



UNIVERSIDADE FEDERAL DO PARANÁ

FRANCIVAL CARDOSO FELIX

ANÁLISE DE SEMENTES ASSOCIADO A APRENDIZAGEM DE MÁQUINA PARA
IDENTIFICAR ESPÉCIES FLORESTAIS NATIVAS

CURITIBA

2023

FRANCIVAL CARDOSO FELIX

ANÁLISE DE SEMENTES ASSOCIADO A APRENDIZAGEM DE MÁQUINA PARA
IDENTIFICAR ESPÉCIES FLORESTAIS NATIVAS

Tese apresentada ao curso de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Engenharia Florestal.

Orientador: Prof. Dr. Antonio Carlos Nogueira
Coorientadores: Prof^a. Dr^a. Dagma Kratz
Prof. Dr. Richardson Ribeiro

CURITIBA

2023

Ficha catalográfica elaborada pela
Biblioteca de Ciências Florestais e da Madeira - UFPR

Felix, Francival Cardoso

Análise de sementes associado a aprendizagem de máquina para identificar espécies florestais nativas / Francival Cardoso Felix . - Curitiba, 2023.

1 recurso on-line : PDF.

Orientador: Prof. Dr. Antonio Carlos Nogueira

Coorientadores: Prof^a. Dr^a. Dagma Kratz

Prof. Dr. Richardson Ribeiro

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências Agrárias. Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 31/07/2023.

1. Árvores - Semente - Identificação. 2. Plantas florestais - Semente - Identificação. 3. Sementes - Identificação. 4. Aprendizado do computador. 5. Visão por computador. 6. Processamento de imagens. 7. Inteligência artificial. I. Nogueira, Antonio Carlos. II. Kratz, Dagma. III. Ribeiro, Richardson. IV. Universidade Federal do Paraná, Setor de Ciências Agrárias. V. Título.

CDD - 634.9

631.521

CDU - 634.0.231.31

631.53.01



MINISTÉRIO DA EDUCAÇÃO
SETOR DE CIÊNCIAS AGRÁRIAS
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA
FLORESTAL - 40001016015P0

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **FRANCIVAL CARDOSO FELIX** intitulada: **ANÁLISE DE SEMENTES ASSOCIADO A APRENDIZAGEM DE MÁQUINA PARA IDENTIFICAR ESPÉCIES FLORESTAIS NATIVAS**, sob orientação da Profa. Dra. DAGMA KRATZ, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 31 de Julho de 2023.

Assinatura Eletrônica
01/08/2023 09:36:32.0
DAGMA KRATZ

Presidente da Banca Examinadora

Assinatura Eletrônica
01/08/2023 16:26:19.0

LAUSANNE SORAYA DE ALMEIDA

Avaliador Externo (UNIVERSIDADE FEDERAL DE VIÇOSA)

Assinatura Eletrônica
31/07/2023 21:57:26.0

JULIO EDUARDO ARCE

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica
31/07/2023 13:51:45.0

ALLAN LIBANIO PELISSARI

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica
01/08/2023 15:14:20.0

MAURO VASCONCELOS PACHECO

Avaliador Externo (UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE)

Dedico aos meus pais, Francisco de Assis Felix
e Francisca Cardoso Felix, pelo apoio em toda
trajetória de minha vida.

AGRADECIMENTOS

À Universidade Federal do Paraná, e ao Programa de Pós-graduação em Engenharia Florestal pelo apoio na trajetória acadêmica de Doutorado.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão de bolsa de estudos e apoio financeiro.

Aos parceiros descritos a seguir, que contribuíram com o envio de amostras de sementes de diferentes espécies florestais, em um momento de Pandemia e isolamento social.

À Embrapa Florestas, Instituto Água e Terra, Sociedade Chauá e ao Laboratório de Sementes Florestais da Universidade Federal do Paraná, pela disponibilidade de sementes utilizadas nesta pesquisa.

Ao programa Bolsa de Sementes, parceria entre Associação dos Fumicultores do Brasil (AFUBRA) e a Universidade Federal de Santa Maria. E, ao Núcleo de Conservação da Biodiversidade do Instituto de Pesquisas Ambientais do Estado de São Paulo, pelo fornecimento de sementes.

Ao Núcleo de Ecologia e Monitoramento Ambiental - NEMA/UNIVASF, o Projeto de Integração do Rio São Francisco com as Bacias Hidrográficas do Nordeste Setentrional - PISF e o Ministério do Desenvolvimento Regional - MDR pela disponibilização das sementes.

Aos professores Dr. Antonio Carlos Nogueira, Dra. Dagma Kratz e Dr. Richardson Ribeiro pela orientação despendida durante o Doutorado. E ao grupo do Laboratório de Sementes Florestais da UFPR, pelo apoio e parceria na execução das atividades de pesquisa, sintam-se reconhecidos os parceiros atuais e os anteriores.

Aos meus colegas, especialmente Kyvia Pontes, Fernando Araújo, Letícia Walter, Mauro Pacheco e Salvador Torres, pelas parcerias de pesquisa e amizade. À Kyvia destaco a trajetória acadêmica juntos desde a graduação, onze anos de amizade e companheirismo que levamos para a vida.

À Maick Silva, que percorreu Norte e Sul do Brasil, somente para estar ao meu lado - acreditando e me apoiando - serei eternamente grato. Aos meus familiares e amigos, cujo apoio foi fundamental nessa jornada.

*Todas as grandes e belas árvores do mundo
nascem de uma pequena semente.*

RESUMO

A identificação e caracterização de sementes nativas representam um desafio para o setor florestal devido à variabilidade de características morfobiométricas. Atualmente, as metodologias para a análise biométrica de sementes florestais são realizadas por especialistas humanos utilizando métodos tradicionais de medições, como os paquímetros e variáveis baseadas em tamanho. Nesse contexto, concebeu-se uma nova metodologia empregando técnicas de processamento de imagens digitais e aprendizado de máquina com base em características externas das sementes para possibilitar a identificação de espécies florestais. A pesquisa foi dividida em três capítulos distintos. No primeiro capítulo foi realizada uma análise bibliométrica para quantificar e analisar os estudos científicos que abordam a análise de imagens e o aprendizado de máquina aplicados às sementes, e com isso apontar os principais tópicos e lacunas existentes para pesquisas com sementes florestais com esse enfoque. Os resultados indicam um aumento significativo de publicações a partir de 2017, com foco predominante em espécies de culturas agrícolas. Esses estudos estão direcionados principalmente para a classificação, identificação/detecção de cultivares e avaliação da qualidade das sementes, em que apenas 6,6% das publicações abordam espécies florestais, evidenciando a necessidade de mais pesquisas nesse campo com espécies nativas. No segundo capítulo foi proposta uma metodologia de captura e processamento de imagens para caracterização e diferenciação de espécies florestais nativas. Os resultados demonstraram que a análise de imagens de sementes, por meio dessa metodologia, contribuiu para a caracterização e diferenciação de espécies florestais nativas do Brasil, o que apresenta implicações diretas nos aspectos silviculturais, ecológicos e genéticos. No terceiro capítulo foram aplicados diferentes classificadores de aprendizado de máquina associados à análise de imagens para identificar espécies florestais nativas com base em características morfobiométricas das sementes. Os resultados revelaram que é possível identificar espécies florestais nativas com taxa satisfatória de acurácia usando imagens de sementes e aprendizado de máquina. Recomenda-se o classificador de árvores de decisão para a identificação de espécies. Os resultados fornecem subsídios importantes para aprimorar a caracterização e identificação de espécies, o que pode ser aplicado em diversos campos. Por fim, este trabalho contribuiu para identificar espécies florestais nativas, por meio do desenvolvimento de uma metodologia de análise e processamento de imagens e da aplicação de técnicas de aprendizado de máquina em sementes florestais.

Palavras-chave: sementes florestais; processamento de imagens; inteligência artificial; espécies nativas; morfobiometria.

ABSTRACT

The identification and characterization of native seeds represent a challenge for the forest sector due to the variability of morphobiometric characteristics. Currently, methodologies for the biometric analysis of forest seeds are carried out by human specialists using traditional measurement methods, such as calipers and variables based on size. In this context, a new methodology was conceived using techniques of digital image processing and machine learning based on external characteristics of the seeds to enable the identification of forest species. The research was divided into three distinct chapters. In the first chapter, a bibliometric analysis was carried out to quantify and analyze scientific studies that address image analysis and machine learning applied to seeds, and thereby point out the main topics and existing gaps for research with forest seeds with this focus. The results indicate a significant increase in publications from 2017 onwards, with a predominant focus on agricultural crop species. These studies are mainly focused on classification, identification/detection of cultivars and evaluation of seed quality, in which only 6.6% of publications address forest species, highlighting the need for further research in this field with native species. In the second chapter, a methodology for capturing and processing images for the characterization and differentiation of native forest species was proposed. The results showed that the analysis of seed images, using this methodology, contributed to the characterization and differentiation of forest species native to Brazil, which has direct implications for silvicultural, ecological, and genetic aspects. In the third chapter, different machine learning classifiers associated with image analysis were applied to identify native forest species based on morphobiometric characteristics of seeds. The results revealed that it is possible to identify native forest species with a satisfactory rate of accuracy using seed images and machine learning. The decision tree classifier is recommended for species identification. The results provide important subsidies to improve the characterization and identification of species, which can be applied in several fields. Finally, this work contributes to identify native forest species, through the development of an image analysis and processing methodology and the application of machine learning techniques in forest seeds.

Keywords: forest seeds; image processing; artificial intelligence; native species; morphobiometry.

LISTA DE FIGURAS

FIGURA 1 – ETAPAS DA METODOLOGIA PARA ANÁLISE BIBLIOMÉTRICA....	40
FIGURA 2 – DEFINIÇÃO DAS PALAVRAS-CHAVE PARA A PRIMEIRA E SEGUNDA BUSCA DE TRABALHOS	41
FIGURA 3 – HISTÓRICO DE PUBLICAÇÕES DE ARTIGOS CIENTÍFICOS INDEXADOS NAS BASES DE DADOS SELECIONADAS ATÉ O ANO DE 2022	45
FIGURA 4 – PRODUÇÃO CIENTÍFICA ANUAL COM TEMA RELEVANTE DESTACADO NAS PALAVRAS-CHAVE DE BUSCA ATÉ O ANO DE 2022.....	46
FIGURA 5 – PRODUÇÃO CIENTÍFICA MUNDIAL DE ARTIGOS COM A TEMÁTICA BUSCADA E COLABORAÇÃO ENTRE AUTORES DE DIFERENTES PAÍSES	49
FIGURA 6 – PRINCIPAIS PERIÓDICOS (A) E AUTORES (B) MAIS RELEVANTES NO ÂMBITO INTERNACIONAL QUE PUBLICARAM ARTIGOS COM A TEMÁTICA BUSCADA	50
FIGURA 7 – TEMAS PRINCIPAIS ABORDADOS NOS ARTIGOS A PARTIR DAS PALAVRAS-CHAVES INDICADAS PELOS AUTORES.....	51
FIGURA 8 – TENDÊNCIA DOS TEMAS AO LONGO DOS ANOS NOS ARTIGOS PUBLICADOS A PARTIR DAS PALAVRAS-CHAVES INDICADAS PELOS AUTORES.....	53
FIGURA 9 – REDE DE COCORRÊNCIA DOS TEMAS ABORDADOS NOS ARTIGOS PUBLICADOS A PARTIR DOS TERMOS CONTIDOS NOS TÍTULOS.....	54
FIGURA 10 – ETAPAS PARA AQUISIÇÃO E PROCESSAMENTO DAS IMAGENS EM SEMENTES NATIVAS	66
FIGURA 11 – PROTOCOLO PARA O PROCESSAMENTO DAS IMAGENS NO SOFTWARE IMAGEJ.....	68
FIGURA 12 – EXEMPLIFICAÇÃO DA EXTRAÇÃO DE CARACTERÍSTICAS DE TAMANHO E FORMATO EM SEMENTES FLORESTAIS NATIVAS.	69
FIGURA 13 – FORMAS DE VIDA (A) E DOMÍNIOS FITOGEOGRÁFICOS (B) DAS ESPÉCIES AVALIADAS NESTE ESTUDO.....	73

FIGURA 14 – CORRELAÇÃO DE PEARSON ENTRE AS CARACTERÍSTICAS DE TAMANHO, FORMATO E COLORAÇÃO OBTIDAS COM O PROCESSAMENTO DIGITAL DE IMAGENS DE SEMENTES NATIVAS.....	74
FIGURA 15 – ANÁLISE DE COMPONENTES PRINCIPAIS COM REPRESENTAÇÃO BILOT PARA TAMANHO, FORMATO E COLORAÇÃO OBTIDAS COM O PROCESSAMENTO DIGITAL DE IMAGENS EM SEMENTES DE 155 ESPÉCIES NATIVAS.....	75
FIGURA 16 – FREQUÊNCIA DE OCORRÊNCIA DAS ESPÉCIES EM FUNÇÃO DO TAMANHO DE SEMENTES PARA 155 ESPÉCIES NATIVAS.....	77
FIGURA 17 – FREQUÊNCIA DE OCORRÊNCIA DAS ESPÉCIES EM FUNÇÃO DO FORMATO DE SEMENTES PARA 155 ESPÉCIES NATIVAS	78
FIGURA 18 – FREQUÊNCIA DE OCORRÊNCIA DAS ESPÉCIES EM FUNÇÃO DA ESCALA DE COLORAÇÃO DE SEMENTES PARA 155 ESPÉCIES NATIVAS	79
FIGURA 19 – DENDROGRAMA CIRCULAR FORMADO COM BASE NA DISTÂNCIA EUCLIDIANA PARA 155 ESPÉCIES NATIVAS A PARTIR DO PROCESSAMENTO DIGITAL DE IMAGENS DAS SEMENTES.....	93
FIGURA 20 – METODOLOGIA DE TRABALHO PARA AQUISIÇÃO E ANÁLISE DAS IMAGENS, APLICAÇÃO E SELEÇÃO DOS ALGORITMOS...	106
FIGURA 21 – MATRIZ DE CONFUSÃO UTILIZADA PARA AVALIAÇÃO DO DESEMPENHO DOS CLASSIFICADORES.....	110
FIGURA 22 – TREINAMENTO E VALIDAÇÃO DOS CLASSIFICADORES TESTADOS A PARTIR DA SEPARAÇÃO DOS DADOS MORFOBIOMÉTRICOS DE SEMENTES	111
FIGURA 23 – EXEMPLIFICAÇÃO DO CLASSIFICADOR POR ÁRVORES DE DECISÃO	112
FIGURA 24 – EXEMPLIFICAÇÃO DO CLASSIFICADOR POR REDES NEURAIAS ARTIFICIAIS	113
FIGURA 25 – EXEMPLIFICAÇÃO DO CLASSIFICADOR POR K-VIZINHOS MAIS PRÓXIMOS.....	113
FIGURA 26 – EXEMPLIFICAÇÃO DO CLASSIFICADOR NAIVE-BAYES	114

FIGURA 27 – EXEMPLIFICAÇÃO DO CLASSIFICADOR POR MÁQUINA DE VETORES DE SUPORTE.....	115
FIGURA 28 – NÍVEL DE RECONHECIMENTO DAS ESPÉCIES A PARTIR DA ANÁLISE DE IMAGENS DE SEMENTES ASSOCIADA À APRENDIZAGEM DE MÁQUINA USANDO O CLASSIFICADOR POR ÁRVORES DE DECISÃO	118

LISTA DE TABELAS

TABELA 1 – RESULTADO DA SELEÇÃO DOS TRABALHOS COM SEPARAÇÃO POR TEMÁTICA E ABRANGÊNCIA DOS ESTUDOS, FOCO DAS PESQUISAS, QUANTITATIVO DE PUBLICAÇÕES E ESPÉCIES-ALVO DOS ARTIGOS	48
TABELA 2 – ARTIGOS SELECIONADOS COM BASE NA TEMÁTICA EM CIÊNCIAS FLORESTAIS E ENFOQUE EM SEMENTES, ANÁLISE DE IMAGENS E APRENDIZADO DE MÁQUINA	56
TABELA 3 – CONTRIBUIÇÃO DAS CARACTERÍSTICAS AVALIADAS PARA AS COMPONENTES PRINCIPAIS (CP) SELECIONADAS.....	76
TABELA 4 – CARACTERIZAÇÃO DE SEMENTES DE 155 ESPÉCIES NATIVAS A PARTIR DO PROCESSAMENTO DIGITAL DE IMAGENS PARA OBTENÇÃO DE DESCRITORES DE TAMANHO, FORMATO E COLORAÇÃO DAS SEMENTES	81
TABELA 5 – ATRIBUTOS DE TAMANHO, FORMATO E COLORAÇÃO SELECIONADOS E ANALISADOS A PARTIR DAS IMAGENS DE SEMENTES	108
TABELA 6 – DESEMPENHO DOS CLASSIFICADORES DE APRENDIZADO DE MÁQUINA TESTADOS PARA IDENTIFICAÇÃO DAS ESPÉCIES A PARTIR DA ANÁLISE DE IMAGENS DE SEMENTES.....	117
TABELA 7 – PRECISÃO DE IDENTIFICAÇÃO CORRETA DAS ESPÉCIES A PARTIR DA ANÁLISE DE IMAGENS DE SEMENTES ASSOCIADA À APRENDIZAGEM DE MÁQUINA USANDO O CLASSIFICADOR POR ÁRVORES DE DECISÃO.....	120

SUMÁRIO

1	INTRODUÇÃO	16
1.1	OBJETIVOS	19
1.1.1	Objetivo geral	19
1.1.2	Objetivos específicos.....	19
1.2	DIVISÃO E ORGANIZAÇÃO DA TESE.....	19
	REFERÊNCIAS	20
2	REVISÃO DE LITERATURA	24
2.1	CONTEXTUALIZAÇÃO	24
2.2	BIOMETRIA PARA CARACTERIZAÇÃO DE SEMENTES	25
2.3	IMPLICAÇÕES PARA DIFERENTES ESTUDOS	26
2.4	ANÁLISE DE IMAGENS APLICADO ÀS SEMENTES	27
2.5	APRENDIZADO DE MÁQUINA NA SILVICULTURA	30
	REFERÊNCIAS	32
	CAPÍTULO 1: ANÁLISE DE IMAGENS E APRENDIZADO DE MÁQUINA APLICADA A SEMENTES: UMA REVISÃO BIBLIOMÉTRICA	37
3.1	INTRODUÇÃO	38
3.2	MATERIAL E MÉTODOS	40
3.2.1	Seleção das bases de dados	41
3.2.2	Definição das palavras-chave	41
3.2.3	Pesquisa.....	42
3.2.4	Triagem dos trabalhos.....	42
3.2.5	Tratamento bibliométrico	43
3.3	RESULTADOS E DISCUSSÃO.....	44
3.4	CONCLUSÕES	58
	REFERÊNCIAS	60
	CAPÍTULO 2: CARACTERIZAÇÃO E DIFERENCIAÇÃO DE ESPÉCIES NATIVAS DO BRASIL POR MEIO DA ANÁLISE DE IMAGENS DE SEMENTES: UMA NOVA ABORDAGEM METODOLÓGICA	62
4.1	INTRODUÇÃO	63
4.2	MATERIAL E MÉTODOS	65
4.2.1	Obtenção das sementes.....	65
4.2.2	Captura e processamento das imagens	66

4.2.3	Descritores de tamanho, formato e de coloração	69
4.2.4	Análise dos dados	71
4.3	RESULTADOS E DISCUSSÃO.....	72
4.4	CONCLUSÕES	95
	REFERÊNCIAS.....	96
	CAPÍTULO 3: APLICAÇÃO DE APRENDIZAGEM DE MÁQUINA PARA IDENTIFICAR ESPÉCIES NATIVAS A PARTIR DA ANÁLISE DE SEMENTES POR IMAGENS	103
5.1	INTRODUÇÃO	104
5.2	MATERIAL E MÉTODOS	106
5.2.1	Desenho do trabalho	106
5.2.2	Aquisição e processamento das imagens de sementes.....	106
5.2.3	Aprendizado de máquina e classificação	109
5.2.4	Avaliação do desempenho	115
5.3	RESULTADOS E DISCUSSÃO.....	116
5.4	CONCLUSÕES	124
	REFERÊNCIAS.....	125
	CONSIDERAÇÕES FINAIS	128
	REFERÊNCIAS.....	131
	APÊNDICE 1	145
	APÊNDICE 2.....	154
	APÊNDICE 3.....	158

1 INTRODUÇÃO

As sementes desempenham um papel fundamental na perpetuação das espécies vegetais, são estruturas que contêm um ou mais embriões, nutrientes para a germinação e tecidos externos de proteção (BEWLEY *et al.*, 2013, p. 2). Das partes básicas que formam sua estrutura, o tegumento ou envoltórios da semente são comumente usados para o reconhecimento das espécies por apresentarem características próprias em cada planta.

A identificação e caracterização de espécies florestais nativas é realizada com base em características botânicas (COSTA *et al.*, 2016, p. 388), relacionadas às estruturas reprodutivas e vegetativas. No Brasil, estudos indicam a existência de aproximadamente 35 mil plantas nativas, incluindo principalmente Angiospermas, sendo 8 mil arbóreas (BRASIL, 2009, p. 55). Diante dessa diversidade, a identificação de espécies florestais com base nas características externas das sementes é uma tarefa difícil ao analista, e requer treinamento e conhecimento do profissional especializado.

As sementes nativas exibem diferenças morfológicas e biométricas distintas entre as espécies. Essas variações podem ser mensuradas e utilizadas em estudos com populações e seleção de indivíduos (MENEGATTI *et al.*, 2017, p. 370; ROVERI-NETO; PAULA, 2017, p. 320; CORREIA *et al.*, 2019, p. 758; ALFARO-SOLÍS *et al.*, 2020, p. 1920; ROSA *et al.*, 2020, p. 2). Nesse sentido, a análise biométrica de sementes contribui para trabalhos que abordam essa temática com espécies florestais.

Estudos indicam que variações morfobiométricas das sementes estão diretamente associados à diversidade genética das populações e interações fenotípicas (BRUS *et al.*, 2011, p. 667; REWICZ *et al.*, 2016, p. 32; SILVA *et al.*, 2017, p. 85; PONTES *et al.*, 2018, p. 452; FELIX *et al.*, 2020, p. 5 e 7), essencialmente importantes para o entendimento da dinâmica populacional, estabelecimento das espécies em novos ambientes (COSTA *et al.*, 2016, p. 391; KHUMAEVA *et al.*, 2016, p. 140), e propagação da espécie em programas de restauração ambiental (SANTOS *et al.*, 2018, p. 219).

Apesar da evidente importância, a biometria convencional em sementes florestais nativas utiliza apenas o tamanho com poucas medidas e variáveis, geralmente comprimento, largura e espessura, os quais são mensurados

manualmente com o auxílio de paquímetro digital utilizando amostras não superiores a 100 sementes (DUTRA *et al.*, 2017, p. 128; MENEGATTI *et al.*, 2017, p. 367; CORREIA *et al.*, 2019, p. 752; ZUFFO *et al.*, 2019, p. 626; ROSA *et al.*, 2020, p. 2). Além disso, a coloração da semente a olho nu é de difícil definição, e por isso, pouco utilizada nesses estudos.

Uma alternativa para superar isto, é empregar técnicas de processamento digital de imagens que podem permitir outras análises usando medidas relativas à coloração, formato e dimensão das sementes (VARMA *et al.*, 2013, p. 31; RAHMAN; CHO, 2016, p. 286; HEMENDER *et al.*, 2018, p. 2 e 3). Na coloração é possível gerar características como cor e contraste, predominância da ocorrência de tons de cinza, vermelho, verde e azul na imagem, usando o formato é possível definir geometricamente e quantitativamente as sementes em alongadas, elípticas ou ovaladas, ou mesmo sem formato predominante definido. Enquanto para dimensão, é possível medir as sementes em relação a área, perímetro, diferentes comprimentos e larguras conforme o formato da semente. Mas quanto desses atributos são suficientes para a caracterização de sementes e identificação das espécies nativas?

Dentre as aplicações que podem ser usadas com imagens digitais de sementes com o uso de diferentes descritores, destacam-se: distinguir espécies do mesmo gênero (BACCHETTA *et al.*, 2008, p. 681; BIANCO *et al.*, 2017, p. 8; PONTES *et al.*, 2018, p. 452); fornecer informações sobre a identificação de genótipos de diferentes regiões (MEDINA; SKURTYYS; AGUILERA, 2010, p. 245; REWICZ *et al.*, 2016, p. 28; SARIGU *et al.*, 2019, p. 808); auxiliar na taxonomia, catalogação, e delimitação de espécies (BACCHETTA *et al.*, 2008, p. 671; ORRÙ *et al.*, 2012, p. 231; BIANCO *et al.*, 2017, p. 8; UCCHESU *et al.*, 2016, p. 15; SARIGU *et al.*, 2019, p. 808); bem como diferenciar morfológicamente as sementes (MEDINA; SKURTYYS; AGUILERA, 2010, p. 245; ORRÙ *et al.*, 2012, p. 240). Contudo, não há relatos de estudos similares com espécies florestais do Brasil ou abordagens de uma metodologia de aquisição e processamento de imagens focado em sementes nativas.

Um aspecto importante no processamento digital de imagens são as ferramentas computacionais. Dentre as ferramentas disponíveis para capturar informações contidas em uma imagem digital e amplamente utilizada em diferentes estudos com sementes, destaca-se o *software* ImageJ® (FERREIRA; RASBAND,

2012, p. 1), o qual permite obter dados quantitativos de elementos contidos em uma imagem. Este *software* pode ser utilizado para avaliação morfométrica (NORONHA *et al.*, 2018, p. 1), caracterização biométrica (FELIX *et al.*, 2020, p. 7), discriminação taxonômica (SARIGU *et al.*, 2019, p. 808) e classificação de sementes (MEDEIROS *et al.*, 2020a, p. 1), bem como auxiliar na avaliação da diversidade genética em bancos de germoplasma (SAU *et al.*, 2018, p. 124) e processamento de imagens radiográficas de sementes agrícolas (MEDEIROS *et al.*, 2020b, p. 2). Portanto, é uma ferramenta de ampla utilização nas ciências agrárias que também pode ser aplicada em sementes nativas desde que se desenvolva uma metodologia adequada para isto, como a proposta apresentada no presente trabalho.

A aplicação de métodos de aprendizagem de máquina é amplamente utilizada e mostrou-se eficiente em estudos florestais com base em técnicas de análise de imagens (FRANKLIN; AHMED, 2017, p. 5236; FRANKLIN *et al.*, 2017, p. 501; CAO *et al.*, 2018, p. 17; WESSEL *et al.*, 2018, p. 19; XI *et al.*, 2020, p. 14). Em sementes, a análise de imagens associada à aprendizagem de máquina contribuiu para a avaliação de diversos aspectos (RAHMAN; CHO, 2016, p. 286 e 299; HEMENDER *et al.*, 2018, p. 2), como aplicação de imagens de espectroscopia para identificar sementes transgênicas e discriminar culturas agrícolas (LIU *et al.*, 2016, p. 420), selecionar variedades com visão computacional (KURTULMUŞ; ÜNAL, 2015, p. 1880), classificar sementes através de imagens radiográficas (MEDEIROS *et al.*, 2020a, p. 1; MEDEIROS *et al.*, 2020b, p. 8) e medir com precisão o tamanho de grãos de arroz com processamento de imagens em tempo real (SINGH *et al.*, 2020, p. 19). Contudo, as metodologias usadas nos estudos citados não podem ser simplesmente adotadas em sementes nativas devido as variações morfobiométricas que estas apresentam.

Portanto, necessita-se comprovar que o uso associado de diferentes descritores em cada semente é capaz de reduzir os erros de identificação devido à maior precisão de mensuração e baixa interferência humana, bem como estabelecer uma metodologia para captura das imagens de sementes que seja acessível, eficiente e reproduzível. Nesse sentido, a possibilidade de identificar espécies florestais nativas por meio das características externas das sementes, capturadas por imagens digitais e classificadas por aprendizado de máquina, apresenta-se como uma alternativa metodológica para identificar espécies e analisar de sementes florestais.

1.1 OBJETIVOS

1.1.1 Objetivo geral

Possibilitar a identificação de sementes florestais por meio da análise de imagens combinada com técnicas de aprendizado de máquina. Além de estabelecer uma metodologia para aquisição e processamento de imagens que seja acessível, reproduzível e eficiente, com enfoque em sementes nativas.

1.1.2 Objetivos específicos

- Quantificar e analisar os trabalhos científicos que contemplem estudos com imagem e aprendizado de máquina aplicados às sementes por meio da análise bibliométrica, bem como apontar os principais tópicos e lacunas existentes para pesquisas em sementes florestais com esse enfoque;
- Utilizar ferramentas de análise de imagens em sementes para fins de diferenciação e caracterização de espécies florestais nativas, a partir de uma metodologia de captura e processamento de imagens; e
- Aplicar diferentes classificadores de aprendizado de máquina associado à análise de imagens para identificação de espécies florestais nativas a partir de características morfobiométricas de sementes, empregando ferramentas de livre acesso para processamento de imagens e aprendizado de máquina.

1.2 DIVISÃO E ORGANIZAÇÃO DA TESE

Para alcançar os objetivos propostos, esta tese foi dividida em três capítulos, além da inclusão de uma revisão de literatura sobre a temática abordada neste trabalho:

Capítulo 1 - Análise de imagens e aprendizado de máquina aplicada a sementes: uma revisão bibliométrica;

Capítulo 2 - Caracterização e diferenciação de espécies nativas do Brasil por meio da análise de imagens de sementes: uma nova abordagem metodológica; e

Capítulo 3 - Aplicação de aprendizagem de máquina para identificar espécies nativas a partir da análise de sementes por imagens.

REFERÊNCIAS

- ALFARO-SOLÍS, J. D.; MONTOYA-ARROYO, A.; JIMÉNEZ, V. M.; ARNAEZ-SERRANO, E.; PÉREZ, J.; VETTER, W.; FRANK, J.; LEWANDOWSKI, I. *Acrocomia aculeata* fruits from three regions in Costa Rica: an assessment of biometric parameters, oil content and oil fatty acid composition to evaluate industrial potential. **Agroforestry Systems**, v. 2020, p. 1-15, 2020. <https://doi.org/10.1007/s10457-020-00511-8>
- BACCHETTA, G.; GRILLO, O.; MATTANA, E.; VENORA, G. Morpho-colorimetric characterization by image analysis to identify diaspores of wild plant species. **Flora**, v. 203, n. 8, p. 669-682, 2008. <https://doi.org/10.1016/j.flora.2007.11.004>
- BEWLEY, J. D.; BRADFORD, K. J.; HILHORST, H. W. M.; NONOGAKI, H. **Seeds - physiology of development, germination and dormancy**, 3rd Edition. Springer: New York, 2013. 392 p.
- BIANCO, M.; GRILLO, O.; ESCOBAR GARCIA, P.; MASCIA, F.; VENORA, G.; BACCHETTA, G. Morpho-colorimetric characterisation of *Malva* alliance taxa by seed image analysis. **Plant Biology**, v. 19, n. 1, p. 90-98, 2017. <https://doi.org/10.1111/plb.12481>
- BRASIL. Ministério da Agricultura, pecuária e Abastecimento. **Florestas do Brasil em resumo: 2019**. Ministério da Agricultura, pecuária e Abastecimento. Serviço Florestal Brasileiro. Brasília: MMA/SFB, 2009. 124p. www.fundoamazonia.gov.br/export/sites/default/pt/galleries/documentos/acervo-projetos-cartilhas-outros/SFB-Florestas-Brasil-2009-livro.pdf
- BRUS, R.; BALLIAN, D.; ZHELEV, P.; PANDZA, M.; BOBINAC, M.; ACEVSKI, J.; RAFTOYANNIS, Y.; JARNI, K. Absence of geographical structure of morphological variation in *Juniperus oxycedrus* L. subsp. *oxycedrus* in the Balkan Peninsula. **European Journal of Forest Research**, v. 130, p. 657-670, 2011. <https://doi.org/10.1007/s10342-010-0457-1>
- CAO, J.; LIU, K.; LIU, L.; ZHU, Y.; LI, J.; HE, Z. Identifying mangrove species using field close-range snapshot hyperspectral imaging and machine-learning techniques. **Remote Sensing**, v. 10, n. 12, e2047, 2018. <https://doi.org/10.3390/rs10122047>
- CORREIA, L. A. S.; FELIX, F. C.; ARAUJO, F. D. S.; FERRARI, C. D. S.; PACHECO, M. V. Morphometric descriptors and physiological seed quality for selecting *Aspidosperma pyrifolium* Mart. matrix trees. **Revista Caatinga**, v. 32, n. 3, p. 751-759, 2019. <https://doi.org/10.1590/1983-21252019v32n319rc>
- COSTA, M. F.; LOPES, A. C. A.; GOMES, R. L. F.; ARAÚJO, A. S. F.; ZUCCHI, M. I.; PINHEIRO, J. B.; VALENTE, S. E. S. Characterization and genetic divergence of *Casearia grandiflora* populations in the Cerrado of Piauí State, Brazil. **Floresta e Ambiente**, v. 23, n. 3, p. 387-396, 2016. <https://doi.org/10.1590/2179-8087.007115>

DUTRA, F. V.; CARDOSO, A. D.; BANDEIRA, A. S.; SILVA, R. M.; MORAIS, O. M.; PRATES, C. J. N. Biometrical characteristics of fruits and seeds of flamboyant. **Scientia Agraria Paranaensis**, v. 16, n. 1, p. 127-132, 2017.

FELIX, F. C.; MEDEIROS, J. A. D.; FERRARI, C. S.; VIEIRA, F. A.; PACHECO, M. V. Biometry of *Pityrocarpa moniliformis* seeds using digital imaging: implications for studies of genetic divergence. **Brazilian Journal of Agricultural Sciences**, v. 15, n. 1, e6128, 2020. <https://doi.org/10.5039/agraria.v15i1a6128>

FERREIRA, T.; RASBAND, W. **ImageJ**: user guide (IJ 1.46r), 2012. 198 p. <https://imagej.nih.gov/ij/docs/guide/user-guide.pdf>

FRANKLIN, S. E.; AHMED, O. S. Deciduous tree species classification using object-based analysis and machine learning with unmanned aerial vehicle multispectral data. **International Journal of Remote Sensing**, v. 39, p. 5236-5245, 2017. <https://doi.org/10.1080/01431161.2017.1363442>

FRANKLIN, S. E.; AHMED, O. S.; WILLIAMS, G. Northern conifer forest species classification using multispectral data acquired from an unmanned aerial vehicle. **Photogrammetric Engineering and Remote Sensing**, v. 83, n. 7, p. 501-507, 2017. <https://doi.org/10.14358/PERS.83.7.501>

HEMENDER; SHARMA, S.; MOR, V.; JITENDER; BHUKER, A. Image analysis: a modern approach to seed quality testing. **Current Journal of Applied Science and Technology**, v. 27, n. 1, p. 1-11, 2018. <https://doi.org/10.9734/cjast/2018/40945>

KHUMAIEVA, U. H.; KHABIBOV, A. D.; MURATCHAEVA, P. M. Assessment of the structure of the variability of morphological signs of *Trifolium medium* L. introduced under the conditions of mountainous dagestan. **Arid Ecosystems**, 6, p. 135-141, 2016. <https://doi.org/10.1134/S2079096116020074>

KURTULMUŞ, F.; ÜNAL, H. Discriminating rapeseed varieties using computer vision and machine learning. **Expert Systems with Applications**, v. 42, n. 4, p. 1880-1891, 2015. <https://doi.org/10.1016/j.eswa.2014.10.003>

LIU, W.; LIU, C.; HU, X.; YANG, J.; ZHENG, L. Application of terahertz spectroscopy imaging for discrimination of transgenic rice seeds with chemometrics. **Food Chemistry**, v. 210, p. 415-421, 2016. <https://doi.org/10.1016/j.foodchem.2016.04.117>

MEDEIROS, A. D.; PINHEIRO, D. T.; XAVIER, W. A.; SILVA, L. J.; DIAS, D. C. F. S. Quality classification of *Jatropha curcas* seeds using radiographic images and machine learning. **Industrial Crops and Products**, v. 146, p. 112-162, 2020a. <https://doi.org/10.1016/j.indcrop.2020.112162>

MEDEIROS, A. D.; SILVA, L. J.; SILVA, J. M.; DIAS, D. C. F. S.; PEREIRA, M. D. IJCropSeed: An open-access tool for high-throughput analysis of crop seed radiographs. **Computers and Electronics in Agriculture**, v. 175, e105555, 2020b. <https://doi.org/10.1016/j.compag.2020.105555>

- MEDINA, W.; SKURTYS, O.; AGUILERA, J. M. Study on image analysis application for identification quinoa seeds (*Chenopodium quinoa* Willd) geographical provenance. **Food Science and Technology**, v. 43, n. 2, p. 238-246, 2010. <https://doi.org/10.1016/j.lwt.2009.07.010>
- MENEGATTI, R. D.; MANTOVANI, A.; NAVROSKI, M. C.; SOUZA, A. G. Genetic divergence among provenances of *Mimosa scabrella* Benth. based on seed analysis. **Brazilian Journal of Agricultural Sciences**, v. 12, n. 3, p. 366-371, 2017. <http://dx.doi.org/10.5039/agraria.v12i3a5449>
- NORONHA, B. G.; PEREIRA, M. D.; FLORES, A. V.; DEMARTELAERE, A. C. F.; MEDEIROS, A. D. Morphometry and physiological quality of *Moringa oleifera* seeds in the function of their fruit position. **Journal of Experimental Agriculture International**, v. 25, n. 6, p. 1-10, 2018. <https://doi.org/10.9734/JEAI/2018/43375>
- ORRÙ, M.; GRILLO, O.; LOVI, G.; VENORA, G.; BACCHETTA, G. Morphological characterisation of *Vitis vinifera* L. seeds by image analysis and comparison with archaeological remains. **Vegetation History and Archaeobotany**, v. 22, n. 231, p. 231-242, 2012. <https://doi.org/10.1007/s00334-012-0362-2>
- PONTES, M. S.; MONTEFUSCO-PEREIRA, C. V.; MISRA, B. B.; RIBEIRO-JUNIOR, H. L.; GRACIANO, D. E.; SANTOS J. S.; NOBREGA, M. A. S.; FERNANDES, S. S. L.; CAIRES, A. R. L.; SANTIAGO, E. F. High-throughput phenotyping by applying digital morphometrics and fluorescence induction curves in seeds to identifying variations: a case study of *Annona* (Annonaceae) species. **Information Processing in Agriculture**, v. 5, n. 4, p. 443-455, 2018. <https://doi.org/10.1016/j.inpa.2018.07.001>
- RAHMAN, A.; CHO, B. W. Assessment of seed quality using non destructive measurement techniques: a review. **Seed Science Research**, v. 26, p. 285-305, 2016. <https://doi.org/10.1017/S0960258516000234>
- REWICZ, A.; BOMANOWSKA, A.; MAGDA, J.; REWICZ, T. Morphological variability of *Consolida regalis* seeds of south-eastern and central Europe. **Systematics and Biodiversity**, v. 15, n. 1, p. 25-34, 2016. <https://doi.org/10.1080/14772000.2016.1216017>
- ROSA, T. L. M.; ARAUJO, C. P.; KAMKE, C.; FERREIRA, A.; FERREIRA, M. F. S.; OLIVEIRA, J. B.; SCHMILDT, E. R.; LOPES, J. C.; MENGARDA, L. H. G.; OTONI, W. C.; SANTOS, A. R.; ALEXANDRE, R. S. Sapucaia nut: morphophysiology, minerals content, methodological validation in image analysis, phenotypic and molecular diversity in *Lecythis pisonis* Cambess. **Food Research International**, v. 137, e109383, 2020. <https://doi.org/10.1016/j.foodres.2020.109383>
- ROVERI-NETO, A.; PAULA, R. C. Variability among mother trees of *Ceiba speciosa* St. Hil for characteristics of the fruits and seeds. **Revista Ciência Agronômica**, v. 48, n. 2, p. 318-327, 2017. <https://doi.org/10.5935/1806-6690.20170037>
- SARIGU, M.; PORCEDDU, M.; SCHMITT, E.; CAMARDA, I.; BACCHETTA, G. Taxonomic discrimination of the *Paeonia mascula* group in the Tyrrhenian Islands by

seed image analysis. **Systematics and Biodiversity**, v. 17, n. 8, p. 801-810, 2019.
<https://doi.org/10.1080/14772000.2019.1685607>

SAU, S.; UCCHESE, M.; DONDINI, L.; DE FRANCESCHI, P.; D'HALLEWIN, G.; BACCHETTA, G. Seed morphometry is suitable for apple-germplasm diversity-analyses. **Computers and Electronics in Agriculture**, v. 151, p. 118-125, 2018.
<https://doi.org/10.1016/j.compag.2018.06.002>

SILVA, R. M.; CARDOSO, A. D.; DUTRA, F. V.; MORAIS, O. M. Biometric aspects of fruit and seed of *Caesalpinia ferrea* Mart. ex Tul. from semiarid baiano. **Journal of Neotropical Agriculture**, v. 4, n. 3, p. 85-91, 2017.
<https://doi.org/10.32404/rean.v4i3.1427>

SINGH, S. K.; VIDYARTHI, S. K.; TIWARI, R. Machine learnt image processing to predict weight and size of rice kernels. **Journal of Food Engineering**, v. 274, e109828, 2020. <https://doi.org/10.1016/j.jfoodeng.2019.109828>

UCCHESE, M.; ORRÙ, M.; GRILLO, O.; VENORA, G.; PAGLIETTI, G.; ARDU, A.; BACCHETTA, G. Predictive method for correct identification of archaeological charred grape seeds: support for advances in knowledge of grape domestication process. **Plos One**, v. 11, n. 2, p. 01-18, 2016.
<http://dx.doi.org/10.1371/journal.pone.0149814>

VARMA, V. S.; DURGA, K.; KESHAVULU, K. Seed image analysis: its applications in seed science research. **International Research Journal of Agricultural Sciences**, v. 1, n. 2, p. 30-36, 2013.

WESSEL, M.; BRANDMEIER, M.; TIEDE, D. Evaluation of different machine learning algorithms for scalable classification of tree types and tree species based on Sentinel-2 data. **Remote Sensing**, v. 10, n. 9, e1419, 2018.
<https://doi.org/10.3390/rs10091419>

XI, Z.; HOPKINSON, C.; ROOD, S. B.; PEDDLE, D. R. See the forest and the trees: effective machine and deep learning algorithms for wood filtering and tree species classification from terrestrial laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 168, p. 1-16, 2020.
<https://doi.org/10.1016/j.isprsjprs.2020.08.001>

ZUFFO, A. M. A.; STEINER, F.; ALVES, C. Z.; ALCÂNTARA-NETO, F.; SANTOS, M. D. A.; OLIVEIRA, A. M.; SOUSA, T. O.; FONSECA, W. L. Biometric characteristics of fruits, seeds and plants of *Hancornia speciosa* Gomes. (Apocynaceae). **Australian Journal of Crop Science**, v. 13, p 622-627, 2019.
<https://doi.org/10.21475/ajcs.19.13.04.p1651>

2 REVISÃO DE LITERATURA

A revisão bibliográfica desempenha um papel fundamental no contexto da pesquisa e estudo acadêmico, fornecendo uma introdução ao tema principal deste documento. Neste sentido, será abordada a relevância da caracterização de sementes florestais por meio de métodos biométricos, destacando suas implicações em diferentes áreas de estudo e explorando possíveis abordagens alternativas com o uso de ferramentas de processamento de imagens. Além disso, ênfase será dada ao emprego do aprendizado de máquina na área da Silvicultura.

2.1 CONTEXTUALIZAÇÃO

As sementes nativas apresentam diversidade dos aspectos biométricos e morfológicos. Nesse sentido, a identificação de espécies por meio das características externas das sementes se apresenta como um fator limitante, uma vez que a quantidade de plantas que compõe a biodiversidade brasileira impossibilita o uso de métodos manuais e estatísticos. Por isso, uma alternativa é explorar técnicas de análise de imagens e aprendizagem de máquina para identificar espécies a partir de uma metodologia de captura e processamento de imagens, inexistentes em sementes florestais nativas.

Exploração que incluem a análise de imagens associadas a modelagens de inteligência artificial foi feita para identificação de fungos, plantas e doenças sistêmicas em espécies de uso ornamental e comercial, a partir de características morfológicas capturadas por câmera. Inclusive, com o desenvolvimento de aplicativos por *startups*, instituições públicas e empresas, como *iNaturalist*¹, *Mushroom Identify*², *PlantNet*³, *PlantSnap*⁴, *Plantyx*⁵, *Picture Mushroom*⁶ e *PictureThis*⁷. Por isso, essa temática é continuamente estudada e aprofundada em diversas áreas devido às inúmeras aplicações.

¹ <https://www.inaturalist.org/>

² <https://champignouf.com/>

³ <https://identify.plantnet.org/>

⁴ <https://www.plantsnap.com/>

⁵ <https://apps.apple.com/br/app/plantyx-identificar-plantas/id1490577892>

⁶ <https://apps.apple.com/us/app/mushroom-identificador/id1227854971>

⁷ <https://www.picturethisai.com/>

Nas ciências agrárias, é possível encontrar aplicação de aprendizagem de máquina em diferentes domínios de problemas, como manejo de culturas, previsão de produtividade, detecção de doenças e matocompetição, qualidade da cultura e reconhecimento das espécies, além de gestão do solo e da água (LIAKOS *et al.*, 2018, p. 1). Nesse sentido, técnicas de aprendizagem de máquina na silvicultura e tecnologia de sementes florestais deve ser incentivada, sobretudo para as espécies nativas que carecem destes estudos.

2.2 BIOMETRIA PARA CARACTERIZAÇÃO DE SEMENTES

A “biometria” é caracterizada como medida da vida em seu contexto geral (*bio*=vida, e *metria*=medida)⁸ com base em análise estatística⁹, mensuração de órgãos, tecidos, estruturas e indivíduos. A caracterização biométrica em plantas pode ser feita com avaliação dos aspectos morfológicos (flores, folhas, frutos e sementes), sendo frutos e sementes essencialmente importantes na área florestal, como destacado nos trabalhos de Santos *et al.* (2018), Conceição *et al.* (2019), Araújo *et al.* (2022) e Bezerra *et al.* (2022) com espécies nativas.

Variações nas características biométricas das sementes estão diretamente associadas à diversidade genética de populações e alterações ambientais da região de origem, como estudado para *Acrocomia aculeata* (Jacq.) Lodd. ex Mart. (ALFARO-SOLÍS *et al.*, 2020, p. 1920), *Annona* sp. L. (PONTES *et al.*, 2018, p. 452), *Aspidosperma discolor* A.DC. (LIMA *et al.*, 2015, p. 2 e 9), *Caesalpinia ferrea* Mart. ex Tul. (SILVA *et al.*, 2017, p. 85), *Casearia grandiflora* Cambess. (COSTA *et al.*, 2016, p. 395), *Consolida regalis* Gray (REWICZ *et al.*, 2016, p. 32), *Juniperus oxycedrus* subsp. *oxycedrus* L. (BRUS *et al.*, 2011, p. 667) e *Pityrocarpa moniliformis* (Benth.) Luckow & R.W. Jobson (FELIX *et al.*, 2020, p. 5 e 7).

A avaliação de aspectos biométricos de sementes são fundamentais para o entendimento da dinâmica populacional e estabelecimento de espécies em novos ambientes (BRUS *et al.*, 2011, p. 667; KHUMAEVA *et al.*, 2016, p. 140; REWICZ *et al.*, 2016, p. 32; SILVA *et al.*, 2017, p. 85). Além disso, a análise biométrica auxilia na seleção de indivíduos e populações através da divergência genética encontrada entre diferentes progenitoras como destacado nos estudos de Menegatti *et al.* (2017,

⁸ <https://dicionario.priberam.org/biometria>

⁹ <https://www.dicio.com.br/biometria/>

p. 370), Roveri-Neto e Paula (2017, p. 320), Pontes *et al.* (2018, p. 452), Correia *et al.* (2019, p. 758) e Rosa *et al.* (2020, p. 4). Portanto, evidencia-se que a caracterização biométrica de sementes contribui para estudos populacionais, diferenciação de espécies e genótipos. No entanto, vale ressaltar que a biometria convencional geralmente utiliza um descritor de tamanho, como comprimento, largura e espessura das sementes.

Frequentemente, a obtenção dos caracteres biométricos em sementes florestais é feita manualmente com paquímetro digital (COSTA *et al.*, 2016, p. 390; SILVA *et al.*, 2017, p. 87; SANTOS *et al.*, 2018, p. 220; CONCEIÇÃO *et al.*, 2019, p. 328; CORREIA *et al.*, 2019, p. 752), o qual é susceptível a erros do avaliador e demanda tempo para aferição de muitas amostras. Por isso, normalmente é realizada com pequenas quantidades dificilmente superiores a 100 sementes (DUTRA *et al.*, 2017, p. 128; MENEGATTI *et al.*, 2017, p. 367; ROVERI-NETO; PAULA, 2017, p. 320; ZUFFO *et al.*, 2019, p. 1; ROSA *et al.*, 2020, p. 2). Além disso, a definição de coloração da semente a olho nu tem limitações por ser de difícil definição e susceptível a erro humano.

Diante das limitações apresentadas e para caracterizar de forma fidedigna as espécies florestais nativas, deve-se realizar um esforço amostral maior, que somente é alcançado com o uso de ferramentas de análises e processamento com várias amostras. O processamento digital de imagens para geração de atributos das sementes é capaz de fornecer diversos descritores quantitativos (DELL'AQUILA, 2006, p. 21; VARMA *et al.*, 2013, p. 31; RAHMAN; CHO, 2016, p. 286; HEMENDER *et al.*, 2018, p. 2 e 3). Portanto, utilizar técnicas de análise de imagens para biometria de sementes nativas associada a uma metodologia de captura e processamento de imagens é uma alternativa para geração de atributos e caracterização de espécies.

2.3 IMPLICAÇÕES PARA DIFERENTES ESTUDOS

A avaliação biométrica além de fornecer informações relacionadas a diversidade genética entre indivíduos e populações, também contribui para identificação de espécies e diferenciação de genótipos a partir de sementes (BACCHETTA *et al.*, 2008, p. 681; MARANHO *et al.*, 2014, p. 56; BIANCO *et al.*, 2017, p. 8). Além disso, a biometria associada a morfologia de sementes auxilia em

estudos de taxonomia, identificação, variabilidade genética e interações fenotípicas (PONTES *et al.*, 2018, p. 444 e 452).

A aplicação da análise biométrica também auxilia na determinação de divergência genética entre populações e indivíduos, subsidiando a escolha de descritores que podem ser utilizados para seleção de genótipos, visto que as variações biométricas encontradas em sementes estão associadas ao estabelecimento da espécie e dinâmica populacional (COSTA *et al.*, 2016, p. 395; PONTES *et al.*, 2018, p. 452). Assim, existe a necessidade de estabelecer e quantificar os descritores biométricos que reflitam a existência de diversidade genética entre genótipos e populações florestais.

A seleção de genótipos potenciais por meio de análise biométrica de sementes contribui para o melhoramento genético e diversidade das espécies florestais. Nesse sentido, a biometria de sementes auxiliou na seleção de matrizes de *Ceiba speciosa* St. Hil (ROVERI-NETO; PAULA, 2017, p. 320), *Bowdichia virgilioides* Kunth (CONCEIÇÃO *et al.*, 2019, p. 334) e *Aspidosperma pyriformium* Mart. (CORREIA *et al.*, 2019, p.758), bem como no melhoramento e acesso a variabilidade genética de populações de *Mimosa scabrella* Benth. (MENEGATTI *et al.*, 2017, p. 370) e *Lecythis pisonis* Cambess. (ROSA *et al.*, 2020, p. 6). E em estudos de divergência genética em *Casearia grandiflora* Camb. (COSTA *et al.*, 2016, p. 395) e *Pityrocarpa moniliformis* (Benth.) Luckow & R.W. Jobson (FELIX *et al.*, 2020, p.7).

Portanto, a análise de sementes a partir de imagens apresenta-se como alternativa para estudos de populações, seleção de matrizes, melhoramento genético, diferenciação de genótipos e análise da variabilidade genética em espécies florestais, substituindo os métodos convencionais de mensuração e obtenção dos dados biométricos em sementes nativas. Para isso, é necessário o desenvolvimento de uma metodologia de captura e processamento de imagens voltados para sementes florestais.

2.4 ANÁLISE DE IMAGENS APLICADO ÀS SEMENTES

A análise de sementes por imagens apresenta vantagens em relação às técnicas tradicionais ou manuais de mensuração (VARMA *et al.*, 2013, p. 31), principalmente em relação a velocidade e otimização das avaliações (HEMENDER

et al., 2018, p. 2). É um método não invasivo, e as análises podem ser automatizadas, ter baixo custo operacional e de qualificação dos profissionais, proporcionando, por exemplo, uma correta identificação varietal e de qualidade de sementes, essencial para produtores, comerciantes e usuários (KAPADIA; SASIDHARAN; KALYANRAO, 2017, p. 43).

