IC-CMC)**. [s.n.], 2019. p. 35–40. Disponível em: <https://doi.org/10.1109/ICCMC.2019.8819775>. Acesso em: 18 jan. 2024.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and Computing**, v. 14, n. 3, p. 199–222, ago 2004. ISSN 1573-1375. Disponível em: <https://doi.org/10.1023/B:STCO.0000035301.49549.88>. Acesso em: 20 maio 2023.

SONG, Y.; LIANG, J.; LU, J.; ZHAO, X. An efficient instance selection algorithm for k nearest neighbor regression. **Neurocomputing**, v. 251, p. 26–34, 2017. ISSN 0925-2312. Disponível em: <https://doi.org/10.1016/j.neucom.2017.04.018>. Acesso em: 20 maio 2023.

TENG, C.-H.; CHEN, Y.-S.; HSU, W.-H. Tree segmentation from an image. In: **Proceedings of the 9th IAPR Conference on Machine Vision Applications**. Tsukuba, Japan: MVA Conference Committee, 2005. p. 59–63. Disponível em: <http://b2.cvl.iis.u-tokyo.ac.jp/mva/proceedings/CommemorativeDVD/2005/papers/2005059.pdf>. Acesso em: 30 maio 2023.

VERGARA, J. R.; ESTÉVEZ, P. A. A review of feature selection methods based on mutual information. **Neural Computing and Applications**, v. 24, n. 1, p. 175–186, jan 2014. ISSN 1433-3058. Disponível em: <https://doi.org/10.1007/s00521-013-1368-0>. Acesso em: 17 jan. 2024.

WANG, H.; WEI, Y.; WU, C. K.; TSANG, K. F.; LIU, Y.; ZHU, H. An assessment and guidance for the prevention and transmission of tree hazard to human safety. In: **2018 IEEE Symposium**

on Product Compliance Engineering - Asia (ISPCE-CN). [s.n.], 2018. p. 1–4. Disponível em: <https://doi.org/10.1109/ISPCE-CN.2018.8805788>. Acesso em: 28 abr. 2023.

WANG, X.-s.; HUANG, X.-y.; FU, H. The study of color tree image segmentation. In: **Proceedings of the 2009 Second International Workshop on Computer Science and Engineering**. Washington, DC, United States: IEEE Computer Society, 2009. v. 2, p. 303–307. Disponível em: <http://doi.org/10.1109/WCSE.2009.818>. Acesso em: 30 maio 2023.

WU, C. K.; TSANG, K. F.; LIU, Y.; WANG, H.; ZHU, H.; KOO, C. H.; WAN, W. H.; WEI, Y. An IoT tree health indexing method using heterogeneous neural network. **IEEE Access**, v. 7, p. 66176–66184, 2019. Disponível em: <https://doi.org/10.1109/ACCESS.2019.2918060>. Acesso em: 30 abr. 2023.

YANG, X. S. **Nature-Inspired Optimization Algorithms**. [S.l.]: Elsevier Inc., 2014. ISBN 9780124167438.

ZHENG, A.; CASARI, A. **Feature Engineering for Machine Learning**. Sebastopol, CA: O'Reilly Media, 2018.

ZHU, L.; KIM, S.-J.; HARA, M.; AONO, M. Remarkable problem-solving ability of unicellular amoeboid organism and its mechanism. **Royal Society Open Science**, v. 5, n. 12, artigo 180396, p. 1–13, 2018. Disponível em: <https://doi.org/10.1098/rsos.180396>. Acesso em: 17 jan. 2024.