As análises de imagens são testadas e padronizadas por espécie para avaliar com precisão diversos aspectos das sementes (RAHMAN; CHO, 2016, p. 299), empregando-se *softwares* que extraem dados quantitativos relacionados à semente, e facilitam a obtenção de descritores específicos (DELL'AQUILA, 2006, p. 21; VARMA *et al.*, 2013, p. 31; HEMENDER *et al.*, 2018, p. 2). Contudo, nota-se que os estudos se concentram em culturas agrícolas de importância econômica.

O processamento digital de imagens também contribui para a biologia, morfologia e indústria de sementes em geral, atuando em programas de identificação, produção, colheita, controle de qualidade, classificação, pesquisa e fenotipagem (VARMA *et al.*, 2013, p. 32), além de auxiliar na avaliação da qualidade fisiológica de sementes (DELL'AQUILA, 2006, p. 21; PEÑALOZA; DURÁN, 2015, p. 270; RAHMAN; CHO, 2016, p. 286 e 295). Como resultado, o uso de técnicas de análise de imagens reduz o tempo necessário para a execução de atividades, otimizando metodologias de avaliação, o que traz vantagens operacionais e objetividade para as análises (PEÑALOZA; DURÁN, 2015, p. 267).

Os principais descritores morfobiométricos das sementes obtidos com a análise de imagens estão relacionados à coloração, formato e dimensões das sementes (DELL'AQUILA, 2006, p. 21; VARMA *et al.*, 2013, p. 31; HEMENDER *et al.*, 2018, p. 4). Esses descritores foram utilizados com diversos objetivos: identificar espécies do mesmo gênero (BACCHETTA *et al.*, 2008, p. 681; BIANCO *et al.*, 2017, p. 8; PONTES *et al.*, 2018, p. 452); identificar genótipos de diferentes regiões (MEDINA; SKURTYS; AGUILERA, 2010, p. 245; REWICZ *et al.*, 2016, p. 28 e 29; SARIGU *et al.*, 2019, p. 808); taxonomia, catalogação, e delimitação de espécies (BACCHETTA *et al.*, 2008, p. 671; ORRÙ *et al.*, 2012, p. 231; BIANCO *et al.*, 2017, p. 8; UCCHESE *et al.*, 2016, p. 15; SARIGU *et al.*, 2019, p. 808); e diferenciação morfológica de sementes (MEDINA; SKURTYS; AGUILERA, 2010, p. 245; ORRÙ *et al.*, 2012, p. 240). Todos os estudos citados foram conduzidos em espécies não nativas do Brasil.

As técnicas de análises de imagens em sementes também contribuem para estudos arqueológicos (GONG *et al.*, 2010, p. 82; ORRÙ *et al.*, 2012, p. 240; UCCHESE *et al.*, 2016, p. 15), caracterização de bancos de germoplasma (BACCHETTA *et al.*, 2008, p. 670 e 681; SAU *et al.*, 2018, p. 124), diferenciação de indivíduos em função da origem geográfica e classificação de sementes (MEDINA; SKURTYS; AGUILERA, 2010, p. 245; PEÑALOZA; DURÁN, 2015, p. 268). Entretanto, não há relatos de estudos similares com espécies florestais nativas.

Dentre as ferramentas tecnológicas que podem ser utilizadas para capturar informações contidas em uma imagem digital, destaca-se o *software* ImageJ® (FERREIRA; RASBAND, 2012, p. 1) que foi desenvolvido em plataforma Java. Este permite incontáveis possibilidades para tratamento de imagens digitais e obtenção de dados em elementos contidos da imagem e delimitados pelo *software*, os quais são interpretados como partículas em uma imagem. Por exemplo, este *software* foi utilizado para avaliação morfométrica em *Moringa oleifera* Lam. (NORONHA *et al.*, 2018, p. 1), caracterização biométrica de *Pityrocarpa moniliformis* (Benth.) Luckow & R.W. Jobson (FELIX *et al.*, 2020, p. 7), discriminação taxonômica de *Paeonia mascula* (L.) Mill. (SARIGU *et al.*, 2019, p. 808) e classificação de sementes de *Jatropha curcas* L. (MEDEIROS *et al.*, 2020a, p. 1), bem como avaliação da diversidade genética em bancos de germoplasma de *Malus domestica* Borkh. (SAU *et al.*, 2018, p. 124) e processamento de imagens radiográficas de sementes agrícolas (MEDEIROS *et al.*, 2020b, p. 2).

Outros métodos não destrutivos com base em imagens digitais são utilizados para avaliação de sementes, como visão de máquina (*machine vision*), espectroscopia (*spectroscopy*), imagens hiperespectrais (*hyperspectral imaging*), imagem de raios-X (*soft x-ray imaging*), imagem térmica (*thermal imaging*) e técnicas de nariz eletrônico (*electronic nose*) (RAHMAN; CHO, 2016, p. 287). Juntamente à essas técnicas, algoritmos de inteligência artificial são empregados para otimizar o processo de análise das sementes (BIANCHINI *et al.*, 2021, p. 3), como aplicação de imagens de espectroscopia para identificar sementes transgênicas e discriminar culturas agrícolas (LIU *et al.*, 2016, p. 420), selecionar variedades com visão computacional (KURTULMUŞ; ÜNAL, 2015 p. 1880) ou classificar sementes através de imagens radiográficas e aprendizado de máquina (MEDEIROS *et al.*, 2020a, p. 1; 2020b, p. 8).

Portanto, a utilização de análise de imagens associada à inteligência artificial é uma alternativa para identificação de sementes, entretanto, não foram encontrados relatos de estudos com esse enfoque para espécies florestais nativas. Por isso, é necessário testar diferentes técnicas de aprendizado de máquina para confirmar a efetividade de aplicação do algoritmo para o problema proposto.

2.5 APRENDIZADO DE MÁQUINA NA SILVICULTURA

A aprendizagem de máquina (*Machine Learning*), método dentro do universo da inteligência artificial, proporcionou novas investigações e oportunidades para as ciências que trabalham com grandes volumes de dados (*big data*), tornando possível desvendar, quantificar e compreender processos intensivos (LIAKOS *et al.*, 2018, p. 1). Assim, o objetivo com o aprendizado de máquina é a construção de programas que melhorem seu desempenho por meio de exemplos (MITCHELL, 1997).

No setor florestal, técnicas de aprendizagem de máquina são utilizadas em diversas aplicações, como classificação de espécies arbóreas decíduas (FRANKLIN; AHMED, 2017, p. 5236) e de pináceas com base em imagens multiespectrais coletadas a partir de veículos aéreos não tripulados – VANTs (FRANKLIN *et al.*, 2017, p. 501). Também contribui para identificação de espécies de mangue (CAO *et al.*, 2018, p. 17), classificação e diferenciação de folhosas e coníferas (WESSEL *et al.*, 2018, p. 19) e manejo de florestas para sortimento e filtragem da madeira (XI *et al.*, 2020, p. 14).

No processamento de imagens digitais, a quantidade de dados relacionados às sementes tornaria difícil a identificação e classificação das sementes, por isso, emprega-se técnicas de aprendizagem de máquina para definir os critérios e identificar os atributos que o pesquisador deseja. Existem diversos algoritmos de aprendizagem de máquina que podem ser utilizados nas ciências agrárias, como redes neurais artificiais (*artificial neural networks*), modelos bayesianos (*bayesian models*), aprendizado profundo (*deep learning*), redução de dimensionalidade (*dimensionality reduction*), árvores de decisão (*decision trees*), aprendizado por conjunto (*ensemble learning*), aprendizagem com base em instâncias (*instance-based learning*) e máquinas de vetores de suporte (*support vector machines*) (LIAKOS *et al.*, 2018, p. 2).

Em resumo, estudos evidenciaram a importância da aplicação da aprendizagem de máquinas na área de sementes em vários aspectos (RAHMAN; CHO, 2016, p. 286 e 299; HEMENDER *et al.*, 2018, p. 2), como aplicação de imagens de espectroscopia para identificar sementes transgênicas e discriminar culturas agrícolas (LIU *et al.*, 2016, p. 420), selecionar variedades com visão computacional (KURTULMUŞ; ÜNAL, 2015, p. 1880), classificar sementes através de imagens radiográficas (MEDEIROS *et al.*, 2020a, p. 1; 2020b, p. 8) e medir com precisão o tamanho de grãos de arroz com processamento de imagens em tempo real (SINGH *et al.*, 2020, p. 19). Portanto, a aplicação de aprendizagem de máquina a partir da morfobiometria de sementes poderá contribuir em trabalhos de identificação de espécies, diferenciação de genótipos e análise de sementes florestais em geral.

A revisão bibliográfica apresentada destaca as possibilidades de aplicação da análise de imagens e aprendizado de máquina na área da Silvicultura. No entanto, é evidente a falta de respaldo quantitativo e qualitativo nos estudos que abordam essa temática, especialmente em relação às espécies florestais nativas do Brasil. Nesse sentido, é necessário realizar estudos bibliométricos abrangentes que possam fornecer informações atualizadas sobre o estado da arte da análise de imagens e aprendizado de máquina aplicados em sementes; temática essa que será abordada no primeiro capítulo. Pesquisas como esta ajudarão a preencher uma lacuna de conhecimento e promover avanços significativos nesse campo.

REFERÊNCIAS

- ALFARO-SOLÍS, J. D.; MONTOYA-ARROYO, A.; JIMÉNEZ, V. M.; ARNAEZ-SERRANO, E.; PÉREZ, J.; VETTER, W.; FRANK, J.; LEWANDOWSKI, I. *Acrocomia aculeata* fruits from three regions in Costa Rica: an assessment of biometric parameters, oil content and oil fatty acid composition to evaluate industrial potential. **Agroforestry Systems**, v. 2020, p. 1-15, 2020. <https://doi.org/10.1007/s10457-020-00511-8>
- ARAÚJO, J. K. P.; ARAÚJO, J. S. O.; SANTOS, D. F.; PACHECO, M. V.; ARAUJO, P. C. D. Seminiferous propagation of *Cordia oncocalyx* (Allemão) Baill. and biometric characterization of diaspores and seeds. **Revista Caatinga**, v. 35, n. 1, p. 160 – 169, 2022. <https://doi.org/10.1590/1983-21252022v35n116rc>
- BACCHETTA, G.; GRILLO, O.; MATTANA, E.; VENORA, G. Morpho-colorimetric characterization by image analysis to identify diaspores of wild plant species. **Flora**, v. 203, n. 8, p. 669-682, 2008. <https://doi.org/10.1016/j.flora.2007.11.004>
- BEZERRA, A. C.; ZUZA, J. F. C.; SILVA BARBORA, L.; AZEVEDO, C. F.; ALVES, E. U. Biometrics of mulungu seeds from different mother plants in the semi-arid region of Paraíba, Brazil. **Revista Caatinga**, v. 35, n. 2, p. 393 – 401, 2022. <https://doi.org/10.1590/1983-21252022v35n215rc>
- BIANCO, M. L.; GRILLO, O.; GARCIA, P. E.; MASCIA, F.; VENORA, G.; BACCHETTA, G. Morpho- colorimetric characterisation of *Malva alliance* taxa by seed image analysis. **Plant Biology**, v. 19, n. 1, p. 1-9, 2017. <https://doi.org/10.1111/plb.12481>
- BRUS, R.; BALLIAN, D.; ZHELEV, P.; PANDZA, M.; BOBINAC, M.; ACEVSKI, J.; RAFTOYANNIS, Y.; JARNI, K. Absence of geographical structure of morphological variation in *Juniperus oxycedrus* L. subsp. *oxycedrus* in the Balkan Peninsula. **European Journal of Forest Research**, v. 130, p. 657-670, 2011. <https://doi.org/10.1007/s10342-010-0457-1>
- CAO, J.; LIU, K.; LIU, L.; ZHU, Y.; LI, J.; HE, Z. Identifying mangrove species using field close-range snapshot hyperspectral imaging and machine-learning techniques. **Remote Sensing**, v. 10, n. 12, e2047, 2018. <https://doi.org/10.3390/rs10122047>
- CONCEIÇÃO, T. A.; MENDONÇA, A. V. R.; SOUZA, M. O.; SOUZA, J. S.; MOREIRA, R. F. C. Seed collection environment: effects of forest cover reduction on biometrics and seed lot quality of *Bowdichia virgilioides* Kunth. **Científica**, v. 47, n. 3, p. 327-336, 2019. <https://doi.org/10.15361/1984-5529.2019v47n3p327-336>
- CORREIA, L. A. S.; FELIX, F. C.; ARAUJO, F. D. S.; FERRARI, C. D. S.; PACHECO, M. V. Morphometric descriptors and physiological seed quality for selecting *Aspidosperma pyriforme* Mart. matrix trees. **Revista Caatinga**, v. 32, n. 3, p. 751-759, 2019. <https://doi.org/10.1590/1983-21252019v32n319rc>
- COSTA, M. F.; LOPES, A. C. A.; GOMES, R. L. F.; ARAÚJO, A. S. F.; ZUCCHI, M. I.; PINHEIRO, J. B.; VALENTE, S. E. S. Characterization and genetic divergence of

Casearia grandiflora populations in the Cerrado of Piauí State, Brazil. **Floresta e Ambiente**, v. 23, n. 3, p. 387-396, 2016. <https://doi.org/10.1590/2179-8087.007115>

DELL'AQUILA, A. Computerised seed imaging: a new tool to evaluate germination quality. **Communications in Biometry and Crop Science**, v. 1, n. 1, p. 20-31, 2006.

DUTRA, F. V.; CARDOSO, A. D.; BANDEIRA, A. S.; SILVA, R. M.; MORAIS, O. M.; PRATES, C. J. N. Biometrical characteristics of fruits and seeds of flamboyant. **Scientia Agraria Paranaensis**, v. 16, n. 1, p. 127-132, 2017.

FELIX, F. C.; MEDEIROS, J. A. D.; FERRARI, C. S.; VIEIRA, F. A.; PACHECO, M. V. Biometry of *Pityrocarpa moniliformis* seeds using digital imaging: implications for studies of genetic divergence. **Brazilian Journal of Agricultural Sciences**, v. 15, n. 1, e6128, 2020. <https://doi.org/10.5039/agraria.v15i1a6128>

FERREIRA, T.; RASBAND, W. **ImageJ**: user guide (IJ 1.46r), 2012. 198 p. <https://imagej.nih.gov/ij/docs/guide/user-guide.pdf>

FRANKLIN, S. E.; AHMED, O. S. Deciduous tree species classification using object-based analysis and machine learning with unmanned aerial vehicle multispectral data. **International Journal of Remote Sensing**, v. 39, p. 5236-5245, 2017. <https://doi.org/10.1080/01431161.2017.1363442>

FRANKLIN, S. E.; AHMED, O. S.; WILLIAMS, G. Northern conifer forest species classification using multispectral data acquired from an unmanned aerial vehicle. **Photogrammetric Engineering and Remote Sensing**, v. 83, n. 7, p. 501-507, 2017. <https://doi.org/10.14358/PERS.83.7.501>

GONG, F.; KARSAI, I.; LIU, Y. S. C. *Vitis* seeds (Vitaceae) from the late Neogene Gray Fossil Site, northeastern Tennessee, U.S.A. **Review of Palaeobotany and Palynology**, v. 162, n. 1, p. 71-83, 2010. <https://doi.org/10.1016/j.revpalbo.2010.05.005>

HEMENDER; SHARMA, S.; MOR, V.; JITENDER; BHUKER, A. Image analysis: a modern approach to seed quality testing. **Current Journal of Applied Science and Technology**, v. 27, n. 1, p. 1-11, 2018. <https://doi.org/10.9734/cjast/2018/40945>

KAPADIA, V.; SASIDHARAN, N.; KALYANRAO, P. Seed image analysis and its application in seed science research. **Advances in Biotechnology & Microbiology**, v. 7, n. 2, e555709, 2017. <https://doi.org/10.19080/AIBM.2017.07.555709>

KHUMAEVA, U. H.; KHABIBOV, A. D.; MURATCHAEVA, P. M. Assessment of the structure of the variability of morphological signs of *Trifolium medium* L. introduced under the conditions of mountainous dagestan. **Arid Ecosystems**, 6, p. 135-141, 2016. <https://doi.org/10.1134/S2079096116020074>

KURTULMUŞ, F.; ÜNAL, H. Discriminating rapeseed varieties using computer vision and machine learning. **Expert Systems with Applications**, v. 42, n. 4, p. 1880-1891, 2015. <https://doi.org/10.1016/j.eswa.2014.10.003>

LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine learning in agriculture: a review. **Sensors in Agriculture**, v. 18, n. 8, p. 1-29, 2018. <https://doi.org/10.3390/s18082674>

LIMA, T. V.; FELICIANO, A. L. P.; MARAGON, L. C.; MOURA, A. R. Evaluation of biometric characteristics and predation of reproductive structures on ax handle (*Aspidosperma discolor*). **Scientia Plena**, v. 11, n. 5, p. 01-11, 2015.

LIU, W.; LIU, C.; HU, X.; YANG, J.; ZHENG, L. Application of terahertz spectroscopy imaging for discrimination of transgenic rice seeds with chemometrics. **Food Chemistry**, v. 210, p. 415-421, 2016. <https://doi.org/10.1016/j.foodchem.2016.04.117>

MARANHO, A. S.; SOARES, I. D.; GUIMARÃES, A. V. P. J. Biometrics measures of fruits seeds and seedling emergence of *Cordia alliodora* (Ruiz & Pav.) Cham. in different substrates and sowing depths. **Revista Biociências**, v. 20, n. 1, p. 56-62, 2014.

MEDEIROS, A. D.; PINHEIRO, D. T.; XAVIER, W. A.; SILVA, L. J.; DIAS, D. C. F. S. Quality classification of *Jatropha curcas* seeds using radiographic images and machine learning. **Industrial Crops and Products**, v. 146, p. 112-162, 2020a. <https://doi.org/10.1016/j.indcrop.2020.112162>

MEDEIROS, A. D.; SILVA, L. J.; SILVA, J. M.; DIAS, D. C. F. S.; PEREIRA, M. D. IJCropSeed: An open-access tool for high-throughput analysis of crop seed radiographs. **Computers and Electronics in Agriculture**, v. 175, e105555, 2020b. <https://doi.org/10.1016/j.compag.2020.105555>

MEDINA, W.; SKURTYS, O.; AGUILERA, J. M. Study on image analysis application for identification quinoa seeds (*Chenopodium quinoa* Willd) geographical provenance. **Food Science and Technology**, v. 43, n. 2, p. 238-246, 2010. <https://doi.org/10.1016/j.lwt.2009.07.010>

MENEGATTI, R. D.; MANTOVANI, A.; NAVROSKI, M. C.; SOUZA, A. G. Genetic divergence among provenances of *Mimosa scabrella* Benth. based on seed analysis. **Brazilian Journal of Agricultural Sciences**, v. 12, n. 3, p. 366-371, 2017. <http://dx.doi.org/10.5039/agraria.v12i3a5449>

MITCHELL, T. M. **Machine Learning**. McGraw–Hill Science/Engineering/Math, 1997. 421 p.

NORONHA, B. G.; PEREIRA, M. D.; FLORES, A. V.; DEMARTELAERE, A. C. F.; MEDEIROS, A. D. Morphometry and physiological quality of *Moringa oleifera* seeds in the function of their fruit position. **Journal of Experimental Agriculture International**, v. 25, n. 6, p. 1-10, 2018. <https://doi.org/10.9734/JEAI/2018/43375>

ORRÙ, M.; GRILLO, O.; LOVI, G.; VENORA, G.; BACCHETTA, G. Morphological characterisation of *Vitis vinifera* L. seeds by image analysis and comparison with archaeological remains. **Vegetation History and Archaeobotany**, v. 22, n. 231, p. 231-242, 2012. <https://doi.org/10.1007/s00334-012-0362-2>

PEÑALOZA, P.; DURÁN, J. M.; Association between biometric characteristics of tomato seeds and seedling growth and development. **Electronic Journal of Biotechnology**, v. 18, n. 4, p. 267-272, 2015.

<https://doi.org/10.1016/j.ejbt.2015.04.003>

PONTES, M. S.; MONTEFUSCO-PEREIRA, C. V.; MISRA, B. B.; RIBEIRO-JUNIOR, H. L.; GRACIANO, D. E.; SANTOS J. S.; NOBREGA, M. A. S.; FERNANDES, S. S. L.; CAIRES, A. R. L.; SANTIAGO, E. F. High-throughput phenotyping by applying digital morphometrics and fluorescence induction curves in seeds to identifying variations: a case study of *Annona* (Annonaceae) species. **Information Processing in Agriculture**, v. 5, n. 4, p. 443-455, 2018.

<https://doi.org/10.1016/j.inpa.2018.07.001>

RAHMAN, A.; CHO, B. W. Assessment of seed quality using non destructive measurement techniques: a review. **Seed Science Research**, v. 26, p. 285-305, 2016. <https://doi.org/10.1017/S0960258516000234>

REWICZ, A.; BOMANOWSKA, A.; MAGDA, J.; REWICZ, T. Morphological variability of *Consolida regalis* seeds of south-eastern and central Europe. **Systematics and Biodiversity**, v. 15, n. 1, p. 25-34, 2016.

<https://doi.org/10.1080/14772000.2016.1216017>

ROSA, T. L. M.; ARAUJO, C. P.; KAMKE, C.; FERREIRA, A.; FERREIRA, M. F. S.; OLIVEIRA, J. B.; SCHMILDT, E. R.; LOPES, J. C.; MENGARDA, L. H. G.; OTONI, W. C.; SANTOS, A. R.; ALEXANDRE, R. S. Sapucaia nut: morphophysiology, minerals content, methodological validation in image analysis, phenotypic and molecular diversity in *Lecythis pisonis* Cambess. **Food Research International**, v. 137, e109383, 2020. <https://doi.org/10.1016/j.foodres.2020.109383>

ROVERI-NETO, A.; PAULA, R. C. Variability among mother trees of *Ceiba speciosa* St. Hil for characteristics of the fruits and seeds. **Revista Ciência Agronômica**, v. 48, n. 2, p. 318-327, 2017. <https://doi.org/10.5935/1806-6690.20170037>

SANTOS, J. C. C.; SILVA, D. M. R.; COSTA, R. N.; SILVA, C. H.; SANTOS, W. D. S.; MOURA, F. D. B. P.; SILVA, J. V. Biometric and morphological aspects of the fruits and seeds of *Schinopsis brasiliensis*. **Nativa**, v. 6, n. 3, p. 219-224, 2018.

<http://dx.doi.org/10.31413/nativa.v6i3.4709>

SARIGU, M.; PORCEDDU, M.; SCHMITT, E.; CAMARDA, I.; BACCHETTA, G. Taxonomic discrimination of the *Paeonia mascula* group in the Tyrrhenian Islands by seed image analysis. **Systematics and Biodiversity**, v. 17, n. 8, p. 801-810, 2019.

<https://doi.org/10.1080/14772000.2019.1685607>

SAU, S.; UCCHESU, M.; DONDINI, L.; DE FRANCESCHI, P.; D'HALLEWIN, G.; BACCHETTA, G. Seed morphometry is suitable for apple-germplasm diversity-analyses. **Computers and Electronics in Agriculture**, v. 151, p. 118-125, 2018.

<https://doi.org/10.1016/j.compag.2018.06.002>

SILVA, R. M.; CARDOSO, A. D.; DUTRA, F. V.; MORAIS, O. M. Biometric aspects of fruit and seed of *Caesalpinia ferrea* Mart. ex Tul. from semiarid baiano. **Journal of Neotropical Agriculture**, v. 4, n. 3, p. 85-91, 2017.

<https://doi.org/10.32404/rean.v4i3.1427>

SINGH, S. K.; VIDYARTHI, S. K.; TIWARI, R. Machine learnt image processing to predict weight and size of rice kernels. **Journal of Food Engineering**, v. 274, e109828, 2020. <https://doi.org/10.1016/j.jfoodeng.2019.109828>

UCCHESU, M.; ORRÙ, M.; GRILLO, O.; VENORA, G.; PAGLIETTI, G.; ARDU, A.; BACCHETTA, G. Predictive method for correct identification of archaeological charred grape seeds: support for advances in knowledge of grape domestication process. **Plos One**, v. 11, n. 2, p. 01-18, 2016.

<http://dx.doi.org/10.1371/journal.pone.0149814>

VARMA, V. S.; DURGA, K.; KESHAVULU, K. Seed image analysis: its applications in seed science research. **International Research Journal of Agricultural Sciences**, v. 1, n. 2, p. 30-36, 2013.

WESSEL, M.; BRANDMEIER, M.; TIEDE, D. Evaluation of different machine learning algorithms for scalable classification of tree types and tree species based on Sentinel-2 data. **Remote Sensing**, v. 10, n. 9, e1419, 2018.

<https://doi.org/10.3390/rs10091419>

XI, Z.; HOPKINSON, C.; ROOD, S. B.; PEDDLE, D. R. See the forest and the trees: effective machine and deep learning algorithms for wood filtering and tree species classification from terrestrial laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 168, p. 1-16, 2020.

<https://doi.org/10.1016/j.isprsjprs.2020.08.001>

ZUFFO, A. M. A.; STEINER, F.; ALVES, C. Z.; ALCÂNTARA-NETO, F.; SANTOS, M. D. A.; OLIVEIRA, A. M.; SOUSA, T. O.; FONSECA, W. L. Biometric characteristics of fruits, seeds and plants of *Hancornia speciosa* Gomes. (Apocynaceae). **Australian Journal of Crop Science**, v. 13, p 622-627, 2019.

<https://doi.org/10.21475/ajcs.19.13.04.p1651>

CAPÍTULO 1: ANÁLISE DE IMAGENS E APRENDIZADO DE MÁQUINA APLICADA A SEMENTES: UMA REVISÃO BIBLIOMÉTRICA

RESUMO

A bibliometria como área da ciência da informação permite aplicar métodos estatísticos e matemáticos para analisar e contribuir com a dinâmica e evolução da informação científica e tecnológica sobre determinado tema ou área do conhecimento. Assim, o presente capítulo pretende quantificar e analisar os trabalhos científicos que contemplem estudos com imagem e aprendizado de máquina aplicados às sementes por meio da análise bibliométrica, com a justificativa de apontar os principais tópicos e lacunas existentes para pesquisas com sementes florestais. A metodologia de análise bibliométrica seguiu cinco etapas: seleção das principais bases de dados, definição das palavras-chave, pesquisa dos trabalhos, triagem dos artigos científicos, e tratamento bibliométrico para análise dos resultados. As publicações de artigos contendo os termos avaliados tiveram os primeiros registros entre os anos 2000-2010, tendo até 2022 um total de 136 publicações dentro das áreas de Arqueologia (0,7%), Botânica (2,2%), Ciências Agrônomicas (90,4%) e Ciências Florestais (6,6%). O principal foco dos estudos selecionados foram classificação de sementes, identificação e detecção de sementes, avaliação da qualidade de sementes e germinação, sobretudo com espécies de culturas agrícolas de importância econômica. China, Brasil, Índia e Estados Unidos da América são os países com maior número de publicações, entretanto, o Brasil apresenta baixa conexão e colaboração entre pesquisadores de diferentes países, enquanto os autores mais relevantes são da China. A abordagem de análise de imagens e aprendizado de máquina nos artigos com sementes apresentou expressivo aumento de publicações a partir de 2017, sobretudo, entre pesquisadores internacionais. O baixo número de publicações com o objetivo “espécies florestais” demonstra uma maior necessidade de pesquisas. Além disso, este estudo evidenciou possibilidades de aplicações de análise de imagens e aprendizado de máquina em sementes nativas. Portanto, a bibliometria apresentada possibilita preencher ao menos este espaço com algum trabalho que vislumbre a biodiversidade florestal brasileira.

Palavras-chave: bibliometria; ciência da informação; inteligência artificial; metadados; sementes florestais.

ABSTRACT

Bibliometrics, as a field of information science, allows for the application of statistical and mathematical methods to analyze and contribute to the dynamics and evolution of scientific and technological information on a specific theme or area of knowledge. Thus, this chapter aims to quantify and analyze scientific works that encompass studies on image and machine learning applied to seeds through bibliometric analysis, with the justification of identifying key topics and existing gaps for research on forest seeds. The bibliometric analysis methodology followed five stages: selection of the main databases, definition of keywords, literature search, screening of scientific articles, and bibliometric treatment for results analysis. The publications of articles containing the evaluated terms had their first records between 2000-2010, with a total of 136 publications by 2022 within the fields of Archaeology (0.7%), Botany (2.2%), Agronomic Sciences (90.4%), and Forestry Sciences (6.6%). The main focus of the selected studies was seed classification, identification and detection of seeds, seed quality evaluation and germination, particularly with economically important crop species. China, Brazil, India, and the United States of America are the countries with the highest number of publications, however, Brazil shows low connection and collaboration among researchers from different countries, while the most relevant authors are from China. The approach of image analysis and machine learning in articles with seeds showed a significant increase in publications since 2017, especially among international researchers. The low number of publications targeting "forest species" demonstrates a greater need for research. Moreover, this study highlighted possibilities for applications of image analysis and machine learning in native seeds. Therefore, the presented bibliometrics allows for filling at least this gap with some work that envisions the Brazilian forest biodiversity.

Keywords: bibliometrics; information science; artificial intelligence; metadata; forest seeds.

3.1 INTRODUÇÃO

O aprendizado de máquina é uma área de estudo dentro da inteligência artificial, sendo aplicado cada vez mais na resolução de problemas em diferentes setores da economia, pesquisa científica e tecnológica (CERRI; CARVALHO, 2017, p. 297). Nesse sentido, a análise de imagens em sementes e aplicação de técnicas de aprendizado de máquina nos trabalhos científicos se mostrou uma tendência crescente nos últimos anos em plataformas como *Web of Science* e *Scopus*, entretanto, sem respaldo quantitativo ou estatístico. Uma forma de resolver isto, é utilizar a bibliometria como área da ciência da informação que permite aplicar métodos estatísticos e matemáticos para analisar e contribuir com a dinâmica e

evolução da informação científica e tecnológica sobre determinado tema ou área do conhecimento, a exemplo de estudos com sementes.

A análise bibliométrica tem abrangência interdisciplinar, podendo ser aplicada em diferentes contextos. Pode-se citar: identificar tendências do conhecimento em um determinado tema, estudar dispersão e obsolescências dos campos científicos, medir o impacto das publicações e dos serviços de disseminação da informação, estimar a cobertura das revistas científicas, identificar autores e instituições mais produtivas (FONSECA, 1986, p. 10). Segundo o mesmo autor, é possível identificar as revistas do núcleo de cada disciplina, estudar relações entre a ciência e a tecnologia, investigar relações entre disciplinas e áreas do conhecimento, avaliar a produção científica, monitorar o desenvolvimento de tecnologias, bem como adaptar políticas de aquisição e descarte de publicações.

Entre os exemplos de estudos bibliométricos amplos no Brasil, destaca-se a avaliação da produção científica sobre indicadores educacionais no país entre 2011 e 2020 (SOUZA; FORTE, 2022). Como resultados, os autores encontraram nos últimos cinco anos um crescimento do número de publicações, entretanto, apesar do aumento nos últimos anos, o número de artigos analisado não apresenta concentração em temáticas de estudo ou de pesquisadores para a área da educação (SOUZA; FORTE, 2022, p. 477). Entre os exemplos de trabalhos na área florestal ao redor do mundo, destacam-se as causas e efeitos de incêndios em florestas tropicais (JUÁREZ-OROZCO; SIEBE; FERNÁNDEZ, 2017, p. 1) e tendências na pesquisa global em sequestro de carbono (HUANG *et al.*, 2020, p. 1). Em resumo, os trabalhos citados buscaram compreender a dinâmica do tema abordado com base na revisão bibliométrica.

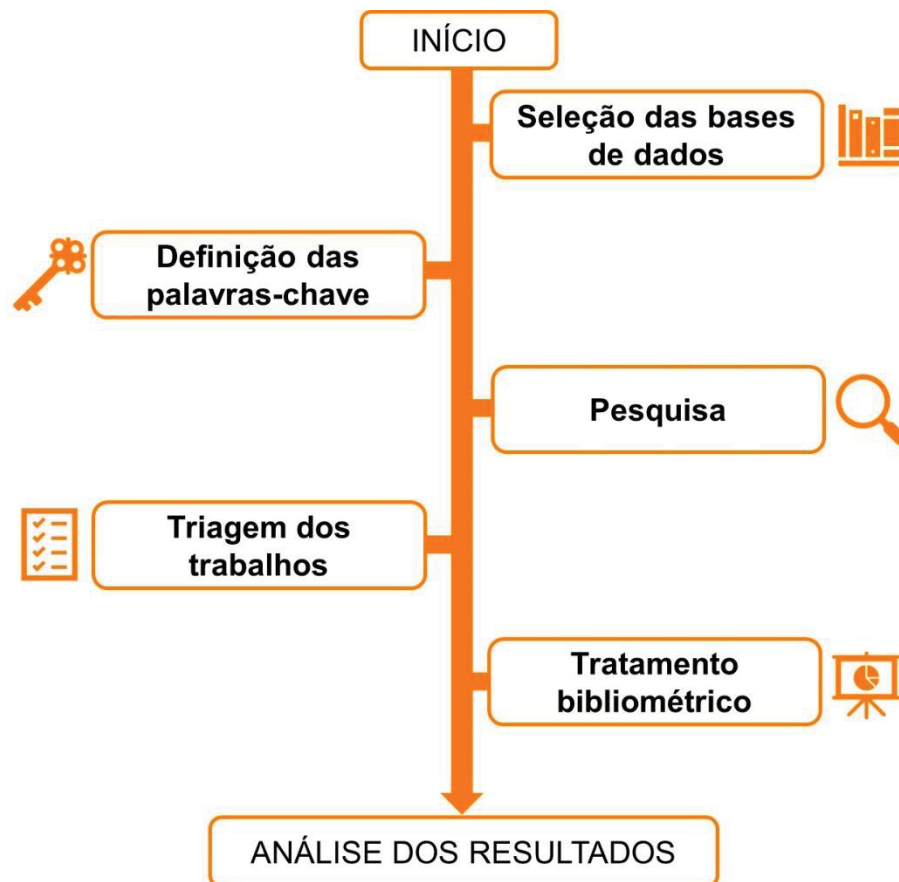
Em sementes, estudos bibliométricos foram conduzidos com patologia de sementes agrícolas para a visualização das necessidades e possibilidades de pesquisa científica nesta área (CUNHA; FERREIRA, 2021), bem como avaliação das tendências de pesquisas sobre dispersão de sementes e suas consequências (LIU *et al.*, 2022), além do progresso da pesquisa sobre o banco de sementes no solo (SHI *et al.*, 2020). Fato interessante, é que não foram encontrados trabalhos bibliométricos com foco em testes e análise de sementes. Assim, fica o questionamento: e quanto aos trabalhos com análise de imagens de sementes e aplicação de aprendizado de máquina? E quanto aos estudos com espécies florestais?

Diante do esboço, o presente capítulo objetivou quantificar e analisar os trabalhos científicos que contemplem estudos com imagem e aprendizado de máquina aplicados às sementes por meio da análise bibliométrica, bem como apontar os principais tópicos e lacunas existentes para pesquisas em sementes florestais com esse enfoque.

3.2 MATERIAL E MÉTODOS

A metodologia de análise bibliométrica seguiu cinco etapas conforme descrito na FIGURA 1, adaptado de Chueke e Amatucci (2022): (i) seleção das principais bases de dados, (ii) definição das palavras-chave, (iii) pesquisa dos trabalhos, (iv) triagem dos artigos científicos, e (v) tratamento bibliométrico para análise dos resultados.

FIGURA 1 – ETAPAS DA METODOLOGIA PARA ANÁLISE BIBLIOMÉTRICA



FONTE: O autor (2023).

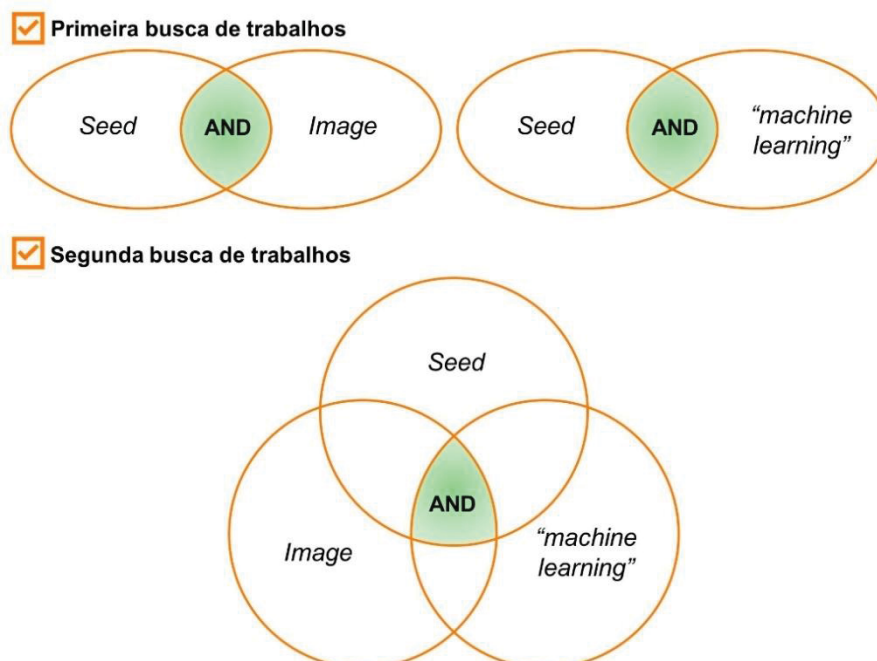
3.2.1 Seleção das bases de dados

As bases de dados selecionadas para a análise bibliométrica foram a *Web of Science* (<https://www.webofscience.com>) e *Scopus* (<https://www.scopus.com>), por apresentarem uma base internacional abrangente de artigos científicos e contemplarem os principais periódicos do mundo.

3.2.2 Definição das palavras-chave

As palavras-chaves foram utilizadas em idioma inglês (*keywords*), definidas de maneira ampla para abranger o maior número de trabalhos com a temática semente “*seed*”, acrescida dos termos imagem “*image*” e aprendizado de máquina “*machine learning*”. A primeira busca de trabalhos visou analisar a evolução quantitativa das publicações nos temas relacionados em conjunto “*seed*” e “*image*”, e “*seed*” e “*machine learning*”, seguido do refinamento e análise bibliométrica dos trabalhos em uma segunda busca que contemplem a interação das palavras-chave: “*seed*” e “*image*” e “*machine learning*” (FIGURA 2).

FIGURA 2 – DEFINIÇÃO DAS PALAVRAS-CHAVE PARA A PRIMEIRA E SEGUNDA BUSCA DE TRABALHOS



FONTE: O autor (2023).

3.2.3 Pesquisa

A busca dos trabalhos nas duas bases de dados foi realizada por meio do Portal do Periódico Capes (<https://www-periodicos-capes-gov-br.ez22.periodicos.capes.gov.br/index.php>), acesso CAFe, com acesso livre permitido por meio da Universidade Federal do Paraná, no mês de abril de 2023.

3.2.4 Triagem dos trabalhos

A primeira e segunda busca de trabalhos contemplando os termos selecionados foram limitados a artigos científicos, indexados em periódicos e publicados até o ano de 2022, ou seja, publicados até 31/12/2022. Esses termos são os principais pontos da tese, por isso, a pesquisa dos termos selecionados foi feita para elementos contidos no título (*Title*), resumo (*Abstract*) e palavras-chaves (*Keywords*) em cada artigo.

Os arquivos contendo os metadados das duas bases foram salvos no formato BibTeX e exportados para microcomputador. Na sequência, os artigos repetidos em mais de uma base de dados foram excluídos usando os recursos computacionais do pacote “bibliometrix” (ARIA; CUCCURULLO, 2017) por meio do *software* estatístico R, versão 4.3.0 (R CORE TEAM, 2020).

Os artigos usados no tratamento bibliométrico foram classificados com base na área de abrangência (Arqueologia, Botânica, Ciências Agrônômicas e Ciências Florestais), foco ou objetivos das publicações (Classificação, Detecção, Germinação, Identificação e Qualidade de sementes), e listados quanto às espécies-alvo estudadas. As definições usadas para seleção dos trabalhos com análise de imagens e aprendizado de máquina aplicados em sementes estão descritas a seguir:

1. *Arqueologia* - pesquisas com fósseis, história da agricultura e conhecimento sobre dietas alimentares na antiguidade.
2. *Botânica* – pesquisas que contribuam para a biologia vegetal, evolução das espécies ou botânica.
3. *Ciências Agrônômicas* – pesquisas envolvendo sementes de culturas agrícolas comercializadas.

4. *Ciências Florestais* – pesquisas envolvendo sementes florestais nativas, exóticas, plantadas, de importância ecológica ou econômica.

3.2.5 Tratamento bibliométrico

Os metadados obtidos após a etapa de triagem dos trabalhos foram processados usando o pacote “bibliometrix” e analisados quanto aos seguintes critérios:

1. *Annual Scientific Production* - histórico de publicações de artigos científicos indexados nas bases de dados selecionadas;

2. *Total Documents* - quantitativo de publicações com tema relevante destacado nas palavras-chave de busca até o ano de 2022;

3. *Country Scientific Production e Collaboration WorldMap* - quantificação da produção mundial de artigos com a temática buscada e colaboração entre autores de diferentes países, a modelagem de busca dos artigos considerou Reino Unido formado por países constituintes da Inglaterra, Escócia, País de Gales e Irlanda do Norte;

4. *Most Relevant Sources e Most Relevant Authors* - principais periódicos e pesquisadores mais relevantes no âmbito internacional que publicaram artigos com a temática buscada;

5. *WordCloud* - temas principais abordados nos artigos a partir das palavras-chaves indicadas pelos autores, os termos “*machine learning*” não foram apresentados na nuvem de palavras, por ser um tema comum em todos os artigos analisados;

6. *Trend Topics* - tendência dos temas ao longo dos anos nos artigos publicados a partir das palavras-chaves indicadas pelos autores;

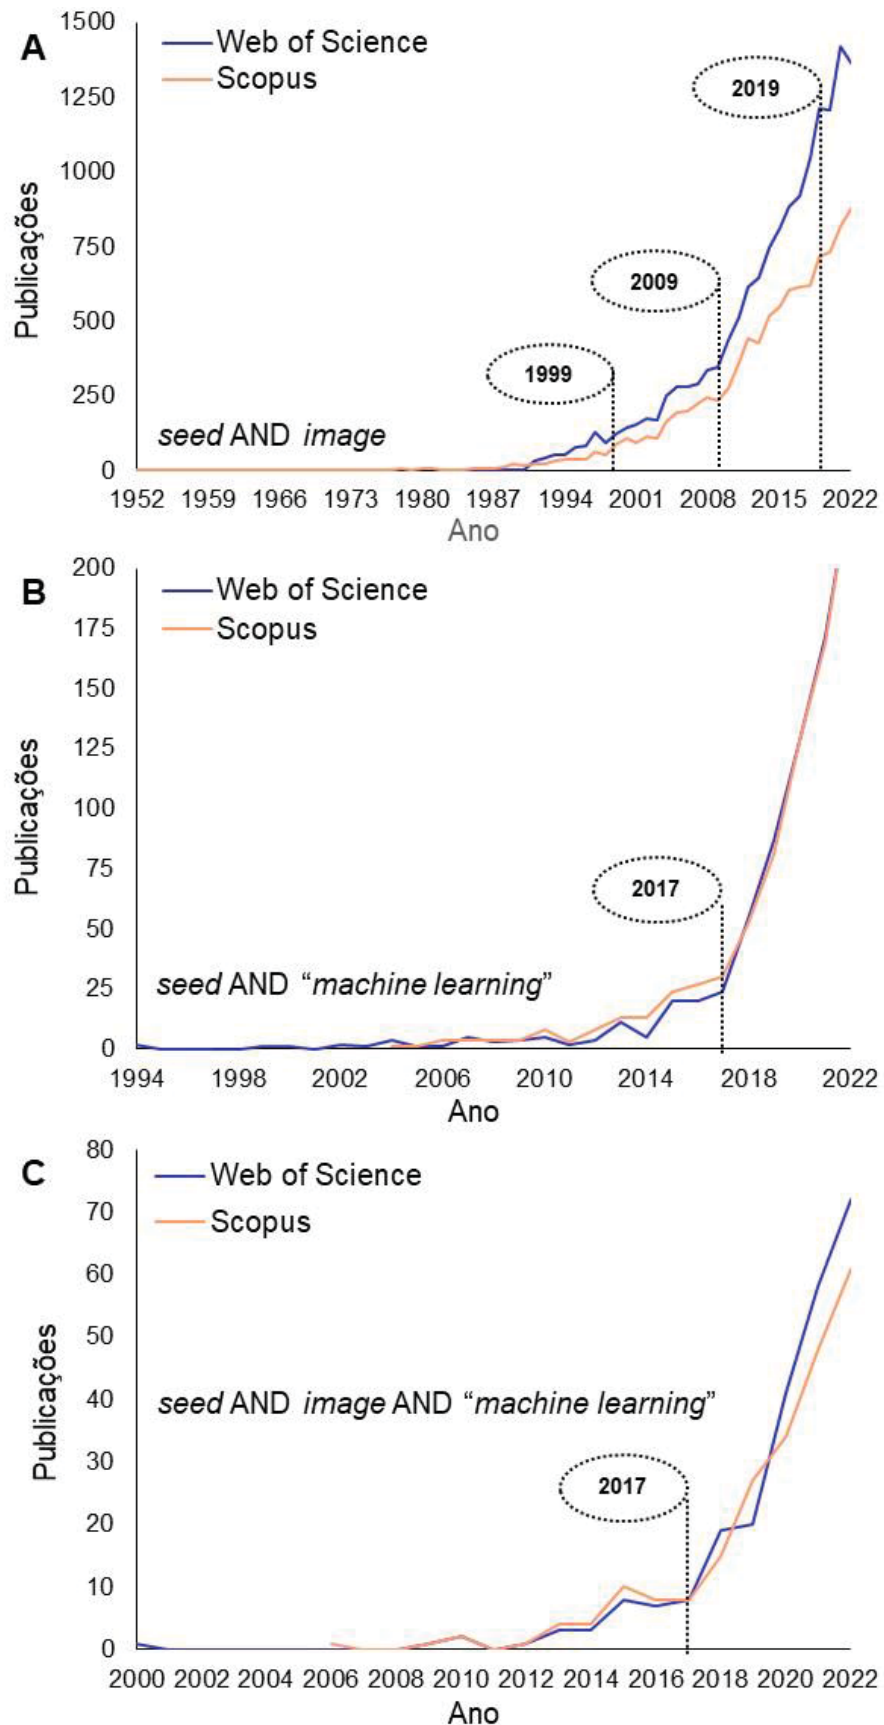
7. *Co-occurrence Network* - rede de coocorrência dos temas abordados nos artigos publicados a partir dos termos contidos nos títulos.

Por fim, apresentou-se uma síntese com os artigos relativos aos estudos florestais com resumo metodológico, objetivos e conclusões, demonstrando o que foi trabalhado com espécies florestais até o momento.

3.3 RESULTADOS E DISCUSSÃO

As publicações de artigos nas bases *Web of Science* e *Scopus* contendo os termos “*seed*” e “*image*” tiveram crescimento de tendência exponencial desde 1999 (210 artigos), elevando-se para 578 artigos em 2009 e 1931 artigos em 2019, reforçando a relevância do tema em trabalhos científicos recentes (FIGURA 3A). Enquanto os artigos englobando os termos “*seed*” e “*machine learning*” apresentaram expressivo quantitativo de publicações a partir de 2017, saindo de 54 artigos publicados para 473 artigos em 2022 (FIGURA 3B). Embora estes números não sejam exclusivamente de trabalhos com sementes agrícolas ou florestais, os resultados demonstram como o tema vem sendo estudado em diferentes áreas do conhecimento.

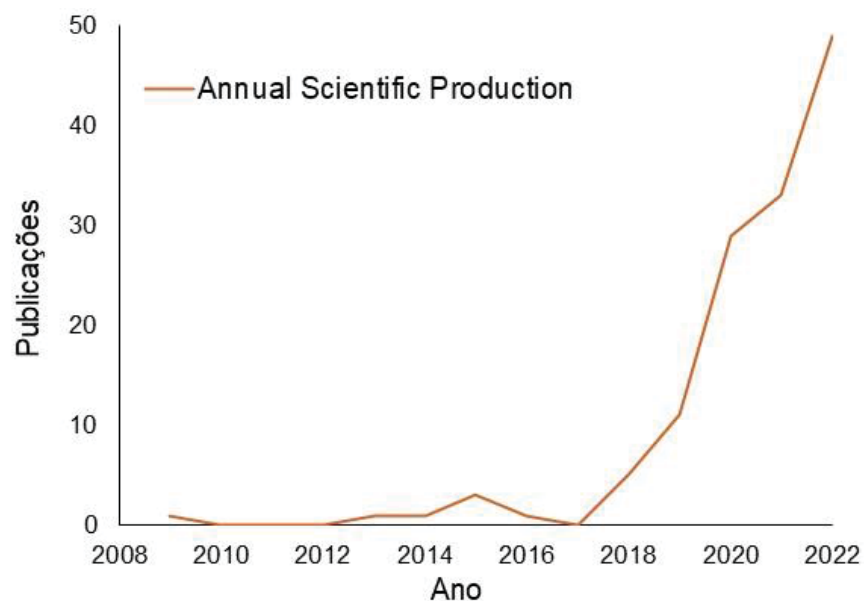
FIGURA 3 – HISTÓRICO DE PUBLICAÇÕES DE ARTIGOS CIENTÍFICOS INDEXADOS NAS BASES DE DADOS SELECIONADAS ATÉ O ANO DE 2022



FONTE: O autor (2023).

Publicações de artigos contendo os termos “seed”, “image” e “machine learning” em conjunto são menos representativos, com os primeiros registros apenas entre 2000-2010. A partir de 2017, as publicações passaram de 16 para 133 artigos por ano em 2022 (FIGURA 3C). No total, foram encontrados registros de 224 artigos na base de dados *Scopus* e 244 artigos na base de dados *Web of Science*. Após refinamento desses números, 138 arquivos repetidos ou duplicados foram excluídos por estarem presentes em mais de uma base de dados, resultando em um universo de 330 artigos. Destes, 136 publicações (*Total Documents*) relacionados ao tema da tese foram classificadas dentro das áreas de Arqueologia, Botânica, Ciências Agrônomicas e Ciências Florestais, onde verifica-se a crescente evolução da produção científica anual (*Annual Scientific Production*) a partir de 2017 (FIGURA 4). A lista completa dos trabalhos selecionados e analisados encontra-se no APÊNDICE 1.

FIGURA 4 – PRODUÇÃO CIENTÍFICA ANUAL COM TEMA RELEVANTE DESTACADO NAS PALAVRAS-CHAVE DE BUSCA ATÉ O ANO DE 2022



FONTE: O autor (2023).

A pandemia da COVID-19 pelo novo coronavírus (SARS-CoV-2) pode ter causado uma pequena inflexão entre os anos de 2019 e 2020 no número de trabalhos indexados com temática em semente e análise de imagem, como demonstrado nas curvas da FIGURA 3A. Entretanto, nota-se que a pandemia não

afetou negativamente no número de artigos publicados com a temática buscada nos anos seguintes, mantendo a tendência exponencial de publicações com as temáticas analisadas (FIGURA 3).

As primeiras técnicas de inteligência artificial foram definidas nos anos de 1950 (NEWELL; SIMON, 1956), porém, o incremento da utilização nos últimos anos é devido ao desenvolvimento computacional e da disponibilização de muitos dados, preteritamente não disponíveis, fato que possibilita a resolução de problemas complexos. Atualmente tem havido um crescente interesse entre pesquisadores e profissionais em desenvolver e implantar técnicas de aprendizado de máquina precisos e explicáveis nas diferentes áreas do conhecimento, como nas ciências florestais (FASSNACHT *et al.*, 2016; MICHAŁOWSKA; RAPIŃSKI, 2021; CETIN; YASTIKLI, 2022).

Em resumo, 90,4% das publicações são de artigos da grande área de Ciências Agronômicas, seguido 6,6% em Ciências Florestais, 2,2% de Botânica e 0,7% com Arqueologia (TABELA 1). O principal foco dos estudos selecionados foram classificação de sementes (40 trabalhos), identificação e detecção de sementes (32 trabalhos cada), avaliação da qualidade de sementes (19 trabalhos) e germinação (12 trabalhos), sobretudo para espécies de culturas agrícolas. Esses números se explicam evidentemente pelo elevado investimento que existe com pesquisas com sementes agrícolas no mundo, base fundamental da economia global.

TABELA 1 - RESULTADO DA SELEÇÃO DOS TRABALHOS COM SEPARAÇÃO POR TEMÁTICA E ABRANGÊNCIA DOS ESTUDOS, FOCO DAS PESQUISAS, QUANTITATIVO DE PUBLICAÇÕES E ESPÉCIES-ALVO DOS ARTIGOS

Abrangência dos estudos	Foco dos estudos	<i>n</i>	Espécies-alvo dos estudos
Arqueologia (1 artigo relacionado)	Identificação de sementes	1	sementes, moedas, cerâmica e vidro medieval.
Botânica (3 artigos relacionados)	Análise de sementes	1	herbáceas nativas.
	Detecção de sementes	1	arabidopse-do-tale e bálsamo.
	Identificação de sementes	1	plantas aquáticas.
Ciências Agrônomicas (123 artigos relacionados)	Classificação de sementes	38	algodão, arroz, astrágalo, berinjela, cebola, colza, culturas agrícolas*, feijão, melancia, milho, soja, trigo e uva.
	Detecção de sementes	29	algodão, amendoim, arroz, batata, colza, culturas agrícolas*, erva-doce, ervilha, linhaça, milho, panícula, soja, trigo e uva.
	Germinação de sementes	11	arroz, cânhamo, culturas agrícolas*, ervas-daninhas, gramíneas, milho, soja, tomate e trigo.
	Identificação de sementes	28	algodão, arroz, brássicas, cereais, cevada, couve, feijão, melancia, milho, pimenta, repolho, soja, tomate e trigo.
	Qualidade de sementes	17	amendoim, arroz, chia, colza, culturas agrícolas*, gramíneas, milho, huang-qin e soja.
Ciências Florestais (9 artigos relacionados)	Classificação de sementes	2	herbáceas e pináceas.
	Detecção de sementes	2	acácia-do-japão e estercúlia.
	Germinação de sementes	1	acácia-do-japão.
	Identificação de sementes	2	árvore-do-paraíso e herbáceas.
	Qualidade de sementes	2	pinhão-manso.
Total de trabalhos analisados		136	

FONTE: O autor (2023).

Nota: publicações de artigos contendo os termos “*seed*”, “*image*” e “*machine learning*” em conjunto.

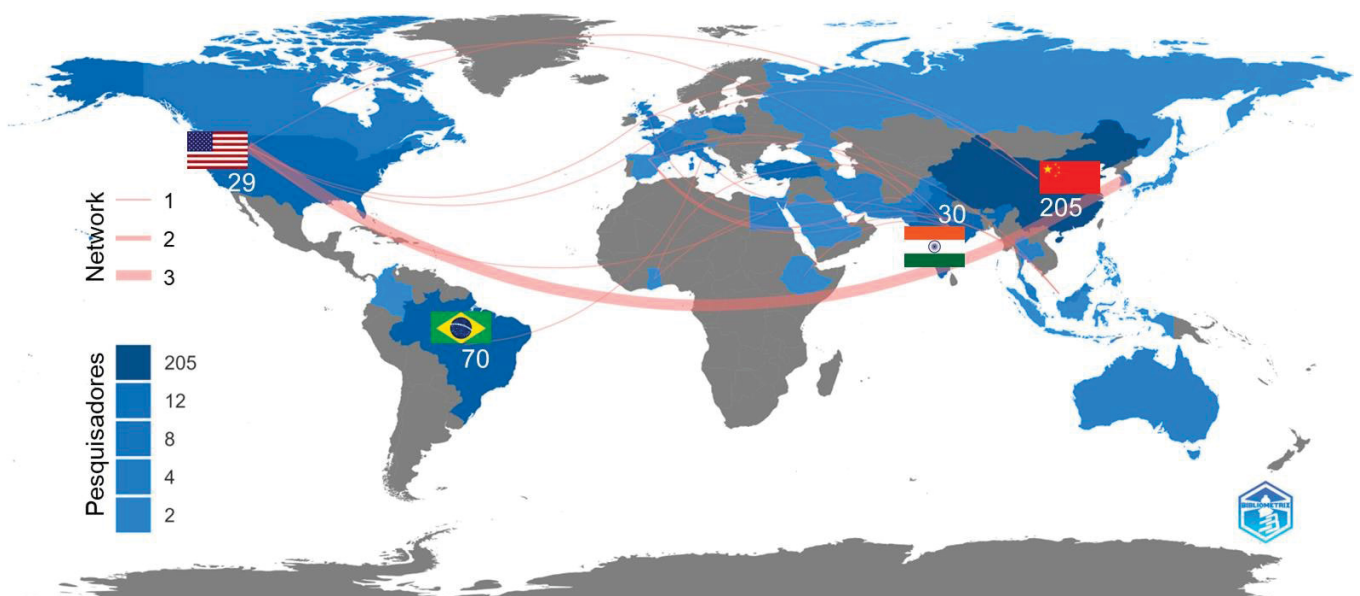
*culturas agrícolas: várias espécies agrícolas estudadas em conjunto.

Ao analisarmos os artigos com abrangência nas Ciências Florestais (TABELA 1), nota-se que as pesquisas tiveram foco em poucas espécies, sobretudo herbáceas (LODDO; RUBERTO, 2021; LODDO; LODDO; RUBERTO, 2021), pináceas (HUANG *et al.*, 2022), acácia-do-japão (PANG *et al.*, 2021; 2022), árvore-do-paraíso (GAO *et al.*, 2019), estercúlia (XUE *et al.*, 2022) e pinhão-manso (MEDEIROS *et al.*, 2020; SILVA *et al.*, 2021). Contudo, na busca realizada não foi

encontrado nenhum relato de qualquer estudo com sementes florestais arbóreas nativas do Brasil (TABELA 1). Deste modo, há possibilidades de aplicação de análise de imagens e aprendizado de máquina na classificação, identificação e detecção de sementes, bem como na germinação e qualidade de sementes.

Os autores de países com maior número de publicações com a temática relacionada com sementes e imagem/aprendizado de máquina são da China (205 pesquisadores), Brasil (70 pesquisadores), Índia (30 pesquisadores) e Estados Unidos da América (29 pesquisadores) (FIGURA 5). Os trabalhos publicados por pesquisadores brasileiros apresentam baixa conexão e colaboração (*network*) com pesquisadores de outros países. Este fato pode impactar na qualidade dos trabalhos produzidos em cada país, demonstrando necessidade ou potencial de pesquisas com essa temática terem maior intercâmbio de pesquisadores estrangeiros e conhecimento internacional, uma vez que a maioria das produções brasileiras com a temática buscada são feitas sem intercâmbio de pesquisadores de outras nacionalidades. Os Estados Unidos da América, Espanha, Índia e China são os países com maior internacionalidade de pesquisadores colaboradores. Enquanto a maior relação de pesquisadores ocorre entre os Estados Unidos da América e Coreia do Sul (FIGURA 5).

FIGURA 5 – PRODUÇÃO CIENTÍFICA MUNDIAL DE ARTIGOS COM A TEMÁTICA BUSCADA E COLABORAÇÃO ENTRE AUTORES DE DIFERENTES PAÍSES




FONTE: O autor (2023).

*linhas referem-se à participação de autores de diferentes nacionalidades no mesmo trabalho, quanto maior a linha, mais trabalhos com autores de diferentes nacionalidades o país possui.

Os periódicos com o maior número de trabalhos publicados com a temática selecionada são a *Frontiers in Plant Science* (12), *Computers and Electronics in Agriculture* (10), *Sensors* (8) e *Scientific Reports* (7) (FIGURA 6A). Enquanto os autores com maior número de publicações são oriundos da China, com cinco e sete publicações de artigos para cada autor (FIGURA 6B). Os manuscritos com temática específica voltados para a área de estudo podem ter maiores chances de serem aceitos nesses periódicos internacionais, e a colaboração entre autores de diferentes nacionalidades é um fato que também pode favorecer o aprimoramento dos trabalhos científicos publicados.

FIGURA 6 – PRINCIPAIS PERIÓDICOS (A) E AUTORES (B) MAIS RELEVANTES NO ÂMBITO INTERNACIONAL QUE PUBLICARAM ARTIGOS COM A TEMÁTICA BUSCADA



FONTE: O autor (2023).

A principal referência com trabalhos abordando sementes e aprendizado de máquina é do pesquisador chinês Zhang J. com trabalhos voltados para culturas de

arroz (YANG *et al.*, 2020), milho (XU *et al.*, 2021) e soja (ZHU *et al.*, 2020), sobretudo com aplicações de tecnologias de imagens para classificação varietal e avaliação da qualidade de sementes, destacando a importância do tema em sementes agrícolas nos últimos anos. Pesquisadores brasileiros tem em média um ou dois artigos publicados com a temática buscada.

Os principais temas abordados nos artigos selecionados foram *machine learning* (aprendizado de máquina), *deep learning* (aprendizado profundo), *image processing* (processamento de imagens), *classification* (classificação) e *hyperspectral imaging* (imagem hiperespectral) (FIGURA 7). A repetição das palavras-chave entre trabalhos e autores indicam a relevância do tema e a tendência nos artigos produzidos. Com isso, fica evidente que trabalhos envolvendo *machine learning* (aprendizado de máquina) e *deep learning* (aprendizado profundo) são os mais relevantes para os estudos com imagens de sementes na atualidade. O aprendizado de máquina e o aprendizado profundo estão intimamente relacionados, mas se referem a conceitos diferentes dentro do campo da inteligência artificial.

FIGURA 7 – TEMAS PRINCIPAIS ABORDADOS NOS ARTIGOS A PARTIR DAS PALAVRAS-CHAVES INDICADAS PELOS AUTORES




FONTE: O autor (2023).

**Machine learning* não apresentado na escala da nuvem de palavras.

O aprendizado de máquina envolve algoritmos e modelos que permitem que as máquinas aprendam padrões a partir de dados e façam previsões ou tomem decisões com base nessas informações. Enquanto o aprendizado profundo é uma subcategoria do aprendizado de máquina que utiliza redes neurais artificiais para aprender representações complexas de dados, como imagens, texto e áudio. Estudos com *deep learning* estão sendo amplamente conduzidos em sementes de culturas agrícolas (LODDO; LODDO; RUBERTO, 2021; KOKLU, CINAR, TASPINAR, 2021; MUKASA *et al.*, 2022) (FIGURA 7), mas o seu uso requer conhecimentos de programação, quantidades elevadas de dados rotulados, recursos computacionais que não são plenamente reproduzíveis entre todos os pesquisadores, comunidade científica ou uso comum. Além da falta de interpretabilidade, ou seja, à medida que as redes neurais se tornam mais profundas e complexas, entender a tomada de decisões e chegada a determinadas conclusões pelas máquinas se torna cada vez mais desafiador para o pesquisador.

Por outro lado, a menção das palavras-chave apontadas pelos autores, apresentadas na nuvem de palavras (*WordCloud*) indica apenas o quantitativo de vezes em que o termo se repete nos diferentes trabalhos. Para uma análise dinâmica ao longo dos anos, usa-se as *Trend Topics* (tópicos de tendência) para verificar quais temas indicados pelas palavras-chave dos autores estão sendo amplamente estudados no momento, e quais estão deixando de ser usados. Percebe-se que o uso dos principais termos indicados na FIGURA 8 começaram a ocorrer entre os anos de 2020 e 2022, portanto, são temáticas recentes nas ciências agrárias e florestais, exceto para *support vector machine* que continuam sendo aplicados em sementes continuamente desde 2016.

FIGURA 8 – TENDÊNCIA DOS TEMAS AO LONGO DOS ANOS NOS ARTIGOS PUBLICADOS A PARTIR DAS PALAVRAS-CHAVES INDICADAS PELOS AUTORES

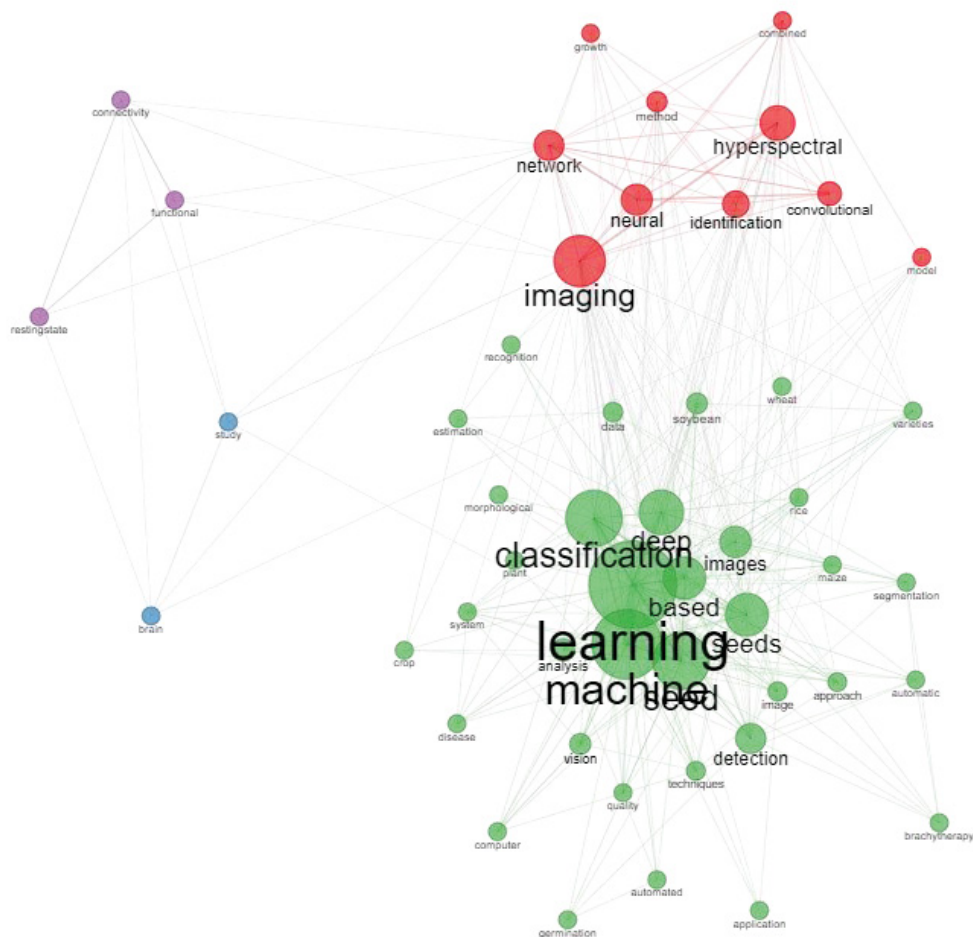


FONTE: O autor (2023).

Dentre as abordagens temáticas utilizadas nos títulos dos artigos, é possível notar relação entre os trabalhos, formando dois grupos principais - com enfoque em diferentes áreas de pesquisa (FIGURA 9). O primeiro grupamento (verde) reúne publicações relacionadas com aprendizado de máquina (*machine learning*), classificação (*classification*), imagens (*images*) e doenças (*disease*) em sementes de culturas agrônômicas de arroz (*rice*), milho (*maize*), trigo (*wheat*) e soja (*soybean*), com abordagens de técnicas de automação e detecção. O segundo grupamento (vermelho) reúne publicações relacionadas com imagens (*images*), hiperespectral (*hyperspectral*) e redes neurais (*neural network*) com abordagens para identificação (*identification*) de sementes. A conexão dessas palavras no título indica as principais

abordagens dos autores nos trabalhos publicados. Os grupamentos menores (roxo e azul) não mostraram relação expressiva com os principais temas abordados.

FIGURA 9 – REDE DE COCORRÊNCIA DOS TEMAS ABORDADOS NOS ARTIGOS PUBLICADOS A PARTIR DOS TERMOS CONTIDOS NOS TÍTULOS



FONTE: O autor (2023).

*os círculos representam o quantitativo de vezes que os termos se repetem.

Os artigos que foram englobados como estudos das Ciências Florestais estão apresentados na TABELA 2 com detalhamento dos objetivos, metodologia e principais conclusões. Em suma, destaca-se que os autores buscaram analisar as sementes por meio de imagens hiperespectrais (GAO *et al.*, 2019; PANG *et al.*; 2022), espectral unidimensional e bidimensional (PANG *et al.*, 2021), raios X (MEDEIROS *et al.*, 2020; XUE *et al.*, 2022), processamento de imagens (LODDO; RUBERTO, 2021; LODDO; LODDO; RUBERTO, 2021), imagens multiespectrais pelo método de ressonância magnética (SILVA *et al.*, 2021) e infravermelho próximo (HUANG *et al.*, 2022) com o objetivo de identificar e classificar as sementes

empregando recursos de aprendizado de máquina. Os equipamentos usados indicam a tendência do emprego de tecnologias avançadas de imagens para visualização das sementes além do espectro visual, uma possibilidade de uso em sementes nativas.

TABELA 2 - ARTIGOS SELECIONADOS COM BASE NA TEMÁTICA EM CIÊNCIAS FLORESTAIS E ENFOQUE EM SEMENTES, ANÁLISE DE IMAGENS E APRENDIZADO DE MÁQUINA

Gao <i>et al.</i> (2019)		(continua)
Objetivo	Identificar as origens geográficas de sementes de <i>Elaeagnus angustifolia</i> com métodos de aprendizado de máquina e imagens hiperespectrais de infravermelho próximo.	
Metodologia	Análise discriminante, máquina de vetores de suporte e rede neural convolucional foram usados para identificação da origem geográfica das sementes usando espectros completos e comprimentos de onda efetivos.	
Conclusão	Os resultados ilustraram que a imagem hiperespectral de infravermelho próximo, juntamente com o aprendizado de máquina, pode ser usada para rastrear as origens geográficas de sementes.	
Medeiros <i>et al.</i> (2020)		
Objetivo	Propor um método para prever a capacidade germinativa e discriminar sementes de <i>Jatropha curcas</i> quanto à velocidade de germinação e vigor da plântula, combinando análise automática de raios X e aprendizado de máquina.	
Metodologia	Análise automatizada de imagens radiográficas de sementes e avaliações fisiológicas foram usadas com aplicação de classes de qualidade e modelos de análise discriminante linear.	
Conclusão	A metodologia proposta pode ser usada para discriminar classes de sementes de <i>J. curcas</i> de forma rápida e robusta.	
Loddo e Ruberto (2021)		
Objetivo	Comparar diferentes recursos computacionais para a classificação de sementes de seis famílias botânicas (Amaranthaceae, Apiaceae, Asteraceae, Brassicaceae, Plantaginaceae e Solanaceae).	
Metodologia	Otimização de cinco classificadores de aprendizado de máquina, redes neurais convolucionais e SeedNet para determinar em que medida podem ser vantajosos.	
Conclusão	Os resultados obtidos oferecem um excelente passo preliminar para a realização de uma estrutura automática de reconhecimento e classificação de sementes.	
Pang <i>et al.</i> (2021)		
Objetivo	Identificar a viabilidade das sementes de <i>Sophora japonica</i> em diferentes graus de envelhecimento e estados de hidratação.	
Metodologia	Foram utilizados <i>naive bayes</i> , algoritmo <i>self-organizing feature mapping</i> , <i>support vector machine</i> , <i>convolutional neural networks</i> e <i>long short-term memory</i> para modelar a imagem espectral unidimensional e bidimensional das sementes.	
Conclusão	Provou que o aprendizado profundo combinado com espectro ou imagem tem potencial na identificação da viabilidade da semente.	
Loddo; Loddo e Ruberto (2021)		
Objetivo	Classificar famílias ou espécies de sementes de plantas por meio de técnicas de aprendizado profundo.	
Metodologia	SeedNet foi proposto para classificar famílias e espécies, usando redes neurais convolucionais.	
Conclusão	Os resultados obtidos são um ponto de partida para desenvolver um sistema completo de reconhecimento, classificação e recuperação de sementes.	
Silva <i>et al.</i> (2021)		
Objetivo	Classificar a qualidade sanitária das sementes de <i>Jatropha curcas</i> a partir de imagens multiespectrais e aprendizado de máquina.	
Metodologia	As sementes foram inoculadas, e as imagens multiespectrais foram adquiridas pelo método de ressonância magnética e classificadas por aprendizado de máquina.	
Conclusão	Imagens multiespectrais e de ressonância magnética podem ser ferramentas úteis para a detecção rápida e precisa de diferentes espécies de fungos em sementes de <i>J. curcas</i> .	

Huang <i>et al.</i> (2022)		(conclusão)
Objetivo	Classificar sementes de sete espécies de pináceas e resolver o problema da adulteração de sementes de forma rápida e não destrutiva.	
Metodologia	Cinco métodos de aprendizado de máquina foram usados para identificar sementes de espécies de pináceas a partir de infravermelho próximo.	
Conclusão	Demonstrou-se que o aprendizado de máquina é eficaz para a classificação de espécies de pináceas, fornecendo soluções e métodos científicos para classificação rápida, não destrutiva e precisa de diferentes espécies de pináceas.	
Xue <i>et al.</i> (2022)		
Objetivo	Detectar defeitos internos em sementes de estercúlia usando aprendizado de máquina <i>on-line</i> com base na técnica de avaliação de qualidade não destrutiva de raios-X.	
Metodologia	Uma <i>convolutional neural network</i> (BSSNet) foi treinada para identificar as sementes de estercúlia defeituosas com base nas imagens de raios-X.	
Conclusão	Os resultados apresentados demonstraram que o método de classificação tem potencial para aplicações industriais de sementes.	
Pang <i>et al.</i> (2022)		
Objetivo	Usar imagem hiperespectral combinado com técnicas de aprendizado profundo para identificar a viabilidade de sementes de <i>Sophora japonica</i> .	
Metodologia	Aplicou-se máquina de vetor de suporte, floresta randômica, rede neural convolucional, rede neural recorrente e sua superposição a partir de imagens hiperespectral.	
Conclusão	Os resultados mostram que a imagem hiperespectral combinada com o modelo de aprendizado profundo pode prever com mais precisão a viabilidade da semente de <i>Sophora japonica</i> .	

FONTE: O autor (2023).

O fato de não haver trabalhos com análise de imagens de sementes e aprendizado de máquina aplicado a espécies nativas, a exceção de *Jatropha curcas*; indica a possibilidade de pesquisas com espécies florestais arbóreas do Brasil voltadas para a identificação, classificação/detecção e avaliação da qualidade de sementes. Portanto, o presente estudo possibilitou preencher essa lacuna com um trabalho que vislumbre possibilidades de aplicação com essa temática para a biodiversidade florestal brasileira.

A análise bibliométrica se mostrou importante para demonstrar a evolução e os objetivos das pesquisas envolvendo sementes, análise de imagens e aprendizado de máquina até então publicados nas diferentes áreas de abrangência do conhecimento. Além disso, a aplicação dessas técnicas tem mostrado resultados promissores, fornecendo métodos eficazes para auxiliar na seleção de sementes de alta qualidade e melhorar os processos de produção de sementes. Portanto, o acompanhamento de publicações com essas temáticas ao longo dos anos pode revelar novas tendências de pesquisas e novos objetos de estudos, sobretudo, para espécies florestais nativas.

Poucas publicações tiveram como objetivo espécies florestais em relação às culturas agrícolas, demonstrando uma necessidade de aprimoramento das pesquisas com espécies nativas. Isto ocorre devido a indústria de sementes agrícolas ser superior à de sementes florestais. Por isso, novos estudos em sementes florestais são continuamente necessários, principalmente com o emprego de técnicas acessíveis e tecnologias de baixo custo, uma vez que o setor florestal de espécies nativas não dispõe de recursos financeiros comparado ao setor de sementes agrícolas.

Ao incentivar pesquisas nessa área, é possível desbloquear o potencial do uso da análise de imagens e aprendizado de máquina em sementes florestais, ampliando o conhecimento sobre essas espécies e fornecendo subsídios para a tomada de decisões mais eficazes em termos de manejo e conservação dos recursos florestais. Por fim, fica constada a ausência de trabalhos com sementes nativas, sobretudo com o uso de metodologias de aquisição e processamento de imagens para identificação de sementes.

Em síntese, este capítulo revelou as oportunidades e perspectivas de aplicação dessas abordagens em sementes, sendo a utilização de técnicas de processamento de imagens e aprendizado de máquina importantes para contribuir para a classificação precisa e identificação de espécies florestais, auxiliando em estudos futuros de diversidade genética, monitoramento de populações e conservação de espécies. Vale destacar que a caracterização e a identificação de sementes florestais possuem objetivos diferentes e propósitos distintos, por isso, esses temas serão abordados nos capítulos seguintes.

3.4 CONCLUSÕES

A análise de imagens e o aprendizado de máquina são amplamente utilizados em estudos científicos relacionados a sementes, resultando em um aumento de publicações nos últimos anos. Essas abordagens têm sido empregadas principalmente por pesquisadores internacionais, com foco predominante em culturas agrícolas. Os estudos nessa área estão direcionados para a classificação, identificação e detecção de cultivares ou variedades, além da avaliação da qualidade das sementes.

O número de publicações relacionadas a sementes florestais é baixo, o que indica uma maior necessidade de pesquisas. Portanto, esse estudo destaca as possibilidades de aplicação da análise de imagens e do aprendizado de máquina no contexto das sementes florestais, preenchendo uma lacuna na literatura científica atual.

REFERÊNCIAS

- ARIA, M.; CUCCURULLO, C. Bibliometrix: an R-tool for comprehensive science mapping analysis, **Journal of Informetrics**, v. 11, n. 4, p. 959-975, 2017.
- CERRI, R.; CARVALHO, A. C. P. L. F. Machine learning: brief introduction and applications. **Cadernos de Ciência & Tecnologia**, v. 34, n. 3, p. 297-313, 2017.
- CHUEKE, G. V.; AMATUCCI, M. Métodos de sistematização de literatura em estudos científicos: bibliometria, meta-análise e revisão sistemática. **Revista Eletrônica de Negócios Internacionais**, v. 17, n. 2, p. 284-292, 2022. <https://doi.org/10.18568/internext.v17i2.704>
- CUNHA, A. L. A.; FERREIRA, T. C. Patologia de sementes na atualidade: revisão bibliométrica. **Holos**, v. 37, n. 1, p. 1-20, 2020. <https://doi.org/10.15628/holos.2021.10627>
- FONSECA, E. N. **Bibliometria: teoria e prática**. São Paulo: Cultrix, Ed. da USP, 1986.
- GAO, P.; XU, W.; YAN, T.; ZHANG, C.; LV, X.; HE, Y. Application of near-infrared hyperspectral imaging with machine learning methods to identify geographical origins of dry narrow-leaved oleaster (*Elaeagnus angustifolia*) fruits. **Foods**, v. 8, n. 12, e620, 2019. <https://doi.org/10.3390/foods8120620>
- HUANG, B.; LIU, J.; JIAO, J.; LU, J.; LV, D.; MAO, J.; ZHAO, U.; ZHANG, Y. Applications of machine learning in pine nuts classification. **Scientific Reports**, v. 12, e8799, 2022. <https://doi.org/10.1038/s41598-022-12754-9>
- HUANG, L.; ZHOU, M.; LV, J.; CHEN, K. Trends in global research in forest carbon sequestration: a bibliometric analysis. **Journal of Cleaner Production**, v. 252, e119908, 2020. <https://doi.org/10.1016/j.jclepro.2019.119908>
- JUÁREZ-OROZCO, S. M.; SIEBE, C.; FERNÁNDEZ, F. D. Causes and effects of forest fires in tropical rainforests: a bibliometric approach. **Tropical Conservation Science**, v. 10, p. 1-14, 2017. <https://doi.org/10.1177/1940082917737207>
- LIU, Y.; LI, C.; LIU, W.; DONG, Q. Trends in global research on seed dispersal: a bibliometric analysis. **Sustainability**, v. 14, e16577, 2022. <https://doi.org/10.3390/su142416577>
- LODDO, A.; LODDO, M.; RUBERTO, C. D. A novel deep learning based approach for seed image classification and retrieval. **Computers and Electronics in Agriculture**, v. 187, e106269, 2021. <https://doi.org/10.1016/j.compag.2021.106269>
- LODDO, A.; RUBERTO, C. D. On the efficacy of handcrafted and deep features for seed image classification. **Journal of Imaging**, v. 7, n. 9, e171, 2021. <https://doi.org/10.3390/jimaging7090171>

MEDEIROS, A. D.; PINHEIRO, D. T.; XAVIER, W. A.; SILVA, L. J.; DIAS, D. C. F. S. Quality classification of *Jatropha curcas* seeds using radiographic images and machine learning. **Industrial Crops and Products**, v. 146, e112162, 2020. <https://doi.org/10.1016/j.indcrop.2020.112162>

PANG, L.; WANG, L.; YUAN, P.; YAN, L.; YANG, Q.; XIAO, J. Feasibility study on identifying seed viability of *Sophora japonica* with optimized deep neural network and hyperspectral imaging. **Computers and Electronics in Agriculture**, v. 190, e106426, 2021. <https://doi.org/10.1016/j.compag.2021.106426>

PANG, L.; WANG, L.; YUAN, P.; YAN, L.; XIAO, J. Rapid seed viability prediction of *Sophora japonica* by improved successive projection algorithm and hyperspectral imaging. **Infrared Physics and Technology**, v. 123, e104143, 2022. <https://doi.org/10.1016/j.infrared.2022.104143>

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna. 2020. <https://www.r-project.org/>

SHI, Z.; ZHANG, J.; WEI, H. Research progress on soil seed bank: a bibliometrics analysis. **Sustainability**, v. 12, e4888, 2020. <https://doi.org/10.3390/su12124888>

SILVA, C. B.; BIANCHINI, V. J. M.; MEDEIROS, A. D.; MORAES, M. H. D.; MARASSI, A. G.; TANNÚS, A. A novel approach for *Jatropha curcas* seed health analysis based on multispectral and resonance imaging techniques. **Industrial Crops and Products**, v. 161, e113186, 2021. <https://doi.org/10.1016/j.indcrop.2020.113186>

SOUZA, E. P.; FORTE, S. H. A. C. Avaliação da produção científica sobre indicadores educacionais no Brasil entre 2011 e 2020. **Revista de Gestão e Secretariado**, v. 13, n. 3, p. 476-496, 2022. <https://doi.org/10.7769/gesec.v13i3.1338>

YANG, Y.; CHEN, J.; HE, Y.; LIU, F.; FENG, X.; ZHANG, J. Assessment of the vigor of rice seeds by near-infrared hyperspectral imaging combined with transfer learning. **RSC Advances**, v. 10, p. 44149–44158, 2020. <https://doi.org/10.1039/d0ra06938h>

XU, P.; YANG, R.; ZENG, T.; ZHANG, J.; ZHANG, Y.; TAN, Q. Varietal classification of maize seeds using computer vision and machine learning techniques. **Journal of Food Process Engineering**, v. 44, n. 11, e13846, 2021. <https://doi.org/10.1111/jfpe.13846>

XUE, Q.; MIAO, P.; MIAO, K.; YU, Y.; LI, Z. X-ray-based machine vision technique for detection of internal defects of sterculia seeds. **Journal of Food Science**, v. 87, n. 8, p. 3386-3395, 2022. <https://doi.org/10.1111/1750-3841.16237>

ZHU, S.; ZHANG, J.; CHAO, M.; XU, X.; SONG, P.; ZHANG, J.; HUANG, Z. A rapid and highly efficient method for the identification of soybean seed varieties: hyperspectral images combined with transfer learning. **Molecules**, v. 25, n. 1, e152, 2020. <https://doi.org/10.3390/molecules25010152>

CAPÍTULO 2: CARACTERIZAÇÃO E DIFERENCIAÇÃO DE ESPÉCIES NATIVAS DO BRASIL POR MEIO DA ANÁLISE DE IMAGENS DE SEMENTES: UMA NOVA ABORDAGEM METODOLÓGICA

RESUMO

A análise biométrica de sementes contribui para a caracterização e diferenciação de espécies florestais. Contudo, os estudos com espécies nativas geralmente utilizam métodos manuais como o paquímetro digital, o qual extrai uma quantidade limitada de características, enquanto espécies agronômicas dispõem de equipamentos caros e pouco acessíveis. Assim, o objetivo deste capítulo é determinar uma metodologia com ferramentas de análise e processamento de imagens em sementes para auxiliar na caracterização e diferenciação de espécies nativas. Para isso, sementes de 155 espécies, distribuídas em 42 famílias botânicas foram fotografadas com câmera em mini estúdio e analisadas utilizando o *software* ImageJ®. Foram considerados aspectos de dimensão, formato e coloração, totalizando 18 características: oito para dimensões, quatro para formato, e seis para cor. Um conjunto de aproximadamente 1,827 milhões de dados morfobiométricos foram obtidos a partir 101.521 imagens de sementes, aplicando-se aos dados: estatística descritiva, distribuição da frequência, correlação de Pearson, distância Euclidiana e análise de componentes principais. O processamento digital de imagens de sementes foi eficiente para a caracterização das espécies, e as características utilizadas permitiram diferenciar as sementes, inclusive àquelas contidas na mesma família botânica e gênero. Portanto, conclui-se que a análise de imagens em sementes pela metodologia proposta contribui para a caracterização e diferenciação de sementes de espécies florestais nativas do Brasil.

Palavras-chave: análise de sementes; biometria; descritores morfológicos; processamento de imagens; sementes florestais.

ABSTRACT

Biometric analysis of seeds contributes to the characterization and differentiation of forest species. However, studies with native species often rely on manual methods such as digital calipers, which extract a limited number of characteristics, while agronomic species have expensive and inaccessible equipment. Thus, the objective of this chapter is to determine a methodology with analysis tools and image processing in seeds to aid in the characterization and differentiation of native species. For this purpose, seeds of 155 species, distributed in 42 botanical families, were photographed with a camera in a mini-studio and analyzed using ImageJ® software. Aspects of dimension, shape, and color were considered, totaling 18 characteristics: eight for dimensions, four for shape, and six for color. A dataset of approximately 1.827 million morpho-biometric data points was obtained from 101,521 seed images, and the following analyses were applied to the data: descriptive statistics, frequency distribution, Pearson correlation, Euclidean distance, and principal component analysis. The digital image processing of seeds was efficient for species characterization, and the utilized characteristics allowed for differentiation of seeds, including those within the same botanical family and genus. Therefore, it is concluded that the analysis of seed images using the proposed methodology contributes to the characterization and differentiation of seeds from native forest species in Brazil.

Keywords: seed analysis; biometrics; morphological descriptors; image processing; forest seeds.

4.1 INTRODUÇÃO

A caracterização de sementes florestais nativas é fundamental para os especialistas da área de recursos florestais, pois contribui em estudos de identificação taxonômica, condições de germinação, escolha de espécies para a restauração de ambientes degradados, seleção de árvores matrizes e estudos genéticos (CORREIA *et al.*, 2019, p. 758; DUARTE; GONZALEZ-RONDAN; ROCHA, 2019, p. 404; SANTOS *et al.*, 2019, p. 958; MOREIRA; NEVES; LOBO, 2021, p. 525; BEZERRA *et al.*, 2022, p. 394). As análises de sementes nativas geralmente empregam métodos manuais para determinar medidas de comprimento, largura e espessura de um número limitado de sementes, normalmente não superiores a 100 (ZUFFO *et al.*, 2019, p. 626; POLLI *et al.*, 2020, p. 2; ROSA *et al.*, 2020, p. 2; FERNANDES *et al.*, 2021, p. 678; SALVADOR *et al.*, 2022, p. 3). Deste modo, as abordagens tradicionais que utilizam paquímetro digital não são efetivas quando se pretende analisar maior número de sementes de uma ou mais espécies.

Nesse sentido, métodos de processamento de imagens são amplamente explorados em sementes agrícolas e de importância econômica ou ecológica (PAN *et al.*, 2016; SILVA *et al.*, 2016; BAGHERI *et al.*, 2019; GONZÁLEZ-CORTÉS *et al.*, 2019; MARTÍN-GÓMEZ *et al.*, 2020; NAZARI *et al.*, 2021). Por isso, o emprego de ferramentas de processamento de imagens e análise de sementes associados à uma metodologia de captura de imagens pode ser uma alternativa para a análise biométrica de sementes nativas. Entretanto, observa-se a falta de estudos em espécies nativas, principalmente devido à diversidade de características que estas apresentam, como: variação de tamanhos, formatos, coloração das sementes, e estruturas de dispersão ou diásporos.

Para espécies de culturas agrícolas (exemplo: arroz, milho e quiabo), herbáceas daninhas e de importância ambiental, existem estudos com sementes empregando o uso de scanners de alta resolução (BIANCO *et al.*, 2017, p. 92; FARRIS *et al.*, 2020, p. 8), microscópios ópticos (BAO; BAMBIL, 2021, p. 18) e de varredura (MAZUR *et al.*, 2022, p. 13), tomografia computadorizada (JOSHI *et al.*, 2021, p. 2), espectroscopia de infravermelho (CECCO *et al.*, 2019, p. 509), colorimetria espectral e hiperespectral (AREFI *et al.*, 2011, p. 380; ZHANG *et al.*, 2018, p. 3; YU *et al.*, 2021, p. 48; WANG; WANG, 2021, p. 2235) que se mostraram efetivos na diferenciação de espécies e caracterização de genótipos. Essas técnicas são úteis em pesquisas científicas com espécies de sementes pequenas e homogêneas, entretanto, não é aplicável a diversidade de formas e tamanhos observados nas espécies nativas do Brasil.

Além do custo dos equipamentos citados, a maioria dos recursos computacionais para o processamento digital de imagens requer conhecimentos especializados em computação, seja por meio de interface de programação de aplicação (APIs) ou ferramentas de integração complexos (OpenCV, ArcGIS, Python, C/C++ e MatLab), o que na maioria das vezes dificulta o uso por profissionais de outras áreas. Nesse sentido, utilizar ferramentas de captura e processamento digital de imagens, com *software* de livre acesso, pode ser uma alternativa ao uso de equipamentos caros e pouco acessíveis.

O ImageJ® é uma alternativa para superar isso, podendo ser empregado na caracterização de sementes para algumas espécies (FARRIS *et al.*, 2020, p. 2-5; FELIX *et al.*, 2020, p. 7; ARAÚJO *et al.*, 2022, p. 164), além de outros usos nas ciências florestais, como processamento de imagens de raios-x em sementes

(MEDEIROS *et al.*, 2019, p. 3), mensuração de plântulas (SILVA *et al.*, 2020, p. 3) e contagem de sementes (FELIX *et al.*, 2021a, p. 3). Esse *software* é capaz de analisar aspectos relativos ao tamanho, formato e coloração de elementos de uma imagem após processamento (FERREIRA; RASBAND, 2012). Deste modo, observa-se o potencial de utilização abrangendo sementes florestais para caracterização e diferenciação de espécies.

Diante disto, levantou-se a hipótese de que a obtenção de imagens com câmera fotográfica em mini estúdio, e o processamento digital por meio de *software* de livre acesso, pode ser uma alternativa para a extração de características morfobiométricas de sementes. Assim, o objetivo com este capítulo foi determinar uma nova metodologia de análise e processamento de imagens em sementes para fins de diferenciação e caracterização de espécies florestais nativas.

4.2 MATERIAL E MÉTODOS

4.2.1 Obtenção das sementes

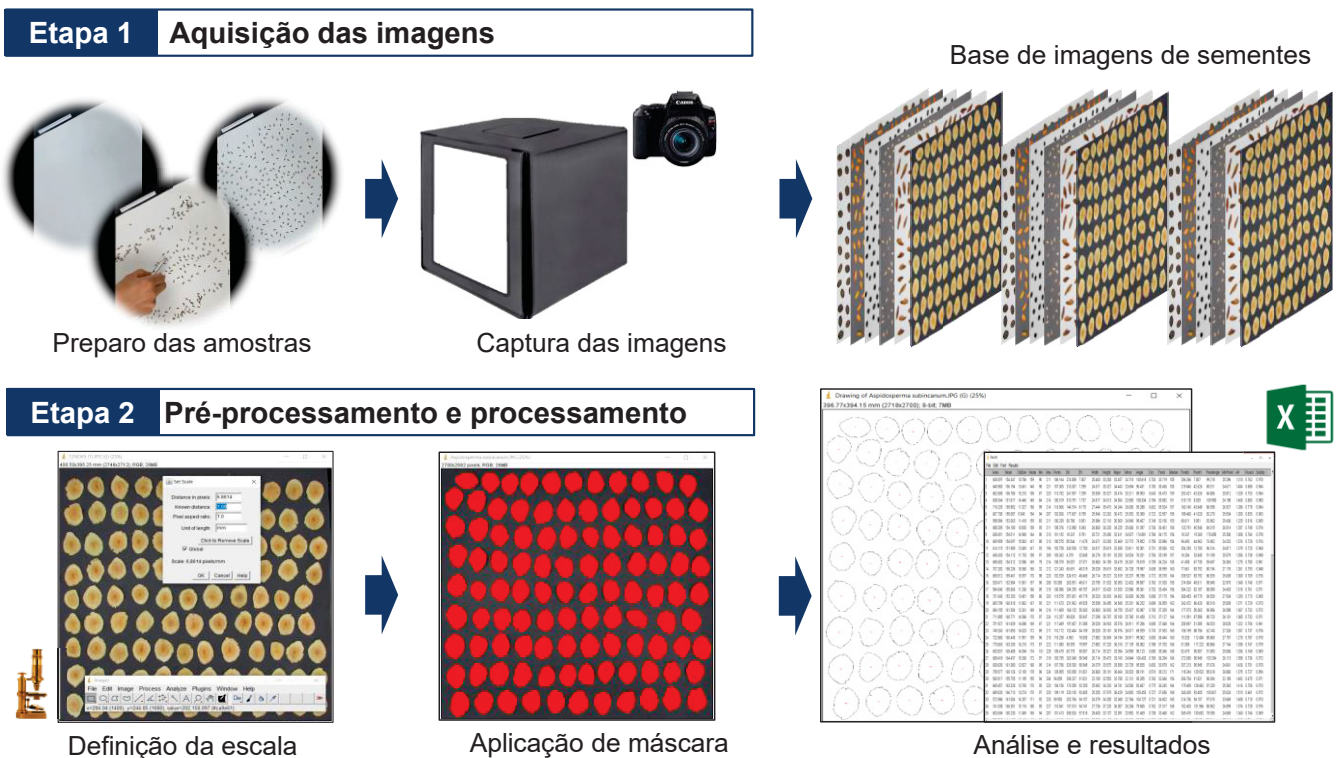
As amostras de sementes utilizadas neste estudo são provenientes dos bancos de sementes de sete instituições nacionais e regionais de pesquisa, produção e ensino: (i) Embrapa Florestas, (ii) Instituto Água e Terra (IAT/PR), (iii) Sociedade Chauá, (iv) Laboratório de Sementes Florestais (UFPR), (v) Programa Bolsa de Sementes (AFUBRA/UFSM), (vi) Núcleo de Conservação da Biodiversidade do Instituto de Pesquisas Ambientais do Estado de São Paulo, e (vii) Núcleo de Ecologia e Monitoramento Ambiental (NEMA/UNIVASF). A lista completa das espécies analisadas encontra-se no APÊNDICE 2.

Foram analisadas um total de 155 espécies florestais nativas pertencentes a 42 famílias botânicas, considerando-se neste estudo sementes e/ou unidades de dispersão quando a separação não é utilizada, a exemplo de *Araucaria angustifolia* (Bertol.) Kuntze (pinhão: semente + megasporófilo maduro) e *Ilex paraguariensis* A.St.-Hil. (pirênio: semente + endocarpo persistente). As sementes de cada espécie foram fotografadas e analisadas quanto aos aspectos de tamanho, formato e de coloração no Laboratório de Sementes Florestais da Universidade Federal do Paraná, entre os anos de 2020 e 2022.

4.2.2 Captura e processamento das imagens

O processo da metodologia proposta seguiu uma sequência de atividades, dividida em duas etapas: (i) aquisição das imagens, e (ii) pré-processamento e processamento das imagens. Na etapa 1, realizou-se as atividades de preparo das amostras de sementes, capturas das imagens e geração da base de imagens de sementes; e na etapa 2, realizou-se o processamento e análise das imagens (FIGURA 10).

FIGURA 10 – ETAPAS PARA AQUISIÇÃO E PROCESSAMENTO DAS IMAGENS EM SEMENTES NATIVAS



FONTE: O autor (2022).


Na atividade de preparo das amostras, as sementes de cada espécie foram dispostas espacialmente sobre folha de espuma vinílica acetinada (EVA). O quantitativo de sementes usadas para cada espécie se encontra na TABELA 4. As sementes escuras foram fotografadas sobre EVA branca e sementes claras sobre EVA preta fosca, visando gerar contraste entre a coloração das sementes e o fundo do papel (*background*). Em seguida, realizou-se a captura das imagens com câmera fotográfica Canon PowerShot SX500 IS (f/4) lente de 12 MP a 50 cm de distância das sementes com gabarito de referência. As capturas das imagens foram feitas em

triplicatas para cada espécie usando mini estúdio fotográfico (50 x 50 x 50 cm), com luz artificial branca (LED) para padronização das condições de luminosidade. Para cada fotografia foram realizadas novas amostragens de sementes por espécie, totalizando 465 imagens que compuseram a base de imagens de sementes utilizadas neste estudo.

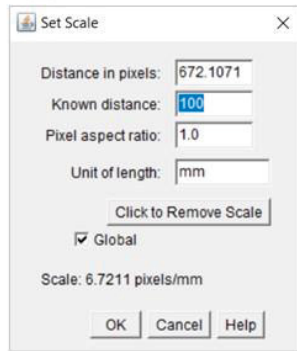
As imagens em seu formato original (.JPEG) foram transferidas para microcomputador, e no *software* ImageJ[®], versão 1.53 (FERREIRA; RASBAND, 2012) foi determinada a escala de referência em milímetros a partir do referencial sobre o EVA e mantida apenas as sementes como elementos da imagem. Em seguida, foi aplicada a máscara de *Threshold* para contrastar os componentes da imagem. Por fim, as sementes foram analisadas para obtenção das características de tamanho, formato e de cor, em que o *software* computou automaticamente para cada semente na imagem as características de dimensões, formato e coloração, cujos dados foram exportados para uma planilha de dados eletrônica (Microsoft Office Excel[®]) (FIGURA 11).

FIGURA 11 - PROTOCOLO PARA O PROCESSAMENTO DAS IMAGENS NO SOFTWARE IMAGEJ


1 Abertura do software e carregamento da imagem



2 Definição da escala



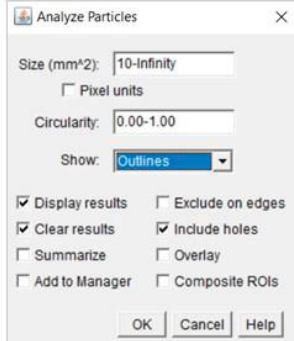
3 Aplicação de máscaras



4 Seleção de caracteres



5 Análise das imagens



6 Exportação dos resultados

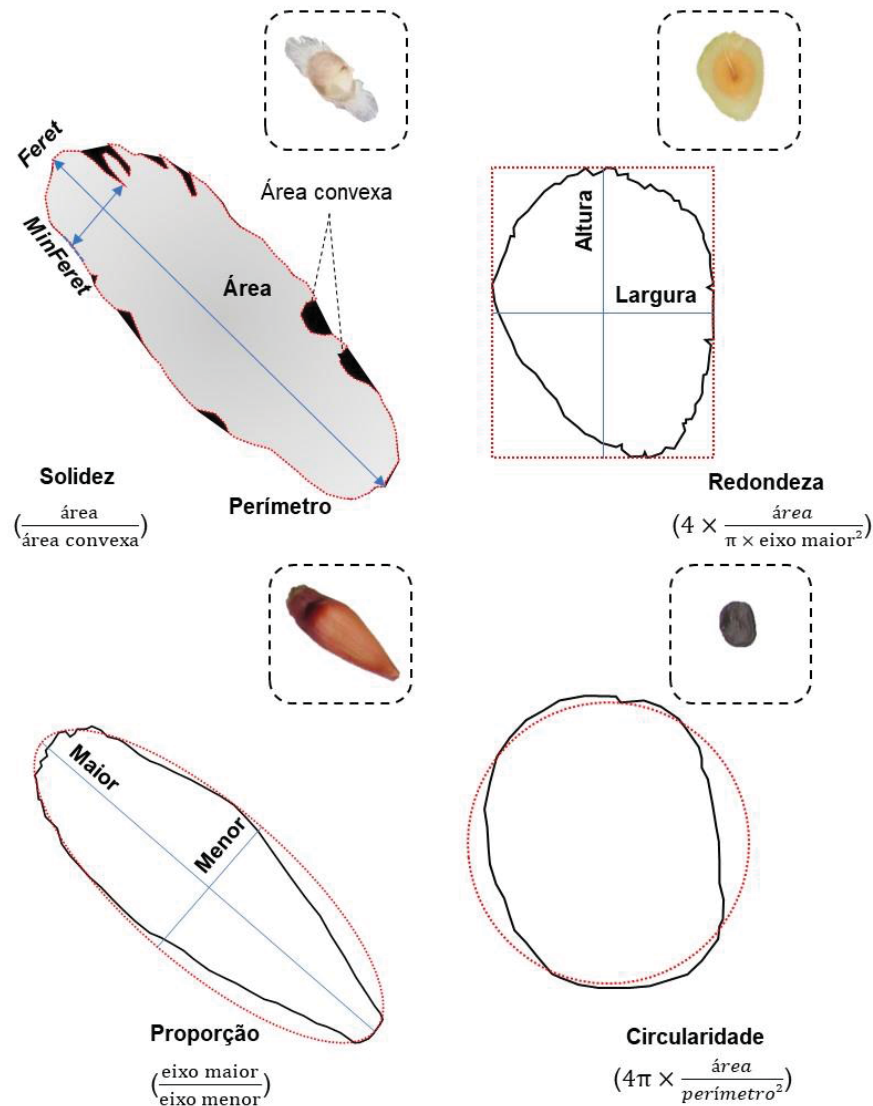
	Area	Mean	StdDev	Mode	Min	Max	X
1	655.062	154.310	10.786	159	90	211	296.341
2	666.286	156.164	13.706	148	94	221	229.979
3	689.087	156.750	15.261	158	87	223	263.209
4	663.519	151.789	14.489	148	84	214	333.136
5	744.563	155.851	11.383	156	99	214	165.343
6	631.907	155.044	9.442	154	93	207	197.545
7	622.720	152.028	11.485	159	83	211	74.529
8	715.342	154.160	10.868	158	93	211	132.018
9	663.497	153.992	14.996	164	90	210	39.612
10	633.966	154.072	15.577	147	88	213	103.378
11	638.482	151.950	12.122	147	92	196	367.023
12	665.821	154.074	11.807	158	93	209	20.885
13	717.954	154.283	12.634	149	78	214	54.471
14	735.199	158.203	15.415	165	32	212	84.828
15	676.181	159.431	15.441	170	98	220	348.223
16	550.508	152.866	11.928	157	94	208	284.833
17	617.717	155.616	11.313	166	95	215	316.110
18	759.816	152.227	13.488	158	80	203	382.386
19	710.693	160.894	11.913	167	93	221	253.470

FONTE: O autor (2022).

4.2.3 Descritores de tamanho, formato e de coloração

As características de tamanho, formato e coloração selecionadas foram analisadas a partir das partículas capturadas nas imagens. Esses descritores estão detalhados em análise de partículas de uma imagem proposto por Ferreira e Rasband (2012, p. 136-138). Em suma, foram utilizadas oito características para dimensões, quatro para formato, e seis para cor, totalizando 18 características analisadas. Na sequência da FIGURA 12, pode-se observar uma exemplificação de extração das características de tamanho e formato em sementes florestais nativas.

FIGURA 12 – EXEMPLIFICAÇÃO DA EXTRAÇÃO DE CARACTERÍSTICAS DE TAMANHO E FORMATO EM SEMENTES FLORESTAIS NATIVAS



FONTE: O autor (2022).

Dimensões das sementes

Área: seleção da superfície das sementes em unidades quadradas calibradas (mm²), calculado a partir dos limites definidos pelo perímetro.

Perímetro: limite externo da seleção das sementes em unidades calibradas (mm), calculado a partir dos centros dos pixels limite.

Largura e Altura: medidas de largura e altura definidos pelo menor retângulo delimitador que envolve a seleção da semente, distância calculada em unidades calibradas (mm).

Maior e Menor: eixo maior e menor ajustado à uma elipse que envolve a seleção da semente, distância calculada em unidades calibradas (mm).

Feret e MinFerret: maior e menor distância entre dois pontos ao longo do limite da seleção da semente ajustado em um ângulo de até 180°, distância calculada em unidades calibradas (mm).

Formato das sementes

Circularidade (Circ.): valor escalar de 0,0 a 1,0 calculado a partir da fórmula abaixo, indicando um círculo perfeito quando próximo a 1,0 para o formato da semente em relação ao seu perímetro, e uma forma alongada quando próximo de zero.

$$Circularidade = 4\pi \times \frac{\text{área}}{\text{perímetro}^2}$$

Proporção: relação entre os eixos maior e menor a partir de uma elipse ajustada para a semente, calculado de acordo com a fórmula abaixo.

$$Proporção = \frac{\text{eixo maior}}{\text{eixo menor}}$$

Redondeza: valor escalar de 0,0 a 1,0 calculado a partir da fórmula abaixo, inverso da proporção da semente.

$$Redondeza = 4 \times \frac{\text{área}}{\pi \times \text{eixo maior}^2}$$

Solidez: valor escalar de 0,0 a 1,0 calculado a partir da fórmula abaixo, indicando a relação entre a área da semente capturada na imagem e a área convexa da semente. A área convexa é caracterizada como um delimitador da forma original do objeto da imagem envolvendo firmemente a área, sem reentrâncias.

$$\text{Solidez} = \frac{\text{área}}{\text{área convexa}}$$

Coloração das sementes

Cor: valor médio de cinza entre 0 e 255 resultantes do somatório de valores dos pixels da seleção da superfície da imagem da semente dividido pelo número de pixels, calculado a partir das fórmulas abaixo.

$$\text{Cor} = 0,229 \times \text{red} + 0,587 \times \text{green} + 0,144 \times \text{blue}$$

Ou,

$$\text{Cor} = \frac{\text{red} + \text{green} + \text{blue}}{3}$$

Desvio padrão (StdDev): cálculo do desvio padrão dos valores de cor de cinza da superfície da imagem da semente usadas para gerar o valor médio de cinza.

Valor de cinza modal (Modal): valor de cinza para a cor da seleção da superfície da semente que ocorre com mais frequência, correspondente ao pico mais alto no histograma.

Nível de cinza Mínimo e Máximo (Min e Max): valores mínimos e máximos para a cor de cinza da seleção da superfície da semente.

Mediana: valor mediano dos pixels para a coloração da seleção da superfície da semente.

4.2.4 Análise dos dados

Um conjunto com 1,827 milhões de dados, composto por 18 características morfobiométricas de sementes foi obtido a partir do processamento de imagens para


155 espécies. Esses dados foram submetidos a estatística descritiva para obtenção da média aritmética por espécie. Em seguida, realizou-se a distribuição da frequência de ocorrência das espécies em função das características avaliadas. Aplicou-se a correlação de Pearson (r_p) entre as variáveis para todas as espécies em conjunto para verificar a correlação entre as características analisadas, e elaborou-se um dendrograma a partir da distância Euclidiana utilizando o modelo *Unweighted Pair-Group Method using Arithmetic Averages* (UPGMA) para agrupamento e diferenciação das espécies. Adicionalmente, foi incluída a análise multivariada de componentes principais com os dados padronizados e representação *biplot* das características. O *software* estatístico utilizado foi o Past®, versão 3.8 (HAMMER; HARPER, 2008). Os dados padronizados foram calculados da seguinte forma:

$$\text{Padronização} = \frac{x - \text{média}}{\text{desvio padrão}}$$

4.3 RESULTADOS E DISCUSSÃO

Foram analisadas 101.521 sementes de 155 espécies nativas distribuídas em 42 famílias botânicas com ocorrência em diferentes domínios fitogeográficos do Brasil. Dentre as espécies analisadas, 143 são denominadas árvores e arbustos (92%), cinco espécies são palmeiras (3%) e as demais são classificadas como lianas, ervas ou suculentas (5%) (FIGURA 13A). Destas, 124 espécies têm ocorrência na Mata Atlântica (79%), 106 no Cerrado (68%), 82 na Caatinga (52%), 58 na Amazônia (37%), 49 no Pampa (31%) e 40 no Pantanal (25%) (FIGURA 13B). Ressalta-se que algumas espécies ocorrem em mais de um domínio fitogeográfico e, por este motivo, o somatório não é 100%.

FIGURA 13 – FORMAS DE VIDA (A) E DOMÍNIOS FITOGEOGRÁFICOS (B) DAS ESPÉCIES AVALIADAS NESTE ESTUDO




FONTE: O autor (2022).

No Brasil, tem-se catalogado 33.978 espécies de Angiospermas e 26 espécies de Gimnospermas nativas (REFLORA, 2020), o que evidencia a elevada biodiversidade de plantas com sementes existente no país. Nesse sentido, o presente estudo abrangeu sementes de cerca de 0,46% das espermatófitas nativas (de 34.004) com ocorrência em território nacional, sendo 1,72% das arbóreas (de 8.324). Assim, para caracterização de sementes de todas as espécies nativas do Brasil, estima-se que seriam necessários cerca de 22 milhões de sementes das espécies não incluídas neste estudo. Isso somente será possível com o emprego de ferramentas de processamento de imagens, como a apresentada neste trabalho.

O processamento digital de imagens extraiu características de tamanho, formato e de coloração das sementes de todas as espécies analisadas. Assim, foi possível notar alta correlação entre as características que compõem cada descritor (tamanho, formato e cor), entretanto, não foi verificada correlações expressivas entre os descritores (FIGURA 14). Lembra-se que correlações altas são aquelas acima de 0.7, enquanto correlações moderadas variam de 0.3 a 0.7, e baixas correlação são aquelas inferiores a 0.3. As características relativas ao tamanho das sementes apresentaram alta correlação entre si, baixa correlação com as características de formato das sementes, e não apresentaram correlação expressiva para as características de coloração.

FIGURA 14 - CORRELAÇÃO DE PEARSON ENTRE AS CARACTERÍSTICAS DE TAMANHO, FORMATO E COLORAÇÃO OBTIDAS COM O PROCESSAMENTO DIGITAL DE IMAGENS DE SEMENTES NATIVAS




FONTE: O autor (2022).

A análise de componentes principais permitiu capturar 75,5% da variação dos dados nas duas primeiras componentes (FIGURA 15). A componente 1 corresponde a 47,7% (autovalor 8,58) e a componente 2 representa 27,8% (autovalor 5,00). As características de tamanho das sementes mostraram-se correlacionadas no quarto quadrante, enquanto as características de formato estão correlacionadas no terceiro quadrante, exceto para proporção, a qual é inversamente correlacionada à redondeza. As características de coloração da semente encontram-se correlacionadas no primeiro quadrante, exceto para o desvio padrão (StdDev) da cor média de cinza que se encontra no segundo quadrante. Em resumo, isso significa que a avaliação de todos os descritores (cor, tamanho e formato) deve ser utilizada em uma análise de sementes de modo a permitir capturar

a maior parte da variação dos dados contidos no primeiro, terceiro e quarto quadrantes das componentes principais.

FIGURA 15 - ANÁLISE DE COMPONENTES PRINCIPAIS COM REPRESENTAÇÃO BIPLLOT PARA TAMANHO, FORMATO E COLORAÇÃO OBTIDAS COM O PROCESSAMENTO DIGITAL DE IMAGENS EM SEMENTES DE 155 ESPÉCIES NATIVAS



FONTE: O autor (2022).

As características relativas ao tamanho foram as que mais contribuem para a caracterização de sementes (63,9%), seguido do formato (18,9%) e coloração (17,2%) para a componente 1 que tem maior peso (47,7%), enquanto cor (59,1%), tamanho (29,1%) e formato (11,8%) contribuem para a componente 2 que tem menor peso (27,8%) (TABELA 3). Evidenciando que o tamanho de sementes seguido do formato são as características em sementes florestais que mais refletem a diversidade das espécies nativas.

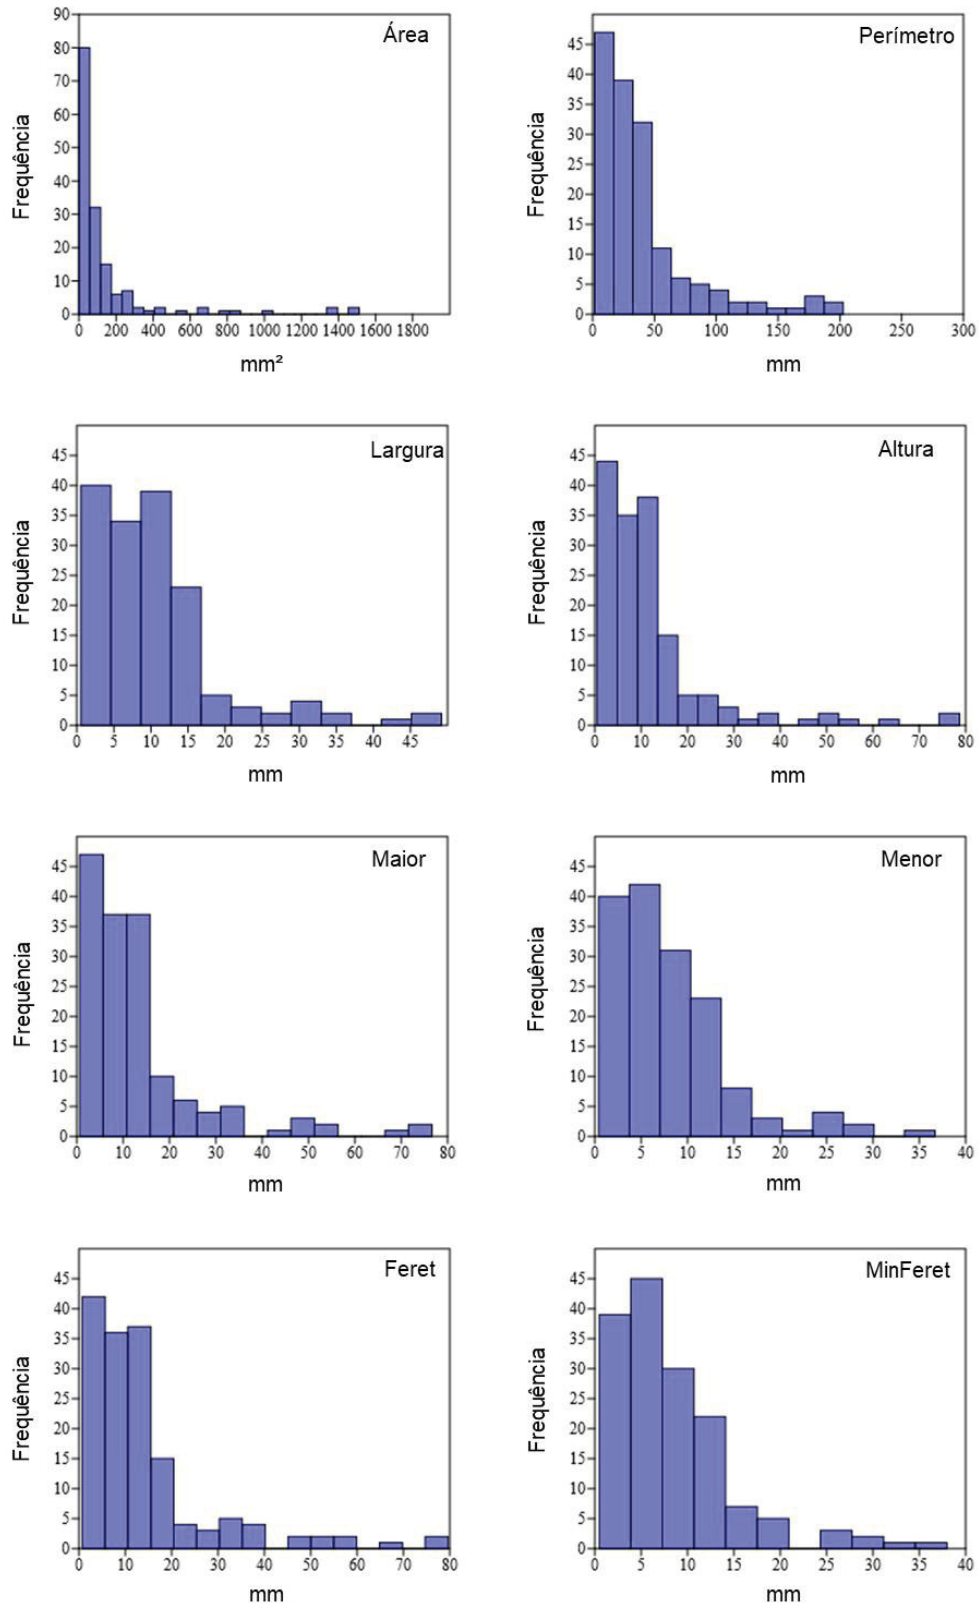
TABELA 3 – CONTRIBUIÇÃO DAS CARACTERÍSTICAS AVALIADAS PARA AS COMPONENTES PRINCIPAIS (CP) SELECIONADAS

Descritores	Características	CP 1	Contribuição (%)		CP 2	Contribuição (%)	
			Relativa	Acumulada		Relativa	Acumulada
Tamanho	Área	0,298	7,8	7,8	-0,155	4,3	4,3
	Perímetro	0,330	8,6	16,3	-0,092	2,5	6,8
	Largura	0,301	7,8	24,2	-0,107	3,0	9,8
	Altura	0,308	8,0	32,2	-0,135	3,8	13,6
	Maior	0,323	8,4	40,6	-0,124	3,4	17,0
	Menor	0,282	7,3	47,9	-0,166	4,6	21,6
	Feret	0,325	8,5	56,4	-0,117	3,2	24,8
	MinFeret	0,289	7,5	63,9	-0,156	4,3	29,1
Formato	Circularidade	-0,263	6,9	70,8	-0,116	3,2	32,3
	Proporção	0,204	5,3	76,1	0,057	1,6	33,9
	Redondeza	-0,179	4,7	80,8	-0,054	1,5	35,4
	Solidez	-0,081	2,1	82,8	-0,197	5,5	40,9
Coloração	Cor	0,132	3,4	86,3	0,401	11,1	52,0
	StdDev	-0,005	0,1	86,4	0,175	4,8	56,8
	Modal	0,141	3,7	90,1	0,391	10,8	67,7
	Min	0,061	1,6	91,6	0,409	11,3	79,0
	Max	0,186	4,8	96,5	0,360	10,0	89,0
	Mediana	0,135	3,5	100,0	0,398	11,0	100,0
Total		3,843	100,0	-	3,609	100,0	-

FONTE: O autor (2022).

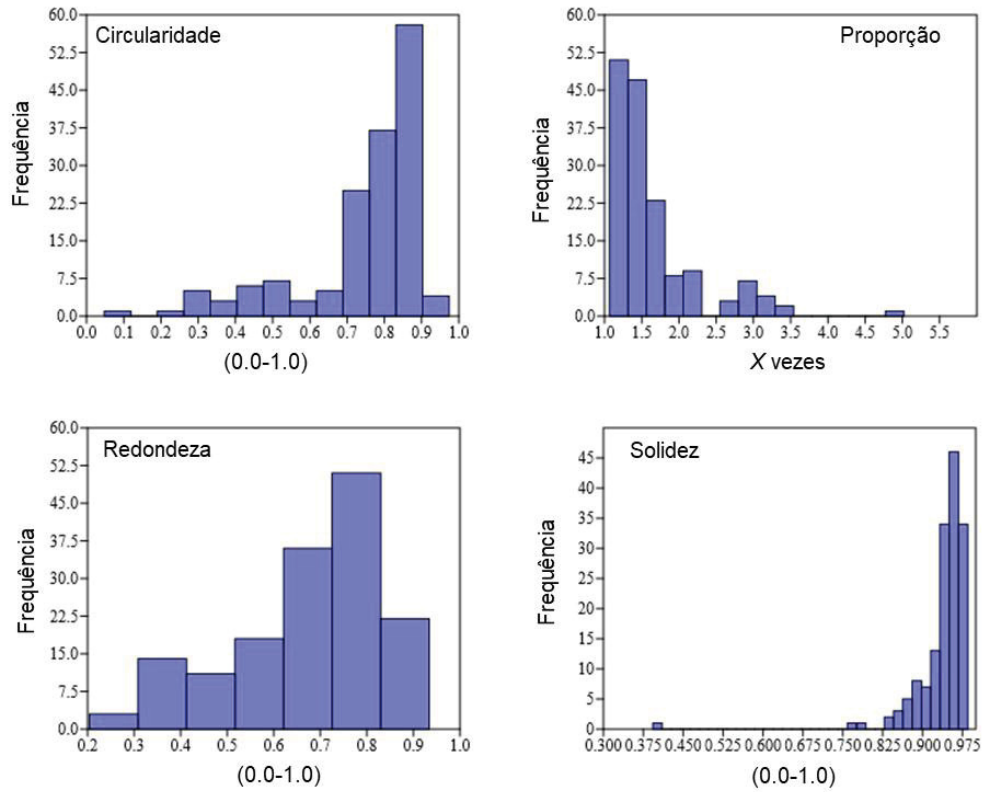
As espécies avaliadas apresentaram sementes com dimensões de até ~1.500 mm² de área e até ~200 mm de perímetro, sendo a maioria (~80%; 123 espécies) concentrada em intervalos de até 150 mm² e até 50 mm, respectivamente (FIGURA 16). As medidas relativas de largura, altura, maior, menor, Feret e MinFeret apresentaram maior variação em relação ao número de espécies, concentrando-se até 15 mm. O formato das sementes florestais avaliadas é mais circular (acima de 0,7), e a maioria (~83%) das espécies apresentam sementes com proporção de até duas vezes (FIGURA 17). No geral, as sementes apresentam índice de solidez elevada acima de 0,9. Com relação a cor, houve variação e distribuição em função da coloração predominante entre as espécies, sendo possível notar a ocorrência de sementes mais escuras do que claras (escala de 50 a 100) (FIGURA 18).

FIGURA 16 - FREQUÊNCIA DE OCORRÊNCIA DAS ESPÉCIES EM FUNÇÃO DO TAMANHO DE SEMENTES PARA 155 ESPÉCIES NATIVAS



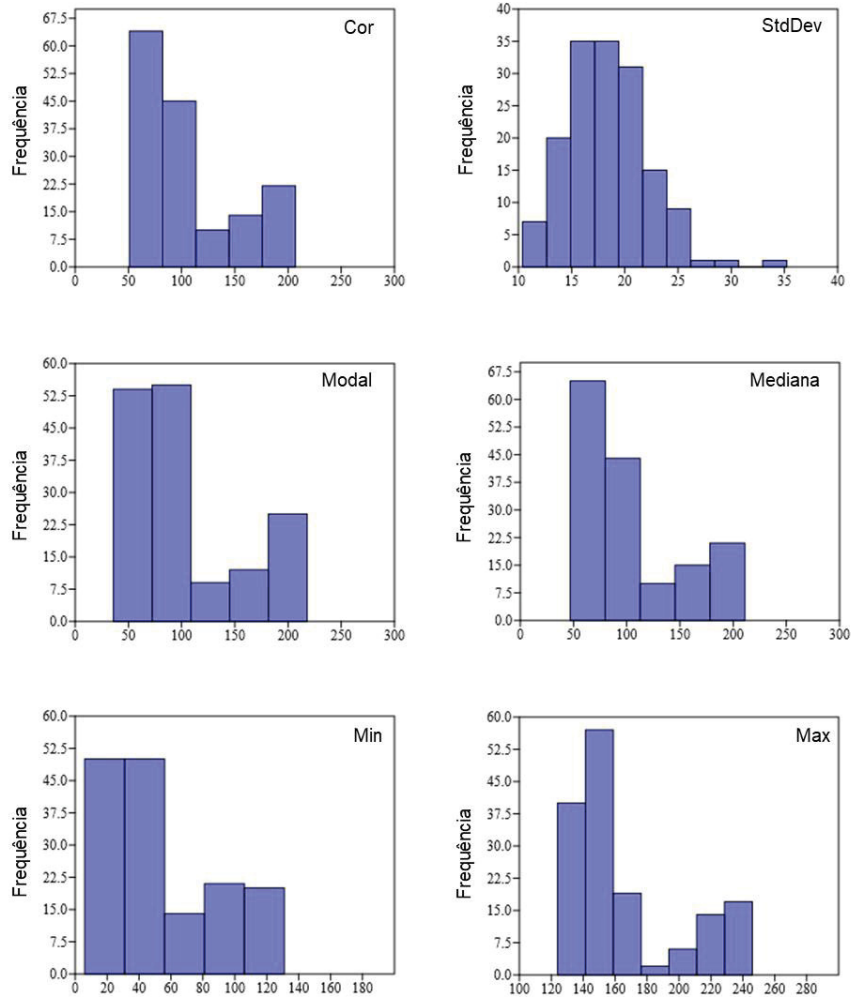
FONTE: O autor (2022).

FIGURA 17 - FREQUÊNCIA DE OCORRÊNCIA DAS ESPÉCIES EM FUNÇÃO DO FORMATO DE SEMENTES PARA 155 ESPÉCIES NATIVAS



FONTE: O autor (2022).

FIGURA 18 - FREQUÊNCIA DE OCORRÊNCIA DAS ESPÉCIES EM FUNÇÃO DA ESCALA DE COLORAÇÃO DE SEMENTES PARA 155 ESPÉCIES NATIVAS



FONTE: O autor (2022).

As espécies *Machaerium acutifolium* Vogel, *Platypodium elegans* Vogel, *Pterocarpus rohrii* Vahl e *Terminalia mameluco* Pickel apresentam sementes de maior área superficial (área > 1.350 mm² e perímetro > 1.720 mm), enquanto *Miconia theaezans* (Bonpl.) Cogn., *Pleroma sellowianum* (Cham.) P.J.F.Guim. & Michelang. e *Pleroma raddianum* (DC.) Gardner são de menor tamanho (área < 0,255 mm² e perímetro < 1,90 mm) (TABELA 4). A mensuração de sementes diminutas não é possível quando se utiliza ferramentas manuais como paquímetro digital ou régua, entretanto, é mensurável usando a metodologia proposta, revelando que a esta metodologia não se limita aos trabalhos que utilizam equipamentos como scanners e microscópios (FARRIS *et al.*, 2020; BAO; BAMBIL, 2021; MAZUR *et al.*,

2022). Além disso, o uso de técnicas de imagens como a apresentada proporciona maior precisão e agilidade nas análises e diminui as possibilidades de erro no momento da mensuração das sementes. Por outro lado, sementes esféricas necessitam de maior cuidado de colocação sobre o fundo de papel no momento da captura das imagens, devido ao deslocamento entre as sementes.

TABELA 4 - CARACTERIZAÇÃO DE SEMENTES DE 155 ESPÉCIES NATIVAS A PARTIR DO PROCESSAMENTO DIGITAL DE IMAGENS PARA OBTENÇÃO DE DESCRITORES DE TAMANHO, FORMATO E COLORAÇÃO DAS SEMENTES

Famílias e espécies	n	Dimensões e tamanho da semente										Formato da semente										Coloração da semente			Contraste
		Área (mm ²)	Perímetro (mm)	Largura (mm)	Altura (mm)	Maior (mm)	Menor (mm)	Feret (mm)	MinFeret (mm)	Circularidade (0,0-1,0)	Proporção	Redondeza (0,0-1,0)	Solidez (0,0-1,0)	Cor	StdDev	Modal	Min	Max	Mediana	background					
ANACARDIACEAE (5)																									
<i>Astronium urundeuva</i>	1212	10,03	12,07	3,73	3,61	3,87	3,28	4,10	3,37	0,862	1,18	0,849	0,936	81	21,04	68	35	143	76	Branco					
<i>Lithraea molleoides</i>	315	16,15	15,14	4,70	4,55	5,09	4,03	5,21	4,13	0,883	1,27	0,793	0,953	59	18,52	49	20	128	53	Branco					
<i>Schinopsis brasiliensis</i>	508	48,78	27,92	8,63	8,14	9,60	6,44	10,29	6,74	0,782	1,50	0,672	0,950	207	17,55	213	128	237	211	Preto					
<i>Schinus terebinthifolia</i>	970	11,21	12,74	3,94	3,78	4,11	3,46	4,29	3,56	0,867	1,19	0,845	0,940	88	19,97	76	46	148	83	Branco					
<i>Spondias tuberosa</i>	399	179,18	54,87	12,95	17,97	18,11	12,55	18,29	12,56	0,749	1,45	0,695	0,966	195	20,63	201	117	241	198	Preto					
ANNONACEAE (4)																									
<i>Annona cacans</i>	469	73,49	33,77	10,36	10,12	12,03	7,77	12,23	8,00	0,807	1,56	0,649	0,970	78	14,97	72	40	142	75	Branco					
<i>Annona emarginata</i>	461	93,30	40,13	12,08	11,21	13,59	8,72	14,03	9,05	0,729	1,58	0,647	0,962	102	18,45	97	51	161	100	Branco					
<i>Annona mucosa</i>	425	80,80	36,82	11,31	10,89	14,17	7,25	14,27	7,36	0,748	1,97	0,516	0,970	63	16,79	57	24	135	61	Branco					
<i>Annona sylvatica</i>	461	104,76	40,54	12,52	11,82	13,74	9,69	14,18	9,98	0,798	1,43	0,710	0,972	85	14,77	82	36	146	83	Branco					
APOCYNACEAE (3)																									
<i>Aspidosperma parvifolium</i>	217	1040,12	150,96	31,20	46,16	45,03	29,34	46,91	30,22	0,580	1,54	0,654	0,946	140	12,85	140	77	207	140	Preto					
<i>Aspidosperma pyriforme</i>	200	842,88	163,17	34,84	36,78	36,05	29,64	39,57	31,59	0,413	1,22	0,827	0,879	170	12,77	173	87	221	171	Preto					
<i>Aspidosperma subincanum</i>	315	680,63	109,66	26,29	35,56	34,35	25,19	36,01	25,89	0,714	1,37	0,734	0,969	160	13,69	166	91	216	162	Preto					
AQUIFOLIACEAE (1)																									
<i>Ilex paraguariensis</i>	1016	6,96	10,61	3,01	3,32	3,75	2,35	3,86	2,43	0,776	1,61	0,631	0,945	195	21,80	208	129	232	200	Preto					
ARAUCARIACEAE (1)																									
<i>Araucaria angustifolia</i>	187	792,43	138,30	21,48	54,97	53,31	18,85	56,04	20,23	0,524	2,85	0,358	0,963	79	18,75	78	19	152	78	Branco					
ARECACEAE (5)																									
<i>Butia capitata</i>	189	166,53	52,68	15,18	14,57	15,77	13,39	16,52	13,60	0,759	1,18	0,849	0,968	100	12,47	99	60	146	99	Branco					
<i>Butia eriopantha</i>	250	176,83	53,61	15,29	15,14	15,70	14,25	16,27	14,43	0,788	1,10	0,909	0,971	101	12,44	98	58	154	100	Branco					
<i>Copernicia prunifera</i>	328	168,74	50,12	14,94	14,69	15,30	13,94	15,69	14,05	0,842	1,10	0,914	0,976	91	13,23	88	49	144	90	Branco					
<i>Euterpe edulis</i>	381	79,64	36,44	10,54	10,19	10,52	9,56	11,14	9,71	0,761	1,10	0,911	0,949	99	14,47	95	57	147	97	Branco					
<i>Syagrus romanzoffiana</i>	174	287,96	123,57	20,73	25,67	21,71	16,87	27,13	18,84	0,304	1,29	0,780	0,789	186	25,04	200	83	238	190	Preto					

(Continuação)

ASTERACEAE (1)																				
<i>Vernonanthura discolor</i>	360	19,50	76,76	8,57	9,07	6,20	3,97	10,45	7,10	0,048	1,61	0,652	0,393	168	22,03	156	104	238	164	Preto
BERBERIDACEAE (1)																				
<i>Berberis laurina</i>	979	5,41	9,05	2,81	2,78	3,38	2,03	3,54	2,14	0,827	1,68	0,605	0,932	80	21,61	73	28	146	76	Branco
BIGNONIACEAE (6)																				
<i>Handroanthus albus</i>	613	100,54	68,63	13,51	16,66	20,59	6,18	22,40	6,97	0,282	3,35	0,304	0,832	196	21,42	204	114	243	200	Preto
<i>Handroanthus chrysotrichus</i>	485	221,81	84,80	28,78	12,61	29,99	9,37	30,44	9,98	0,393	3,25	0,316	0,886	181	19,84	187	102	234	183	Preto
<i>Handroanthus heptaphyllus</i>	314	319,40	107,29	21,69	28,16	33,55	12,06	35,82	13,07	0,364	2,81	0,372	0,859	176	19,51	182	95	233	178	Preto
<i>Handroanthus impetiginosus</i>	365	242,76	108,31	31,19	13,01	29,26	10,51	31,98	11,44	0,275	2,81	0,367	0,833	180	21,67	187	106	234	182	Preto
<i>Handroanthus ochraceus</i>	513	253,56	102,44	12,30	30,07	29,32	11,01	30,47	11,50	0,322	2,69	0,380	0,866	189	21,97	199	101	246	193	Preto
<i>Tabebuia aurea</i>	257	687,38	171,83	49,18	22,42	48,27	18,07	51,25	19,73	0,304	2,69	0,377	0,870	192	21,18	203	71	239	196	Preto
BIXACEAE (2)																				
<i>Bixa orellana</i>	314	12,48	13,57	4,20	4,10	4,61	3,45	4,86	3,60	0,851	1,35	0,749	0,949	78	20,17	66	37	147	71	Branco
<i>Cochlospermum orinocense</i>	514	107,58	74,01	14,08	13,61	12,90	10,35	15,51	11,98	0,257	1,27	0,804	0,761	130	35,21	153	36	177	143	Branco
BORAGINACEAE (1)																				
<i>Cordia superba</i>	310	71,46	33,46	9,84	9,69	10,15	8,90	10,64	9,07	0,798	1,15	0,877	0,956	85	15,83	86	40	135	85	Branco
BROMELIACEAE (1)																				
<i>Encholirium spectabile</i>	776	7,59	11,71	3,47	3,55	4,23	2,27	4,46	2,49	0,693	1,89	0,541	0,897	107	24,60	100	58	157	108	Branco
BURSERACEAE (1)																				
<i>Commiphora leptophloeos</i>	803	46,85	30,26	8,78	7,95	9,65	6,18	10,24	6,60	0,652	1,58	0,646	0,931	73	28,10	47	28	141	63	Branco
CACTACEAE (2)																				
<i>Cereus jamacaru</i>	979	3,95	7,57	2,38	2,30	2,72	1,84	2,86	1,94	0,863	1,48	0,663	0,922	69	23,53	58	20	133	64	Branco
<i>Xiquefique gounellei</i>	1178	2,14	5,47	1,73	1,68	1,87	1,45	2,03	1,51	0,894	1,30	0,779	0,908	81	25,46	70	30	140	78	Branco
CAPPARACEAE (1)																				
<i>Neocalyptrocalyx longifolium</i>	300	158,09	49,65	14,62	14,30	15,75	12,71	15,93	12,88	0,803	1,24	0,810	0,969	171	21,86	188	109	212	174	Preto
CELASTRACEAE (1)																				
<i>Monteverdia ilicifolia</i>	993	18,36	16,44	5,21	4,85	5,94	3,92	6,11	4,02	0,845	1,54	0,664	0,957	74	18,43	67	32	144	70	Branco
COMBRETACEAE (2)																				
<i>Terminalia glabrescens</i>	360	64,19	42,30	10,18	12,40	15,23	5,35	15,44	6,08	0,456	2,87	0,355	0,854	160	20,18	163	103	214	160	Preto
<i>Terminalia mameuco</i>	187	1352,73	186,95	30,11	64,36	67,51	25,38	67,30	26,08	0,507	2,67	0,378	0,959	96	19,36	95	27	171	96	Branco
EBENACEAE (1)																				

(Continuação)

<i>Diospyros inconstans</i>	489	97,42	39,67	12,96	10,75	14,34	8,62	14,56	8,64	0,776	1,67	0,602	0,970	65	14,34	59	25	142	61	Branco
ERICACEAE (1)																				
<i>Gaylussacia brasiliensis</i>	1732	2,83	6,39	2,03	1,91	2,23	1,61	2,38	1,70	0,866	1,40	0,722	0,910	123	17,67	116	83	162	120	Branco
ERYTHROXYLACEAE (1)																				
<i>Erythroxylum argentinum</i>	539	35,81	25,40	7,83	7,25	9,70	4,70	9,87	4,87	0,700	2,08	0,489	0,950	184	19,72	194	122	225	187	Preto
EUPHORBIACEAE (11)																				
<i>Alchornea glandulosa</i>	327	21,46	17,41	5,41	5,17	5,48	4,97	5,69	5,05	0,888	1,10	0,909	0,957	83	19,23	74	45	149	77	Branco
<i>Cnidoscolus quercifolius</i>	442	94,93	40,25	12,52	11,07	14,55	8,26	14,76	8,34	0,738	1,77	0,570	0,966	88	18,50	83	35	155	86	Branco
<i>Croton blanchetianus</i>	906	13,79	14,12	4,41	4,21	4,88	3,58	5,09	3,69	0,865	1,37	0,737	0,950	86	17,67	78	45	148	81	Branco
<i>Croton floribundus</i>	920	17,93	16,16	4,93	4,88	5,49	4,16	5,75	4,28	0,862	1,33	0,763	0,953	89	17,67	82	47	147	86	Branco
<i>Euphorbia heterophylla</i>	915	15,81	15,08	4,64	4,47	4,80	4,18	5,00	4,26	0,873	1,15	0,874	0,948	80	18,48	68	43	140	74	Branco
<i>Gymnanthes klotzschiana</i>	641	14,88	14,73	4,53	4,45	4,98	3,80	5,19	3,90	0,861	1,32	0,763	0,949	92	21,19	81	49	150	88	Branco
<i>Hevea brasiliensis</i>	302	409,41	77,42	20,79	24,34	25,05	20,69	25,14	20,38	0,855	1,21	0,827	0,985	74	15,57	70	22	141	72	Branco
<i>Jatropha curcas</i>	411	159,60	53,90	11,58	18,00	17,91	11,33	18,28	11,23	0,709	1,59	0,635	0,964	63	14,33	58	15	146	61	Branco
<i>Jatropha mollissima</i>	357	94,20	40,51	11,19	11,95	13,77	8,69	13,93	8,94	0,726	1,59	0,633	0,960	94	20,60	88	42	160	90	Branco
<i>Mabea fistulifera</i>	352	38,29	23,62	7,22	7,06	7,78	6,25	8,09	6,35	0,860	1,25	0,805	0,963	73	16,31	66	42	131	69	Branco
<i>Manihot carthagenensis</i>	423	71,14	33,04	10,09	9,61	11,25	8,03	11,55	8,17	0,820	1,41	0,716	0,969	77	19,33	70	26	150	74	Branco
FABACEAE (57)																				
<i>Abrus precatorius</i>	406	27,46	19,71	6,03	6,00	6,65	5,26	6,82	5,38	0,888	1,27	0,792	0,964	83	17,75	81	36	142	82	Branco
<i>Albizia niopoides</i>	335	15,63	14,75	4,55	4,45	4,73	4,18	4,97	4,27	0,897	1,13	0,885	0,956	81	16,56	75	41	143	78	Branco
<i>Amburana cearensis</i>	599	107,51	44,77	10,99	13,45	13,55	10,08	14,14	10,28	0,685	1,35	0,746	0,949	190	25,75	210	99	232	199	Preto
<i>Anadenanthera colubrina</i>	1236	97,68	37,65	11,60	11,18	12,78	9,72	12,79	9,63	0,863	1,32	0,764	0,976	61	16,58	55	11	139	58	Branco
<i>Ateleia glazioviana</i>	1115	29,04	21,04	6,41	6,31	7,41	4,98	7,41	5,08	0,823	1,49	0,673	0,947	61	17,15	53	20	133	56	Branco
<i>Bauhinia forficata</i>	679	65,60	30,81	9,34	9,29	10,11	8,23	10,40	8,29	0,864	1,23	0,818	0,969	53	15,54	47	8	129	50	Branco
<i>Calliandra brevipes</i>	315	37,03	25,28	7,26	8,09	9,92	4,75	10,04	4,79	0,729	2,10	0,485	0,958	70	16,32	64	29	139	66	Branco
<i>Calopogonium mucunoides</i>	1000	8,57	10,93	3,42	3,32	3,67	2,96	3,84	3,01	0,899	1,24	0,808	0,942	106	16,43	97	72	156	101	Branco
<i>Cassia ferruginea</i>	819	25,30	18,90	5,82	5,70	6,46	4,94	6,61	5,06	0,881	1,32	0,765	0,963	56	20,13	43	14	130	50	Branco
<i>Cassia grandis</i>	335	94,77	38,45	11,41	11,58	13,71	8,71	14,20	8,94	0,796	1,59	0,638	0,972	94	15,45	89	51	159	91	Branco
<i>Cassia leptophylla</i>	620	68,52	31,13	9,69	9,22	10,29	8,44	10,63	8,63	0,884	1,22	0,822	0,974	80	12,69	75	44	141	78	Branco
<i>Cenostigma microphyllum</i>	343	75,14	34,58	10,41	9,75	11,02	8,65	11,45	8,86	0,791	1,28	0,786	0,964	97	15,22	91	52	158	94	Branco
<i>Cenostigma pyramidale</i>	365	75,26	33,34	10,11	9,91	11,01	8,64	11,40	8,84	0,845	1,28	0,789	0,971	78	14,96	72	35	146	75	Branco

(Continuação)

<i>Clitoria fairchildiana</i>	321	115,75	40,77	12,31	12,17	12,90	11,23	13,31	11,27	0,860	1,15	0,872	0,972	51	14,18	45	8	129	48	Branco
<i>Daibergia brasiliensis</i>	307	51,53	30,53	9,58	8,79	11,93	5,48	11,67	5,79	0,693	2,18	0,461	0,920	67	15,80	60	22	137	64	Branco
<i>Daibergia ecatastaphyllum</i>	752	62,53	30,18	9,33	8,95	10,42	7,58	10,46	7,59	0,855	1,38	0,731	0,967	79	16,31	73	28	152	76	Branco
<i>Daibergia frutescens</i>	758	64,14	31,79	9,71	9,37	11,37	7,14	11,28	7,27	0,794	1,60	0,630	0,949	81	16,08	75	32	153	78	Branco
<i>Dimorphandra mollis</i>	304	55,10	31,18	9,56	9,35	12,45	5,63	12,41	5,63	0,711	2,22	0,454	0,963	71	13,55	68	29	140	69	Branco
<i>Enterolobium contortisiliquum</i>	230	125,96	44,51	13,51	12,71	14,93	10,70	15,52	10,85	0,804	1,41	0,717	0,971	65	15,23	61	29	149	62	Branco
<i>Enterolobium timbouva</i>	375	55,54	30,60	9,21	9,33	11,72	6,03	12,18	6,28	0,745	1,95	0,517	0,966	75	12,15	71	38	133	72	Branco
<i>Erythrina speciosa</i>	294	67,92	32,26	9,99	9,45	11,45	7,53	11,52	7,50	0,816	1,53	0,661	0,970	52	17,08	44	21	124	47	Branco
<i>Hymenaea altissima</i>	309	273,66	71,92	16,58	22,05	22,32	15,56	22,78	15,80	0,677	1,44	0,704	0,969	69	25,97	53	19	146	66	Branco
<i>Hymenaea courbaril</i>	252	356,79	81,48	19,34	24,53	24,76	18,29	25,37	18,47	0,706	1,43	0,744	0,972	66	24,42	49	23	144	62	Branco
<i>Inga lentiscifolia</i>	376	136,16	45,77	11,35	16,03	16,40	10,53	16,67	10,72	0,812	1,57	0,645	0,978	67	13,22	63	25	132	65	Branco
<i>Leptolobium dasycarpum</i>	460	26,21	19,50	6,02	5,78	6,48	5,14	6,81	5,31	0,864	1,27	0,796	0,959	84	16,76	79	39	154	80	Branco
<i>Leucochloron incuriale</i>	648	140,60	47,12	13,55	13,71	14,75	12,01	15,05	12,14	0,788	1,23	0,817	0,966	145	18,31	149	85	203	147	Preto
<i>Libidibia ferrea</i>	327	41,44	24,51	7,51	7,38	8,43	6,24	8,61	6,32	0,863	1,36	0,744	0,967	84	13,62	79	52	145	81	Branco
<i>Lonchocarpus cultratus</i>	311	63,47	32,18	9,67	9,70	12,09	6,67	11,81	6,62	0,768	1,82	0,556	0,959	77	16,00	71	32	151	74	Branco
<i>Machaerium acutifolium</i>	159	1511,17	199,63	30,78	78,66	76,63	25,08	79,64	27,84	0,481	3,06	0,328	0,881	78	16,20	73	9	175	76	Branco
<i>Machaerium stipitatum</i>	253	562,19	116,24	46,16	18,20	46,36	15,32	47,49	16,35	0,521	3,04	0,331	0,918	72	19,94	77	6	152	74	Branco
<i>Machaerium villosum</i>	259	327,70	88,46	15,09	33,78	35,50	11,70	35,24	12,01	0,527	3,05	0,331	0,919	73	14,93	73	19	151	72	Branco
<i>Mimosa bimucronata</i>	930	9,19	11,46	3,57	3,49	3,96	2,94	4,14	3,01	0,875	1,35	0,748	0,943	86	18,05	81	38	147	83	Branco
<i>Mimosa flocculosa</i>	949	6,94	9,92	3,09	3,02	3,38	2,61	3,54	2,69	0,881	1,33	0,777	0,938	68	21,32	56	26	132	62	Branco
<i>Mimosa ophthalmocentra</i>	496	10,35	12,19	3,83	3,66	4,17	3,15	4,46	3,27	0,872	1,33	0,758	0,947	81	17,19	75	39	144	77	Branco
<i>Mimosa pigra</i>	949	10,86	13,27	4,06	4,06	5,15	2,68	5,32	2,80	0,774	1,93	0,524	0,941	96	17,61	87	55	155	91	Branco
<i>Mimosa scabrella</i>	989	12,76	13,59	4,18	4,16	4,76	3,41	5,01	3,52	0,863	1,41	0,721	0,950	63	21,69	52	14	138	57	Branco
<i>Mimosa tenuiflora</i>	1095	8,08	10,62	3,32	3,22	3,64	2,80	3,82	2,89	0,892	1,31	0,771	0,945	70	19,94	61	21	136	65	Branco
<i>Mucuna pruriens</i>	457	128,32	44,42	13,54	12,96	15,47	10,49	15,48	10,58	0,813	1,48	0,680	0,968	54	20,04	41	19	132	50	Branco
<i>Myrcarpus frondosus</i>	303	458,37	126,37	16,49	51,12	53,61	10,82	55,24	11,50	0,363	5,02	0,204	0,940	171	22,24	182	92	226	175	Preto
<i>Ormosia arborea</i>	347	134,08	43,62	13,24	13,13	13,67	12,43	14,05	12,52	0,881	1,10	0,910	0,978	66	25,11	69	21	134	70	Branco
<i>Parapiptadenia rigida</i>	859	120,14	43,18	12,74	12,85	14,29	10,69	14,58	10,85	0,808	1,34	0,754	0,963	159	13,88	164	100	208	161	Preto
<i>Peltophorum dubium</i>	985	32,91	24,07	7,21	7,28	9,48	4,41	9,64	4,52	0,713	2,16	0,466	0,954	172	13,62	174	122	209	173	Preto
<i>Piptadenia gonoacantha</i>	712	60,70	29,52	9,07	8,84	9,96	7,74	10,12	7,80	0,871	1,29	0,781	0,971	66	15,20	62	16	140	64	Branco
<i>Ptyocarpa moniliformis</i>	1397	22,32	18,00	5,49	5,40	5,97	4,74	6,27	4,88	0,863	1,26	0,796	0,957	192	22,79	206	125	233	195	Preto

(Continuação)

<i>Platypodium elegans</i>	153	1493,87	202,71	33,07	74,69	73,79	25,58	77,63	27,53	0,471	2,92	0,346	0,930	87	18,57	88	16	171	87	Branco
<i>Poecilanthe parviflora</i>	605	133,93	43,89	13,27	13,13	14,00	12,03	14,40	12,10	0,862	1,17	0,858	0,976	69	14,22	66	24	146	67	Branco
<i>Pterocarpus rohrii</i>	101	1386,63	172,59	41,63	48,88	47,54	36,70	52,20	37,97	0,590	1,30	0,774	0,928	72	13,53	69	13	163	71	Branco
<i>Pterogyne nitens</i>	310	75,02	35,26	10,47	10,73	12,96	7,36	13,83	7,67	0,757	1,76	0,568	0,965	176	15,12	182	112	206	180	Preto
<i>Schizolobium parahyba</i>	495	237,00	60,26	16,13	20,19	21,51	14,01	22,19	14,39	0,819	1,54	0,652	0,982	67	12,14	63	22	139	65	Branco
<i>Senegalia bonariensis</i>	728	51,75	29,60	8,29	9,22	10,69	6,14	11,18	6,30	0,747	1,75	0,577	0,957	63	15,77	57	14	139	60	Branco
<i>Senna macranthera</i>	377	29,91	20,59	6,26	6,28	6,80	5,49	7,05	5,58	0,867	1,26	0,802	0,962	58	20,49	43	16	130	53	Branco
<i>Senna multijuga</i>	1005	12,94	17,35	5,23	5,33	7,54	2,19	7,51	2,30	0,542	3,50	0,294	0,913	93	17,87	86	51	150	89	Branco
<i>Senna pendula</i>	535	13,73	14,17	4,34	4,34	4,95	3,51	5,18	3,63	0,853	1,42	0,711	0,950	71	18,26	61	30	135	67	Branco
<i>Senna spectabilis</i>	758	16,92	15,72	4,81	4,76	5,31	4,04	5,66	4,21	0,856	1,32	0,763	0,953	77	17,09	70	36	142	72	Branco
<i>Sesbania punicea</i>	302	23,40	18,82	5,64	5,84	6,75	4,41	6,72	4,42	0,829	1,53	0,654	0,949	91	14,68	88	49	142	89	Branco
<i>Sesbania virgata</i>	534	23,94	18,85	5,72	5,76	6,56	4,63	6,65	4,67	0,844	1,42	0,707	0,952	104	12,59	100	74	149	102	Branco
<i>Stryphnodendron adstringens</i>	323	34,69	24,29	7,27	7,28	8,81	5,01	9,16	5,16	0,749	1,77	0,572	0,949	55	17,33	47	17	128	51	Branco
LAMIACEAE (2)																				
<i>Aegiphila integrifolia</i>	785	19,15	17,00	5,23	5,08	6,02	4,05	6,23	4,19	0,832	1,49	0,676	0,953	107	16,15	102	65	160	104	Branco
<i>Vitex megapotamica</i>	224	52,86	29,97	8,54	9,11	10,57	6,34	10,88	6,65	0,741	1,68	0,608	0,957	99	17,20	97	44	150	99	Branco
LAURACEAE (2)																				
<i>Cryptocarya aschersoniana</i>	176	212,81	56,89	16,66	16,69	16,99	15,83	17,91	15,94	0,823	1,07	0,933	0,972	174	17,79	184	110	214	176	Preto
<i>Nectandra lanceolata</i>	219	129,85	44,30	13,27	13,58	15,93	10,36	16,27	10,54	0,830	1,54	0,652	0,978	61	12,05	58	22	127	59	Branco
LYTHRACEAE (2)																				
<i>Lafoensia glyptocarpa</i>	417	139,97	48,23	12,16	15,98	16,70	10,59	17,02	10,93	0,748	1,61	0,637	0,960	161	19,77	166	97	215	163	Preto
<i>Lafoensia pacari</i>	670	144,47	53,63	15,98	14,62	20,15	9,13	19,71	9,20	0,633	2,25	0,456	0,951	137	17,56	138	86	197	137	Preto
MALPIGIACEAE (1)																				
<i>Lophanthera lactescens</i>	346	10,14	12,37	3,76	3,80	4,51	2,83	4,69	2,99	0,825	1,59	0,634	0,940	91	18,41	82	51	146	87	Branco
MALVACEAE (4)																				
<i>Ceiba speciosa</i>	316	41,81	24,39	7,45	7,35	7,96	6,64	8,18	6,73	0,876	1,20	0,837	0,966	59	14,71	52	21	129	55	Branco
<i>Guazuma ulmifolia</i>	1506	4,84	8,24	2,58	2,49	2,80	2,19	2,94	2,26	0,889	1,29	0,787	0,935	105	20,39	93	65	157	100	Branco
<i>Luehea divaricata</i>	1268	22,83	21,31	6,20	6,50	8,04	3,60	8,50	3,89	0,629	2,26	0,451	0,913	181	20,49	189	119	224	184	Preto
<i>Pachira glabra</i>	300	226,14	62,25	17,40	17,33	18,66	15,36	19,14	15,54	0,758	1,22	0,829	0,974	97	15,86	90	55	168	94	Branco
MELASTOMATACEAE (3)																				
<i>Miconia theezans</i>	3775	0,22	1,64	0,54	0,53	0,62	0,46	0,70	0,48	0,974	1,37	0,747	0,883	157	15,40	149	131	177	160	Branco

(Continuação)

<i>Pteroma raddianum</i>	3636	0,25	1,90	0,63	0,58	0,75	0,43	0,81	0,47	0,874	1,77	0,583	0,870	135	20,65	127	98	165	138	Branco
<i>Pteroma sellowianum</i>	5985	0,24	1,77	0,57	0,57	0,67	0,45	0,74	0,48	0,931	1,51	0,679	0,878	134	21,66	126	94	165	137	Branco
MELIACEAE (1)																				
<i>Cedrela fissilis</i>	467	176,71	65,75	20,42	17,83	25,62	8,75	27,32	9,73	0,518	2,94	0,344	0,933	92	17,51	89	33	162	90	Branco
MYRTACEAE (4)																				
<i>Campomanesia xanthocarpa</i>	702	30,40	22,67	6,49	6,51	7,43	5,16	7,62	5,28	0,741	1,44	0,700	0,951	89	16,97	82	48	160	86	Branco
<i>Psidium cattleianum</i>	1051	11,03	12,75	3,87	3,87	4,27	3,28	4,50	3,41	0,847	1,32	0,772	0,937	185	23,02	200	117	217	193	Preto
<i>Psidium guajava</i>	943	7,77	11,30	3,25	3,37	3,65	2,70	3,82	2,82	0,765	1,36	0,746	0,935	194	23,33	212	128	231	200	Preto
<i>Psidium myrtilodes</i>	292	29,23	21,29	6,30	6,36	6,79	5,46	7,18	5,66	0,810	1,25	0,808	0,946	200	25,90	218	119	236	206	Preto
PHYTOLACCACEAE (2)																				
<i>Gaileisia integrifolia</i>	440	244,75	80,24	20,86	23,79	31,07	9,92	31,55	11,10	0,474	3,18	0,319	0,898	162	17,56	169	87	218	165	Preto
<i>Phytolacca dioica</i>	897	8,77	11,46	3,50	3,40	3,66	3,04	3,91	3,15	0,838	1,21	0,831	0,926	116	19,41	104	74	161	114	Branco
PODOCARPACEAE (1)																				
<i>Podocarpus lambertii</i>	939	12,45	13,32	4,15	4,00	4,40	3,60	4,67	3,71	0,881	1,23	0,818	0,945	77	16,71	69	39	132	72	Branco
RHAMNACEAE (1)																				
<i>Sarcophallus joazeiro</i>	294	66,49	33,91	10,49	9,24	12,00	7,04	12,21	7,22	0,732	1,71	0,589	0,960	113	10,40	109	83	152	111	Branco
ROSACEAE (1)																				
<i>Prunus brasiliensis</i>	456	72,06	34,70	10,35	9,34	10,19	8,97	10,68	9,12	0,759	1,14	0,884	0,958	115	19,01	114	55	168	114	Branco
RUBIACEAE (1)																				
<i>Genipa americana</i>	316	52,26	28,85	8,78	8,34	9,47	6,97	9,90	7,21	0,781	1,38	0,741	0,955	90	14,31	86	52	140	88	Branco
RUTACEAE (4)																				
<i>Balfourodendron riedelianum</i>	376	286,42	94,23	15,07	30,00	27,51	13,18	30,56	14,17	0,418	2,17	0,483	0,898	161	24,22	159	78	234	160	Preto
<i>Dictyoloma vandellianum</i>	591	18,64	23,80	5,46	5,37	5,32	4,43	6,07	4,81	0,430	1,20	0,837	0,848	107	30,45	89	43	163	111	Branco
<i>Helietta apiculata</i>	264	72,60	40,74	11,02	11,71	14,04	6,52	14,95	7,14	0,549	2,17	0,486	0,892	183	17,60	189	117	227	186	Preto
<i>Zanthoxylum rhoifolium</i>	317	11,17	12,38	3,89	3,73	4,03	3,53	4,16	3,58	0,914	1,14	0,877	0,951	58	20,49	48	21	129	51	Branco
SAPINDACEAE (5)																				
<i>Allophylus edulis</i>	900	18,16	16,23	4,85	4,99	5,48	4,21	5,77	4,36	0,864	1,31	0,772	0,954	201	20,75	216	129	233	209	Preto
<i>Allophylus guaraniticus</i>	829	25,33	19,54	5,87	5,80	6,33	5,08	6,70	5,25	0,834	1,25	0,807	0,952	190	19,93	206	124	221	195	Preto
<i>Cupania vernalis</i>	306	104,23	40,32	12,28	11,83	14,10	9,41	14,49	9,60	0,806	1,50	0,669	0,973	56	23,62	36	19	151	50	Branco
<i>Matayba elaeagnoides</i>	616	54,72	28,90	8,66	8,56	9,55	7,39	9,91	7,55	0,847	1,40	0,794	0,967	52	19,10	40	21	126	47	Branco
<i>Sapindus saponaria</i>	523	105,49	38,53	11,76	11,48	11,93	11,13	12,18	11,22	0,884	1,07	0,934	0,977	52	19,12	40	24	127	47	Branco

(Conclusão)

SAPOTACEAE (1)																				
<i>Manilkara elata</i>	448	149,50	47,65	14,58	14,10	16,73	11,33	17,33	11,62	0,825	1,48	0,680	0,978	76	15,88	71	40	146	74	Branco
SOLANACEAE (4)																				
<i>Solanum granuloseprosum</i>	1527	3,54	7,02	2,21	2,13	2,34	1,92	2,48	1,99	0,899	1,22	0,825	0,924	134	15,82	124	105	174	131	Branco
<i>Solanum lycocarpum</i>	1001	6,01	9,20	2,87	2,80	3,08	2,47	3,24	2,56	0,888	1,25	0,804	0,933	104	15,94	96	67	152	100	Branco
<i>Solanum viarum</i>	947	4,30	7,64	2,38	2,35	2,55	2,14	2,70	2,20	0,924	1,19	0,842	0,934	101	20,44	92	57	156	97	Branco
<i>Vassobia breviflora</i>	211	55,83	28,17	8,43	8,50	8,71	8,12	8,95	8,20	0,880	1,07	0,934	0,969	192	17,83	202	128	227	196	Preto
STYRACACEAE (1)																				
<i>Styrax leprosus</i>	1533	0,79	3,42	1,04	1,05	1,13	0,87	1,25	0,92	0,836	1,32	0,774	0,887	131	19,24	122	94	166	130	Branco
URTICACEAE (5)																				
<i>Cecropia glaziovii</i>	955	2,63	6,45	1,99	2,02	2,58	1,30	2,65	1,38	0,791	2,03	0,505	0,908	91	22,78	83	46	146	87	Branco
<i>Cecropia hololeuca</i>	701	2,84	6,52	2,05	1,99	2,51	1,44	2,59	1,52	0,836	1,77	0,581	0,916	93	21,35	84	50	147	88	Branco
<i>Cecropia pachystachya</i>	742	2,57	6,35	1,97	1,95	2,46	1,32	2,56	1,41	0,795	1,87	0,542	0,922	92	20,82	85	44	147	88	Branco
<i>Cecropia peltata</i>	1460	1,28	4,31	1,35	1,36	1,69	0,95	1,78	1,02	0,848	1,82	0,566	0,895	99	23,60	87	55	148	96	Branco
<i>Cecropia sciadophylla</i>	592	1,96	5,45	1,70	1,67	2,08	1,20	2,16	1,27	0,825	1,76	0,581	0,920	86	23,29	78	36	146	81	Branco
WINTERACEAE (1)																				
<i>Dirmys brasiliensis</i>	873	4,72	8,77	2,73	2,65	3,24	1,86	3,35	2,01	0,770	1,78	0,583	0,896	70	23,80	59	19	134	65	Branco
TOTAL (155 espécies)																				

FONTE: O autor (2022).

Legenda: n (número de sementes amostradas) e StdDev (Desvio padrão)

A circularidade e a redondeza são medidas de formato que podem ser aplicadas em sementes, entretanto, não é possível mensurar manualmente. As sementes que apresentaram maiores índices de circularidade ($> 0,910$) foram *Miconia theaezans* (Bonpl.) Cogn., *Pleroma sellowianum* (Cham.) P.J.F.Guim. & Michelang., *Solanum viarum* Dunal e *Zanthoxylum rhoifolium* Lam., enquanto *Cochlospermum orinocense* (Kunth) Steud., *Handroanthus impetiginosus* (Mart. ex DC.) Mattos e *Handroanthus albus* (Cham.) Mattos apresentaram os menores índices ($< 0,290$). Para redondeza, sementes de *Vassobia breviflora* (Sendtn.) Hunz., *Sapindus saponaria* L. e *Cryptocarya aschersoniana* Mez apresentaram maiores índices ($> 0,930$), enquanto *Myrocarpus frondosus* Allemão, *Senna multijuga* (Rich.) H.S.Irwin & Barneby e *Handroanthus albus* (Cham.) Mattos apresentam menor redondeza ($< 0,300$) (TABELA 4). A espécie *Myrocarpus frondosus* Allemão se destaca por apresentar a maior proporção (cinco vezes) entre comprimento e largura da semente.

As características de formato em conjunto com o tamanho podem contribuir para diferenciar as espécies florestais devido às características próprias de cada semente, como: arredondadas, alongadas e elípticas. As características biométricas que mais contribuíram para a divergência entre procedências de *Mimosa scabrella* Benth. foram o comprimento e largura de sementes (MENEGATTI *et al.*, 2017, p. 366), uma vez que medidas de formato e coloração da semente não foram analisadas. Nesse sentido, o uso de processamento de imagens permite extrair mais informações das sementes e eliminaria a necessidade de mensuração de poucas características em estudos como este.

Ao padronizar a coloração em escala de cor de cinza (0-255) a partir do formato RGB (*red*, *green* e *blue*), é possível diferenciar as sementes em função das cores que compõem a imagem. Por exemplo, *Schinopsis brasiliensis* Engl., *Allophylus edulis* (A.St.-Hil. *et al.*) Hieron. ex Niederl., *Psidium myrtoides* O.Berg e *Handroanthus albus* (Cham.) Mattos apresentam sementes mais claras, enquanto *Clitoria fairchildiana* R.A.Howard, *Erythrina speciosa* Andrews, *Matayba elaeagnoides* Radlk. e *Sapindus saponaria* L. são sementes com coloração mais escuras (TABELA 4). Valores médios e medianos de cor, mínimos (Min) e máximos (Max) também auxiliam na determinação da coloração da semente devido à variabilidade de coloração que estas podem apresentar, assim como o quanto variável é a superfície da semente em função da coloração predominante (StdDev),

a exemplo de sementes com duas cores (*Abrus precatorius* L. e *Ormosia arborea* (Vell.) Harms) e textura (*Hevea brasiliensis* (Willd. ex A.Juss.) Müll.Arg.).

A metodologia proposta neste trabalho mostrou-se vantajosa devido ao maior número de características avaliadas, possíveis apenas a partir do processamento de imagens para a mensuração de tamanho, formato e coloração em relação as abordagens manuais com paquímetro digital ou régua. Além disso, a velocidade de execução do trabalho é otimizada e um número maior de sementes podem ser avaliadas em conjunto, substituindo a necessidade de mensuração manual. Em contrapartida, é necessário do avaliador conhecimento do uso de *software* de processamento de imagens para extração de dados das sementes, que com treinamento adequado não apresenta maiores dificuldades.

A aplicação do método proposto em sementes tem implicações importantes para a silvicultura, genética de populações, identificação botânica, classificação de sementes, e entendimento das estratégias ecológicas e fisiológicas das espécies. As características das sementes são determinadas geneticamente para cada espécie e afetadas pelo ambiente ou fenótipo, como destacam Fenner e Thompson (2005, p. 29) e Bewley *et al.* (2013, p. 6). Por isso, a mensuração de sementes é amplamente utilizada em estudos florestais (MELO *et al.*, 2018, p. 113; MENEGATTI; MANTOVANI; NAVROSKI, 2019, p. 3; SANTOS *et al.*, 2019, p. 958; SOARES; SANTOS; SILVA, 2019, p. 453, PATRÍCIO; TROVÃO, 2020, p. 3; SOUSA *et al.*, 2021, p. 162; BEZERRA *et al.*, 2022, p. 395).

A caracterização de sementes com base no tamanho pode ser usada para detectar variabilidade genética dentro e entre populações (PAULA; NOGUEIRA; BASTOS, 2015, p. 151; MENEGATTI *et al.*, 2017, p. 369; ROVERI-NETO; PAULA, 2017, p. 326; FAJARDO *et al.*, 2018, p. 6; BEZERRA *et al.*, 2022, p. 397), selecionar árvores para produção de sementes (CORREIA *et al.*, 2019, p. 752; GERBER *et al.*, 2021, p. 328), melhoramento genético (YADAV *et al.*, 2017, p. 1627) e testes de progênes (SILVA *et al.*, 2018, p. 920; LOVATEL *et al.*, 2021, p. 547), bem como estudos dos aspectos morfológicos de sementes (SOARES; SANTOS; SILVA, 2019, p. 453), e estratégias ecológicas de estabelecimento, dispersão e adaptação aos diferentes ambientes terrestres (PATRÍCIO; TROVÃO, 2020, p. 8; CONCEIÇÃO *et al.*, 2019, p. 327; DUARTE; GONZALEZ-RONDAN; ROCHA, 2019, p. 404), o que tradicionalmente demanda tempo do pesquisador para aferir um número limitado de características.

Estudos biométricos em sementes também são importantes para a caracterização de espécies florestais, como destacado em trabalhos com *Psidium rufum* Mart. ex DC. e *Annona crassiflora* Mart. que auxiliam em fornecer informações úteis e norteadoras para o reconhecimento da espécie, em laboratórios de sementes ou outros fins (SOARES *et al.*, 2017, p. 226; PIMENTA *et al.*, 2013, p. 530). Além disso, possibilita um melhor entendimento da funcionalidade ecológica das sementes nos ecossistemas, contribuindo assim para o desenvolvimento de programas de conservação e restauração florestal (COSMO *et al.*, 2017, p. 480). Uma vez que ainda existe carência desses estudos sobre sementes para espécies florestais nativas (PAULA; NOGUEIRA; ANGELO, 2016, p. 104).

Por isso, o maior número de sementes deve ser avaliado quando se deseja extrair informações importantes entre indivíduos ou populações florestais. Entretanto, como as metodologias usadas nos trabalhos citados anteriormente se limitam a mensuração de comprimento, largura e/ou espessura/diâmetro de uma semente por vez para poucas espécies, torna-se necessário uma maior demanda por tempo e aumenta as chances de erro, devido ao número de repetições necessárias entre uma semente e outra. Portanto, o uso de câmera fotográfica e mini estúdio para a captura de imagens, e o processamento das imagens em *software* de livre acesso se mostra uma solução para diferentes estudos futuros com espécies nativas.

O tamanho e formato da semente tem implicações diretas no processo de semeadura para germinação, classificação por peneiras e beneficiamento. As espécies florestais não possuem padronização quanto ao uso de equipamentos específicos para semeadura, beneficiamento ou classificação por peneiras como há para espécies agrícolas. Os resultados de tamanho e formato demonstram que é possível classificar as sementes por imagens de modo a abranger o maior número de espécies. Além disso, padronizar medidas de profundidade de semeadura em testes de emergência de plântulas ou produção de mudas para todas as espécies florestais não é adequado devido a diversidade de tamanhos e formatos de sementes.

Embora estudos sugiram que exista baixa correlação entre aspectos fisiológicos e biométricos de sementes florestais (ROVERI-NETO; PAULA, 2017, p. 326; MENEGATTI; MANTOVANI; NAVROSKI, 2019, p. 8), outros indicam que sementes formadas em locais diferentes no mesmo fruto podem apresentar variação

nos aspectos biométricos (SILVA *et al.*, 2021, p. 1032), devido a alocação diferenciada de biomassa nos frutos (SANTOS *et al.*, 2019, p. 964). Assim, o uso da metodologia sugerida também poderá ser empregado para avaliação de sementes nativas por tamanho/formato e separação por classes como demonstrado nas FIGURAS 16 e 17, possibilitando a classificação e composição de lotes homogêneos para a comercialização ou armazenamento.

Os dados biométricos também podem ser usados para estimar a produção de sementes no contexto econômico de uma determinada área ou conjunto de árvores, embora não haja um tamanho ideal da amostra para a caracterização biométrica (LIMA *et al.*, 2020, p. 1830). Por isso, em estudos florestais deve-se avaliar o máximo quantitativo de sementes possível. Para a morfologia de sementes, a subjetividade relacionada ao formato e coloração da semente poderia ser substituída valores atribuídos a circularidade, redondeza, proporção, solidez e cor. Por exemplo, a semente de *Casearia decandra* Jacq. é elipsóide com tegumento de cor creme (HALISKI *et al.*, 2013, p. 258) e *Albizia edwallii* (Hoehne) Barneby & J.W.Grimes possuem forma simplesmente elíptica e cor verde-acinzentada (DUARTE *et al.*, p. 168, 2015), enquanto sementes de *Richeria grandis* Vahl foram descritas visualmente como elipsóide com sarcotesta de coloração vermelho-alaranjada (MOURA *et al.*, 2020, p. 12), e sementes de *Simira gardneriana* M.R.V. Barbosa & Peixoto são oval-oblongas e irregularmente arredondadas (FELIX *et al.*, 2021b, p. 4), o que limita uma exploração quantitativa em novos estudos ou comparação entre espécies. Além disso, a coloração auxilia na identificação de sementes e diferenciação de espécies, entretanto, não deve ser considerada isoladamente.

A partir dos descritores de tamanho, formato e de coloração das sementes foi possível gerar um dendrograma para as espécies nativas (FIGURA 19). A distância Euclidiana agrupa todas as características avaliadas por espécie demonstrando a similaridade ou dissimilaridade entre espécies. Os descritores usados em conjunto permitiram diferenciar as espécies (coeficiente de correlação de 0,908), inclusive àquelas que estão contidas na mesma família botânica e gênero, a exemplo das espécies dos gêneros *Allophylus* (*A. edulis* e *A. guaraniticus*), *Annona* (*A. cacans*, *A. emarginata*, *A. mucosa* e *A. sylvatica*), *Aspidosperma* (*A. parvifolium*, *A. pyriforme* e *A. subincanum*), *Butia* (*B. capitata* e *B. eriospatha*), *Cassia* (*C. ferruginea*, *C. grandis* e *C. leptophylla*), *Cecropia* (*C. glaziovii*, *C. hololeuca*, *C.*

pachystachya, *C. peltata* e *C. sciadophylla*), *Cenostigma* (*C. microphyllum* e *C. pyramidale*), *Croton* (*C. blanchetianus* e *C. floribundus*), *Dalbergia* (*D. brasiliensis*, *D. ecastaphyllum* e *D. frutescens*), *Enterolobium* (*E. contortisiliquum* e *E. timbouva*), *Handroanthus* (*H. albus*, *H. chrysotrichus*, *H. heptaphyllus*, *H. impetiginosus* e *H. ochraceus*), *Hymenaea* (*H. altissima* e *H. courbaril*), *Jatropha* (*J. curcas* e *J. mollissima*), *Lafoensia* (*L. glyptocarpa* e *L. pacari*), *Machaerium* (*M. acutifolium*, *M. stipitatum* e *M. villosum*), *Mimosa* (*M. bimucronata*, *M. flocculosa*, *M. ophthalmocentra*, *M. pigra*, *M. scabrella* e *M. tenuiflora*), *Pleroma* (*P. raddianum* e *P. sellowianum*), *Psidium* (*P. cattleyanum*, *P. guajava* e *P. myrtoides*), *Senna* (*S. macranthera*, *S. multijuga*, *S. pendula* e *S. spectabilis*), *Sesbania* (*S. punicea* e *S. virgata*), *Solanum* (*S. granuloseprosum*, *S. lycocarpum* e *S. viarum*) e *Terminalia* (*T. glabrescens* e *T. mameluco*).

biométricas de sementes e frutos têm valor diagnóstico para diferenciar espécies florestais (PEREIRA; FERREIRA, 2017, p. 6; DUARTE; GONZALEZ-RONDAN; ROCHA, 2019, p. 404), com importante contribuição para identificação botânica de espécies, como citado por Barros *et al.* (2020, p. 878); da mesma forma em que foi demonstrado neste estudo para diferenciação de espécies do mesmo gênero e entre famílias botânicas. A proximidade das características evolutivas das sementes das espécies para alguns gêneros botânicos foi detectada pela metodologia proposta, a exemplo dos grupamentos dos gêneros citados anteriormente.

A análise de sementes por imagens proporciona maior contribuição que a mensuração tradicional - paquímetro digital - para a caracterização de espécies florestais nativas. Contudo, a abrangência deste trabalho deve ser ampliada em estudos futuros com sementes de novas espécies florestais visando abastecer um banco de dados robusto da flora brasileira. E, o emprego de ferramentas automatizadas de classificação por inteligência artificial com base em análise morfobiométrica de sementes é uma alternativa para identificar milhares de espécies florestais que compõem a biodiversidade de plantas nativas no Brasil, contribuindo em etapas da produção de sementes, identificação de espécies, comercialização e fiscalização ambiental.

O desenvolvimento contínuo de metodologias e aprimoramento das técnicas de processamento de imagens contribuirão para avanços ainda maiores nessa área de pesquisa. No entanto, é importante destacar que o processamento de imagens para a identificação de sementes requer uma série de considerações técnicas e metodológicas. A extração adequada de características relevantes e a escolha de algoritmos de classificação robustos são aspectos críticos a serem considerados. Além disso, é necessário ter acesso a um conjunto de dados representativo e de alta qualidade para treinar e validar os modelos utilizados.

A metodologia de análise de imagens em sementes apresentada também pode ser explorada no contexto das espécies exóticas, ampliando seu alcance e utilidade para a pesquisa florestal. A aplicação dessa abordagem em sementes de espécies não nativas pode contribuir para a identificação de invasoras e auxiliar na gestão de áreas de conservação, onde o controle dessas espécies é fundamental para a preservação da biodiversidade local. Além disso, a definição de novas metodologias em testes de pureza em sementes de eucalipto pode ser explorada em estudos futuros.

Neste capítulo, apresentou-se uma metodologia para aquisição, processamento e análise de imagens, a qual se revela fundamental para a caracterização de sementes florestais e extração de informações morfobiométricas de sementes. Essa abordagem demonstra a contribuição do processamento de imagens de sementes para estudos na área florestal. No entanto, é importante ressaltar que ferramentas estatísticas possuem limitações quando aplicadas a conjuntos extensos de informações e dados, não sendo suficientemente capazes de prever ou reconhecer padrões nas sementes em sua totalidade. Por isso, no próximo capítulo, o objetivo é verificar a efetividade da identificação de espécies nativas por meio da aplicação de técnicas de classificação baseados em aprendizado de máquina, utilizando as características de tamanho, formato e coloração das sementes obtidas através da metodologia proposta.

4.4 CONCLUSÕES

A metodologia proposta para análise de imagens em sementes se mostra uma ferramenta importante para a caracterização e diferenciação de espécies florestais nativas do Brasil. A análise biométrica em sementes por meio do processamento de imagens pode ser empregada em estudos silviculturais, genéticos e ecológicos. Além disso, o método promove ganhos econômicos, pois otimiza o tempo de avaliação das sementes pelo analista.

REFERÊNCIAS

- ARAÚJO, J. K. P.; ARAÚJO, J. S. O.; SANTOS, D. F.; PACHECO, M. V.; ARAUJO, P. C. D. Semiferous propagation of *Cordia oncocalyx* (Allemão) Baill. and biometric characterization of diaspores and seeds. **Revista Caatinga**, v. 35, n. 1, p. 160 – 169, 2022. <https://doi.org/10.1590/1983-21252022v35n116rc>
- AREFI, A.; MOTLAGH, A. M.; KHOSHROO, A. Recognition of weed seed species by image processing. **Journal of Food Agriculture and Environment**, v. 9, n. 1, p. 379-383, 2011.
- BAGHERI, A.; EGHBALI, L.; SADRABADI-HAGHIGHI, R. Seed classification of three species of amaranth (*Amaranthus* spp.) using artificial neural network and canonical discriminant analysis. **The Journal of Agricultural Science**, v. 157, n. 4, p. 333-341, 2019. <https://doi.org/10.1017/S0021859619000649>
- BAO, F.; BAMBIL, D.; Applicability of computer vision in seed identification: deep learning, random forest, and support vector machine classification algorithms. **Acta Botânica Brasílica**, v. 35, n. 1, p. 17-21, 2021. <https://doi.org/10.1590/0102-33062020abb0361>
- BARROS, H. S. D.; CRUZ, E. D.; PEREIRA, A. G.; SILVA, E. A. A. Fruit and seed morfometry, seed germination and seedling vigor of *Parkia gigantocarpa*. **Floresta**, v. 50, n. 1, p. 877–886, 2020. <http://dx.doi.org/10.5380/uf.v50i1.56855>
- BEWLEY, J. D.; BRADFORD, K. J.; HILHORST, H. W. M.; NONOGAKI, H. **Seeds - physiology of development, germination and dormancy**, 3rd Edition. Springer: New York, 2013. 392 p.
- BEZERRA, A. C.; ZUZA, J. F. C.; SILVA BARBORA, L.; AZEVEDO, C. F.; ALVES, E. U. Biometrics of mulungu seeds from different mother plants in the semi-arid region of Paraíba, Brazil. **Revista Caatinga**, v. 35, n. 2, p. 393 – 401, 2022. <https://doi.org/10.1590/1983-21252022v35n215rc>
- BIANCO, M.; GRILLO, O.; ESCOBAR GARCIA, P.; MASCIA, F.; VENORA, G.; BACCHETTA, G. Morpho-colorimetric characterisation of *Malva* alliance taxa by seed image analysis. **Plant Biology**, v. 19, n. 1, p. 90-98, 2017. <https://doi.org/10.1111/plb.12481>
- CECCO, V. D.; MUSCIANO, M. D.; D'ARCHIVIO, A. A.; FRATTAROLI, A. R.; MARTINO, L. D. Analysis of intraspecific seed diversity in *Astragalus aquilanus* (Fabaceae), an endemic species of Central Apennine. **Plant Biology**, v. 21, n. 1, p. 507–514, 2019. <https://doi.org/10.1111/plb.12844>
- CONCEIÇÃO, T. A.; MENDONÇA, A. V. R.; SOUZA, M. O.; SOUZA, J. S.; MOREIRA, R. F. C. Seed collection environment: effects of forest cover reduction on biometrics and seed lot quality of *Bowdichia virgilioides* Kunth. **Científica**, v. 47, n. 3, p. 327–336, 2019. <https://doi.org/10.15361/1984-5529.2019v47n3p327-336>

CORREIA, L. A. S.; FELIX, F. C.; ARAUJO, F. D. S.; FERRARI, C. D. S.; PACHECO, M. V. Morphometric descriptors and physiological seed quality for selecting *Aspidosperma pyriformis* Mart. matrix trees. **Revista Caatinga**, v. 32, n. 3, p. 751-759, 2019. <https://doi.org/10.1590/1983-21252019v32n319rc>

COSMO, N. L.; GOGOSZ, A. M.; REGO, S. S.; NOGUEIRA, A. C.; KUNIYOSHI, Y. S. Morphology of fruit, seed and seedling and seed germination of *Myrceugenia euosma* (O. Berg) D. Legrand (Myrtaceae). **Floresta**, v. 47, n. 4, p. 479 - 488, 2017. <https://doi.org/10.5380/rf.v47i4.46933>

DUARTE, E. R.; GONZALEZ-RONDAN, B.; ROCHA, S. P. Physical analysis and seed germination of *Austrochthamalia teyucuaensis* H. A. Keller, endemic of the Atlantic Forest and in danger of extinction. **Agrociencia**, v. 53, n. 3, p. 403–416, 2019.

DUARTE, M. M.; MILANI, J. E. F.; BLUM, C. T.; NOGUEIRA, A. C. Germination and morphological of seed and seedling of *Albizia edwallii* (Hoehne) Barneby & J. W. Grimes. **Revista Caatinga**, v. 28, n. 3, p. 166-173, 2015.

FAJARDO, C. G.; SILVA, R. A. R.; CHAGAS, K. P. T.; VIEIRA, F. A. Genetic and phenotypic association of the carnauba palm tree evaluated by Inter-Simple Sequence Repeat and biometric traits. **Genetics and Molecular Research**, v. 17, n. 3, p. 1-9, 2018. <http://dx.doi.org/10.4238/gmr18018>

FARRIS, E.; ORRÙ, M.; UCCHESU, M.; AMADORI, A.; PORCEDDU, M.; BACCHETTA, G. Morpho-colorimetric characterization of the Sardinian endemic taxa of the genus *Anchusa* L. by seed image analysis. **Plants**, v. 9, n. 10, p. 1-13, 2020. <https://doi.org/10.3390/plants9101321>

FELIX, F. C.; MEDEIROS, J. A. D.; FERRARI, C. S.; VIEIRA, F. A.; PACHECO, M. V. Biometry of *Pityrocarpa moniliformis* seeds using digital imaging: implications for studies of genetic divergence. **Brazilian Journal of Agricultural Sciences**, v. 15, n. 1, p. 1-8, 2020. <https://doi.org/10.5039/agraria.v15i1a6128>

FELIX, F. C.; MOCELIM, F. L.; TORRES, S. B.; KRATZ, D.; RIBEIRO, R.; NOGUEIRA, A. C. Thousand-seed weight determination in forest species by image analysis. **Journal of Seed Science**, v. 43, e202143040, p. 1-9, 2021a. <https://doi.org/10.1590/2317-1545v43254684>

FELIX, F. C.; OLIVEIRA, F. N.; FREITAS, N. W. N.; FREITAS, R. M. O.; JILANI, I. B. H.; TORRES, S. B. Seed characterization and germination morpho-physiology of *Simira gardneriana* (Rubiaceae). **Journal of Seed Science**, v. 43, e202143025, p. 1-11, 2021b. <https://doi.org/10.1590/2317-1545v43250771>

FENNER, M.; THOMPSON, K. **The ecology of seeds**. Cambridge University Press: New York, 2005. 250 p.

FERNANDES, R. M.; ABREU, C. A. A.; SILVA, B. C. F. L.; OLIVEIRA, A. K. M. Germination, vigor and seed biometrics of *Licania kunthiana* Hook.f. **Floresta**, v. 51, n. 3, p. 677–685, 2021. <http://dx.doi.org/10.5380/rf.v51i3.72315>

FERREIRA, T.; RASBAND, W. **ImageJ**: user guide (IJ 1.46r), 2012. 198 p.
<https://imagej.nih.gov/ij/docs/guide/user-guide.pdf>

GERBER, D.; BRUN, E. J.; TOPANOTTI, L. R.; FERREIRA, J. J.; PORRUA, D. A.; GORENSTEIN, M. R.; WAGNER JÚNIOR, A. Genetic variability of *Araucaria angustifolia* Bertol. initial growth: subsidy to the formation of seed orchards. **Ciência Florestal**, v. 31, n. 1, p. 310-332, 2021. <https://doi.org/10.5902/1980509841712>

GONZALÉZ-CORTÉS, A.; GODINA, F. R.; REYES-VALDÉS, M. H.; TORRES, V. R.; RODRÍGUEZ, M. A. P.; QUINTANILLA, J. A. V.; BENÍTEZ, A. L. Morfología de semillas de siete especies del género *Opuntia* (Cactaceae) del sureste de Coahuila (México). **Boletín de la Sociedad Argentina de Botánica**, v. 54, n. 4, p. 493-507, 2019. <https://doi.org/10.31055/1851.2372.v54.n4.23572>

HALISKI, S.; COSMO, N. L.; GOGOSZ, A. M.; REGO, S. S.; NOGUEIRA, A. C.; KUNIYOSHI, Y. S. Morphological characterization and germination of seeds of *Casearia decandra*. **Pesquisa Florestal Brasileira**, v. 33, n. 75, p. 253-259, 2013. <https://doi.org/10.4336/2013.pfb.33.75.451>

HAMMER, O.; HARPER, A.T.D. **Paleontological data analysis**. Malden: Blackwell Publishing, 2008. 368 p. <https://doi.org/10.1002/9780470750711>

JOSHI, D.; BUTOLA, A.; KANADE, S. R.; PRASAD, D. K.; MITHRA, A.; SINGH, N. K.; BISHT, D. S.; MEHTA, D. S. Label-free non-invasive classification of rice seeds using optical coherence tomography assisted with deep neural network. **Optics and Laser Technology**, v.137, e106861, p. 1-7, 2021. <https://doi.org/10.1016/j.optlastec.2020.106861>

LIMA, T. M.; AMARAL, E. S.; GAIOTTO, F. A.; ANJOS, L.; DALMOLIN, A. C.; SANTOS, A. S.; MIELKE, M. S. Fruit and seed biometry of *Carpotroche brasiliensis* (RB) A. Gray (Achariaceae), a tropical tree with great potential to provide natural forest products. **Australian Journal of Crop Science**, v. 14, n. 11, p. 1826–1833, 2020. <https://doi.org/10.21475/ajcs.20.14.11.p2596>

LOVATEL, Q. C.; NAVROSKI, M. C.; GERBER, T. R.; OLIVEIRA, L. M.; PEREIRA, M. O.; SILVEIRA, M. F. Genetic variability in juvenile characters of progenies of *Apuleia leiocarpa*. **Floresta**, v. 51, n. 3, p. 547-556, 2021. <http://dx.doi.org/10.5380/rf.v51i3.69454>

MARTÍN-GÓMEZ, J. J.; GUTIÉRREZ DEL POZO, D.; UCCHESU, M.; BACCHETTA, G.; CABELLO SÁENZ DE SANTAMARÍA, F.; TOCINO, Á.; CERVANTES, E. Seed morphology in the Vitaceae based on geometric models. **Agronomy**, v. 10, n. 739, p. 1-16, 2020. <https://doi.org/10.3390/agronomy10050739>

MAZUR, M.; MARCYSIAK, K.; DUNAJSKA, A.; GAWLAK, M.; KAŁUSK, T. Taxonomic significance of seed morphology in *Veronica* L. (Plantaginaceae) species from central Europe. **Plants**, v. 11, n. 88, p. 1-17, 2022. <https://doi.org/10.3390/plants11010088>

- MEDEIROS, A. D.; ZAVALA-LEÓN, M. J.; ARAÚJO, J. O.; PEREIRA, M. D.; DIAS, D. C. F. S.; SILVA, L. J. Relationship between internal morphology and physiological quality of *Leucaena leucocephala* seeds using image analysis. **Revista Árvore**, v. 43, n. 2, p. 1-9, 2019. <https://doi.org/10.1590/1806-90882019000200008>
- MELO, L. D. F. A.; MELO JUNIOR, J. L. A.; FERREIRA, V. M. F.; ARAÚJO NETO, J. C.; NEVES, M. I. R. S. Biometric characterization and seed germination of giant mimosa (*Mimosa bimucronata* (DC) O. Kuntze). **Australian Journal of Crop Science**, v. 12, n. 1, p. 108-115, 2018. <http://dx.doi.org/10.21475/ajcs.18.12.01.pne773>
- MENEGATTI, R. D.; MANTOVANI, A.; NAVROSKI, M.; SOUZA, A. G. Genetic divergence among provenances of *Mimosa scabrella* Benth. based on seed analysis. **Revista Brasileira de Ciências Agrárias**, v. 12, n. 3, p. 366-371, 2017. <http://dx.doi.org/10.5039/agraria.v12i3a5449>
- MENEGATTI, R. D.; MANTOVANI, A.; NAVROSKI, M. Biometric and physiological quality of bracatinga seeds from different mother trees. **Floresta e Ambiente**, v. 26, n. 1, p. 1-10, 2019. <http://dx.doi.org/10.1590/2179-8087.035916>
- MOREIRA, P. A.; NEVES, F. S.; LOBO, J. A. Consequences of tropical dry forest conversion on diaspore fate of *Enterolobium contortisiliquum* (Fabaceae). **Plant Ecology**, v. 222, n. 4, p. 525–535, 2021. <https://doi.org/10.1007/s11258-021-01124-6>
- MOURA, C. C.; COSTA, T. R.; CARVALHO, L. R.; TITON, M.; PEREIRA, I. M.; MACHADO, E. L. M. Morpho-physiological classification of seeds and morphology of fruits and seedlings of *Richeria grandis*. **Rodriguésia**, v. 71, e02732018, p. 1-15, 2020. <https://doi.org/10.1590/2175-7860202071098>
- NAZARI, L.; SHAKER, M.; KARIMI, A.; ROPELEWSKA, W. Identification of sorghum genotypes using a machine vision system. **Journal of food process engineering**, v. 44, e13673, p. 1-11, 2021. <https://doi.org/10.1111/jfpe.13673>
- PAN, X.; CEN, Y.; MA, Y.; YAN, W.; GAO, X.; LIU, X.; LIU, G. Identification of gramineous grass seeds using Gabor and locality preserving projections. **Multimed Tools Appl**, v. 75, n. 1, p. 16551–16576, 2016. <https://doi.org.ez22.periodicos.capes.gov.br/10.1007/s11042-016-3424-0>
- PATRÍCIO, M. C.; TROVÃO, D. M. B. M. Seed biometry: another functional trait in Caatinga. **Acta Scientiarum. Biological Sciences**, v. 42, e51183, p. 1-11, 2020. <https://doi.org/10.4025/actascibiols.v42i1.51183>
- PAULA, S. R. P.; NOGUEIRA, A. C.; BASTOS, M. C. O. Physiological quality and repeatability in biometric characters of seeds from different trees of *Aspidosperma polyneuron* Müll.Arg. **Australian Journal of Basic and Applied Sciences**, v. 9, n. 31, p. 147-154, 2015.
- PAULA, S. R. P.; NOGUEIRA, A. C.; ANGELO, A. C. Morphological characterization of fruit, seed, germination stages and seedling of *Ocotea paranaensis*. **Revista de**

Ciências Agroveterinárias, v. 15, n. 2, p. 103-108, 2016.

<https://doi.org/10.5965/223811711522016103>

PEREIRA, S. A.; FERREIRA, S. A. N. Fruit and seed biometry and seedling morphology of *Parkia discolor* (Spruce ex Benth.). **Revista Árvore**, v. 41, e410206, p. 1-8, 2017. <http://dx.doi.org/10.1590/1806-90882017000200006>

PIMENTA, A. C.; REGO, S. S.; RIBAS, K. C. Z.; NOGUEIRA, A. C.; KOEHLER, H. S. Morphological characterization of fruits, seeds and seedlings of araticum plant (*Annona crassiflora* Mart – Annonaceae). **Journal of Seed Science**, v. 35, n. 4, p. 524-531, 2013.

POLLI, A.; ROMAGNOLO, M. B.; DE SOUZA, L. A.; PASTORINI, L. H. Influence of the functional traits of seeds on germination dynamics and morphofunctional pattern of the seedlings. **Acta Scientiarum - Biological Sciences**, v. 42, n. 1, p. 1–9, 2020. <https://doi.org/10.4025/actascibiols.v42i1.52154>

REFLORA. **Flora do Brasil 2020**. Jardim Botânico do Rio de Janeiro. Disponível em: < <http://floradobrasil.jbrj.gov.br/> >. Acesso em: 04 mai. 2022

ROSA, T. L. M.; ARAUJO, C. P.; KAMKE, C.; FERREIRA, A.; FERREIRA, M. F. S.; OLIVEIRA, J. B.; SCHMILDT, E. R.; LOPES, J. C.; MENGARDA, L. H. G.; OTONI, W. C.; SANTOS, A. R.; ALEXANDRE, R. S. Sapucaia nut: morphophysiology, minerals content, methodological validation in image analysis, phenotypic and molecular diversity in *Lecythis pisonis* Cambess. **Food Research International**, v. 137, e109383, p. 1-9, 2020. <https://doi.org/10.1016/j.foodres.2020.109383>

ROVERI-NETO, A.; PAULA, R. C. Variability among mother trees of *Ceiba speciosa* St. Hil for characteristics of the fruits and seeds. **Revista Ciência Agronômica**, v. 48, n. 2, p. 318-327, 2017. <https://doi.org/10.5935/1806-6690.20170037>

SALVADOR, H. F.; MAZZOTTINI-DOS-SANTOS, H. C.; DIAS, D. S.; AZEVEDO, A. M.; LOPES, P. S. N.; NUNES, Y. R. F.; RIBEIRO, L. M. The dynamics of *Mauritia flexuosa* (Arecaceae) recalcitrant seed banks reveal control of their persistence in marsh environments. **Forest Ecology and Management**, v. 511, e120155, p. 1-14, 2022. <https://doi.org/10.1016/j.foreco.2022.120155>

SANTOS, J. C. C.; SILVA, D. M. R.; COSTA, R. N.; SANTOS, S. A.; SILVA, L. K. S.; SILVA, J. V. Biometry of fruits and seeds and pre-germination treatments of *Hymenaea courbaril* seeds. **Revista em Agronegócio e Meio Ambiente**, v. 12, n. 3, p. 957–979, 2019. <https://doi.org/10.17765/2176-9168.2019v12n3p957-979>

SILVA, O. L. M.; CORDEIRO, I.; CARUZO, M. B. R. Seed morphology in *Euphorbia* and its taxonomic applications: a case study in São Paulo, Brazil. **Brazilian Journal of Botany**, v. 39, n. 1, p. 349-358, 2016. <https://doi.org/10.1007/s40415-015-0228-9>

SILVA, L. G. C.; MOREIRA, J. F. L.; HOLANDA, H. B. B.; ROCHA, E. L. B.; DIAS, P. C. Evaluation of carnauba progenies and estimates of genetic parameters in the juvenile phase. **Revista Caatinga**, v. 31, n. 4, p. 917–925, 2018. <https://doi.org/10.1590/1983-21252018v31n414rc>

SILVA, J. A.; MEDEIROS, A. D.; PEREIRA, M. D.; RAMOS, A. K. F.; SILVA, L. J. Seed quality analysis of *Senna siamea* Lam. using image analysis techniques. **Journal of Seed Science**, v. 42, e202042042, p. 1-10, 2020. <https://doi.org/10.1590/2317-1545v42241633>

SILVA, P. K. B.; FELIX, F. C.; MEDEIROS, J. A. D.; ARAÚJO, F. S.; FERRARI, C. S.; PACHECO, M. V. Do seeds of *Anadenanthera macrocarpa* and *Pityrocarpa moniliformis* formed in different locations of the fruit have similar physiological quality? **Floresta**, v. 51, n. 4, p. 1029–1036, 2021. <http://dx.doi.org/10.5380/ufv.v51i4.75880>

SOARES, I. D.; NOGUEIRA, A. C.; GRABIAS, J.; KUNIYOSHI, Y. S. Morphological characterization of fruits, seeds and stages of germination of *Psidium rufum* DC. (Myrtaceae). **Iheringia**, v. 72, n. 2, p. 221-227, 2017. <https://doi.org/10.21826/2446-8231201772208>

SOARES, R. N.; SANTOS, R. O.; SILVA, B. M. S. E. Morphological aspects and anatomy of the fruit, seeds and seedlings of *Pentaclethra macroloba* (willd.) Kuntze (Fabaceae). **Journal of Seed Science**, v. 41, n. 4, p. 452–460, 2019. <https://doi.org/10.1590/2317-1545v41n4222721>

SOUSA, P. S.; SILVA, J. A.; MOURA, E. G.; NARDIS, B. O.; SILVA, R. F.; GIL, R. L.; ANDRADE, F. R. Morphological characteristics and methods for breaking seed dormancy in *Enterolobium contorsiliquum* specimens from the Amazonian biome. **Journal of Tropical Forest Science**, v. 33, n. 2, p. 160–172, 2021. <https://doi.org/10.26525/jtfs2021.33.2.160>

URBANETZ, C.; TAMASHIRO, J. Y.; KINOSHIRA, L. S. Identification key for woody species of an Atlantic Rain Forest remnant, in the Southeast of Brazil, based on vegetative characters. **Biota Neotropical**, v. 10, n. 2, p. 349-398, 2010. <https://doi.org/10.1590/S1676-06032010000200036>

YADAV, V.; SINGH, A. K.; SINGH, S.; RAO, V. V. A. Variability in custard apple (*Annona squamosa*) genotypes for quality characters from Gujarat. **Indian Council of Agricultural Research**, v. 87, n. 12, p. 1627-1632, 2017.

YU, Z.; FANG, H.; ZHANGJIN, Q.; MI, C.; FENG, X.; HE, Y. Hyperspectral imaging technology combined with deep learning for hybrid okra seed identification. **Biosystems Engineering**, v. 212, n. 1, p. 46-61, 2021. <https://doi.org/10.1016/j.biosystemseng.2021.09.010>

WANG, L. G.; WANG, L. F. Variety identification model for maize seeds using hyperspectral pixel-level information combined with convolutional neural network. **National Remote Sensing Bulletin**, v. 25, n. 11, p. 2234-2244, 2021. <https://doi.org/10.11834/jrs.20219349>

ZHANG, J.; FENG, X.; LIU, X.; HE, Y. Identification of hybrid okra seeds based on near-infrared hyperspectral imaging technology. **Applied Sciences**, v. 8, e1793, p. 1-13, 2018. <https://doi.org/10.3390/app8101793>

ZUFFO, A. M. A.; STEINER, F.; ALVES, C. Z.; ALCÂNTARA-NETO, F.; SANTOS, M. D. A.; OLIVEIRA, A. M.; SOUSA, T. O.; FONSECA, W. L. Biometric characteristics of fruits, seeds and plants of *Hancornia speciosa* Gomes. (Apocynaceae). **Australian Journal of Crop Science**, v. 13, n. 1, p. 622-627, 2019.
<https://doi.org/10.21475/ajcs.19.13.04.p1651>

CAPÍTULO 3: APLICAÇÃO DE APRENDIZAGEM DE MÁQUINA PARA IDENTIFICAR ESPÉCIES NATIVAS A PARTIR DA ANÁLISE DE SEMENTES POR IMAGENS

RESUMO

A identificação de espécies florestais nativas a partir de sementes é uma atividade complexa devido a elevada biodiversidade e características variadas das sementes. Nesse sentido, o uso de análise de imagens e aprendizado de máquina pode ser uma alternativa para identificar sementes. Assim, objetivou-se com este capítulo aplicar diferentes classificadores de aprendizado de máquina associado à análise de imagens para identificação de espécies florestais a partir de características morfobiométricas de sementes. Foram analisadas um total de 155 espécies nativas pertencentes a 42 famílias botânicas. Para determinar o classificador de aprendizado de máquina mais adequado, cinco técnicas de classificação por aprendizado supervisionado foram implementadas: árvores de decisão (DT), redes neurais artificiais (ANN), k-vizinhos mais próximos (k-NN), classificador Naive-Bayes (NBC) e máquina de vetores de suporte (SVM); os quais tiveram seu desempenho avaliados. Para modelagem, 66% dos dados morfobiométricos das sementes foram usados para o treinamento dos classificadores, enquanto 34% foram reservados para validação. Os classificadores testados mostraram-se promissores para a identificação das espécies a partir do processamento de imagens de sementes, sendo o classificador por árvores de decisão o que apresentou maior precisão para identificação correta das espécies (78,26%), seguido dos classificadores ANN (76,58%), k-NN (76,28%), NBC (75,27%) e SVM (70,27%). Portanto, é possível realizar a identificação de espécies nativas a partir de imagens de sementes e aprendizado de máquina com taxa satisfatória de acurácia, recomendando-se o classificador por árvores de decisão. Esses resultados contribuem para futura automação, elaboração de aplicativos ou ferramentas de captura e processamento de imagens para a identificação de espécies nativas.

Palavras-chave: inteligência artificial; sementes florestais; processamento de imagens.

ABSTRACT

The identification of native forest species based on seeds is a complex task due to the high biodiversity and varied characteristics of seeds. In this regard, the use of image analysis and machine learning can be an alternative for seed recognition. Thus, the objective of this chapter was to apply different machine learning classifiers associated with image analysis for the identification of forest species based on morphobiometric seed characteristics. A total of 155 native species belonging to 42 botanical families were analyzed. To determine the most suitable machine learning classifier, five supervised classification techniques were implemented: decision trees (DT), artificial neural networks (ANN), k-nearest neighbors (k-NN), Naive-Bayes classifier (NBC), and support vector machine (SVM); their performance was evaluated. For modeling, 66% of the morpho-biometric seeds data were used for training the classifiers, while 34% were reserved for validation. The tested classifiers showed promise for species identification based on seed image processing, with the decision tree classifier demonstrating the highest accuracy in correctly identifying species (78.26%), followed by ANN (76.58%), k-NN (76.28%), NBC (75.27%), and SVM (70.27%). Therefore, it is possible to achieve satisfactory species identification of native species using seed images and machine learning, with the decision tree classifier being recommended. These results contribute to automation, development of applications, or tools for seed image capture and processing for species identification.

Keywords: artificial intelligence; forest seeds; image processing.

5.1 INTRODUÇÃO

A identificação de sementes representa um desafio mundial para pesquisadores por diferentes razões (BAO; BAMBIL, 2021, p. 17), sobretudo para as espécies nativas. No Brasil, por exemplo, tem-se reconhecidas 35.653 plantas com sementes, sendo 8.320 destas arbóreas distribuídas em 138 famílias e 938 gêneros botânicos (REFLORA, 2020). Geralmente, a identificação e diferenciação das espécies florestais é realizada por meio de descritores botânicos e morfológicos com base em estruturas vegetativas e reprodutivas das plantas (URBANETZ; TAMASHIRO; KINOSHITA, 2010, p. 350), como folhas, flores, frutos e sementes. Contudo, identificar ou diferenciar centenas ou milhares de espécies a partir de sementes é uma tarefa praticamente impossível para o profissional florestal.

Observou-se nos últimos anos um avanço na identificação de espécies a partir de imagens de sementes e frutos (FARRIS *et al.*, 2020, p. 2). Entretanto, o uso de análise de imagens digitais para a diferenciação de sementes nativas é um

método pouco explorado e não validado devido à ausência de conjunto de dados. No setor florestal, inteligência artificial e tecnologias associadas tem expressivo potencial por permitir um rápido e maior processamento de dados. Por exemplo, empregando aprendizado de máquina que tem a capacidade de identificar padrões e correlações complexas em diferentes níveis de detalhamentos.

Técnicas de aprendizado de máquina a partir de imagens de sementes são explorados com sucesso em espécies agrícolas. Por exemplo, a utilização de scanner de alta resolução para extração de características de textura em sementes de tomate e redes neurais artificiais para classificação de cultivares (ROPELEWSKA; PIECKO, 2022, p. 686), ou classificação de variedades de sementes de cevada a partir de características de forma, cor e textura capturadas por imagem (SHI *et al.*, 2022, p. 215), bem como uso de imagens hiperespectrais e aprendizado de máquina para detecção de variedades de sementes de soja (TAN *et al.*, 2019, p. 1013; ZHU *et al.*, 2019, p. 12; ZHU *et al.*, 2020, p. 6) e de sementes de milho (BAO *et al.*, 2019, p. 13). Entretanto, ainda faltam estudos com espécies nativas do Brasil com estas abordagens tecnológicas ou mesmo apresentando alternativas acessíveis de equipamentos e recursos computacionais.

A aplicação de ferramentas de acesso livre e de fácil execução para processamento de imagens é uma opção ao uso de equipamentos menos acessíveis. Deste modo, ferramentas como ImageJ[®] que extraem dados de uma imagem podem ser aplicados em sementes. Além disso, empregar inteligência artificial com o uso do *software* Weka[®] que contém uma coleção de algoritmos de aprendizado de máquina para tarefas de mineração de dados, ferramentas para pré-processamento de dados, classificação, regressão, agrupamento, regras de associação e visualização para uma análise mais aprofundada é uma opção viável. O *software* Weka[®] foi desenvolvido na Universidade de Waikato, Nova Zelândia, com o objetivo de identificar informações de dados obtidos de domínios agrícolas devido sua usabilidade, entretanto, o uso do *software* foi estendido para outros campos (ŠKRUBEJ; ROZMAN; STAJNKO, 2015, p. 70).

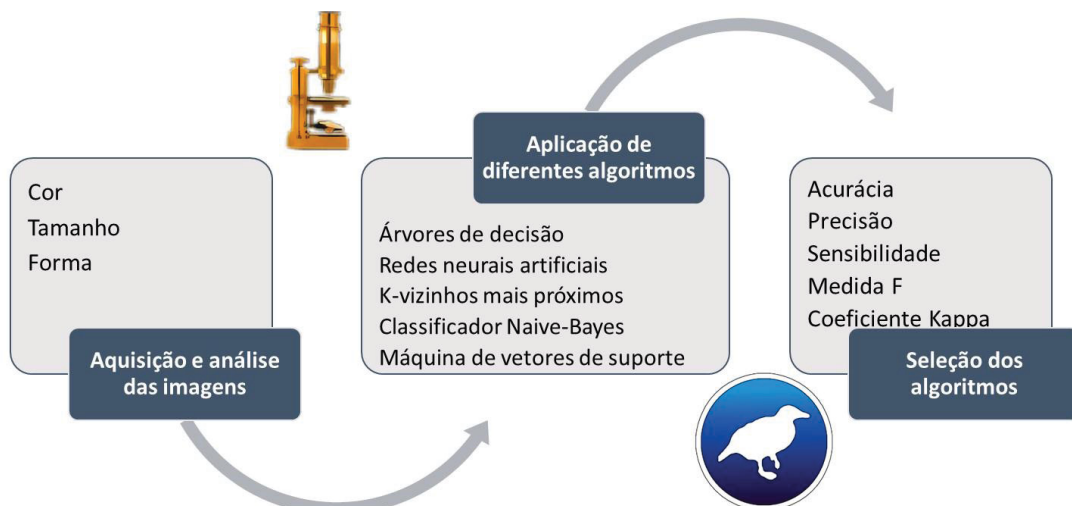
Assim, objetivou-se com este capítulo aplicar diferentes classificadores de aprendizado de máquina associados à análise de imagens para identificação de espécies florestais nativas do Brasil a partir de características morfobiométricas de sementes, empregando ferramentas gratuitas de processamento de imagens e inteligência artificial.

5.2 MATERIAL E MÉTODOS

5.2.1 Desenho do trabalho

A metodologia do presente capítulo seguiu o seguinte fluxograma de trabalho (FIGURA 20): (i) aquisição e análise das imagens de sementes para obtenção de atributos morfobiométricos relativos à cor, tamanho e formato das sementes, conforme metodologia apresentada no capítulo anterior (FIGURA 10), (ii) seguido do processamento dos dados e aplicação de diferentes classificadores de aprendizado de máquina, e (iii) seleção daquele com maior precisão para a identificação correta das espécies.

FIGURA 20 - METODOLOGIA DE TRABALHO PARA AQUISIÇÃO E ANÁLISE DAS IMAGENS, APLICAÇÃO E SELEÇÃO DOS ALGORITMOS



FONTE: o autor (2023).

5.2.2 Aquisição e processamento das imagens de sementes

As amostras de sementes florestais foram fotografadas e analisadas quanto aos aspectos de tamanho, formato e de coloração no Laboratório de Sementes Florestais da Universidade Federal do Paraná, entre os anos de 2020 e 2022. Foram analisadas um total de 155 espécies florestais nativas pertencentes a 42 famílias botânicas. As sementes utilizadas neste estudo são provenientes dos bancos de sementes de sete instituições nacionais e regionais de pesquisa, produção e ensino: (i) Embrapa Florestas, (ii) Instituto Água e Terra (IAT/PR), (iii) Sociedade Chauá, (iv)

Laboratório de Sementes Florestais (UFPR), (v) Programa Bolsa de Sementes (AFUBRA/UFMS), (vi) Núcleo de Conservação da Biodiversidade do Instituto de Pesquisas Ambientais do Estado de São Paulo, e (vii) Núcleo de Ecologia e Monitoramento Ambiental (NEMA/UNIVASF). A lista completa das espécies analisadas encontra-se no APÊNDICE 2.

As sementes de cada espécie foram dispostas espacialmente sobre folha de espuma vinílica acetinada (EVA). Em seguida, realizou-se a captura das imagens com câmera fotográfica Canon PowerShot SX500 IS (f/4) lente de 12 MP a 50 cm de distância das sementes com gabarito de referência milimetrado. As aquisições das imagens foram feitas usando mini estúdio fotográfico (50 x 50 x 50 cm) com luz artificial branca (LED) para padronização das condições de luminosidade. Para cada fotografia foram realizadas novas amostragens de sementes por espécie, totalizando 465 imagens que compuseram a base de imagens de sementes utilizadas neste estudo (TABELA 4).

As imagens em seu formato original (.JPEG) foram transferidas para microcomputador, e no *software* ImageJ®, versão 1.53 (<https://imagej.nih.gov/ij/index.html>) foi determinada a escala de referência em milímetros. Em seguida, foi aplicada a máscara de *Threshold* para contrastar os componentes da imagem. As características de tamanho, formato e coloração foram analisadas conforme descrito por Ferreira e Rasband (2012, p. 136-138). Em suma, foram utilizadas oito características para dimensões, quatro para formato, e seis para cor, totalizando 18 atributos analisados (TABELA 5).

TABELA 5 - ATRIBUTOS DE TAMANHO, FORMATO E COLORAÇÃO SELECIONADOS E ANALISADOS A PARTIR DAS IMAGENS DE SEMENTES

Dimensões das sementes	Descrição dos atributos	(Continua)
Área	seleção da superfície das sementes (mm ²), calculado a partir dos limites definidos pelo perímetro.	
Perímetro	limite externo da seleção das sementes (mm), calculado a partir dos centros dos pixels limite.	
Largura	medida de largura (mm) definidos pelo menor retângulo delimitador que envolve a seleção da semente.	
Altura	medida de altura (mm) definidos pelo menor retângulo delimitador que envolve a seleção da semente.	
Maior	eixo maior (mm) ajustado à uma elipse que envolve a seleção da semente.	
Menor	eixo menor (mm) ajustado à uma elipse que envolve a seleção da semente.	
Feret	maior distância (mm) entre dois pontos ao longo do limite da seleção da semente ajustado em um ângulo de até 180°.	
MinFeret	menor distância (mm) entre dois pontos ao longo do limite da seleção da semente ajustado em um ângulo de até 180°.	
Formato das sementes	Descrição dos atributos	
Circularidade	valor escalar (0,0 a 1,0) calculado a partir da fórmula abaixo, indicando um círculo perfeito quando próximo a 1.0 para o formato da semente em relação ao seu perímetro, e uma forma alongada quando próximo de zero. $Circularidade = 4\pi \times \frac{\text{área}}{\text{perímetro}^2}$	
Proporção	relação entre os eixos maior e menor a partir de uma elipse ajustada para a imagem da semente, calculado a partir da fórmula abaixo. $Proporção = \frac{\text{eixo maior}}{\text{eixo menor}}$	
Redondeza	valor escalar (0,0 a 1,0) calculado a partir da fórmula abaixo, inverso da proporção da semente. $Redondeza = 4 \times \frac{\text{área}}{\pi \times \text{eixo maior}^2}$	
Solidez	valor escalar (0,0 a 1,0) calculado a partir da fórmula abaixo, indicando a relação entre a área da semente capturada na imagem e a área convexa de cada semente. $Solidez = \frac{\text{área}}{\text{área convexa}}$	
Coloração das sementes	Descrição dos atributos	
Cor	valor médio de cinza (0 a 255) resultantes do somatório de valores dos pixels da seleção da superfície da imagem da semente dividido pelo número de pixels, calculado a partir das fórmulas abaixo. $Cor = 0,229 \times red + 0,587 \times green + 0,144 \times blue \text{ Ou } \frac{red + green + blue}{3}$	
Desvio padrão (StdDev)	cálculo do desvio padrão dos valores de cor de cinza da superfície da imagem da semente usadas para gerar o valor médio de cinza.	
Valor de cinza modal (Modal)	valor de cinza (0 a 255) para a cor da seleção da superfície da semente que ocorre com mais frequência, correspondente ao pico mais alto no histograma.	
Nível de cinza Mínimo	valores mínimos (0 a 255) para a cor de cinza da seleção da superfície da semente.	
Nível de cinza	valores máximos (0 a 255) para a cor de cinza da seleção da superfície da	

(Conclusão)

Máximo	semente.
Mediana	valor mediano (0 a 255) dos pixels para a coloração da seleção da superfície da semente.

FONTE: o autor (2022).

Um conjunto com 1,827 milhões de dados morfobiométricos, composto por 18 atributos obtidos a partir do processamento de imagens de 101.521 sementes para 155 espécies foram analisados. Os arquivos em formato *Comma-separated values* (.CSV) contendo os dados morfobiométricos das sementes foram utilizados para processamento dos modelos de aprendizado de máquina no *software* Weka®, versão 3.8.3 (WAIKATO ENVIRONMENT FOR KNOWLEDGE ANALYSIS, 2018).

Os atributos de coloração (cor, desvio padrão, mínimo e máximo, modal e mediana), tamanho (área, perímetro, largura, altura, maior, menor, feret e minferet) e formato (circularidade, proporção e solidez) foram previamente selecionados (*attribute evaluator*) com triagem das melhores variáveis primeiro (mérito do melhor subconjunto encontrado com alta correlação: 0,805). A redondeza das sementes não foi selecionada por ser o inverso da proporção, por isso, fornece exatamente a mesma informação.

5.2.3 Aprendizado de máquina e classificação

Para determinar o classificador de aprendizado de máquina mais adequado para identificação das espécies, cinco técnicas de classificação por aprendizado supervisionado foram implementadas e comparadas neste trabalho: árvores de decisão (DT), redes neurais artificiais (ANN), k-vizinhos mais próximos (k-NN), classificador Naive-Bayes (NBC) e máquina de vetores de suporte (SVM). Selecionando-se o classificador com base no melhor desempenho em acurácia, precisão, sensibilidade e medida F (WITTEN; FRANK, 2005) derivadas da matriz de confusão (FIGURA 21) para a classificação das espécies a partir dos conjuntos de validação e que possua o maior coeficiente de correlação Kappa (0,0-1,0).

FIGURA 21 - MATRIZ DE CONFUSÃO UTILIZADA PARA AVALIAÇÃO DO DESEMPENHO DOS CLASSIFICADORES

		ESPÉCIE PREDITA	
		Sim	Não
REAL	Sim	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (VN)

FONTE: o autor (2023).

Na matriz de confusão apresentada na FIGURA 21, tem-se as seguintes categorias:

Verdadeiro Positivo (VP): ocorre quando a espécie que estamos buscando prever é corretamente identificada no conjunto de validação.

Falso Positivo (FP): ocorre quando a espécie que estamos buscando prever é erroneamente identificada no conjunto de validação.


Verdadeiro Negativo (VN): ocorre quando a espécie que não estamos buscando prever é corretamente identificada no conjunto de validação.

Falso Negativo (FN): ocorre quando a espécie que não estamos buscando prever é erroneamente identificada no conjunto de validação.

Esses termos são utilizados para avaliar o desempenho de um modelo de classificação e fornecem informações importantes sobre a capacidade do modelo em identificar corretamente as sementes.

Para modelagem, 66% dos dados morfobiométricos das sementes foram usados para o treinamento dos classificadores, enquanto 34% dos dados não vistos pelos classificadores foram deixados para validação (FIGURA 22). Esta separação foi usada para que os classificadores não tenham acesso ao conjunto total de dados para treinamento, o que não refletiria uma situação real em que sementes nunca vista seriam encontradas naturalmente.

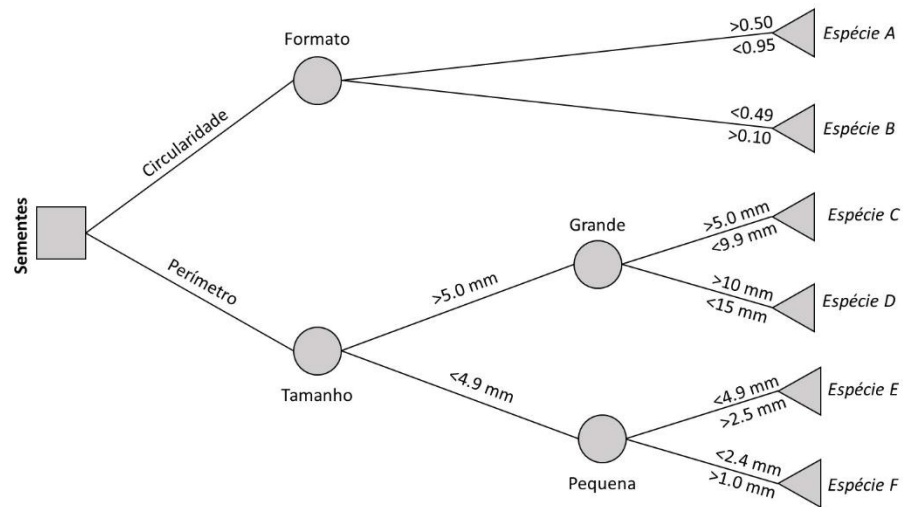
FIGURA 22 - TREINAMENTO E VALIDAÇÃO DOS CLASSIFICADORES TESTADOS A PARTIR DA SEPARAÇÃO DOS DADOS MORFOBIOMÉTRICOS DE SEMENTES



FONTE: o autor (2023).

Árvores de decisão (*decision trees*): organiza o conhecimento extraído do conjunto de dados em uma estrutura hierárquica semelhante a uma árvore (FIGURA 23), composta por nós e ramos, cada nó interno representa um atributo e está associado à um teste para classificação de dados, os nós e folhas da árvore correspondem às classes e as ramificações representam cada um dos possíveis resultados dos testes aplicados (QUINLAN, 1996). Um novo exemplo pode ser classificado seguindo os nós e ramifica-se até que uma folha seja alcançada. O processo de modelagem por árvores de decisão visa maximizar a classificação correta de todos os dados de treinamento. Para isso, foi utilizado o algoritmo J48 (C4.5) por ser o aprendizado com esta abordagem mais usado para gerar uma árvore de decisão. A árvore de decisão criada possui 7.283 folhas, levou 37,4 s para construir o modelo e 1,2 s para testar o modelo construído. Foi utilizado no Weka® o seguinte esquema de execução: `weka.classifiers.trees.J48-C0.25-M2`.


FIGURA 23 - EXEMPLIFICAÇÃO DO CLASSIFICADOR POR ÁRVORES DE DECISÃO



FONTE: o autor (2023).

Redes neurais artificiais (*artificial neural networks*): simula o comportamento do cérebro humano, compostos por um elevado número de elementos de processamento altamente interconectados semelhante ao funcionamento dos neurônios biológicos, ligados com conexões ponderadas correspondentes às sinapses cerebrais (McCULLOCH; WALTER, 1943). O *Multilayer perceptron* (MLP) é um tipo comum de rede neural artificial amplamente utilizado para fins de classificação (FIGURA 24). Para a arquitetura da rede neural, o valor da taxa de aprendizado foi estabelecido em 0,3 e a taxa de impulso em 0,2 (ŠKRUBEJ; ROZMAN; STAJNKO, 2015, p. 71). O número de neurônios nas camadas de entrada e saída foi definido como 17 e 155, respectivamente, pois o número de atributos avaliados foram 17 e o número de espécies analisadas foi 155. A camada intermediária foi construída com 240 neurônios. O tempo de treinamento foi de 500 épocas, o que levou 3,82 h para construir o modelo e 12,7 s para testar o modelo construído. Foi utilizado no Weka® o seguinte esquema de execução: `weka.classifiers.functions.MultilayerPerceptron-L0.3-M0.2-N500-V0-S0-E20-Ha`.

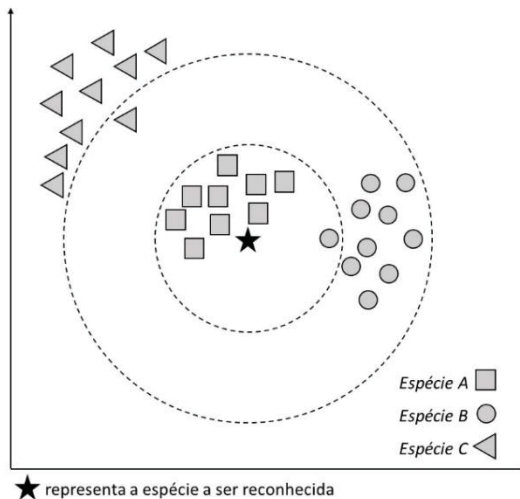
FIGURA 24 - EXEMPLIFICAÇÃO DO CLASSIFICADOR POR REDES NEURAIS ARTIFICIAIS



FONTE: o autor (2023).

K-vizinhos mais próximos (*k-nearest neighbors*): aprende com base em instâncias, em que se analisa as instâncias ou exemplos ao redor de um caso específico (FIGURA 25). Este modelo calcula a distância entre cada amostra de treinamento e o caso de teste com base na distância Euclidiana. Após classificar todas as distâncias, o modelo seleciona o k mais próximo daqueles que são considerados como os vizinho k mais próximos (AHA; KIBLER; ALBERT, 1991). Se o algoritmo retorna mais de um k vizinho, eles são votados para formar a classificação final, o que levou 0,03 s para construir o modelo e 6,23 min para testar o modelo construído. Foi utilizado no Weka® o seguinte esquema de execução: `weka.classifiers.lazy.IBk-K1-W0-A`.

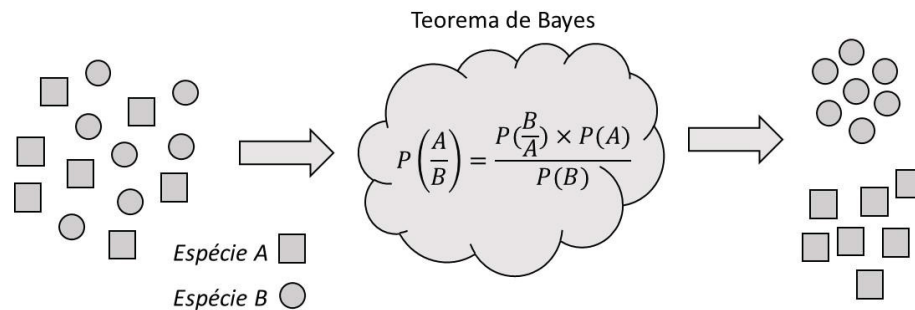
FIGURA 25 - EXEMPLIFICAÇÃO DO CLASSIFICADOR POR K-VIZINHOS MAIS PRÓXIMOS



FONTE: o autor (2023).

Classificador Naive-Bayes (*Naive-Bayes classifiers*): prediz a classe para a qual a probabilidade a posteriori é maior, dadas as variáveis preditoras do caso a ser classificado, baseia-se na teoria da probabilidade utilizando o teorema de Thomas Bayes (FIGURA 26) (SHANNON, 1948). Neste trabalho, foi utilizado o classificador Naive-Bayes que é um dos métodos de aprendizado Bayesiano, o que levou 0,4 s para construir o modelo e 34,24 s para testar o modelo construído. Foi utilizado no Weka® o seguinte esquema de execução: `weka.classifiers.bayes.NaiveBayes`.

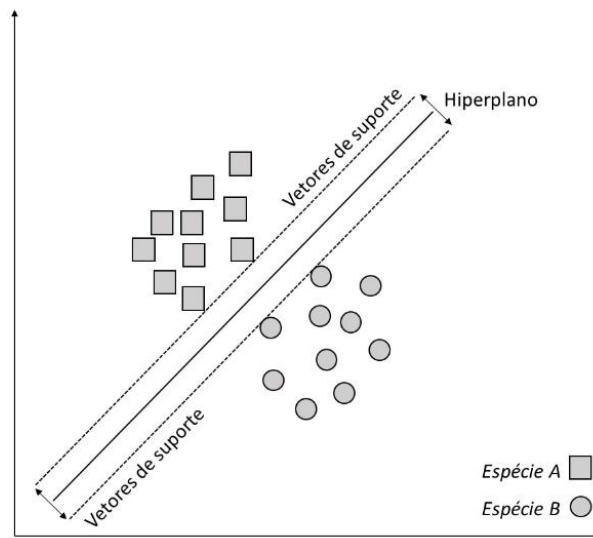
FIGURA 26 - EXEMPLIFICAÇÃO DO CLASSIFICADOR NAIVE-BAYES



FONTE: o autor (2023).

Máquina de vetores de suporte (*support vector machines*): constrói um hiperplano com uma linha de decisão para classificação das instâncias (FIGURA 27) (CORTES; VAPNIK, 1995; VAPNIK, 1995), tem sido amplamente utilizado em diversas aplicações, neste trabalho, levou 57,6 s para construir o modelo e 23,36 s para testar o modelo construído. Foi utilizado no Weka® o seguinte esquema de execução: `weka.classifiers.functions.SMO-C1.0-L0.001-P1.0E-12-N0-V-1-W1-K`.

FIGURA 27 - EXEMPLIFICAÇÃO DO CLASSIFICADOR POR MÁQUINA DE VETORES DE SUPORTE



FONTE: o autor (2023).

5.2.4 Avaliação do desempenho

Acurácia (*accuracy*): percentual de previsões corretas feitas a partir do modelo testado quando comparado com a classificação real do conjunto de dados de validação, calculado em função do número de sementes classificadas corretamente dividido pelo número total de sementes, conforme fórmula abaixo:

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN}$$

Onde VP refere-se ao verdadeiro positivo, VN refere-se ao verdadeiro negativo, FP refere-se ao falso positivo e FN refere-se ao falso negativo. Assim, $VP + VN + FP + FN$ é o número total de sementes do conjunto de validação e $VP + VN$ é o número de sementes identificadas corretamente.

Precisão (*precision*): proporção de casos positivos previstos que são realmente os reais entre todas as sementes que foram classificadas para cada espécie. É calculado da seguinte forma:

$$Precisão = \frac{VP}{VP + FP}$$

Onde VP refere-se ao verdadeiro positivo e FP refere-se ao falso positivo. Um falso positivo ocorre quando a semente é incorretamente prevista como positiva quando na verdade é negativa.

Sensibilidade (*recall*): definido como a razão entre o verdadeiro positivo e a soma do verdadeiro positivo e falso negativo. É calculado da seguinte forma:

$$\text{Sensibilidade} = \frac{VP}{VP + FN}$$

Onde VP refere-se ao verdadeiro positivo e FN refere-se ao falso negativo. O falso negativo ocorre quando a semente predita como negativa é na verdade positiva.

Medida F (*F-measure*): definida como uma média harmônica calculada com base na precisão e na sensibilidade. É calculado da seguinte forma:

$$\text{Medida F} = 2 \times \frac{\text{precisão} \times \text{sensibilidade}}{\text{precisão} + \text{sensibilidade}}$$

Coefficiente Kappa: definido como uma métrica que avalia o nível de concordância de uma tarefa de classificação entre dois ou mais conjuntos de dados, indicando quais daqueles dados classificados tem maior coesão. É calculado da seguinte forma:

$$\text{Kappa} = 2 \times \frac{VP \times VN - FP \times FN}{VP \times FN + VP \times FP + 2 \times VP \times VN + FN^2 + FN \times VN + FP^2 + FP \times VN}$$

Onde VP refere-se ao verdadeiro positivo, VN refere-se ao verdadeiro negativo, FP refere-se ao falso positivo e FN refere-se ao falso negativo.

5.3 RESULTADOS E DISCUSSÃO

Os classificadores de aprendizagem de máquina testados mostraram-se promissores para a identificação das espécies a partir do processamento de imagens e obtenção de atributos morfobiométricos de sementes, sendo o modelo por árvores de decisão o que apresentou maior acurácia para identificação correta das sementes a partir do conjunto de dados de validação (82,8%), cujo coeficiente Kappa foi de 0,780 (TABELA 6). Seguido dos classificadores de redes neurais

artificiais (81,7%; 0,763), k-vizinhos mais próximos (81,7%; 0,760), classificador Naive-Bayes (81,1%; 0,749) e máquina de vetores de suporte (78,7%; 0,699). Portanto, o modelo por árvore de decisão se mostrou mais efetivo para identificação correta das espécies a partir de características relacionadas a cor, tamanho e formato das sementes, constatado pela maior precisão de identificação das sementes para o conjunto de dados de validação (TABELA 6). Os demais parâmetros de desempenho avaliados também foram superiores para árvore de decisão em relação aos outros classificadores.

TABELA 6 - DESEMPENHO DOS CLASSIFICADORES DE APRENDIZADO DE MÁQUINA TESTADOS PARA IDENTIFICAÇÃO DAS ESPÉCIES A PARTIR DA ANÁLISE DE IMAGENS DE SEMENTES

Classificadores testados	Acurácia (%)	Precisão	Sensibilidade	Medida F	Coeficiente Kappa
Árvores de decisão	82,8	0,782	0,783	0,782	0,780
Redes neurais artificiais	81,7	0,767	0,766	0,767	0,763
K-vizinhos mais próximos	81,7	0,762	0,763	0,762	0,760
Classificador Naive-Bayes	81,1	0,754	0,753	0,750	0,749
Máquina de vetores de suporte	78,7	0,703	0,703	0,704	0,699

FONTE: o autor (2022).

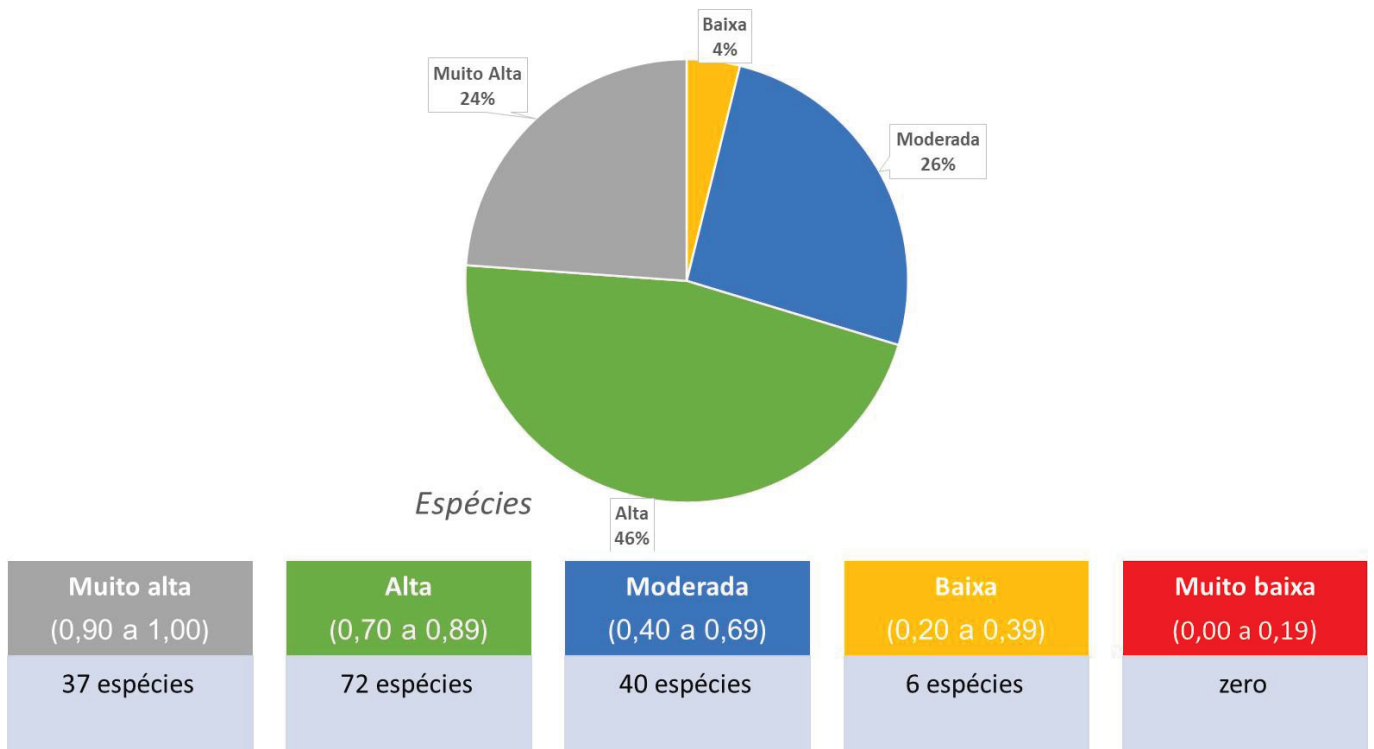
O uso de aprendizado de máquina para resolver alguma questão requer alguns pré-requisitos, visto que nem todos os algoritmos resolvem todos os tipos de problemas, sendo necessário um conjunto de dados e exemplos robustos, bem como sua construção e atualização constante. Além disso, é preciso fazer a seleção dos conjuntos de classificadores adequados para o problema que se quer resolver. Após o treinamento, a validação dos classificadores precisa ser mensurada em nível de precisão para o problema que está sendo solucionado.

Por exemplo, em estudos que utilizaram aprendizado de máquina e técnicas de visão computacional para classificar sementes de melancia, foram capturadas imagens das sementes por meio de uma câmera, resultando em uma precisão de classificação que variou de 69,5% a 84,3% com o uso da máquina de vetores de suporte (MUKASA *et al.*, 2022). Por outro lado, a utilização dessas metodologias para detectar a autenticidade de sementes de milho alcançou uma precisão de reconhecimento de 98,0% utilizando redes neurais artificiais (TU *et al.*, 2022). Enquanto um sistema de classificação baseado em mecanismos de rotação alternada para expor as características externas das sementes de soja obteve

precisão de 97,8% utilizando aprendizado profundo (ZHAO *et al.*, 2021). Esses diferentes resultados demonstram a necessidade de validação das técnicas, uma vez que podem apresentar níveis de precisão variados de acordo com o problema analisado.

O coeficiente Kappa encontrado para o classificador por árvores de decisão é considerado alto (0,780), em uma escala de 0,0 a 1,0. Contudo, deve-se destacar que as espécies avaliadas apresentaram diferenças de precisão na identificação correta a partir da análise de imagens de sementes, variando de baixa até muita alta precisão (FIGURA 28). O classificador por árvores de decisão considerou corretamente seis espécies com baixa precisão (0,20 a 0,39), 40 espécies com precisão moderada (0,40 a 0,69), 72 espécies com alta precisão (0,70 a 0,89) e 37 espécies com precisão muito alta (0,90 a 1,00).

FIGURA 28 - NÍVEL DE RECONHECIMENTO DAS ESPÉCIES A PARTIR DA ANÁLISE DE IMAGENS DE SEMENTES ASSOCIADA À APRENDIZAGEM DE MÁQUINA USANDO O CLASSIFICADOR POR ÁRVORES DE DECISÃO



FONTE: o autor (2023).

Diferentemente das culturas agrícolas que apresentam sementes majoritariamente homogêneas devido ao melhoramento genético (DUAN *et al.*,

2022, p. 1808), espécies florestais apresentam grande variação das características das sementes para uma mesma espécie. Além disso, a proximidade de gêneros botânicos se mostra como um fator de confusão para a identificação correta das sementes pelo método proposto usando mini estúdio e câmera fotográfica.

Dentro dos gêneros avaliados, a similaridade ou proximidade das características das sementes foi um dos motivos de confusão para identificação correta das sementes das espécies dos gêneros *Annona* (*A. cacans*, *A. emarginata*, *A. mucosa* e *A. sylvatica*), *Butia* (*B. capitata* e *B. eriospatha*), *Cassia* (*C. grandis* e *C. leptophylla*), *Cecropia* (*C. glaziovii*, *C. hololeuca*, *C. pachystachya* e *C. sciadophylla*), *Enterolobium* (*E. contortisiliquum* e *E. timbouva*) e *Senna* (*S. macranthera*, *S. pendula* e *S. spectabilis*) que apresentaram precisão moderada para a identificação correta das espécies (TABELA 7). O principal motivo de confusão é a proximidade de características morfobiométricas das sementes dentro do mesmo gênero.

TABELA 7 – PRECISÃO DE IDENTIFICAÇÃO CORRETA DAS ESPÉCIES A PARTIR DA ANÁLISE DE IMAGENS DE SEMENTES ASSOCIADA À APRENDIZAGEM DE MÁQUINA USANDO O CLASSIFICADOR POR ÁRVORES DE DECISÃO

Precisão para identificação correta	<i>n</i>	Espécies	(continua)
Muita baixa 0,00 a 0,19	0	Nenhuma	
Baixa 0,20 a 0,39	6	<i>Cenostigma pyramidale</i> (0.283), <i>Mimosa ophthalmocentra</i> (0.340), <i>Croton blanchetianus</i> (0.361), <i>Manihot carthagenensis</i> (0.364), <i>Albizia niopoides</i> (0.374) e <i>Genipa americana</i> (0.398).	
Moderada 0,40 a 0,69	40	<i>Vitex megapotamica</i> (0.402), <i>Bixa orellana</i> (0.408), <i>Annona cacans</i> (0.418), <i>Annona emarginata</i> (0.428), <i>Jatropha molissima</i> (0.429), <i>Mimosa bimucronata</i> (0.431), <i>Cassia grandis</i> (0.446), <i>Cecropia hololeuca</i> (0.451), <i>Enterolobium contortisiliquum</i> (0.465), <i>Cnidioscolus quercifolius</i> (0.473), <i>Butia eriospatha</i> (0.489), <i>Cenostigma microphyllum</i> (0.500), <i>Annona sylvatica</i> (0.517), <i>Butia capitata</i> (0.529), <i>Lophanthera lactescens</i> (0.540), <i>Senna macranthera</i> (0.541), <i>Croton floribundus</i> (0.542), <i>Senna pendula</i> (0.556), <i>Cecropia pachystachya</i> (0.559), <i>Senna spectabilis</i> (0.570), <i>Cecropia glaziovii</i> (0.575), <i>Cecropia sciadophylla</i> (0.581), <i>Dalbergia ecastaphyllum</i> (0.585), <i>Mimosa tenuiflora</i> (0.599), <i>Handroanthus heptaphyllum</i> (0.613), <i>Enterolobium timbouva</i> (0.614), <i>Euphorbia heterophylla</i> (0.615), <i>Euterpe edulis</i> (0.620), <i>Lonchocarpus cultratus</i> (0.626), <i>Alchornea glandulosa</i> (0.626), <i>Schinus terebinthifolia</i> (0.629), <i>Piptadenia gonoacantha</i> (0.633), <i>Annona mucosa</i> (0.638), <i>Lafoensia glyptocarpa</i> (0.638), <i>Ceiba speciosa</i> (0.641), <i>Leptolobium dasycarpum</i> (0.643), <i>Poecilanthe parviflora</i> (0.647), <i>Cordia superba</i> (0.655), <i>Copernicia prunifera</i> (0.676) e <i>Cassia leptophylla</i> (0.680).	
Alta 0,70 a 0,89	72	<i>Inga lentiscifolia</i> (0.703), <i>Erythroxylum argentinum</i> (0.704), <i>Mabea fistulifera</i> (0.705), <i>Allophylus guaraniticus</i> (0.709), <i>Astronium urundeuva</i> (0.712), <i>Gymnanthes klotzschiana</i> (0.716), <i>Libidibia ferrea</i> (0.717), <i>Platypodium elegans</i> (0.721), <i>Diospyros inconstans</i> (0.727), <i>Solanum lycocarpum</i> (0.73), <i>Manilkara elata</i> (0.731), <i>Handroanthus chrysotrichus</i> (0.738), <i>Guazuma ulmifolia</i> (0.738), <i>Neocalyptocalyx longifolium</i> (0.740), <i>Clitoria fairchildiana</i> (0.740), <i>Handroanthus impetiginosus</i> (0.743), <i>Psidium myrtoides</i> (0.743), <i>Pachira glabra</i> (0.743), <i>Erythrina speciosa</i> (0.747), <i>Sesbania punicea</i> (0.752), <i>Terminalia mameluco</i> (0.753), <i>Ilex paraguariensis</i> (0.755), <i>Senegalia bonariensis</i> (0.755), <i>Allophylus edulis</i> (0.757), <i>Helietta apiculata</i> (0.760), <i>Dimorphandra mollis</i> (0.763), <i>Hymenaea courbaril</i> (0.763), <i>Psidium guajava</i> (0.767), <i>Mimosa flocculosa</i> (0.769), <i>Cassia ferruginea</i> (0.770), <i>Mimosa scabrella</i> (0.772), <i>Bauhinia forficata</i> (0.774), <i>Calopogonium mucunoides</i> (0.774), <i>Anadenanthera colubrina</i> (0.775), <i>Leucochloron incuriale</i> (0.776), <i>Nectandra lanceolata</i> (0.778), <i>Sarcomphalus joazeiro</i> (0.780), <i>Dalbergia frutescens</i> (0.781), <i>Mucuna pruriens</i> (0.790), <i>Pityrocarpa moniliformis</i> (0.792), <i>Solanum viarum</i> (0.795), <i>Lithraea molleoides</i> (0.798), <i>Stryphnodendron adstringens</i> (0.800), <i>Jatropha curcas</i> (0.801), <i>Balfourodendron riedelianum</i> (0.803), <i>Matayba elaeagnoides</i> (0.803), <i>Monteverdia ilicifolia</i> (0.804), <i>Sesbania virgata</i> (0.818), <i>Campomanesia xanthocarpa</i> (0.819), <i>Gallesia integrifolia</i> (0.824), <i>Cryptocarya aschersoniana</i> (0.833), <i>Aegiphila integrifolia</i> (0.833), <i>Drimys brasiliensis</i> (0.838), <i>Podocarpus lambertii</i> (0.840), <i>Phytolacca dioica</i> (0.843), <i>Pleroma raddianum</i> (0.843), <i>Hymenaea altissima</i> (0.847),	

(Conclusão)

		<i>Parapiptadenia rigida</i> (0.851), <i>Berberis laurina</i> (0.851), <i>Cupania vernalis</i> (0.855), <i>Abrus precatorius</i> (0.857), <i>Cecropia peltata</i> (0.858), <i>Xiquexique gounellei</i> (0.860), <i>Handroanthus ochraceus</i> (0.870), <i>Zanthoxylum rhoifolium</i> (0.876), <i>Machaerium acutifolium</i> (0.882), <i>Calliandra brevipes</i> (0.884), <i>Cereus jamacaru</i> (0.885), <i>Encholirium spectabile</i> (0.886), <i>Peltophorum dubium</i> (0.889), <i>Ormosia arborea</i> (0.89) e <i>Syagrus romanzoffiana</i> (0.892).
Muito Alta 0,90 a 1,00	37	<i>Psidium cattleyanum</i> (0.900), <i>Prunus brasiliensis</i> (0.900), <i>Gaylussacia brasiliensis</i> (0.900), <i>Machaerium villosum</i> (0.901), <i>Aspidosperma parvifolium</i> (0.910), <i>Spondias tuberosa</i> (0.910), <i>Mimosa pigra</i> (0.911), <i>Araucaria angustifolia</i> (0.921), <i>Commiphora leptophloeos</i> (0.921), <i>Luehea divaricata</i> (0.922), <i>Sapindus saponaria</i> (0.924), <i>Pleroma sellowianum</i> (0.925), <i>Schizolobium parahyba</i> (0.933), <i>Terminalia glabrescens</i> (0.937), <i>Pterogyne nitens</i> (0.939), <i>Ateleia glazioveana</i> (0.942), <i>Handroanthus albus</i> (0.942), <i>Hevea brasiliensis</i> (0.947), <i>Lafoensia pacari</i> (0.949), <i>Solanum granuloseprosum</i> (0.951), <i>Machaerium stipitatum</i> (0.957), <i>Vassobia breviflora</i> (0.958), <i>Dalbergia brasiliensis</i> (0.958), <i>Aspidosperma subincanum</i> (0.960), <i>Tabebuia aurea</i> (0.961), <i>Schinopsis brasiliensis</i> (0.963), <i>Cochlospermum orinocense</i> (0.965), <i>Aspidosperma pyriforme</i> (0.970), <i>Amburana cearenses</i> (0.973), <i>Cedrela fissilis</i> (0.983), <i>Dictyoloma vandellianum</i> (0.990), <i>Styrax leprosus</i> (0.990), <i>Vernonanthura discolor</i> (0.991), <i>Miconia theaezans</i> (0.992), <i>Senna multijuga</i> (0.994), <i>Myrocarpus frondosus</i> (0.999) e <i>Pterocarpus rohrii</i> (0.999).
Total	155	

FONTE: o autor (2022).

As sementes dos gêneros *Allophylus* (*A. edulis* e *A. guaraniticus*), *Aspidosperma* (*A. parvifolium*, *A. pyriforme* e *A. subincanum*), *Dalbergia* (*D. brasiliensis* e *D. frutescens*), *Handroanthus* (*H. albus*, *H. chrysotrichus*, *H. impetiginosus* e *H. ochraceus*), *Hymenaea* (*H. altissima* e *H. courbaril*), *Machaerium* (*M. stipitatum* e *M. villosum*), *Pleroma* (*P. raddianum* e *P. sellowianum*), *Psidium* (*P. cattleyanum*, *P. guajava* e *P. myrtoide*), *Sesbania* (*S. punicea* e *S. virgata*), *Solanum* (*S. granuloseprosum*, *S. lycocarpum* e *S. viarum*) e *Terminalia* (*T. glabrescens* e *T. mameluco*) foram identificadas corretamente com alta ou muito alta precisão (TABELA 7). Este resultado denota a potencialidade na identificação de sementes florestais, a partir de características morfobiométricas obtidos com análise de imagens e aprendizado de máquina. Entretanto, não é possível fazer generalizações quanto a efetividade de classificação correta dentro dos gêneros botânicos.

Os gêneros *Cenostigma* e *Croton* apresentaram baixa (*Cenostigma pyramidale* e *Croton blanchetianus*) e moderada (*Cenostigma microphyllum* e *Croton floribundus*) precisão na identificação das sementes. Houve maior confusão do

classificador para essas espécies, devido as características morfobiométricas das sementes capturadas por imagem. Enquanto as sementes do gênero *Mimosa* apresentaram diferentes níveis de precisão, sendo baixa para *Mimosa ophthalmocentra*, precisão moderada para *M. bimucronata* e *M. tenuiflora*, e alta precisão para identificação de *M. flocculosa*, *M. pigra* e *M. scabrella*.

A matriz de confusão completa a partir do classificador por árvores de decisão encontra-se no APÊNDICE 3. O classificador por árvores de decisão também confundiu sementes de *Cenostigma pyramidale*, a qual apresentou baixa precisão de identificação correta (0.283), principalmente com *Cassia leptophylla* (20), e em menor proporção para *Annona cacans* (12), *Dalbergia ecastaphyllum* (10), *Piptadenia gonoacantha* (8) e *Anadenanthera colubrina* (7) como falsos negativos, além dos falsos positivos com *Poecilanthe parviflora* (7) e *Annona sylvatica* (5) (APÊNDICE 3). A exceção do gênero *Annona*, as demais espécies são da família Fabaceae, o que pode ter contribuído para a menor precisão de identificação correta das sementes de *Cenostigma pyramidale* conforme constatado pela matriz de confusão.

Para *Mimosa ophthalmocentra* (0.340), maior confusão ocorreu com *Mimosa bimucronata* (40) (APÊNDICE 3), espécie do mesmo gênero e com características morfobiométricas das sementes próximas. O gênero *Mimosa* é reconhecidamente rico em diversidade de espécies, com cerca de 378 espécies nativas ocorrendo no Brasil, sendo 42 arbóreas (REFLORA, 2020). A diferenciação de espécies deste gênero por imagens de sementes é um desafio e deve ser explorado em estudos futuros abrangendo mais espécies. Alta precisão de identificação correta a partir de imagens de sementes foi alcançada para diferenciação de *M. bimucronata*, *M. tenuiflora*, *M. flocculosa*, *M. pigra* e *M. scabrella*.

Croton blanchetianus (0.361) apresentou maior confusão com *Croton floribundus* (38), *Mimosa bimucronata* (26), *Gymnanthes klotzschiana* (21) e *Euphorbia heterophylla* (17) como falsos negativos, e *Senna spectabilis* (25), *Mimosa ophthalmocentra* (21), *Schinus terebinthifolia* (16) e *Monteverdia ilicifolia* (16) como falsos positivos (APÊNDICE 3). Destaca-se aqui os falsos negativos das sementes da família Euphorbiaceae, com exceção de *Mimosa bimucronata* (Fabaceae). A maior taxa de confusão para *C. blanchetianus*, *C. floribundus*, *G. klotzschiana* e *E. heterophylla* pode ser atribuído as sementes apresentarem carúncula, um tipo de arilo persistente pós maturação das sementes que permanece

aderido e conferem características distintas de cor e formato para as sementes, influenciando em sua posição no momento da aquisição das imagens, além de afetar nas características de tamanho e formato da semente.

Em contrapartida, sementes aladas ou com estruturas de dispersão que conferem formatos diferenciados para as sementes devido a conformação das asas apresentaram altas taxas de classificação correta das espécies, como o caso dos gêneros *Aspidosperma*, *Handroanthus*, *Machaerium*, *Tabebuia* e *Terminalia*. A diferenciação de espécies da família Bignoniaceae (*Handroanthus* e *Tabebuia*) pode ser mais complexa em comparação com outras famílias botânicas, devido a morfologia similar de suas sementes, e por apresentar 29 gêneros e 414 espécies nativas (REFLORA, 2020). Para *Manihot carthagenensis* (0.364), maior confusão ocorreu com *Dalbergia ecastaphyllum* (15) e *Cenostigma pyramidale* (12), enquanto *Albizia niopoides* (0.374) apresentou maior confusão com *Euphorbia heterophylla* (28), e *Genipa americana* (0.398) com *Vitex megapotamica* (13) e *Cenostigma microphyllum* (8) como falsos negativos, e *Cordia superba* (11) como falso positivo (APÊNDICE 3).

Sementes de *Genipa americana* não possuem um formato e tamanho padrão, ocorrendo sementes com diferentes características. Desse modo, o coeficiente de assimetria para as características biométricas dessa espécie indica que sementes de menor tamanho predominam na amostra, enquanto a curtose ($k < 3$) indica haver uma maior amplitude de distribuição da frequência das características biométricas das sementes em relação a uma curva normal (SOBRINHO *et al.*, 2017, p. 386). Fato este que justifica a baixa capacidade do classificador por árvore de decisão de fazer o reconhecimento desta espécie apenas com a morfobiometria da semente.

Vale salientar que o uso da metodologia proposta para captura de imagens com câmera fotográfica associado a um mini estúdio, processamento das imagens em *software* de livre acesso e uso de aprendizagem de máquina se mostraram adequados para mais de 70% das espécies estudadas. Portanto, é relevante considerar que o processamento de imagens e o aprendizado de máquina para identificar sementes florestais nativas envolvem desafios e complexidades adicionais.

Dentre os desafios encontrados, destaca-se a variedade de tamanho de sementes na mesma espécie, características próximas para alguns gêneros

botânicos, sementes muito pequenas que não podem ser fotografadas pelos meios comuns, e presença de diásporos ou estruturas de dispersão ligadas as sementes que lhe conferem características distintas, como alas, arilos, carúnculas, e pericarpos persistentes. Além disso, é importante realizar a extração de características relevantes e a seleção adequada de atributos para alimentar o classificador, sendo a disponibilidade de um conjunto de dados de treinamento representativo e de alta qualidade fundamental para obter resultados confiáveis.

Dentre as possibilidades exploradas, destaca-se a implementação de aplicativos com técnicas de aprendizado de máquina para a identificação de sementes, o que pode trazer benefícios significativos em termos de automação, fiscalização e identificação taxonômica. Portanto, é importante considerar o desenvolvimento de trabalhos futuros utilizando técnicas avançadas de aprendizado profundo e programação em sementes florestais nativas, visando a criação de aplicativos ou ferramentas integradas para captura e processamento de imagens voltadas à identificação de sementes. Nesse sentido, os pesquisadores brasileiros necessitam estabelecer parcerias sólidas e obter financiamento adequado para impulsionar as pesquisas com esse enfoque.

Por fim, o método proposto, que envolve o uso de câmera digital e mini estúdio, é aplicável para a identificação de sementes florestais. No entanto, ressalta-se que em casos de espécies com baixa taxa de reconhecimento pelo classificador ou maior grau de confusão, o método proposto pode não ser adequado. Nesses casos, são necessárias novas pesquisas e aprimoramentos da metodologia para atender às demandas das espécies florestais em questão, como explorar alternativas de captura de imagens, maior número amostral e técnicas de aprendizado profundo.

5.4 CONCLUSÕES

O processamento de imagens de sementes e o uso de técnicas de aprendizado de máquina possibilitam a identificação de espécies florestais nativas com taxa satisfatória de acurácia. Recomenda-se os classificadores baseados em árvores de decisão.

REFERÊNCIAS

- AHA, D. W.; KIBLER, D.; ALBERT, M. K. Instance-based learning algorithms. **Machine Learning**, v. 6, n.1, p. 37-66, 1991. <https://doi.org/10.1023/A:1022689900470>
- BAO, F.; BAMBIL, D. Applicability of computer vision in seed identification: deep learning, random forest, and support vector machine classification algorithms. **Acta Botanica Brasilica**, v. 35, n. 1, p. 17–21, 2021. <https://doi.org/10.1590/0102-33062020abb0361>
- BAO, Y.; MI, C.; WU, N.; LIU, F.; HE, Y. "Rapid classification of wheat grain varieties using hyperspectral imaging and chemometrics." **Applied Sciences**, v. 9, n. 19, e4119, 2019. <https://doi.org/10.3390/app9194119>
- CORTES, C.; VAPNIK, V. Support-vector network. **Machine Learning**, v. 20, n. 3, p. 273–297, 1995. <http://dx.doi.org/10.1007/BF00994018>.
- DUAN, Z.; MIN, Z.; ZHIFANG, Z.; SHAN, L.; LEI, F.; XIA, Y.; YAQIN, Y.; YI P.; GUOAN, Z.; SHULIN, L.; ZHIXI, T. Natural allelic variation of GmST05 controlling seed size and quality in soybean. **Plant Biotechnology Journal**, v. 20, n. 9, p. 1807-1818, 2022. <http://dx.doi.org/10.1111/pbi.13865>
- FARRIS, E.; ORRÙ, M.; UCCHESE, M.; AMADORI, A.; PORCEDDU, M.; BACCHETTA, G. Morpho-colorimetric characterization of the Sardinian endemic taxa of the genus *Anchusa* L. by seed image analysis. **Plants**, v. 9, n. 10, p. 1–14, 2020. <https://doi.org/10.3390/plants9101321>
- McCULLOCH, W. S.; WALTER, P. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115-133, 1943.
- MUKASA, P.; WAKHOLI, C.; FAQEERZADA, M. A.; AMANAH, H. Z.; KIM, H.; JOSHI, R.; SUH, H. K.; KIM, G.; LEE, H.; KIM, M. S.; BAEK, I.; CHO, B. K. Nondestructive discrimination of seedless from seeded watermelon seeds by using multivariate and deep learning image analysis. **Computers and Electronics in Agriculture**, v. 194, e106799, 2022. <https://doi.org/10.1016/j.compag.2022.106799>
- QUINLAN, J. R. Learning decision tree classifiers. *ACM Computing Surveys*, v. 28, n. 1, p. 71-72, 1996. <https://doi.org/10.1145/234313.234346>
- REFLORA. **Flora do Brasil 2020**. Jardim Botânico do Rio de Janeiro. Disponível em: < <http://floradobrasil.ibrij.gov.br/> >. Acesso em: 04 mai. 2022
- ROPELEWSKA, E.; PIECKO, J. Discrimination of tomato seeds belonging to different cultivars using machine learning. **European Food Research and Technology**, v. 248, n. 3, p. 685–705, 2022. <https://doi.org/10.1007/s00217-021-03920-w>
- SHANNON, C. E. A mathematical theory of communication. **Bell System Technical Journal**, v. 27, n. 4, p. 623-656, 1948.

SHI, Y.; PATEL, Y.; ROSTAMI, B.; CHEN, H.; WU, L.; YU, Z.; LI, Y. Barley variety identification by iPhone images and deep learning. **Journal of the American Society of Brewing Chemists**, v. 80, n. 3, p. 215-224, 2022.

<https://doi.org/10.1080/03610470.2021.1958602>

ŠKRUBEJ, U.; ROZMAN, C.; STAJNKO, D. Assessment of germination rate of the tomato seeds using image processing and machine learning. **European Journal of Horticultural Science**, v. 80, n. 2, p. 68-75, 2015.

<http://dx.doi.org/10.17660/eJHS.2015/80.2.4>

SOBRINHO, S. P.; ALBUQUERQUE, M. C. F.; LUZ, P. B.; CAMILI, E. C. Physical characterization of fruits and seeds of *Lafoensia pacari*, *Alibertia edulis* and *Genipa americana*. **Revista de Ciências Agrárias**, v. 40, n. 2, p. 382-389, 2017.

<https://doi.org/10.19084/RCA16034>

TAN, K.; RUNTAO W.; MINGYING L.; ZHENPING G. Discriminating soybean seed varieties using hyperspectral imaging and machine learning. **Journal of Computational Methods in Sciences and Engineering**, v. 19, n. 4, p. 1001-1015, 2019.

<http://dx.doi.org/10.3233/JCM-193562>

TU, K.; WEN, S.; CHENG, Y.; ZHANG, T.; PAN, T.; WANG, J.; WANG, J.; SUN, Q. A non-destructive and highly efficient model for detecting the genuineness of maize variety 'JINGKE 968' using machine vision combined with deep learning. **Computers and Electronics in Agriculture**, v. 182, e106002, 2021.

<https://doi.org/10.1016/j.compag.2021.106002>

WEKA, **Waikato Environment for Knowledge Analysis**, versão 3.8.3. Universidade de Waikato, Nova Zelândia. Disponível em: < <https://weka.softonic.com.br/> >. Acesso em: 05 dez. 2022

WITTEN, I.; FRANK, E. **Data mining: practical machine learning tools and techniques**, Morgan Kaufmann, 2005. 629p.

URBANETZ, C.; TAMASHIRO, J. Y.; KINOSHITA, L. S. Chave de identificação de espécies lenhosas de um trecho de floresta ombrófila densa atlântica, no sudeste do Brasil, baseada em caracteres vegetativos. **Biota Neotropica**, v. 10, n. 2, p. 350–388, 2010. <https://doi.org/10.1590/S1676-06032010000200036>

VAPNIK, V. N. **The nature of statistical learning theory**. Springer, New York. 1995. 188p. <http://dx.doi.org/10.1007/978-1-4757-2440-0>

ZHAO, G.; QUAN, L.; LI, H.; FENG, H.; LI, S.; ZHANG, S.; LIU, R. Real-time recognition system of soybean seed full-surface defects based on deep learning. **Computers and Electronics in Agriculture**, v. 187, e106230, 2021.

<https://doi.org/10.1016/j.compag.2021.106230>

ZHU, S.; CHAO, M.; ZHANG, J.; XU, X.; SONG, P.; ZHANG, J.; HUANG, Z. Identification of soybean seed varieties based on hyperspectral imaging technology. **Sensors**, v. 19, n. 23, e5225, 2019. <http://dx.doi.org/10.3390/s19235225>

ZHU, S.; ZHANG, J.; CHAO, M.; XU, X.; SONG, P.; ZHANG, J.; HUANG, Z. A rapid and highly efficient method for the identification of soybean seed varieties: hyperspectral images combined with transfer learning. **Molecules**, v. 25, n. 1, e152, 2020. <http://dx.doi.org/10.3390/molecules25010152>

CONSIDERAÇÕES FINAIS

A abordagem de análise de imagens e aprendizado de máquina tem sido cada vez mais explorada em estudos científicos sobre sementes, evidenciado pelo aumento de publicações recentes nessa área. Esse crescimento é impulsionado por pesquisadores internacionais, que têm contribuído para o avanço do conhecimento nesse campo de pesquisa. No entanto, é importante ressaltar que o número de publicações voltadas para espécies florestais é relativamente baixo, indicando a necessidade de mais pesquisas e trabalhos futuros nesse domínio.

A bibliometria apresentada também evidenciou limitações na abordagem dos artigos científicos em relação às sementes florestais, destacando a falta de uma metodologia específica para a aquisição e processamento de imagens, superada com a metodologia proposta nesta pesquisa. Dado o valor das sementes florestais para a conservação e o manejo sustentável dos ecossistemas, é fundamental explorar as possibilidades dessas técnicas. Portanto, a metodologia proposta para a caracterização e identificação de sementes representa um passo inicial crucial para a disseminação de um procedimento acessível, reproduzível e eficiente.

A caracterização das sementes por meio da metodologia apresentada, utilizando uma câmera digital e um mini estúdio, tem o potencial de superar as limitações existentes decorrentes do uso de recursos manuais e avaliação individual de sementes, ainda amplamente utilizados em estudos florestais no país. A metodologia proposta desempenha um papel fundamental na caracterização e diferenciação de espécies florestais nativas. Ao aplicar a análise morfobiométrica por processamento de imagens, é possível obter informações valiosas com implicações diretas em futuros estudos silviculturais, genéticos e ecológicos. Portanto, espera-se que os pesquisadores adotem cada vez mais essas ferramentas computacionais de análise de imagens em seus trabalhos, utilizando técnicas acessíveis e tecnologias de baixo custo.

O processamento de imagens permitiu a extração de características morfológicas e estruturais das sementes, proporcionando uma abordagem objetiva e quantitativa para a identificação das espécies. Essas informações podem ser utilizadas para determinar a variabilidade genética, avaliar a qualidade das sementes, estudar padrões de dispersão e estabelecer estratégias de conservação.

Quanto a identificação de sementes florestais por meio de imagens e aprendizado de máquina, a metodologia proposta indica que a técnica pode ser empregada com taxa satisfatória de acurácia, não se restringindo ao uso do classificador por árvores de decisão. No entanto, para espécies com baixo índice de reconhecimento pelo classificador ou com maior grau de confusão, o método proposto se mostra inadequado, exigindo pesquisas adicionais e aprimoramento da metodologia para essas espécies florestais. A identificação de sementes requer constante aprimoramento e refinamento das técnicas utilizadas, especialmente para lidar com as particularidades de cada espécie e obter melhores resultados.

Em resumo, os resultados também demonstram a efetividade da identificação de sementes de diferentes espécies por meio da análise de características morfobiométricas, o que viabiliza sua utilização em estudos de biodiversidade, ecologia e pesquisas florestais. Nesse contexto, a exploração da identificação automatizada de sementes em pesquisas futuras é recomendável. A análise automatizada de sementes, por meio da aplicação de técnicas de processamento de imagens e aprendizado de máquina, possibilita a detecção de atributos específicos, como tamanho, forma e cor. Essa abordagem agiliza e aprimora a análise científica, proporcionando uma compreensão mais aprofundada das características das sementes.

A adoção de técnicas de processamento de imagens e aprendizado de máquina também permite a automação de tarefas demoradas, como a classificação manual de sementes, viabilizando um processamento mais rápido e eficiente. Além disso, impulsionam o desenvolvimento de sistemas de visão computacional capazes de analisar grandes volumes de imagens de sementes de maneira automatizada e precisa. Essa abordagem contribui para a criação de bancos de dados robustos e promove avanços na pesquisa nessa área.

Por fim, os resultados apresentados contribuem para futura automação e desenvolvimento de aplicativos ou ferramentas integradas para a captura e processamento de imagens, visando a identificação de sementes nativas. O aprendizado profundo pode desempenhar um papel de destaque na identificação de sementes em trabalhos futuros, por meio de algoritmos complexos e redes neurais artificiais. A capacidade de lidar com variações de iluminação, ângulos de visão e ruídos nas imagens o torna extremamente eficiente em tarefas de reconhecimento. No entanto, é importante ressaltar a exigência de conhecimentos avançados em

programação, recursos computacionais robustos e habilidades de interpretação do pesquisador.

BEZERRA, A. C.; ZUZA, J. F. C.; SILVA BARBORA, L.; AZEVEDO, C. F.; ALVES, E. U. Biometrics of mulungu seeds from different mother plants in the semi-arid region of Paraíba, Brazil. **Revista Caatinga**, v. 35, n. 2, p. 393 – 401, 2022.

<https://doi.org/10.1590/1983-21252022v35n215rc>

BIANCHINI, V. J.; MASCARIN, G. M.; SILVA, M. L. C. A. S.; ARTHUR, V.; CARTENSEN, J. M.; BOELT, B.; SILVA, C. B. Multispectral and X-ray images for characterization of *Jatropha curcas* L. seed quality. **Plant Methods**, v. 2021, p. 1-22, 2021. <https://doi.org/10.21203/rs.3.rs-28449/v1>

BIANCO, M.; GRILLO, O.; ESCOBAR GARCIA, P.; MASCIA, F.; VENORA, G.; BACCHETTA, G. Morpho-colorimetric characterisation of *Malva* alliance taxa by seed image analysis. **Plant Biology**, v. 19, n. 1, p. 90-98, 2017.

<https://doi.org/10.1111/plb.12481>

BRASIL. Ministério da Agricultura, pecuária e Abastecimento. **Florestas do Brasil em resumo: 2019**. Ministério da Agricultura, pecuária e Abastecimento. Serviço Florestal Brasileiro. Brasília: MMA/SFB, 2009. 124p.

www.fundoamazonia.gov.br/export/sites/default/pt/galleries/documentos/acervo-projetos-cartilhas-outros/SFB-Florestas-Brasil-2009-livro.pdf

BRUS, R.; BALLIAN, D.; ZHELEV, P.; PANDZA, M.; BOBINAC, M.; ACEVSKI, J.; RAFTOYANNIS, Y.; JARNI, K. Absence of geographical structure of morphological variation in *Juniperus oxycedrus* L. subsp. *oxycedrus* in the Balkan Peninsula. **European Journal of Forest Research**, v. 130, p. 657-670, 2011.

<https://doi.org/10.1007/s10342-010-0457-1>

CAO, J.; LIU, K.; LIU, L.; ZHU, Y.; LI, J.; HE, Z. Identifying mangrove species using field close-range snapshot hyperspectral imaging and machine-learning techniques. **Remote Sensing**, v. 10, n. 12, e2047, 2018. <https://doi.org/10.3390/rs10122047>

CECCO, V. D.; MUSCIANO, M. D.; D'ARCHIVIO, A. A.; FRATTAROLI, A. R.; MARTINO, L. D. Analysis of intraspecific seed diversity in *Astragalus aquilanus* (Fabaceae), an endemic species of Central Apennine. **Plant Biology**, v. 21, n. 1, p. 507–514, 2019. <https://doi.org/10.1111/plb.12844>

CERRI, R.; CARVALHO, A. C. P. L. F. Machine learning: brief introduction and applications. **Cadernos de Ciência & Tecnologia**, v. 34, n. 3, p. 297-313, 2017.

CETIN, Z.; YASTIKLI, N. The use of machine learning algorithms in urban tree species classification. **ISPRS International Journal of Geo-Information**, v. 11, n. 4, e226, 2022. <https://doi.org/10.3390/ijgi11040226>

CHUEKE, G. V.; AMATUCCI, M. Métodos de sistematização de literatura em estudos científicos: bibliometria, meta-análise e revisão sistemática. **Revista Eletrônica de Negócios Internacionais**, v. 17, n. 2, p. 284-292, 2022.

<https://doi.org/10.18568/internext.v17i2.704>

- CONCEIÇÃO, T. A.; MENDONÇA, A. V. R.; SOUZA, M. O.; SOUZA, J. S.; MOREIRA, R. F. C. Seed collection environment: effects of forest cover reduction on biometrics and seed lot quality of *Bowdichia virgilioides* Kunth. **Científica**, v. 47, n. 3, p. 327-336, 2019. <https://doi.org/10.15361/1984-5529.2019v47n3p327-336>
- CORREIA, L. A. S.; FELIX, F. C.; ARAUJO, F. D. S.; FERRARI, C. D. S.; PACHECO, M. V. Morphometric descriptors and physiological seed quality for selecting *Aspidosperma pyrifolium* Mart. matrix trees. **Revista Caatinga**, v. 32, n. 3, p. 751-759, 2019. <https://doi.org/10.1590/1983-21252019v32n319rc>
- CORTES, C.; VAPNIK, V. Support-vector network. **Machine Learning**, v. 20, n. 3, p. 273–297, 1995. <http://dx.doi.org/10.1007/BF00994018>.
- COSMO, N. L.; GOGOSZ, A. M.; REGO, S. S.; NOGUEIRA, A. C.; KUNIYOSHI, Y. S. Morphology of fruit, seed and seedling and seed germination of *Myrceugenia euosma* (O. Berg) D. Legrand (Myrtaceae). **Floresta**, v. 47, n. 4, p. 479 - 488, 2017. <https://doi.org/10.5380/uf.v47i4.46933>
- COSTA, M. F.; LOPES, A. C. A.; GOMES, R. L. F.; ARAÚJO, A. S. F.; ZUCCHI, M. I.; PINHEIRO, J. B.; VALENTE, S. E. S. Characterization and genetic divergence of *Casearia grandiflora* populations in the Cerrado of Piauí State, Brazil. **Floresta e Ambiente**, v. 23, n. 3, p. 387-396, 2016. <https://doi.org/10.1590/2179-8087.007115>
- CUNHA, A. L. A.; FERREIRA, T. C. Patologia de sementes na atualidade: revisão bibliométrica. **Holos**, v. 37, n. 1, p. 1-20, 2020. <https://doi.org/10.15628/holos.2021.10627>
- DELL'AQUILA, A. Computerised seed imaging: a new tool to evaluate germination quality. **Communications in Biometry and Crop Science**, v. 1, n. 1, p. 20-31, 2006.
- DUAN, Z.; MIN, Z.; ZHIFANG, Z.; SHAN, L.; LEI, F.; XIA, Y.; YAQIN, Y.; YI P.; GUOAN, Z.; SHULIN, L.; ZHIXI, T. Natural allelic variation of GmST05 controlling seed size and quality in soybean. **Plant Biotechnology Journal**, v. 20, n. 9, p. 1807-1818, 2022. <http://dx.doi.org/10.1111/pbi.13865>
- DUARTE, E. R.; GONZALEZ-RONDAN, B.; ROCHA, S. P. Physical analysis and seed germination of *Austrochthamalia teyucuaensis* H. A. Keller, endemic of the Atlantic Forest and in danger of extinction. **Agrociencia**, v. 53, n. 3, p. 403–416, 2019.
- DUARTE, M. M.; MILANI, J. E. F.; BLUM, C. T.; NOGUEIRA, A. C. Germination and morphological of seed and seedling of *Albizia edwallii* (Hoehne) Barneby & J. W. Grimes. **Revista Caatinga**, v. 28, n. 3, p. 166-173, 2015.
- DUTRA, F. V.; CARDOSO, A. D.; BANDEIRA, A. S.; SILVA, R. M.; MORAIS, O. M.; PRATES, C. J. N. Biometrical characteristics of fruits and seeds of flamboyant. **Scientia Agraria Paranaensis**, v. 16, n. 1, p. 127-132, 2017.
- FAJARDO, C. G.; SILVA, R. A. R.; CHAGAS, K. P. T.; VIEIRA, F. A. Genetic and phenotypic association of the carnauba palm tree evaluated by Inter-Simple

Sequence Repeat and biometric traits. **Genetics and Molecular Research**, v. 17, n. 3, p. 1-9, 2018. <http://dx.doi.org/10.4238/gmr18018>

FARRIS, E.; ORRÙ, M.; UCCHESU, M.; AMADORI, A.; PORCEDDU, M.; BACCHETTA, G. Morpho-colorimetric characterization of the Sardinian endemic taxa of the genus *Anchusa* L. by seed image analysis. **Plants**, v. 9, n. 10, p. 1-13, 2020. <https://doi.org/10.3390/plants9101321>

FASSNACHT, F. E.; HOOMAN, L.; KRZYSZTOF, S.; ANETA M.; MICHAEL L.; LARS T. W.; CHRISTOPH S.; ANIRUDDHA G. Review of studies on tree species classification from remotely sensed data. **Remote Sensing of Environment**, v. 186, n. 1, p. 64-87, 2016. <https://doi.org/10.1016/j.rse.2016.08.013>

FELIX, F. C.; MEDEIROS, J. A. D.; FERRARI, C. S.; VIEIRA, F. A.; PACHECO, M. V. Biometry of *Pityrocarpa moniliformis* seeds using digital imaging: implications for studies of genetic divergence. **Brazilian Journal of Agricultural Sciences**, v. 15, n. 1, e6128, 2020. <https://doi.org/10.5039/agraria.v15i1a6128>

FELIX, F. C.; MOCELIM, F. L.; TORRES, S. B.; KRATZ, D.; RIBEIRO, R.; NOGUEIRA, A. C. Thousand-seed weight determination in forest species by image analysis. **Journal of Seed Science**, v. 43, e202143040, p. 1-9, 2021a. <https://doi.org/10.1590/2317-1545v43254684>

FELIX, F. C.; OLIVEIRA, F. N.; FREITAS, N. W. N.; FREITAS, R. M. O.; JILANI, I. B. H.; TORRES, S. B. Seed characterization and germination morpho-physiology of *Simira gardneriana* (Rubiaceae). **Journal of Seed Science**, v. 43, e202143025, p. 1-11, 2021b. <https://doi.org/10.1590/2317-1545v43250771>

FENNER, M.; THOMPSON, K. **The ecology of seeds**. Cambridge University Press: New York, 2005. 250 p.

FERNANDES, R. M.; ABREU, C. A. A.; SILVA, B. C. F. L.; OLIVEIRA, A. K. M. Germination, vigor and seed biometrics of *Licania kunthiana* Hook.f. **Floresta**, v. 51, n. 3, p. 677–685, 2021. <http://dx.doi.org/10.5380/rf.v51i3.72315>

FERREIRA, T.; RASBAND, W. **ImageJ: user guide** (IJ 1.46r), 2012. 198 p. <https://imagej.nih.gov/ij/docs/guide/user-guide.pdf>

FONSECA, E. N. **Bibliometria: teoria e prática**. São Paulo: Cultrix, Ed. da USP, 1986.

FRANKLIN, S. E.; AHMED, O. S. Deciduous tree species classification using object-based analysis and machine learning with unmanned aerial vehicle multispectral data. **International Journal of Remote Sensing**, v. 39, p. 5236-5245, 2017. <https://doi.org/10.1080/01431161.2017.1363442>

FRANKLIN, S. E.; AHMED, O. S.; WILLIAMS, G. Northern conifer forest species classification using multispectral data acquired from an unmanned aerial vehicle. **Photogrammetric Engineering and Remote Sensing**, v. 83, n. 7, p. 501-507, 2017. <https://doi.org/10.14358/PERS.83.7.501>

GAO, P.; XU, W.; YAN, T.; ZHANG, C.; LV, X.; HE, Y. Application of near-infrared hyperspectral imaging with machine learning methods to identify geographical origins of dry narrow-leaved oleaster (*Elaeagnus angustifolia*) fruits. **Foods**, v. 8, n. 12, e620, 2019. <https://doi.org/10.3390/foods8120620>

GERBER, D.; BRUN, E. J.; TOPANOTTI, L. R.; FERREIRA, J. J.; PORRUA, D. A.; GORENSTEIN, M. R.; WAGNER JÚNIOR, A. Genetic variability of *Araucaria angustifolia* Bertol. initial growth: subsidy to the formation of seed orchards. **Ciência Florestal**, v. 31, n. 1, p. 310-332, 2021. <https://doi.org/10.5902/1980509841712>

GONG, F.; KARSAL, I.; LIU, Y. S. C. *Vitis* seeds (Vitaceae) from the late Neogene Gray Fossil Site, northeastern Tennessee, U.S.A. **Review of Palaeobotany and Palynology**, v. 162, n. 1, p. 71-83, 2010. <https://doi.org/10.1016/j.revpalbo.2010.05.005>

GONZALÉZ-CORTÉS, A.; GODINA, F. R.; REYES-VALDÉS, M. H.; TORRES, V. R.; RODRÍGUEZ, M. A. P.; QUINTANILLA, J. A. V.; BENÍTEZ, A. L. Morfología de semillas de siete especies del género *Opuntia* (Cactaceae) del sureste de Coahuila (México). **Boletín de la Sociedad Argentina de Botánica**, v. 54, n. 4, p. 493-507, 2019. <https://doi.org/10.31055/1851.2372.v54.n4.23572>

HALISKI, S.; COSMO, N. L.; GOGOSZ, A. M.; REGO, S. S.; NOGUEIRA, A. C.; KUNIYOSHI, Y. S. Morphological characterization and germination of seeds of *Casearia decandra*. **Pesquisa Florestal Brasileira**, v. 33, n. 75, p. 253-259, 2013. <https://doi.org/10.4336/2013.pfb.33.75.451>

HAMMER, O.; HARPER, A.T.D. **Paleontological data analysis**. Malden: Blackwell Publishing, 2008. 368 p. <https://doi.org/10.1002/9780470750711>

HEMENDER; SHARMA, S.; MOR, V.; JITENDER; BHUKER, A. Image analysis: a modern approach to seed quality testing. **Current Journal of Applied Science and Technology**, v. 27, n. 1, p. 1-11, 2018. <https://doi.org/10.9734/cjast/2018/40945>

HUANG, B.; LIU, J.; JIAO, J.; LU, J.; LV, D.; MAO, J.; ZHAO, U.; ZHANG, Y. Applications of machine learning in pine nuts classification. **Scientific Reports**, v. 12, e8799, 2022. <https://doi.org/10.1038/s41598-022-12754-9>

HUANG, L.; ZHOU, M.; LV, J.; CHEN, K. Trends in global research in forest carbon sequestration: a bibliometric analysis. **Journal of Cleaner Production**, v. 252, e119908, 2020. <https://doi.org/10.1016/j.jclepro.2019.119908>

JOSHI, D.; BUTOLA, A.; KANADE, S. R.; PRASAD, D. K.; MITHRA, A.; SINGH, N. K.; BISHT, D. S.; MEHTA, D. S. Label-free non-invasive classification of rice seeds using optical coherence tomography assisted with deep neural network. **Optics and Laser Technology**, v.137, e106861, p. 1-7, 2021. <https://doi.org/10.1016/j.optlastec.2020.106861>

JUÁREZ-OROZCO, S. M.; SIEBE, C.; FERNÁNDEZ, F. D. Causes and effects of forest fires in tropical rainforests: a bibliometric approach. **Tropical Conservation Science**, v. 10, p. 1-14, 2017. <https://doi.org/10.1177/1940082917737207>

KAPADIA, V.; SASIDHARAN, N.; KALYANRAO, P. Seed image analysis and its application in seed science research. **Advances in Biotechnology & Microbiology**, v. 7, n. 2, e555709, 2017. <https://doi.org/10.19080/AIBM.2017.07.555709>

KHUMAIEVA, U. H.; KHABIBOV, A. D.; MURATCHAEVA, P. M. Assessment of the structure of the variability of morphological signs of *Trifolium medium* L. introduced under the conditions of mountainous dagestan. **Arid Ecosystems**, 6, p. 135-141, 2016. <https://doi.org/10.1134/S2079096116020074>

KOKLU, M.; CINAR, I.; TASPINAR, Y.S. Classification of rice varieties with deep learning methods. **Computers and Electronics in Agriculture**, v. 187, e106285, 2021. <https://doi.org/10.1016/j.compag.2021.106285>

KURTULMUŞ, F.; ÜNAL, H. Discriminating rapeseed varieties using computer vision and machine learning. **Expert Systems with Applications**, v. 42, n. 4, p. 1880-1891, 2015. <https://doi.org/10.1016/j.eswa.2014.10.003>

LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine learning in agriculture: a review. **Sensors in Agriculture**, v. 18, n. 8, p. 1-29, 2018. <https://doi.org/10.3390/s18082674>

LIMA, T. V.; FELICIANO, A. L. P.; MARAGON, L. C.; MOURA, A. R. Evaluation of biometric characteristics and predation of reproductive structures on ax handle (*Aspidosperma discolor*). **Scientia Plena**, v. 11, n. 5, p. 01-11, 2015.

LIMA, T. M.; AMARAL, E. S.; GAIOTTO, F. A.; ANJOS, L.; DALMOLIN, A. C.; SANTOS, A. S.; MIELKE, M. S. Fruit and seed biometry of *Carpotroche brasiliensis* (RB) A. Gray (Achariaceae), a tropical tree with great potential to provide natural forest products. **Australian Journal of Crop Science**, v. 14, n. 11, p. 1826–1833, 2020. <https://doi.org/10.21475/ajcs.20.14.11.p2596>

LIU, W.; LIU, C.; HU, X.; YANG, J.; ZHENG, L. Application of terahertz spectroscopy imaging for discrimination of transgenic rice seeds with chemometrics. **Food Chemistry**, v. 210, p. 415-421, 2016. <https://doi.org/10.1016/j.foodchem.2016.04.117>

LIU, Y.; LI, C.; LIU, W.; DONG, Q. Trends in global research on seed dispersal: a bibliometric analysis. **Sustainability**, v. 14, e16577, 2022. <https://doi.org/10.3390/su142416577>

LODDO, A.; LODDO, M.; RUBERTO, C. D. A novel deep learning based approach for seed image classification and retrieval. **Computers and Electronics in Agriculture**, v. 187, e106269, 2021. <https://doi.org/10.1016/j.compag.2021.106269>

LODDO, A.; RUBERTO, C. D. On the efficacy of handcrafted and deep features for seed image classification. **Journal of Imaging**, v. 7, n. 9, e171, 2021.

<https://doi.org/10.3390/jimaging7090171>

LOVATEL, Q. C.; NAVROSKI, M. C.; GERBER, T. R.; OLIVEIRA, L. M.; PEREIRA, M. O.; SILVEIRA, M. F. Genetic variability in juvenile characters of progenies of *Apuleia leiocarpa*. **Floresta**, v. 51, n. 3, p. 547-556, 2021.

<http://dx.doi.org/10.5380/RF.v51i3.69454>

MARANHO, A. S.; SOARES, I. D.; GUIMARÃES, A. V. P. J. Biometrics measures of fruits seeds and seedling emergence of *Cordia alliodora* (Ruiz & Pav.) Cham. in different substrates and sowing depths. **Revista Biociências**, v. 20, n. 1, p. 56-62, 2014.

MARTÍN-GÓMEZ, J. J.; GUTIÉRREZ DEL POZO, D.; UCCHESU, M.; BACCHETTA, G.; CABELLO SÁENZ DE SANTAMARÍA, F.; TOCINO, Á.; CERVANTES, E. Seed morphology in the Vitaceae based on geometric models. **Agronomy**, v. 10, n. 739, p. 1-16, 2020. <https://doi.org/10.3390/agronomy10050739>

MAZUR, M.; MARCYSIAK, K.; DUNAJSKA, A.; GAWLAK, M.; KAŁUSK, T. Taxonomic significance of seed morphology in *Veronica* L. (Plantaginaceae) species from central Europe. **Plants**, v. 11, n. 88, p. 1-17, 2022.

<https://doi.org/10.3390/plants11010088>

McCULLOCH, W. S.; WALTER, P. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115-133, 1943.

MEDEIROS, A. D.; ZAVALA-LEÓN, M. J.; ARAÚJO, J. O.; PEREIRA, M. D.; DIAS, D. C. F. S.; SILVA, L. J. Relationship between internal morphology and physiological quality of *Leucaena leucocephala* seeds using image analysis. **Revista Árvore**, v. 43, n. 2, p. 1-9, 2019. <https://doi.org/10.1590/1806-90882019000200008>

MEDEIROS, A. D.; PINHEIRO, D. T.; XAVIER, W. A.; SILVA, L. J.; DIAS, D. C. F. S. Quality classification of *Jatropha curcas* seeds using radiographic images and machine learning. **Industrial Crops and Products**, v. 146, p. 112-162, 2020a.

<https://doi.org/10.1016/j.indcrop.2020.112162>

MEDEIROS, A. D.; SILVA, L. J.; SILVA, J. M.; DIAS, D. C. F. S.; PEREIRA, M. D. IJCropSeed: An open-access tool for high-throughput analysis of crop seed radiographs. **Computers and Electronics in Agriculture**, v. 175, e105555, 2020b.

<https://doi.org/10.1016/j.compag.2020.105555>

MEDINA, W.; SKURTYYS, O.; AGUILERA, J. M. Study on image analysis application for identification quinoa seeds (*Chenopodium quinoa* Willd) geographical provenance. **Food Science and Technology**, v. 43, n. 2, p. 238-246, 2010.

<https://doi.org/10.1016/j.lwt.2009.07.010>

MELO, L. D. F. A.; MELO JUNIOR, J. L. A.; FERREIRA, V. M. F.; ARAÚJO NETO, J. C.; NEVES, M. I. R. S. Biometric characterization and seed germination of giant

mimosa (*Mimosa bimucronata* (DC) O. Kuntze). **Australian Journal of Crop Science**, v. 12, n. 1, p. 108-115, 2018.

<http://dx.doi.org/10.21475/ajcs.18.12.01.pne773>

MENEGATTI, R. D.; MANTOVANI, A.; NAVROSKI, M. C.; SOUZA, A. G. Genetic divergence among provenances of *Mimosa scabrella* Benth. based on seed analysis. **Brazilian Journal of Agricultural Sciences**, v. 12, n. 3, p. 366-371, 2017.

<http://dx.doi.org/10.5039/agraria.v12i3a5449>

MENEGATTI, R. D.; MANTOVANI, A.; NAVROSKI, M. Biometric and physiological quality of bracinga seeds from different mother trees. **Floresta e Ambiente**, v. 26, n. 1, p. 1-10, 2019. <http://dx.doi.org/10.1590/2179-8087.035916>

MICHAŁOWSKA, M.; RAPIŃSKI, J. A review of tree species classification based on airborne LIDAR data and applied classifiers. **Remote Sensing**, v. 13, n. 3, e353, 2021. <https://doi.org/10.3390/rs13030353>

MITCHELL, T. M. **Machine Learning**. McGraw–Hill Science/Engineering/Math, 1997. 421 p.

MOREIRA, P. A.; NEVES, F. S.; LOBO, J. A. Consequences of tropical dry forest conversion on diaspore fate of *Enterolobium contortisiliquum* (Fabaceae). **Plant Ecology**, v. 222, n. 4, p. 525–535, 2021. <https://doi.org/10.1007/s11258-021-01124-6>

MOURA, C. C.; COSTA, T. R.; CARVALHO, L. R.; TITON, M.; PEREIRA, I. M.; MACHADO, E. L. M. Morpho-physiological classification of seeds and morphology of fruits and seedlings of *Richeria grandis*. **Rodriguésia**, v. 71, e02732018, p. 1-15, 2020. <https://doi.org/10.1590/2175-7860202071098>

MUKASA, P.; WAKHOLI, C.; FAQEERZADA, M. A.; AMANAH, H. Z.; KIM, H.; JOSHI, R.; SUH, H. K.; KIM, G.; LEE, H.; KIM, M. S.; BAEK, I.; CHO, B. K. Nondestructive discrimination of seedless from seeded watermelon seeds by using multivariate and deep learning image analysis. **Computers and Electronics in Agriculture**, v. 194, e106799, 2022. <https://doi.org/10.1016/j.compag.2022.106799>

NAZARI, L.; SHAKER, M.; KARIMI, A.; ROPELEWSKA, W. Identification of sorghum genotypes using a machine vision system. **Journal of food process engineering**, v. 44, e13673, p. 1-11, 2021. <https://doi.org/10.1111/jfpe.13673>

NEWELL, A.; SIMON, H. The logic theory machine: a complex information processing system. **I.R.E. Transactions on Information Theory**, v. 2, n. 3, p. 61-79, 1956.

NORONHA, B. G.; PEREIRA, M. D.; FLORES, A. V.; DEMARTELAERE, A. C. F.; MEDEIROS, A. D. Morphometry and physiological quality of *Moringa oleifera* seeds in the function of their fruit position. **Journal of Experimental Agriculture International**, v. 25, n. 6, p. 1-10, 2018. <https://doi.org/10.9734/JEAI/2018/43375>

- ORRÙ, M.; GRILLO, O.; LOVI, G.; VENORA, G.; BACCHETTA, G. Morphological characterisation of *Vitis vinifera* L. seeds by image analysis and comparison with archaeological remains. **Vegetation History and Archaeobotany**, v. 22, n. 231, p. 231-242, 2012. <https://doi.org/10.1007/s00334-012-0362-2>
- PAN, X.; CEN, Y.; MA, Y.; YAN, W.; GAO, X.; LIU, X.; LIU, G. Identification of gramineous grass seeds using Gabor and locality preserving projections. **Multimed Tools Appl**, v. 75, n. 1, p. 16551–16576, 2016. <https://doi.org/10.1007/s11042-016-3424-0>
- PANG, L.; WANG, L.; YUAN, P.; YAN, L.; YANG, Q.; XIAO, J. Feasibility study on identifying seed viability of *Sophora japonica* with optimized deep neural network and hyperspectral imaging. **Computers and Electronics in Agriculture**, v. 190, e106426, 2021. <https://doi.org/10.1016/j.compag.2021.106426>
- PANG, L.; WANG, L.; YUAN, P.; YAN, L.; XIAO, J. Rapid seed viability prediction of *Sophora japonica* by improved successive projection algorithm and hyperspectral imaging. **Infrared Physics and Technology**, v. 123, e104143, 2022. <https://doi.org/10.1016/j.infrared.2022.104143>
- PATRÍCIO, M. C.; TROVÃO, D. M. B. M. Seed biometry: another functional trait in Caatinga. **Acta Scientiarum. Biological Sciences**, v. 42, e51183, p. 1-11, 2020. <https://doi.org/10.4025/actascibiols.v42i1.51183>
- PAULA, S. R. P.; NOGUEIRA, A. C.; BASTOS, M. C. O. Physiological quality and repeatability in biometric characters of seeds from different trees of *Aspidosperma polyneuron* Müll.Arg. **Australian Journal of Basic and Applied Sciences**, v. 9, n. 31, p. 147-154, 2015.
- PAULA, S. R. P.; NOGUEIRA, A. C.; ANGELO, A. C. Morphological characterization of fruit, seed, germination stages and seedling of *Ocotea paranaensis*. **Revista de Ciências Agroveterinárias**, v. 15, n. 2, p. 103-108, 2016. <https://doi.org/10.5965/223811711522016103>
- PEÑALOZA, P.; DURÁN, J. M.; Association between biometric characteristics of tomato seeds and seedling growth and development. **Electronic Journal of Biotechnology**, v. 18, n. 4, p. 267-272, 2015. <https://doi.org/10.1016/j.ejbt.2015.04.003>
- PEREIRA, S. A.; FERREIRA, S. A. N. Fruit and seed biometry and seedling morphology of *Parkia discolor* (Spruce ex Benth.). **Revista Árvore**, v. 41, e410206, p. 1-8, 2017. <http://dx.doi.org/10.1590/1806-90882017000200006>
- PIMENTA, A. C.; REGO, S. S.; RIBAS, K. C. Z.; NOGUEIRA, A. C.; KOEHLER, H. S. Morphological characterization of fruits, seeds and seedlings of araticum plant (*Annona crassiflora* Mart – Annonaceae). **Journal of Seed Science**, v. 35, n. 4, p. 524-531, 2013.
- POLLI, A.; ROMAGNOLO, M. B.; DE SOUZA, L. A.; PASTORINI, L. H. Influence of the functional traits of seeds on germination dynamics and morphofunctional pattern

of the seedlings. **Acta Scientiarum - Biological Sciences**, v. 42, n. 1, p. 1–9, 2020. <https://doi.org/10.4025/actascibiols.v42i1.52154>

PONTES, M. S.; MONTEFUSCO-PEREIRA, C. V.; MISRA, B. B.; RIBEIRO-JUNIOR, H. L.; GRACIANO, D. E.; SANTOS J. S.; NOBREGA, M. A. S.; FERNANDES, S. S. L.; CAIRES, A. R. L.; SANTIAGO, E. F. High-throughput phenotyping by applying digital morphometrics and fluorescence induction curves in seeds to identifying variations: a case study of *Annona* (Annonaceae) species. **Information Processing in Agriculture**, v. 5, n. 4, p. 443-455, 2018. <https://doi.org/10.1016/j.inpa.2018.07.001>

QUINLAN, J. R. Learning decision tree classifiers. *ACM Computing Surveys*, v. 28, n. 1, p. 71-72, 1996. <https://doi.org/10.1145/234313.234346>

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna. 2020. <https://www.r-project.org/>

RAHMAN, A.; CHO, B. W. Assessment of seed quality using non destructive measurement techniques: a review. **Seed Science Research**, v. 26, p. 285-305, 2016. <https://doi.org/10.1017/S0960258516000234>

REFLORA. **Flora do Brasil 2020**. Jardim Botânico do Rio de Janeiro. Disponível em: < <http://floradobrasil.jbrj.gov.br/> >. Acesso em: 04 mai. 2022

REWICZ, A.; BOMANOWSKA, A.; MAGDA, J.; REWICZ, T. Morphological variability of *Consolida regalis* seeds of south-eastern and central Europe. **Systematics and Biodiversity**, v. 15, n. 1, p. 25-34, 2016. <https://doi.org/10.1080/14772000.2016.1216017>

ROPELEWSKA, E.; PIECKO, J. Discrimination of tomato seeds belonging to different cultivars using machine learning. **European Food Research and Technology**, v. 248, n. 3, p. 685–705, 2022. <https://doi.org/10.1007/s00217-021-03920-w>

ROSA, T. L. M.; ARAUJO, C. P.; KAMKE, C.; FERREIRA, A.; FERREIRA, M. F. S.; OLIVEIRA, J. B.; SCHMILDT, E. R.; LOPES, J. C.; MENGARDA, L. H. G.; OTONI, W. C.; SANTOS, A. R.; ALEXANDRE, R. S. Sapucaia nut: morphophysiology, minerals content, methodological validation in image analysis, phenotypic and molecular diversity in *Lecythis pisonis* Cambess. **Food Research International**, v. 137, e109383, 2020. <https://doi.org/10.1016/j.foodres.2020.109383>

ROVERI-NETO, A.; PAULA, R. C. Variability among mother trees of *Ceiba speciosa* St. Hil for characteristics of the fruits and seeds. **Revista Ciência Agronômica**, v. 48, n. 2, p. 318-327, 2017. <https://doi.org/10.5935/1806-6690.20170037>

SALVADOR, H. F.; MAZZOTTINI-DOS-SANTOS, H. C.; DIAS, D. S.; AZEVEDO, A. M.; LOPES, P. S. N.; NUNES, Y. R. F.; RIBEIRO, L. M. The dynamics of *Mauritia flexuosa* (Arecaceae) recalcitrant seed banks reveal control of their persistence in marsh environments. **Forest Ecology and Management**, v. 511, e120155, p. 1-14, 2022. <https://doi.org/10.1016/j.foreco.2022.120155>

SANTOS, J. C. C.; SILVA, D. M. R.; COSTA, R. N.; SILVA, C. H.; SANTOS, W. D. S.; MOURA, F. D. B. P.; SILVA, J. V. Biometric and morphological aspects of the fruits and seeds of *Schinopsis brasiliensis*. **Nativa**, v. 6, n. 3, p. 219-224, 2018. <http://dx.doi.org/10.31413/nativa.v6i3.4709>

SANTOS, J. C. C.; SILVA, D. M. R.; COSTA, R. N.; SANTOS, S. A.; SILVA, L. K. S.; SILVA, J. V. Biometry of fruits and seeds and pre-germination treatments of *Hymenaea courbaril* seeds. **Revista em Agronegócio e Meio Ambiente**, v. 12, n. 3, p. 957–979, 2019. <https://doi.org/10.17765/2176-9168.2019v12n3p957-979>

SARIGU, M.; PORCEDDU, M.; SCHMITT, E.; CAMARDA, I.; BACCHETTA, G. Taxonomic discrimination of the *Paeonia mascula* group in the Tyrrhenian Islands by seed image analysis. **Systematics and Biodiversity**, v. 17, n. 8, p. 801-810, 2019. <https://doi.org/10.1080/14772000.2019.1685607>

SAU, S.; UCCHESU, M.; DONDINI, L.; DE FRANCESCHI, P.; D'HALLEWIN, G.; BACCHETTA, G. Seed morphometry is suitable for apple-germplasm diversity-analyses. **Computers and Electronics in Agriculture**, v. 151, p. 118-125, 2018. <https://doi.org/10.1016/j.compag.2018.06.002>

SHANNON, C. E. A mathematical theory of communication. **Bell System Technical Journal**, v. 27, n. 4, p. 623-656, 1948.

SHI, Z.; ZHANG, J.; WEI, H. Research progress on soil seed bank: a bibliometrics analysis. **Sustainability**, v. 12, e4888, 2020. <https://doi.org/10.3390/su12124888>

SHI, Y.; PATEL, Y.; ROSTAMI, B.; CHEN, H.; WU, L.; YU, Z.; LI, Y. Barley variety identification by iPhone images and deep learning. **Journal of the American Society of Brewing Chemists**, v. 80, n. 3, p. 215-224, 2022. <https://doi.org/10.1080/03610470.2021.1958602>

SILVA, O. L. M.; CORDEIRO, I.; CARUZO, M. B. R. Seed morphology in *Euphorbia* and its taxonomic applications: a case study in São Paulo, Brazil. **Brazilian Journal of Botany**, v. 39, n. 1, p. 349-358, 2016. <https://doi.org/10.1007/s40415-015-0228-9>

SILVA, R. M.; CARDOSO, A. D.; DUTRA, F. V.; MORAIS, O. M. Biometric aspects of fruit and seed of *Caesalpinia ferrea* Mart. ex Tul. from semiarid baiano. **Journal of Neotropical Agriculture**, v. 4, n. 3, p. 85-91, 2017. <https://doi.org/10.32404/rean.v4i3.1427>

SILVA, L. G. C.; MOREIRA, J. F. L.; HOLANDA, H. B. B.; ROCHA, E. L. B.; DIAS, P. C. Evaluation of carnauba progenies and estimates of genetic parameters in the juvenile phase. **Revista Caatinga**, v. 31, n. 4, p. 917–925, 2018. <https://doi.org/10.1590/1983-21252018v31n414rc>

SILVA, J. A.; MEDEIROS, A. D.; PEREIRA, M. D.; RAMOS, A. K. F.; SILVA, L. J. Seed quality analysis of *Senna siamea* Lam. using image analysis techniques. **Journal of Seed Science**, v. 42, e202042042, p. 1-10, 2020. <https://doi.org/10.1590/2317-1545v42241633>

SILVA, C. B.; BIANCHINI, V. J. M.; MEDEIROS, A. D.; MORAES, M. H. D.; MARASSI, A. G.; TANNÚS, A. A novel approach for *Jatropha curcas* seed health analysis based on multispectral and resonance imaging techniques. **Industrial Crops and Products**, v. 161, e113186, 2021.

<https://doi.org/10.1016/j.indcrop.2020.113186>

SILVA, P. K. B.; FELIX, F. C.; MEDEIROS, J. A. D.; ARAÚJO, F. S.; FERRARI, C. S.; PACHECO, M. V. Do seeds of *Anadenanthera macrocarpa* and *Pityrocarpa moniliformis* formed in different locations of the fruit have similar physiological quality? **Floresta**, v. 51, n. 4, p. 1029–1036, 2021.

<http://dx.doi.org/10.5380/RF.V51I4.75880>

SINGH, S. K.; VIDYARTHI, S. K.; TIWARI, R. Machine learnt image processing to predict weight and size of rice kernels. **Journal of Food Engineering**, v. 274, e109828, 2020. <https://doi.org/10.1016/j.jfoodeng.2019.109828>

ŠKRUBEJ, U.; ROZMAN, C.; STAJNKO, D. Assessment of germination rate of the tomato seeds using image processing and machine learning. **European Journal of Horticultural Science**, v. 80, n. 2, p. 68-75, 2015.

<http://dx.doi.org/10.17660/eJHS.2015/80.2.4>

SOARES, I. D.; NOGUEIRA, A. C.; GRABIAS, J.; KUNIYOSHI, Y. S. Morphological characterization of fruits, seeds and stages of germination of *Psidium rufum* DC. (Myrtaceae). **Iheringia**, v. 72, n. 2, p. 221-227, 2017. <https://doi.org/10.21826/2446-8231201772208>

SOARES, R. N.; SANTOS, R. O.; SILVA, B. M. S. E. Morphological aspects and anatomy of the fruit, seeds and seedlings of *Pentaclethra macroloba* (willd.) Kuntze (Fabaceae). **Journal of Seed Science**, v. 41, n. 4, p. 452–460, 2019.

<https://doi.org/10.1590/2317-1545v41n4222721>

SOBRINHO, S. P.; ALBUQUERQUE, M. C. F.; LUZ, P. B.; CAMILI, E. C. Physical characterization of fruits and seeds of *Lafoensia pacari*, *Alibertia edulis* and *Genipa americana*. **Revista de Ciências Agrárias**, v. 40, n. 2, p. 382-389, 2017.

<https://doi.org/10.19084/RCA16034>

SOUSA, P. S.; SILVA, J. A.; MOURA, E. G.; NARDIS, B. O.; SILVA, R. F.; GIL, R. L.; ANDRADE, F. R. Morphological characteristics and methods for breaking seed dormancy in *Enterolobium contorsiliquum* specimens from the Amazonian biome. **Journal of Tropical Forest Science**, v. 33, n. 2, p. 160–172, 2021.

<https://doi.org/10.26525/jtfs2021.33.2.160>

SOUZA, E. P.; FORTE, S. H. A. C. Avaliação da produção científica sobre indicadores educacionais no Brasil entre 2011 e 2020. **Revista de Gestão e Secretariado**, v. 13, n. 3, p. 476-496, 2022. <https://doi.org/10.7769/gesec.v13i3.1338>

TAN, K.; RUNTAO W.; MINGYING L.; ZHENPING G. Discriminating soybean seed varieties using hyperspectral imaging and machine learning. **Journal of Computational Methods in Sciences and Engineering**, v. 19, n. 4, p. 1001-1015, 2019. <http://dx.doi.org/10.3233/JCM-193562>

TU, K.; WEN, S.; CHENG, Y.; ZHANG, T.; PAN, T.; WANG, J.; WANG, J.; SUN, Q. A non-destructive and highly efficient model for detecting the genuineness of maize variety 'JINGKE 968' using machine vision combined with deep learning. **Computers and Electronics in Agriculture**, v. 182, e106002, 2021.

<https://doi.org/10.1016/j.compag.2021.106002>

UCCHESU, M.; ORRÙ, M.; GRILLO, O.; VENORA, G.; PAGLIETTI, G.; ARDU, A.; BACCHETTA, G. Predictive method for correct identification of archaeological charred grape seeds: support for advances in knowledge of grape domestication process. **Plos One**, v. 11, n. 2, p. 01-18, 2016.

<http://dx.doi.org/10.1371/journal.pone.0149814>

URBANETZ, C.; TAMASHIRO, J. Y.; KINOSHIRA, L. S. Identification key for woody species of an Atlantic Rain Forest remnant, in the Southeast of Brazil, based on vegetative characters. **Biota Neotropical**, v. 10, n. 2, p. 349-398, 2010.

<https://doi.org/10.1590/S1676-06032010000200036>

VAPNIK, V. N. **The nature of statistical learning theory**. Springer, New York. 1995. 188p. <http://dx.doi.org/10.1007/978-1-4757-2440-0>

VARMA, V. S.; DURGA, K.; KESHAVULU, K. Seed image analysis: its applications in seed science research. **International Research Journal of Agricultural Sciences**, v. 1, n. 2, p. 30-36, 2013.

WANG, L. G.; WANG, L. F. Variety identification model for maize seeds using hyperspectral pixel-level information combined with convolutional neural network.

National Remote Sensing Bulletin, v. 25, n. 11, p. 2234-2244, 2021.

<https://doi.org/10.11834/jrs.20219349>

WEKA, **Waikato Environment for Knowledge Analysis**, versão 3.8.3. Universidade de Waikato, Nova Zelândia. Disponível em: < <https://weka.softonic.com.br/> >. Acesso em: 05 dez. 2022

WESSEL, M.; BRANDMEIER, M.; TIEDE, D. Evaluation of different machine learning algorithms for scalable classification of tree types and tree species based on Sentinel-2 data. **Remote Sensing**, v. 10, n. 9, e1419, 2018.

<https://doi.org/10.3390/rs10091419>

WITTEN, I.; FRANK, E. **Data mining: practical machine learning tools and techniques**, Morgan Kaufmann, 2005. 629p.

XI, Z.; HOPKINSON, C.; ROOD, S. B.; PEDDLE, D. R. See the forest and the trees: effective machine and deep learning algorithms for wood filtering and tree species classification from terrestrial laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 168, p. 1-16, 2020.

<https://doi.org/10.1016/j.isprsjprs.2020.08.001>

XU, P.; YANG, R.; ZENG, T.; ZHANG, J.; ZHANG, Y.; TAN, Q. Varietal classification of maize seeds using computer vision and machine learning techniques. **Journal of**

Food Process Engineering, v. 44, n. 11, e13846, 2021.

<https://doi.org/10.1111/jfpe.13846>

XUE, Q.; MIAO, P.; MIAO, K.; YU, Y.; LI, Z. X-ray-based machine vision technique for detection of internal defects of sterculia seeds. **Journal of Food Science**. v. 87, n. 8, p. 3386-3395, 2022. <https://doi.org/10.1111/1750-3841.16237>

YADAV, V.; SINGH, A. K.; SINGH, S.; RAO, V. V. A. Variability in custard apple (*Annona squamosa*) genotypes for quality characters from Gujarat. **Indian Council of Agricultural Research**, v. 87, n. 12, p. 1627-1632, 2017.

YANG, Y.; CHEN, J.; HE, Y.; LIU, F.; FENG, X.; ZHANG, J. Assessment of the vigor of rice seeds by near-infrared hyperspectral imaging combined with transfer learning. **RSC Advances**, v. 10, p. 44149–44158, 2020. <https://doi.org/10.1039/d0ra06938h>

YU, Z.; FANG, H.; ZHANGJIN, Q.; MI, C.; FENG, X.; HE, Y. Hyperspectral imaging technology combined with deep learning for hybrid okra seed identification.

Biosystems Engineering, v. 212, n. 1, p. 46-61, 2021.

<https://doi.org/10.1016/j.biosystemseng.2021.09.010>

ZHANG, J.; FENG, X.; LIU, X.; HE, Y. Identification of hybrid okra seeds based on near-infrared hyperspectral imaging technology. **Applied Sciences**, v. 8, e1793, p. 1-13, 2018. <https://doi.org/10.3390/app8101793>

ZHAO, G.; QUAN, L.; LI, H.; FENG, H.; LI, S.; ZHANG, S.; LIU, R. Real-time recognition system of soybean seed full-surface defects based on deep learning.

Computers and Electronics in Agriculture, v. 187, e106230, 2021.

<https://doi.org/10.1016/j.compag.2021.106230>

ZHU, S.; CHAO, M.; ZHANG, J.; XU, X.; SONG, P.; ZHANG, J.; HUANG, Z. Identification of soybean seed varieties based on hyperspectral imaging technology.

Sensors, v. 19, n. 23, e5225, 2019. <http://dx.doi.org/10.3390/s19235225>

ZHU, S.; ZHANG, J.; CHAO, M.; XU, X.; SONG, P.; ZHANG, J.; HUANG, Z. A rapid and highly efficient method for the identification of soybean seed varieties:

hyperspectral images combined with transfer learning. **Molecules**, v. 25, n. 1, e152, 2020. <http://dx.doi.org/10.3390/molecules25010152>

ZUFFO, A. M. A.; STEINER, F.; ALVES, C. Z.; ALCÂNTARA-NETO, F.; SANTOS, M. D. A.; OLIVEIRA, A. M.; SOUSA, T. O.; FONSECA, W. L. Biometric characteristics of fruits, seeds and plants of *Hancornia speciosa* Gomes. (Apocynaceae). **Australian Journal of Crop Science**, v. 13, p 622-627, 2019.

<https://doi.org/10.21475/ajcs.19.13.04.p1651>

APÊNDICE 1

LISTA DE TRABALHOS ANALISADOS NA REVISÃO BIBLIOMÉTRICA CONTIDA NO CAPÍTULO 1.

1. 2009 BOON P;VAN D M L;PAIJMANS H;POSTMA E;LANGE G DIGITAL SUPPORT FOR ARCHAEOLOGY INTERDISCIPLINARY SCIENCE REVIEWS 10.1179/174327909X441108
2. 2013 KONG W;ZHANG C;LIU F;NIE P;HE Y RICE SEED CULTIVAR IDENTIFICATION USING NEARINFRARED HYPERSPECTRAL IMAGING AND MULTIVARIATE DATA ANALYSIS SENSORS 10.3390/s130708916
3. 2014 CHENG S C;KONG W K;ZHANG C Z;LIU F L;HE Y H VARIETY RECOGNITION OF CHINESE CABBAGE SEEDS BY HYPERSPECTRAL IMAGING COMBINED WITH MACHINE LEARNING SPECTROSCOPY AND SPECTRAL ANALYSIS 10.3964/j.issn.1000-0593(2014)09-2519-04
4. 2015 SKRUBEJ U;ROZMAN C;STAJNKO D ASSESSMENT OF GERMINATION RATE OF THE TOMATO SEEDS USING IMAGE PROCESSING AND MACHINE LEARNING EUROPEAN JOURNAL OF HORTICULTURAL SCIENCE 10.17660/eJHS.2015/80.2.4
5. 2015 TANG J;HUANG M;ZHU Q PURITY DETECTION MODEL UPDATE OF MAIZE SEEDS BASED ON ACTIVE LEARNING GUANG PU XUE YU GUANG PU FEN XI/SPECTROSCOPY AND SPECTRAL ANALYSIS 10.3964/j.issn.1000-0593(2015)08-2136-05
6. 2015 WANG H;LI H CLASSIFICATION RECOGNITION OF IMPURITIES IN SEED COTTON BASED ON LOCAL BINARY PATTERN AND GRAY LEVEL COOCCURRENCE MATRIX NONGYE GONGCHENG XUEBAO/TRANSACTIONS OF THE CHINESE SOCIETY OF AGRICULTURAL ENGINEERING 10.3969/j.issn.1002-6819.2015.03.031
7. 2016 CHUNG C;HUANG K;CHEN S;LAI M;CHEN Y;KUO Y DETECTING BAKANAE DISEASE IN RICE SEEDLINGS BY MACHINE VISION COMPUTERS AND ELECTRONICS IN AGRICULTURE 10.1016/j.compag.2016.01.008
8. 2018 AWTY-CARROLL D;CLIFTON-BROWN J;ROBSON P USING KNN TO ANALYSE IMAGES OF DIVERSE GERMINATION PHENOTYPES AND DETECT SINGLE SEED GERMINATION IN MISCANTHUS SINENSIS PLANT METHODS 10.1186/s13007-018-0272-0
9. 2018 SENG K;ANG L;SCHMIDTKE L;ROGIERS S COMPUTER VISION AND MACHINE LEARNING FOR VITICULTURE TECHNOLOGY IEEE ACCESS 10.1109/ACCESS.2018.2875862
10. 2018 XIA J;YANG Y;CAO H;ZHANG W;XU L;WAN Q;KE Y;ZHANG W;GE B HYPERSPECTRAL IDENTIFICATION AND CLASSIFICATION OF OILSEED RAPE WATERLOGGING STRESS LEVELS USING PARALLEL COMPUTING IEEE ACCESS 10.1109/ACCESS.2018.2873689
11. 2018 GUTIERREZ S;FERNANDEZ-NOVALES J;DIAGO J ONTHEGO HYPERSPECTRAL IMAGING UNDER FIELD CONDITIONS AND MACHINE LEARNING FOR THE CLASSIFICATION OF GRAPEVINE VARIETIES FRONTIERS IN PLANT SCIENCE 10.3389/fpls.2018.01102
12. 2018 VEERAMANI B;RAYMOND J;CHANDA P DEEPSORT DEEP CONVOLUTIONAL NETWORKS FOR SORTING HAPLOID MAIZE SEEDS BMC BIOINFORMATICS 10.1186/s12859-018-2267-2
13. 2019 DONG W;MA X;LI H;TAN S;GUO L DETECTION OF PERFORMANCE OF HYBRID RICE POTTRAY SOWING UTILIZING MACHINE VISION AND MACHINE LEARNING APPROACH SENSORS 10.3390/s19235332
14. 2019 HUANG S;FAN X;SUN L;SHEN Y;SUO X RESEARCH ON CLASSIFICATION METHOD OF MAIZE SEED DEFECT BASED ON MACHINE VISION JOURNAL OF SENSORS 10.1155/2019/2716975
15. 2019 TAN K;WANG R;LI M;GONG Z DISCRIMINATING SOYBEAN SEED VARIETIES USING HYPERSPECTRAL IMAGING AND MACHINE LEARNING JOURNAL OF COMPUTATIONAL METHODS IN SCIENCES AND ENGINEERING 10.3233/JCM-193562
16. 2019 GAO P;XU W;YAN T;ZHANG C;LV Y APPLICATION OF NEARINFRARED HYPERSPECTRAL IMAGING WITH MACHINE LEARNING METHODS TO IDENTIFY GEOGRAPHICAL ORIGINS OF DRY NARROWLEAVED OLEASTER ELAEAGNUS ANGUSTIFOLIA FRUITS FOODS 10.3390/foods8120620
17. 2019 SHADRIN D;MENSHCHIKOV A;ERMILOV A DESIGNING FUTURE PRECISION AGRICULTURE DETECTION OF SEEDS GERMINATION USING ARTIFICIAL INTELLIGENCE ON A LOWPOWER EMBEDDED SYSTEM IEEE SENSORS JOURNAL 10.1109/JSEN.2019.2935812

18. 2019 DAGER A;UCHIDA T;MAEKAWA T;TACHIBANA M SYNTHESIS AND CHARACTERIZATION OF MONODISPERSE CARBON QUANTUM DOTS FROM FENNEL SEEDS PHOTOLUMINESCENCE ANALYSIS USING MACHINE LEARNING SCIENTIFIC REPORTS 10.1038/s41598-019-50397-5
19. 2019 PEREIRA D;BUGATTI P;LOPES A;SAITO P CONTRIBUTING TO AGRICULTURE BY USING SOYBEAN SEED DATA FROM THE TETRAZOLIUM TEST DATA IN BRIEF 10.1016/j.dib.2018.12.090
20. 2019 ALTUNTAS Y;COMERT Z;KOCAMAZ A IDENTIFICATION OF HAPLOID AND DIPLOID MAIZE SEEDS USING CONVOLUTIONAL NEURAL NETWORKS AND A TRANSFER LEARNING APPROACH COMPUTERS AND ELECTRONICS IN AGRICULTURE 10.1016/j.compag.2019.104874
21. 2019 JITANAN S;CHIMLEK P QUALITY GRADING OF SOYBEAN SEEDS USING IMAGE ANALYSIS INTERNATIONAL JOURNAL OF ELECTRICAL AND COMPUTER ENGINEERING 10.11591/ijece.v9i5.pp3495-3503
22. 2019 MA Z;GONG L;LIN K;MAO Y;WU W;LIU C ESTIMATION OF PANICLE SEED NUMBER BASED ON PANICLE GEOMETRIC PATTERN RECOGNITION SHANGHAI JIAOTONG DAXUE XUEBAO/JOURNAL OF SHANGHAI JIAOTONG UNIVERSITY 10.16183/j.cnki.jsjtu.2019.02.016
23. 2019 PATIL A;TOTAD S NONINVASIVE SOYA BEAN SEED ANALYSIS USING MACHINE LEARNING INTERNATIONAL JOURNAL OF RECENT TECHNOLOGY AND ENGINEERING
24. 2020 AHMED M;YASMIN J;PARK E;KIM G;KIM M;WAKHOLI C;MO C;CHO B CLASSIFICATION OF WATERMELON SEEDS USING MORPHOLOGICAL PATTERNS OF XRAY IMAGING A COMPARISON OF CONVENTIONAL MACHINE LEARNING AND DEEP LEARNING SENSORS 10.3390/s20236753
25. 2020 COLMER J;O'NEILL C;WELLS R;BOSTROM A;REYNOLDS D;WEBSDALE D;SHIRALAGI W;LOU Q;LE C T;BALL J;ANDALUZ G;BENJAMINS R;PENFIELD S;ZHOU J SEEDGERM A COSTEFFECTIVE PHENOTYPING PLATFORM FOR AUTOMATED SEED IMAGING AND MACHINELEARNING BASED PHENOTYPIC ANALYSIS OF CROP SEED GERMINATION NEW PHYTOLOGIST 10.1111/nph.16736
26. 2020 DE M A;CAPOBIANGO N;DA S J;DA S L;DA S D INTERACTIVE MACHINE LEARNING FOR SOYBEAN SEED AND SEEDLING QUALITY CLASSIFICATION SCIENTIFIC REPORTS 10.1038/s41598-020-68273-y
27. 2020 GENZE N;BHARTI R;GRIEB M;SCHULTHEISS S;GRIMM D ACCURATE MACHINE LEARNINGBASED GERMINATION DETECTION PREDICTION AND QUALITY ASSESSMENT OF THREE GRAIN CROPS PLANT METHODS 10.1186/s13007-020-00699-x
28. 2020 DE M A;DA S L;DA S J;FERNANDES D S D D;PEREIRA M IJCROPSEED AN OPENACCESS TOOL FOR HIGHTHROUGHPUT ANALYSIS OF CROP SEED RADIOGRAPHS COMPUTERS AND ELECTRONICS IN AGRICULTURE 10.1016/j.compag.2020.105555
29. 2020 DE M A;PINHEIRO D;XAVIER W;DA S L;FERNANDES D S;DIAS D QUALITY CLASSIFICATION OF JATROPHA CURCAS SEEDS USING RADIOGRAPHIC IMAGES AND MACHINE LEARNING INDUSTRIAL CROPS AND PRODUCTS 10.1016/j.indcrop.2020.112162
30. 2020 DE M A;DA S L;RIBEIRO J;FERREIRA K;ROSAS J;SANTOS A;DA S C MACHINE LEARNING FOR SEED QUALITY CLASSIFICATION AN ADVANCED APPROACH USING MERGER DATA FROM FTNIR SPECTROSCOPY AND XRAY IMAGING SENSORS 10.3390/s20154319
31. 2020 WEI Y;LI X;PAN X;LI L NONDESTRUCTIVE CLASSIFICATION OF SOYBEAN SEED VARIETIES BY HYPERSPECTRAL IMAGING AND ENSEMBLE MACHINE LEARNING ALGORITHMS SENSORS 10.3390/s20236980
32. 2020 ALI A;QADRI S;MASHWANI W;BELHAOUARI S;NAEEM S;RAFIQUE S;JAMAL F;CHESNEAU C;ANAM S MACHINE LEARNING APPROACH FOR THE CLASSIFICATION OF CORN SEED USING HYBRID FEATURES INTERNATIONAL JOURNAL OF FOOD PROPERTIES 10.1080/10942912.2020.1778724
33. 2020 ZHU S;ZHANG J;CHAO M;XU X;SONG P;ZHANG J;HUANG Z A RAPID AND HIGHLY EFFICIENT METHOD FOR THE IDENTIFICATION OF SOYBEAN SEED VARIETIES HYPERSPECTRAL IMAGES COMBINED WITH TRANSFER LEARNING MOLECULES 10.3390/molecules25010152

34. 2020 MASTELING R;VOORHOEVE L;IJSELUIDEN F;DE B W;RAAIJMAKERS J DISCOUNT COMPUTER VISION FOR AUTOMATED QUANTIFICATION OF STRIGA SEED GERMINATION PLANT METHODS 10.1186/s13007-020-00602-8
35. 2020 YANG Y;CHEN J;HE Y;LIU F;FENG X;ZHANG J ASSESSMENT OF THE VIGOR OF RICE SEEDS BY NEARINFRARED HYPERSPECTRAL IMAGING COMBINED WITH TRANSFER LEARNING RSC ADVANCES 10.1039/d0ra06938h
36. 2020 ZHANG J;YANG Y;FENG X;XU H;CHEN J;HE Y IDENTIFICATION OF BACTERIAL BLIGHT RESISTANT RICE SEEDS USING TERAHERTZ IMAGING AND HYPERSPECTRAL IMAGING COMBINED WITH CONVOLUTIONAL NEURAL NETWORK FRONTIERS IN PLANT SCIENCE 10.3389/fpls.2020.00821
37. 2020 SHARMA A;SATISH D;SHARMA S;GUPTA D INDIAN MAJOR BASMATI PADDY SEED VARIETIES IMAGES DATASET DATA IN BRIEF 10.1016/j.dib.2020.106460
38. 2020 PRZYBYL K;WAWRZYNIAK J;KOSZELA F;GAWRYSIAK-WITULSKA M APPLICATION OF DEEP AND MACHINE LEARNING USING IMAGE ANALYSIS TO DETECT FUNGAL CONTAMINATION OF RAPESEED SENSORS 10.3390/s20247305
39. 2020 KOKLU M;OZKAN I MULTICLASS CLASSIFICATION OF DRY BEANS USING COMPUTER VISION AND MACHINE LEARNING TECHNIQUES COMPUTERS AND ELECTRONICS IN AGRICULTURE 10.1016/j.compag.2020.105507
40. 2020 LI X;FAN X;ZHAO L;HUANG S;HE Y;SUO X DISCRIMINATION OF PEPPER SEED VARIETIES BY MULTISPECTRAL IMAGING COMBINED WITH MACHINE LEARNING APPLIED ENGINEERING IN AGRICULTURE 10.13031/aea.13794
41. 2020 RADY A;GUYER D;DONIS-GONZALEZ W;WATSON N A COMPARISON OF DIFFERENT OPTICAL INSTRUMENTS AND MACHINE LEARNING TECHNIQUES TO IDENTIFY SPROUTING ACTIVITY IN POTATOES DURING STORAGE JOURNAL OF FOOD MEASUREMENT AND CHARACTERIZATION 10.1007/s11694-020-00590-2
42. 2020 GALLETTI P;CARVALHO M;HIRAI W;BRANCAGLIONI V;ARTHUR V;BARBOZA D S C INTEGRATING OPTICAL IMAGING TOOLS FOR RAPID AND NONINVASIVE CHARACTERIZATION OF SEED QUALITY TOMATO SOLANUM LYCOPERSICUM L AND CARROT DAUCUS CAROTA L AS STUDY CASES FRONTIERS IN PLANT SCIENCE 10.3389/fpls.2020.577851
43. 2020 GULZAR Y;HAMID Y;SOOMRO A;ALWAN A;JOURNAUX L A CONVOLUTION NEURAL NETWORKBASED SEED CLASSIFICATION SYSTEM SYMMETRY-BASEL 10.3390/sym12122018
44. 2020 KIRATIRATANAPRUK K;TEMNIRANRAT P;SINTHUPINYO W;PREMPREE P;CHAITAVON K;PORNTHEERAPHAT S;PRASERTSAK A DEVELOPMENT OF PADDY RICE SEED CLASSIFICATION PROCESS USING MACHINE LEARNING TECHNIQUES FOR AUTOMATIC GRADING MACHINE JOURNAL OF SENSORS 10.1155/2020/7041310
45. 2020 ZHANG L;SUN H;RAO Z;JI H HYPERSPECTRAL IMAGING TECHNOLOGY COMBINED WITH DEEP FOREST MODEL TO IDENTIFY FROSTDAMAGED RICE SEEDS SPECTROCHIMICA ACTA PART A-MOLECULAR AND BIOMOLECULAR SPECTROSCOPY 10.1016/j.saa.2019.117973
46. 2020 SAMIEI S;RASTI P;LY V J;BUI TINK D DEEP LEARNINGBASED DETECTION OF SEEDLING DEVELOPMENT PLANT METHODS 10.1186/s13007-020-00647-9
47. 2020 IHEONYE A;GARIEPY Y;RAGHAVAN V COMPUTER VISION FOR REALTIME MONITORING OF SHRINKAGE FOR PEAS DRIED IN A FLUIDIZED BED DRYER DRYING TECHNOLOGY 10.1080/07373937.2019.1649277
48. 2020 MADHUSUDHANA R D;NAGA S B;SARADA K;RAMARAO A HYPER SPECTRAL IMAGING TECHNOLOGY FOR SEED QUALITY IDENTIFICATION INDIAN JOURNAL OF ECOLOGY
49. 2020 YANG W;HUAI Y;ZHANG F GRAPE SEED CLASSIFICATION BASED ON GABOR AND DEEP NEURAL NETWORK GABOR DIANZI KEJI DAXUE XUEBAO/JOURNAL OF THE UNIVERSITY OF ELECTRONIC SCIENCE AND TECHNOLOGY OF CHINA 10.12178/1001-0548.2019164
50. 2020 SABANCI K DETECTION OF SUNN PESTDAMAGED WHEAT GRAINS USING ARTIFICIAL BEE COLONY OPTIMIZATIONBASED ARTIFICIAL INTELLIGENCE TECHNIQUES JOURNAL OF THE SCIENCE OF FOOD AND AGRICULTURE 10.1002/jsfa.10093
51. 2020 RUSLAN R;KHAIRUNNIZA-BEJO S;RUKUNUDIN I;JAHARI M;IBRAHIM M DEVELOPMENT OF A MACHINE VISION SYSTEM FOR RICE SEED INSPECTION SYSTEM FOOD RESEARCH 10.26656/fr.2017.4(S6).049

52. 2020 SINGH P;NAYYAR A;SINGH S;KAUR A CLASSIFICATION OF WHEAT SEEDS USING IMAGE PROCESSING AND FUZZY CLUSTERED RANDOM FOREST INTERNATIONAL JOURNAL OF AGRICULTURAL RESOURCES, GOVERNANCE AND ECOLOGY 10.1504/ijarge.2020.109048
53. 2021 SUN L;FAN X;HUANG S;LUO S;ZHAO L;CHEN X;HE Y;SUO X RESEARCH ON CLASSIFICATION METHOD OF EGGPLANT SEEDS BASED ON MACHINE LEARNING AND MULTISPECTRAL IMAGING CLASSIFICATION EGGPLANT SEEDS JOURNAL OF SENSORS 10.1155/2021/8857931
54. 2021 DUAN L D;YAN T Y;WANG J W;YE W Y;CHEN ;WEI C;GAO P G;LU X L COMBINE HYPERSPECTRAL IMAGING AND MACHINE LEARNING TO IDENTIFY THE AGE OF COTTON SEEDS SPECTROSCOPY AND SPECTRAL ANALYSIS 10.3964/j.issn.1000-0593(2021)12-3857-07
55. 2021 DA S C;MARTINS B V;DE ;MEDEIROS A;DUARTE D M M;MARASSI A;TANNUS A A NOVEL APPROACH FOR JATROPHA CURCAS SEED HEALTH ANALYSIS BASED ON MULTISPECTRAL AND RESONANCE IMAGING TECHNIQUES INDUSTRIAL CROPS AND PRODUCTS 10.1016/j.indcrop.2020.113186
56. 2021 DA S C;OLIVEIRA N;AMARAL D;CARVALHO M;DE M A;NOGUEIRA M;DOS R A AUTOFLUORESCENCESPECTRAL IMAGING AS AN INNOVATIVE METHOD FOR RAPID NONDESTRUCTIVE AND RELIABLE ASSESSING OF SOYBEAN SEED QUALITY SCIENTIFIC REPORTS 10.1038/s41598-021-97223-5
57. 2021 KUMAR R;BALOCH G;PANKAJ P;BURIRO J FUNGAL BLAST DISEASE DETECTION IN RICE SEED USING MACHINE LEARNING INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS
58. 2021 BAO F;BAMBIL D APPLICABILITY OF COMPUTER VISION IN SEED IDENTIFICATION DEEP LEARNING RANDOM FOREST AND SUPPORT VECTOR MACHINE CLASSIFICATION ALGORITHMS ACTA BOTANICA BRASILICA 10.1590/0102-33062020abb0361
59. 2021 SINGH P;CHATTERJEE A;RAJPUT L;RANA S;KUMAR S;NATARAJ V;BHATIA V;PRAKASH S DEVELOPMENT OF AN INTELLIGENT LASER BIOSPECKLE SYSTEM FOR EARLY DETECTION AND CLASSIFICATION OF SOYBEAN SEEDS INFECTED WITH SEEDBORNE FUNGAL PATHOGEN COLLETOTRICHUM TRUNCATUM BIOSYSTEMS ENGINEERING 10.1016/j.biosystemseng.2021.11.002
60. 2021 LI H;ZHANG L;SUN H;RAO Z;JI H IDENTIFICATION OF SOYBEAN VARIETIES BASED ON HYPERSPECTRAL IMAGING TECHNOLOGY AND ONEDIMENSIONAL CONVOLUTIONAL NEURAL NETWORK JOURNAL OF FOOD PROCESS ENGINEERING 10.1111/jfpe.13767
61. 2021 XU P;YANG R;ZENG T;ZHANG J;ZHANG Y;TAN Q VARIETAL CLASSIFICATION OF MAIZE SEEDS USING COMPUTER VISION AND MACHINE LEARNING TECHNIQUES JOURNAL OF FOOD PROCESS ENGINEERING 10.1111/jfpe.13846
62. 2021 GAO T;CHANDRAN A;PAUL P;WALIA H;YU H HYPERSEED AN ENDTOEND METHOD TO PROCESS HYPERSPECTRAL IMAGES OF SEEDS SENSORS 10.3390/s21248184
63. 2021 LODDO A;LODDO M;DI R C A NOVEL DEEP LEARNING BASED APPROACH FOR SEED IMAGE CLASSIFICATION AND RETRIEVAL COMPUTERS AND ELECTRONICS IN AGRICULTURE 10.1016/j.compag.2021.106269
64. 2021 YAN T;XU W;LIN J;DUAN L;GAO C;LV X COMBINING MULTIDIMENSIONAL CONVOLUTIONAL NEURAL NETWORK CNN WITH VISUALIZATION METHOD FOR DETECTION OF APHIS GOSSYPHII GLOVER INFECTION IN COTTON LEAVES USING HYPERSPECTRAL IMAGING FRONTIERS IN PLANT SCIENCE 10.3389/fpls.2021.604510
65. 2021 LANDA V;SHAPIRA Y;DAVID M;KARASIK A;WEISS E;REUVENI Y;DRORI E ACCURATE CLASSIFICATION OF FRESH AND CHARRED GRAPE SEEDS TO THE VARIETAL LEVEL USING MACHINE LEARNING BASED CLASSIFICATION METHOD SCIENTIFIC REPORTS 10.1038/s41598-021-92559-4
66. 2021 PANG L;WANG L;YUAN P;YAN L;YANG Q;XIAO J FEASIBILITY STUDY ON IDENTIFYING SEED VIABILITY OF SOPHORA JAPONICA WITH OPTIMIZED DEEP NEURAL NETWORK AND HYPERSPECTRAL IMAGING COMPUTERS AND ELECTRONICS IN AGRICULTURE 10.1016/j.compag.2021.106426
67. 2021 RIERA L;CARROLL M;ZHANG Z;SHOOK J;GHOSAL S;GAO T;SINGH A;BHATTACHARYA S;GANAPATHYSUBRAMANIAN B;SINGH A;SARKAR S DEEP MULTIVIEW IMAGE FUSION FOR SOYBEAN YIELD ESTIMATION IN BREEDING APPLICATIONS PLANT PHENOMICS 10.34133/2021/9846470
68. 2021 SINGH T;GARG N;IYENGAR S NONDESTRUCTIVE IDENTIFICATION OF BARLEY SEEDS VARIETY USING NEARINFRARED HYPERSPECTRAL IMAGING COUPLED WITH

- CONVOLUTIONAL NEURAL NETWORK JOURNAL OF FOOD PROCESS ENGINEERING
10.1111/jfpe.13821
69. 2021 ZIYAAE P; FARZAND A V; BAZYAR P; CAVALLO E COMPARISON OF DIFFERENT
IMAGE PROCESSING METHODS FOR SEGREGATION OF PEANUT ARACHIS HYPOGAEA L
SEEDS INFECTED BY AFLATOXIN PRODUCING FUNGI AGRONOMY-BASEL
10.3390/agronomy11050873
70. 2021 LODDO A; DI R C ON THE EFFICACY OF HANDCRAFTED AND DEEP FEATURES
FOR SEED IMAGE CLASSIFICATION JOURNAL OF IMAGING 10.3390/jimaging7090171
71. 2021 BANERJEE B; SHARMA V; SPANGENBERG G; KANT S MACHINE LEARNING REGRESSION
ANALYSIS FOR ESTIMATION OF CROP EMERGENCE USING MULTISPECTRAL UAV IMAGERY
REMOTE SENSING 10.3390/rs13152918
72. 2021 PEREIRA D; BUGATTI P; LOPES F; DE S A; SAITO P ASSESSING ACTIVE LEARNING
STRATEGIES TO IMPROVE THE QUALITY CONTROL OF THE SOYBEAN SEED VIGOR IEEE
TRANSACTIONS ON INDUSTRIAL ELECTRONICS 10.1109/TIE.2020.2969106
73. 2021 GAO J; LIU C; HAN J; LU H; ZHANG J; BAI X; LUO J IDENTIFICATION METHOD OF
WHEAT CULTIVARS BY USING A CONVOLUTIONAL NEURAL NETWORK COMBINED WITH
IMAGES OF MULTIPLE GROWTH PERIODS OF WHEAT SYMMETRY-BASEL
10.3390/sym13112012
74. 2021 MANHANDO E; ZHOU Y; WANG F EARLY DETECTION OF MOLD CONTAMINATED
PEANUTS USING MACHINE LEARNING AND DEEP FEATURES BASED ON OPTICAL
COHERENCE TOMOGRAPHY AGRICULTURE 10.3390/agriculture11030045
75. 2021 GE H; LV M; LU X; JIANG Y; WU G; LI G; LI L; LI Z; ZHANG Y APPLICATIONS OF THZ
SPECTRAL IMAGING IN THE DETECTION OF AGRICULTURAL PRODUCTS PHOTONICS
10.3390/photronics8110518
76. 2021 HESAMI M; PEPE M; MONTHONY A; BAITON A; JONES A MODELING AND
OPTIMIZING IN VITRO SEED GERMINATION OF INDUSTRIAL HEMP CANNABIS SATIVA L
INDUSTRIAL CROPS AND PRODUCTS 10.1016/j.indcrop.2021.113753
77. 2021 HU Y; ZHANG Z GRIDFREE A PYTHON PACKAGE OF IMAGE ANALYSIS FOR
INTERACTIVE GRAIN COUNTING AND MEASURING PLANT PHYSIOLOGY
10.1093/plphys/kiab226
78. 2021 SHARMA R; KUMAR M; ALAM M IMAGE PROCESSING TECHNIQUES TO ESTIMATE
WEIGHT AND MORPHOLOGICAL PARAMETERS FOR SELECTED WHEAT REFRACTIONS
SCIENTIFIC REPORTS 10.1038/s41598-021-00081-4
79. 2021 NAEEM S; ALI A; NASIR J; FATIMA A; JAMAL F; AHMED M; RIZWAN M; ANAM S; ZUBAIR M
AUTOMATED CORN SEED FUSARIUM DISEASE CLASSIFICATION SYSTEM USING
HYBRID FEATURE SPACE AND CONVENTIONAL MACHINE LEARNING TECHNIQUES
PROCEEDINGS OF THE PAKISTAN ACADEMY OF SCIENCES: PART A
10.53560/PPASA(58-2)692
80. 2021 KOKLU M; CINAR I; TASPINAR Y CLASSIFICATION OF RICE VARIETIES WITH DEEP
LEARNING METHODS COMPUTERS AND ELECTRONICS IN AGRICULTURE
10.1016/j.compag.2021.106285
81. 2021 ZHAO G; QUAN L; LI H; FENG H; LI S; ZHANG S; LIU R REALTIME RECOGNITION SYSTEM
OF SOYBEAN SEED FULL SURFACE DEFECTS BASED ON DEEP LEARNING COMPUTERS
AND ELECTRONICS IN AGRICULTURE 10.1016/j.compag.2021.106230
82. 2021 HABIB M AN ENHANCED SEEDS CATEGORIZATION AND CLASSIFICATION BASED
ON MULTIPLE FEATURES SET INDIAN JOURNAL OF COMPUTER SCIENCE AND
ENGINEERING 10.21817/indjcse/2021/v12i4/211204007
83. 2021 GANJLOO A; ZANDI M; BIMAKR M; GHAREH B A EVALUATION THE EFFECT OF
FARSI GUM CONTAINING HEMP SEED OIL COATING ON MASS AND VOLUME CHANGES OF
GRAPE DURING COLD STORAGE USING MACHINE VISION AND MACHINE LEARNING
SYSTEMS JOURNAL OF FOOD SCIENCE AND TECHNOLOGY (IRAN)
10.29252/fsct.18.04.13
84. 2021 LAABASSI K; BELARBI M; MAHMOUDI S; MAHMOUDI S; FERHAT K WHEAT VARIETIES
IDENTIFICATION BASED ON A DEEP LEARNING APPROACH JOURNAL OF THE SAUDI
SOCIETY OF AGRICULTURAL SCIENCES 10.1016/j.jssas.2021.02.008
85. 2021 TU K; WEN S; CHENG Y; ZHANG T; PAN T; WANG J; WANG J; SUN Q A
NONDESTRUCTIVE AND HIGHLY EFFICIENT MODEL FOR DETECTING THE GENUINENESS OF
MAIZE VARIETY JINGKE 968 USING MACHINE VISION COMBINED WITH DEEP LEARNING
COMPUTERS AND ELECTRONICS IN AGRICULTURE
10.1016/j.compag.2021.106002

86. 2022 SHI Y;PATEL Y;ROSTAMI B;CHEN L;YU Z;LI Y BARLEY VARIETY IDENTIFICATION BY IPHONE IMAGES AND DEEP LEARNING JOURNAL OF THE AMERICAN SOCIETY OF BREWING CHEMISTS 10.1080/03610470.2021.1958602
87. 2022 YAMAN F;KAHRIMAN F CLASSIFICATION OF VIABLE NONVIABLE SEEDS OF SPECIALTY MAIZE GENOTYPES USING SPECTRAL AND IMAGE DATA PLUS MORPHOLOGICAL FEATURES JOURNAL OF CROP IMPROVEMENT 10.1080/15427528.2021.1960942
88. 2022 ROPELEWSKA E;PIECKO J DISCRIMINATION OF TOMATO SEEDS BELONGING TO DIFFERENT CULTIVARS USING MACHINE LEARNING EUROPEAN FOOD RESEARCH AND TECHNOLOGY 10.1007/s00217-021-03920-w
89. 2022 MONTEIRO R;GADOTTI G;VILLELA F;CARDOSO J;DE O M FISSURE IDENTIFICATION METHODS IN RICE SEEDS AFTER ARTIFICIAL DRYING ENGENHARIA AGRICOLA 10.1590/1809-4430-Eng.Agric.v42nepe20210148/2022
90. 2022 RUSLAN R;KHAIRUNNIZA-BEJO S;JAHARI M WEEDY RICE CLASSIFICATION USING IMAGE PROCESSING AND A MACHINE LEARNING APPROACH AGRICULTURE-BASEL 10.3390/agriculture12050645
91. 2022 JIN B;QI H;JIA L;TANG L;LI Z;ZHAO G DETERMINATION OF VIABILITY AND VIGOR OF NATURALLY AGED RICE SEEDS USING HYPERSPECTRAL IMAGING WITH MACHINE LEARNING INFRARED PHYSICS & TECHNOLOGY 10.1016/j.infrared.2022.104097
92. 2022 TU K;WEN S;CHENG Y;XU Y;PAN T;HOU H;GU R;WANG J;WANG Q A MODEL FOR GENUINENESS DETECTION IN GENETICALLY AND PHENOTYPICALLY SIMILAR MAIZE VARIETY SEEDS BASED ON HYPERSPECTRAL IMAGING AND MACHINE LEARNING PLANT METHODS 10.1186/s13007-022-00918-7
93. 2022 CASTRO E;MELO R;DA C E;PESSOA A;OLIVEIRA R;BERTINI C CLASSIFICATION OF PHASEOLUS LUNATUS L USING IMAGE ANALYSIS AND MACHINE LEARNING MODELS1 REVISTA CAATINGA 10.1590/1983-21252022v35n404rc
94. 2022 ARIUNZAYA G;BAASANMUNKH S;CHOI J;CHUNG S A MULTICONSIDERED SEED COAT PATTERN CLASSIFICATION OF ALLIUM L USING UNSUPERVISED MACHINE LEARNING PLANTS-BASEL 10.3390/plants11223097
95. 2022 HU Y;WANG Z;LI X;LI L;WANG X;WEI Y NONDESTRUCTIVE CLASSIFICATION OF MAIZE MOLDY SEEDS BY HYPERSPECTRAL IMAGING AND OPTIMAL MACHINE LEARNING ALGORITHMS SENSORS 10.3390/s22166064
96. 2022 BATISTA T;MASTRANGELO C;DE ;MEDEIROS A;PETRONILIO A;FONSECA ;DE O G;DOS S I;CRUSCIOL C;DA S E A RELIABLE METHOD TO RECOGNIZE SOYBEAN SEED MATURATION STAGES BASED ON AUTOFLUORESCENCESPECTRAL IMAGING COMBINED WITH MACHINE LEARNING ALGORITHMS FRONTIERS IN PLANT SCIENCE 10.3389/fpls.2022.914287
97. 2022 TU K;CHENG Y;NING C;YANG X;CAO H;SUN Q NONDESTRUCTIVE VIABILITY DISCRIMINATION FOR INDIVIDUAL SCUTELLARIA BAICALENSIS SEEDS BASED ON HIGH THROUGHPUT PHENOTYPING AND MACHINE LEARNING AGRICULTURE-BASEL 10.3390/agriculture12101616
98. 2022 ZHANG H;HOU Q;LUO B;TU K;ZHAO C;SUN Q DETECTION OF SEED PURITY OF HYBRID WHEAT USING REFLECTANCE AND TRANSMITTANCE HYPERSPECTRAL IMAGING TECHNOLOGY FRONTIERS IN PLANT SCIENCE 10.3389/fpls.2022.1015891
99. 2022 FONSECA D O G;MASTRANGELO C;HIRAI W;BATISTA T;SUDKI J;PICININI P A;COSTA C C;AMARAL D S E AN APPROACH USING EMERGING OPTICAL TECHNOLOGIES AND ARTIFICIAL INTELLIGENCE BRINGS NEW MARKERS TO EVALUATE PEANUT SEED QUALITY FRONTIERS IN PLANT SCIENCE 10.3389/fpls.2022.849986
100. 2022 MUKASA P;WAKHOLI C;FAQEERZADA H;KIM H;JOSHI R;SUH G;LEE H;KIM M;BAEK I;CHO B NONDESTRUCTIVE DISCRIMINATION OF SEEDLESS FROM SEEDED WATERMELON SEEDS BY USING MULTIVARIATE AND DEEP LEARNING IMAGE ANALYSIS COMPUTERS AND ELECTRONICS IN AGRICULTURE 10.1016/j.compag.2022.106799
101. 2022 POZZA E;ALVES M;SANCHES L USING COMPUTER VISION TO IDENTIFY SEEDBORNE FUNGI AND OTHER TARGETS ASSOCIATED WITH COMMON BEAN SEEDS BASED ON REDGREENBLUE SPECTRAL DATA TROPICAL PLANT PATHOLOGY 10.1007/s40858-021-00485-7
102. 2022 CRUZ-TIRADO J;DE F P;BARBIN D CHIA SALVIA HISPANICA SEEDS DEGRADATION STUDIED BY FUZZY C MEAN FCM AND HYPERSPECTRAL IMAGING AND CHEMOMETRICS FATTY ACIDS QUANTIFICATION SCIENTIA AGROPECUARIA 10.17268/sci.agropecu.2022.015

103. 2022 GIERZ L;PRZYBYL K TEXTURE ANALYSIS AND ARTIFICIAL NEURAL NETWORKS FOR IDENTIFICATION OF CEREALS CASE STUDY WHEAT BARLEY AND RAPE SEEDS SCIENTIFIC REPORTS 10.1038/s41598-022-23838-x
104. 2022 YASAM S;NAIR S;KUMAR K SUPERVISED LEARNING BASED SEED GERMINATION ABILITY PREDICTION FOR PRECISION FARMING SOFT COMPUTING 10.1007/s00500-022-06910-6
105. 2022 PANG L;WANG L;YUAN P;YAN L;XIAO J RAPID SEED VIABILITY PREDICTION OF SOPHORA JAPONICA BY IMPROVED SUCCESSIVE PROJECTION ALGORITHM AND HYPERSPECTRAL IMAGING INFRARED PHYSICS & TECHNOLOGY 10.1016/j.infrared.2022.104143
106. 2022 XUE Q;MIAO P;MIAO K;YU Y;LI Z XRAY BASED MACHINE VISION TECHNIQUE FOR DETECTION OF INTERNAL DEFECTS OF STERCULIA SEEDS JOURNAL OF FOOD SCIENCE 10.1111/1750-3841.16237
107. 2022 XU Y;WU W;CHEN Y;ZHANG T;TU K;HAO Y;CAO H;DONG X;SUN Q HYPERSPECTRAL IMAGING WITH MACHINE LEARNING FOR NONDESTRUCTIVE CLASSIFICATION OF ASTRAGALUS MEMBRANACEUS VAR MONGHOLICUS ASTRAGALUS MEMBRANACEUS AND SIMILAR SEEDS FRONTIERS IN PLANT SCIENCE 10.3389/fpls.2022.1031849
108. 2022 WU Q;XU L;ZOU Z;WANG J;ZENG Q;WANG Q;ZHEN J;WANG Y;ZHAO Y;ZHOU M RAPID NONDESTRUCTIVE DETECTION OF PEANUT VARIETIES AND PEANUT MILDEW BASED ON HYPERSPECTRAL IMAGING AND STACKED MACHINE LEARNING MODELS FRONTIERS IN PLANT SCIENCE 10.3389/fpls.2022.1047479
109. 2022 WANG J;YAN L;WANG F;QI S SVM CLASSIFICATION METHOD OF WAXY CORN SEEDS WITH DIFFERENT VITALITY LEVELS BASED ON HYPERSPECTRAL IMAGING JOURNAL OF SENSORS 10.1155/2022/4379317
110. 2022 OTT T;LAUTENSCHLAGER U GINJINN2 OBJECT DETECTION AND SEGMENTATION FOR ECOLOGY AND EVOLUTION METHODS IN ECOLOGY AND EVOLUTION 10.1111/2041-210X.13787
111. 2022 XU P;ZHANG Y;TAN Q;XU K;SUN W;XING J;YANG R VIGOR IDENTIFICATION OF MAIZE SEEDS BY USING HYPERSPECTRAL IMAGING COMBINED WITH MULTIVARIATE DATA ANALYSIS INFRARED PHYSICS & TECHNOLOGY 10.1016/j.infrared.2022.104361
112. 2022 WANG L;PANG L;YAN L;ZHANG J NONDESTRUCTIVE RAPID IDENTIFICATION OF SOYBEAN VARIETIES USING HYPERSPECTRAL IMAGING TECHNOLOGY JOURNAL OF APPLIED SPECTROSCOPY 10.1007/s10812-022-01329-1
113. 2022 RODRIGUEZ D;URBAN M;SANTAELLA M;GEREDA J;CONTRERAS P USING PHENOMICS TO IDENTIFY AND INTEGRATE TRAITS OF INTEREST FOR BETTER PERFORMING COMMON BEANS A VALIDATION STUDY ON AN INTERSPECIFIC HYBRID AND ITS ACUTIFOLII PARENTS FRONTIERS IN PLANT SCIENCE 10.3389/fpls.2022.1008666
114. 2022 ZHAO Q;ZHANG Z;HUANG Y;FANG J TPERBFSVM MODEL FOR SOYBEAN CATEGORIES RECOGNITION IN SELECTED HYPERSPECTRAL BANDS BASED ON EXTREME GRADIENT BOOSTING FEATURE IMPORTANCE VALUES AGRICULTURE-BASEL 10.3390/agriculture12091452
115. 2022 LIU Q;WANG Z;LONG Y;ZHANG C;FAN S;HUANG W VARIETY CLASSIFICATION OF COATED MAIZE SEEDS BASED ON RAMAN HYPERSPECTRAL IMAGING SPECTROCHIMICA ACTA PART A-MOLECULAR AND BIOMOLECULAR SPECTROSCOPY 10.1016/j.saa.2021.120772
116. 2022 JIAO Y;LIANG B;YANG G;XIN D A SIMPLE AND EFFICIENT METHOD TO QUANTIFY THE CELL PARAMETERS OF THE SEED COAT EMBRYO AND SILIQUE WALL IN RAPESEED PLANT METHODS 10.1186/s13007-022-00948-1
117. 2022 MEDEIROS M;CRUZ-TIRADO J;LIMA A;NETTO J;RIBEIRO A;BASSEGIO D;GODOY H;BARBIN D ASSESSMENT OIL COMPOSITION AND SPECIES DISCRIMINATION OF BRASSICAS SEEDS BASED ON HYPERSPECTRAL IMAGING AND PORTABLE NEAR INFRARED NIR SPECTROSCOPY TOOLS AND CHEMOMETRICS JOURNAL OF FOOD COMPOSITION AND ANALYSIS 10.1016/j.jfca.2022.104403
118. 2022 CHEN J;LUO T;WU J;WANG Z;ZHANG H A VISION TRANSFORMER NETWORK SEEDVIT FOR CLASSIFICATION OF MAIZE SEEDS JOURNAL OF FOOD PROCESS ENGINEERING 10.1111/jfpe.13998
119. 2022 HUANG B;LIU J;JIAO J;LU J;LV D;MAO J;ZHAO Y;ZHANG Y APPLICATIONS OF MACHINE LEARNING IN PINE NUTS CLASSIFICATION SCIENTIFIC REPORTS 10.1038/s41598-022-12754-9

120. 2022 AQIL M;AZRAI M;MEJAYA M;SUBEKTI N;TABRI F;ANDAYANI N;WATI R;PANIKKAI S;SUWARDI S;BUNYAMIN Z;ROY E;MUSLIMIN M;YASIN M;PRAKASA E RAPID DETECTION OF HYBRID MAIZE PARENTAL LINES USING STACKING ENSEMBLE MACHINE LEARNING APPLIED COMPUTATIONAL INTELLIGENCE AND SOFT COMPUTING 10.1155/2022/6588949
121. 2022 AGGARWAL S;SUCHITHRA M;CHANDRAMOULI N;SARADA M;VERMA A;VETRITHANGAM D;PANT B;ADUGNA B RICE DISEASE DETECTION USING ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING TECHNIQUES TO IMPROVISE AGROBUSINESS SCIENTIFIC PROGRAMMING 10.1155/2022/1757888
122. 2022 DONMEZ E ENHANCING CLASSIFICATION CAPACITY OF CNN MODELS WITH DEEP FEATURE SELECTION AND FUSION A CASE STUDY ON MAIZE SEED CLASSIFICATION DATA & KNOWLEDGE ENGINEERING 10.1016/j.datak.2022.102075
123. 2022 KISHORE B;YASAR A;TASPINAR R;CINAR I;SHANKAR V;KOKLU M;OFORI I COMPUTERAIDED MULTICLASS CLASSIFICATION OF CORN FROM CORN IMAGES INTEGRATING DEEP FEATURE EXTRACTION COMPUTATIONAL INTELLIGENCE AND NEUROSCIENCE 10.1155/2022/2062944
124. 2022 ZHOU J;BECHE E;VIEIRA C;YUNGBLUTH D;ZHOU J;SCABOO A;CHEN P IMPROVE SOYBEAN VARIETY SELECTION ACCURACY USING UAVBASED HIGHTHROUGHPUT PHENOTYPING TECHNOLOGY FRONTIERS IN PLANT SCIENCE 10.3389/fpls.2021.768742
125. 2022 ZHAO X;WANG X;LI C;FU H;YANG S;ZHAI C CABBAGE AND WEED IDENTIFICATION BASED ON MACHINE LEARNING AND TARGET SPRAYING SYSTEM DESIGN FRONTIERS IN PLANT SCIENCE 10.3389/fpls.2022.924973
126. 2022 CASTRO B;MELO R;DA C E;PESSOA A;OLIVEIRA R;BERTINI C CLASSIFICATION OF PHASEOLUS LUNATUS L USING IMAGE ANALYSIS AND MACHINE LEARNING MODELS CLASSIFICAÇÃO DE PHASEOLUS LUNATUS L USANDO TÉCNICA DE ANÁLISE DE IMAGEM E MODELOS DE APRENDIZAGEM DE MÁQUINA REVISTA CAATINGA 10.1590/1983-21252022v35n404rc
127. 2022 GUO X;LI J;ZHENG L;ZHANG M;WANG M ACQUIRING SOYBEAN PHENOTYPIC PARAMETERS USING REYOLOV5 AND AREA SEARCH ALGORITHM REYOLOV5 NONGYE GONGCHENG XUEBAO/TRANSACTIONS OF THE CHINESE SOCIETY OF AGRICULTURAL ENGINEERING 10.11975/j.issn.1002-6819.2022.15.020
128. 2022 GEOLLEGUE K;ARBOLEDA E;DIZON A SEED OF RICE PLANT CLASSIFICATION USING COARSE TREE CLASSIFIER IAES INTERNATIONAL JOURNAL OF ARTIFICIAL INTELLIGENCE 10.11591/ijai.v11.i2.pp727-735
129. 2022 ROPELEWSKA E;PIECKO J DISCRIMINATION OF TOMATO SEEDS BELONGING TO DIFFERENT CULTIVARS USING MACHINE LEARNING EUROPEAN FOOD RESEARCH AND TECHNOLOGY 10.1007/s00217-021-03920-w
130. 2022 ZHAO J;ZHOU J;DAI J;DING G;XU L;GUAN X;ZHOU J DEVELOPING VISIONBASED ANALYTIC ALGORITHMS AND SOFTWARE TO DYNAMICALLY MEASURE KEY TRAITS IN SEED GERMINATION JOURNAL OF NANJING AGRICULTURAL UNIVERSITY 10.7685/jnau.202111042
131. 2022 SHI Y;PATEL Y;ROSTAMI B;CHEN H;WU L;YU Z;LI Y BARLEY VARIETY IDENTIFICATION BY IPHONE IMAGES AND DEEP LEARNING JOURNAL OF THE AMERICAN SOCIETY OF BREWING CHEMISTS 10.1080/03610470.2021.1958602
132. 2022 YAMAN F;KAHRIMAN F CLASSIFICATION OF VIABLE NONVIABLE SEEDS OF SPECIALTY MAIZE GENOTYPES USING SPECTRAL AND IMAGE DATA PLUS MORPHOLOGICAL FEATURES JOURNAL OF CROP IMPROVEMENT 10.1080/15427528.2021.1960942
133. 2022 NADIMI M;DIVYANTH L;PALIWAL J AUTOMATED DETECTION OF MECHANICAL DAMAGE IN FLAXSEEDS USING RADIOGRAPHIC IMAGING AND MACHINE LEARNING FOOD AND BIOPROCESS TECHNOLOGY 10.1007/s11947-022-02939-5
134. 2022 YANG Y;LIAO J;LI H;TAN K;ZHANG X IDENTIFICATION OF HIGH OIL CONTENT SOYBEAN USING HYPERSPECTRAL REFLECTANCE AND ONE-DIMENSIONAL CONVOLUTIONAL NEURAL NETWORK SPECTROSCOPY LETTERS 10.1080/00387010.2022.2160463
135. 2022 LODDO A;DI R C;VALE A;UCCHESU J;BACCHETTA G AN EFFECTIVE AND FRIENDLY TOOL FOR SEED IMAGE ANALYSIS VISUAL COMPUTER 10.1007/s00371-021-02333-w

136. 2022 JIN B;ZHANG C;JIA L;TANG Q;GAO L;ZHAO G;QI H IDENTIFICATION OF RICE SEED VARIETIES BASED ON NEARINFRARED HYPERSPECTRAL IMAGING TECHNOLOGY COMBINED WITH DEEP LEARNING ACS OMEGA 10.1021/acsomega.1c04102

APÊNDICE 2

LISTA DE ESPÉCIES ANALISADAS COM LEVANTAMENTO DE INFORMAÇÕES SOBRE A OCORRÊNCIA NOS BIOMAS BRASILEIROS.

Espécie	Família	Formas de vida	Biomas com ocorrência registrada					
			1	2	3	4	5	6
<i>Abrus precatorius</i>	Fabaceae	Liana/volúvel/trepadeira	X	X	X	X	X	X
<i>Aegiphila integrifolia</i>	Lamiaceae	Arbusto, Árvore	X	X	X	X	X	X
<i>Albizia niopoides</i>	Fabaceae	Arbusto	X	X		X		X
<i>Alchornea glandulosa</i>	Euphorbiaceae	Arbusto, Árvore	X	X		X		
<i>Allophylus edulis</i>	Sapindaceae	Arbusto, Árvore	X	X	X	X	X	X
<i>Allophylus guaraniticus</i>	Sapindaceae	Arbusto, Árvore				X		X
<i>Amburana cearensis</i>	Fabaceae	Árvore		X	X	X	X	
<i>Anadenanthera colubrina</i>	Fabaceae	Arbusto, Árvore		X	X	X		
<i>Annona cacans</i>	Annonaceae	Árvore				X		X
<i>Annona emarginata</i>	Annonaceae	Arbusto, Árvore		X	X	X	X	X
<i>Annona mucosa</i>	Annonaceae	Árvore	X	X		X		
<i>Annona sylvatica</i>	Annonaceae	Árvore		X	X	X	X	X
<i>Araucaria angustifolia</i>	Araucariaceae	Árvore				X		X
<i>Aspidosperma parvifolium</i>	Apocynaceae	Árvore				X		
<i>Aspidosperma pyriforme</i>	Apocynaceae	Árvore		X	X			
<i>Aspidosperma subincanum</i>	Apocynaceae	Árvore	X	X		X		
<i>Astronium urundeuva</i>	Anacardiaceae	Árvore		X	X	X	X	X
<i>Ateleia glazioviana</i>	Fabaceae	Árvore		X		X		X
<i>Balfourodendron riedelianum</i>	Rutaceae	Árvore		X		X		
<i>Bauhinia forficata</i>	Fabaceae	Árvore				X		X
<i>Berberis laurina</i>	Berberidaceae	Arbusto, Árvore				X		X
<i>Bixa orellana</i>	Bixaceae	Arbusto, Árvore	X	X		X		
<i>Butia capitata</i>	Arecaceae	Palmeira		X				
<i>Butia eriospatha</i>	Arecaceae	Palmeira				X		
<i>Calliandra brevipes</i>	Fabaceae	Arbusto	X	X	X	X		X
<i>Calopogonium mucunoides</i>	Fabaceae	Erva, Liana/volúvel/trepadeira	X	X	X	X	X	
<i>Campomanesia xanthocarpa</i>	Myrtaceae	Árvore				X		X
<i>Cassia ferruginea</i>	Fabaceae	Árvore		X	X	X		
<i>Cassia grandis</i>	Fabaceae	Árvore	X	X		X	X	
<i>Cassia leptophylla</i>	Fabaceae	Árvore				X		
<i>Cecropia glaziovii</i>	Urticaceae	Árvore				X		
<i>Cecropia hololeuca</i>	Urticaceae	Árvore		X		X		
<i>Cecropia pachystachya</i>	Urticaceae	Árvore	X	X	X	X	X	X
<i>Cecropia peltata</i>	Urticaceae	Árvore	X					
<i>Cecropia sciadophylla</i>	Urticaceae	Árvore	X					
<i>Cedrela fissilis</i>	Meliaceae	Árvore	X	X	X	X	X	X

<i>Ceiba speciosa</i>	Malvaceae	Árvore	X	X	X	X	X	X
<i>Cenostigma microphyllum</i>	Fabaceae	Arbusto, Árvore			X			
<i>Cenostigma pyramidale</i>	Fabaceae	Arbusto, Árvore	X		X			
<i>Cereus jamacaru</i>	Cactaceae	Suculenta		X	X			
<i>Clitoria fairchildiana</i>	Fabaceae	Árvore	X	X	X	X		
<i>Cnidoscolus quercifolius</i>	Euphorbiaceae	Arbusto, Árvore			X			
<i>Cochlospermum orinocense</i>	Bixaceae	Árvore	X					
<i>Commiphora leptophloeos</i>	Burseraceae	Arbusto, Árvore	X	X	X			
<i>Copernicia prunifera</i>	Arecaceae	Palmeira		X	X			
<i>Cordia superba</i>	Boraginaceae	Arbusto, Árvore		X	X	X		
<i>Croton blanchetianus</i>	Euphorbiaceae	Arbusto, Árvore			X			
<i>Croton floribundus</i>	Euphorbiaceae	Árvore				X		
<i>Cryptocarya aschersoniana</i>	Lauraceae	Árvore				X		
<i>Cupania vernalis</i>	Sapindaceae	Árvore	X	X	X	X	X	X
<i>Dalbergia brasiliensis</i>	Fabaceae	Árvore		X		X		
<i>Dalbergia ecastaphyllum</i>	Fabaceae	Arbusto, Liana/volúvel/trepadeira	X			X		
<i>Dalbergia frutescens</i>	Fabaceae	Arbusto, Liana/volúvel/trepadeira	X	X	X	X		X
<i>Dictyoloma vandellianum</i>	Rutaceae	Árvore	X	X	X	X		
<i>Dimorphandra mollis</i>	Fabaceae	Árvore	X	X			X	
<i>Diospyros inconstans</i>	Ebenaceae	Arbusto, Árvore	X	X	X	X	X	X
<i>Drimys brasiliensis</i>	Winteraceae	Arbusto, Árvore		X	X	X		
<i>Encholirium spectabile</i>	Bromeliaceae	Erva			X	X		
<i>Enterolobium contortisiliquum</i>	Fabaceae	Árvore		X	X	X	X	X
<i>Enterolobium timbouva</i>	Fabaceae	Árvore	X	X	X	X	X	
<i>Erythrina speciosa</i>	Fabaceae	Arbusto, Árvore		X		X		
<i>Erythroxylum argentinum</i>	Erythroxylaceae	Arbusto, Árvore				X		
<i>Euphorbia heterophylla</i>	Euphorbiaceae	Erva	X		X			
<i>Euterpe edulis</i>	Arecaceae	Palmeira		X		X		
<i>Gallesia integrifolia</i>	Phytolaccaceae	Árvore	X	X	X	X		
<i>Gaylussacia brasiliensis</i>	Ericaceae	Arbusto, Árvore, Subarbusto		X	X	X		X
<i>Genipa americana</i>	Rubiaceae	Arbusto, Árvore	X	X	X	X	X	
<i>Guazuma ulmifolia</i>	Malvaceae	Árvore	X	X	X	X	X	X
<i>Gymnanthes klotzschiana</i>	Euphorbiaceae	Arbusto, Árvore			X	X		
<i>Handroanthus albus</i>	Bignoniaceae	Árvore				X		
<i>Handroanthus chrysotrichus</i>	Bignoniaceae	Árvore		X		X		X
<i>Handroanthus heptaphyllus</i>	Bignoniaceae	Árvore		X		X		X
<i>Handroanthus impetiginosus</i>	Bignoniaceae	Árvore	X	X	X	X	X	
<i>Handroanthus ochraceus</i>	Bignoniaceae	Árvore	X	X	X	X		
<i>Helietta apiculata</i>	Rutaceae	Árvore		X		X		X
<i>Hevea brasiliensis</i>	Euphorbiaceae	Árvore	X					
<i>Hymenaea altissima</i>	Fabaceae	Árvore				X		

<i>Hymenaea courbaril</i>	Fabaceae	Árvore	X	X	X	X	X	
<i>Ilex paraguariensis</i>	Aquifoliaceae	Arbusto, Árvore		X	X	X		X
<i>Inga lentiscifolia</i>	Fabaceae	Arbusto, Árvore				X		X
<i>Jatropha curcas</i>	Euphorbiaceae	Árvore	X	X	X	X	X	
<i>Jatropha mollissima</i>	Euphorbiaceae	Arbusto, Árvore	X	X	X			
<i>Lafoensia glyptocarpa</i>	Lythraceae	Árvore		X				
<i>Lafoensia pacari</i>	Lythraceae	Árvore		X				
<i>Leptolobium dasycarpum</i>	Fabaceae	Árvore	X	X				
<i>Leucochloron incuriale</i>	Fabaceae	Arbusto, Árvore		X		X		
<i>Libidibia ferrea</i>	Fabaceae	Árvore		X	X	X		
<i>Lithraea molleoides</i>	Anacardiaceae	Arbusto, Árvore		X		X	X	X
<i>Lonchocarpus cultratus</i>	Fabaceae	Árvore	X	X	X	X	X	
<i>Lophanthera lactescens</i>	Malpighiaceae	Árvore	X					
<i>Luehea divaricata</i>	Malvaceae	Árvore		X	X	X	X	X
<i>Mabea fistulifera</i>	Euphorbiaceae	Arbusto, Árvore	X	X	X	X		
<i>Machaerium acutifolium</i>	Fabaceae	Árvore	X	X	X	X	X	
<i>Machaerium stipitatum</i>	Fabaceae	Árvore		X		X		X
<i>Machaerium villosum</i>	Fabaceae	Árvore		X	X	X	X	
<i>Manihot carthagenensis</i>	Euphorbiaceae	Arbusto, Árvore	X	X	X			
<i>Manilkara elata</i>	Sapotaceae	Árvore	X			X		
<i>Matayba elaeagnoides</i>	Sapindaceae	Arbusto, Árvore		X		X		X
<i>Miconia theaezans</i>	Melastomataceae	Arbusto, Árvore		X		X		
<i>Mimosa bimucronata</i>	Fabaceae	Arbusto, Árvore		X	X	X	X	X
<i>Mimosa flocculosa</i>	Fabaceae	Arbusto, Árvore		X		X		
<i>Mimosa ophthalmocentra</i>	Fabaceae	Arbusto, Árvore			X			
<i>Mimosa pigra</i>	Fabaceae	Arbusto	X	X	X	X	X	
<i>Mimosa scabrella</i>	Fabaceae	Árvore				X		
<i>Mimosa tenuiflora</i>	Fabaceae	Arbusto, Árvore, Subarbusto		X	X			
<i>Monteverdia ilicifolia</i>	Celastraceae	Arbusto		X		X	X	X
<i>Mucuna pruriens</i>	Fabaceae	Liana/volúvel/trepadeira	X	X	X	X		
<i>Myrocarpus frondosus</i>	Fabaceae	Árvore				X		
<i>Nectandra lanceolata</i>	Lauraceae	Árvore		X		X	X	
<i>Neocalyptocalyx longifolium</i>	Capparaceae	Arbusto			X			
<i>Ormosia arborea</i>	Fabaceae	Árvore		X		X		
<i>Pachira glabra</i>	Malvaceae	Árvore		X	X	X	X	
<i>Parapiptadenia rigida</i>	Fabaceae	Árvore				X		X
<i>Peltophorum dubium</i>	Fabaceae	Árvore		X	X	X	X	
<i>Phytolacca dioica</i>	Phytolaccaceae	Árvore				X		X
<i>Piptadenia gonoacantha</i>	Fabaceae	Árvore		X		X		
<i>Pityrocarpa moniliformis</i>	Fabaceae	Arbusto, Árvore			X			
<i>Platypodium elegans</i>	Fabaceae	Árvore	X	X	X	X		
<i>Pleroma raddianum</i>	Melastomataceae	Árvore				X		
<i>Pleroma sellowianum</i>	Melastomataceae	Árvore				X		
<i>Podocarpus lambertii</i>	Podocarpaceae	Árvore		X	X	X		X
<i>Poecilanthe parviflora</i>	Fabaceae	Árvore				X		

<i>Prunus brasiliensis</i>	Rosaceae	Arbusto, Árvore		X		X		
<i>Psidium cattleianum</i>	Myrtaceae	Arbusto, Árvore		X	X	X		
<i>Psidium guajava</i>	Myrtaceae	Árvore	X	X	X	X		X
<i>Psidium myrtoides</i>	Myrtaceae	Árvore		X	X	X		
<i>Pterocarpus rohrii</i>	Fabaceae	Árvore	X					
<i>Pterogyne nitens</i>	Fabaceae	Árvore		X	X	X		
<i>Sapindus saponaria</i>	Sapindaceae	Árvore	X	X		X	X	
<i>Sarcomphalus joazeiro</i>	Rhamnaceae	Árvore			X			
<i>Schinopsis brasiliensis</i>	Anacardiaceae	Árvore		X	X			
<i>Schinus terebinthifolia</i>	Anacardiaceae	Arbusto, Árvore		X	X	X		X
<i>Schizolobium parahyba</i>	Fabaceae	Árvore	X			X		
<i>Senegalia bonariensis</i>	Fabaceae	Arbusto, Liana/volúvel/trepadeira				X		X
<i>Senna macranthera</i>	Fabaceae	Arbusto, Árvore		X	X	X		
<i>Senna multijuga</i>	Fabaceae	Arbusto, Árvore	X	X	X	X		
<i>Senna pendula</i>	Fabaceae	Arbusto, Árvore, Liana/volúvel/trepadeira	X	X	X	X	X	X
<i>Senna spectabilis</i>	Fabaceae	Árvore	X	X	X	X		
<i>Sesbania punicea</i>	Fabaceae	Arbusto				X	X	X
<i>Sesbania virgata</i>	Fabaceae	Arbusto		X	X	X	X	X
<i>Solanum granulosoaleprosum</i>	Solanaceae	Árvore		X		X		X
<i>Solanum lycocarpum</i>	Solanaceae	Arbusto, Árvore		X		X		
<i>Solanum viarum</i>	Solanaceae	Arbusto	X	X		X	X	X
<i>Spondias tuberosa</i>	Anacardiaceae	Arbusto, Árvore		X	X			
<i>Stryphnodendron adstringens</i>	Fabaceae	Arbusto, Árvore		X	X			
<i>Styrax leprosus</i>	Styracaceae	Árvore				X		X
<i>Syagrus romanzoffiana</i>	Arecaceae	Palmeira		X		X		X
<i>Tabebuia aurea</i>	Bignoniaceae	Árvore	X	X	X	X	X	
<i>Terminalia glabrescens</i>	Combretaceae	Arbusto, Árvore	X	X	X	X		
<i>Terminalia mameluco</i>	Combretaceae	Árvore			X	X		
<i>Vassobia breviflora</i>	Solanaceae	Arbusto				X		
<i>Vernonanthura discolor</i>	Asteraceae	Árvore		X		X		
<i>Vitex megapotamica</i>	Lamiaceae	Arbusto, Árvore		X	X	X		
<i>Xiquexique gounellei</i>	Cactaceae	Suculenta			X			
<i>Zanthoxylum rhoifolium</i>	Rutaceae	Árvore	X	X	X	X	X	X

Legenda: 1 – Amazônia; 2 – Cerrado; 3 – Caatinga; 4 – Mata Atlântica; 5 – Pantanal; 6 – Pampa.

FONTE: Flora do Brasil 2020. Jardim Botânico do Rio de Janeiro. Disponível em: < <http://floradobrasil.jbrj.gov.br/> >. Acesso em: 04 mai. 2022

APÊNDICE 3

MATRIZ DE CONFUSÃO ANALISADA A PARTIR DO CLASSIFICADOR POR ÁRVORES DE DECISÃO

Link de acesso ao conjunto de dados completo:
<https://docs.google.com/spreadsheets/d/1jQ49mCtoGmNPWqDeQ7GMUvLWgaQLJDkE/edit?usp=sharing&oid=102086821180133654843&rtpof=true&sd=true>