

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
INSTITUTO DE BIOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ECOLOGIA, CONSERVAÇÃO E
BIODIVERSIDADE

CAIQUE ROCHA RESENDE

**CARACTERIZAÇÃO DA DIVERSIDADE DE ABELHAS VIBRADORAS A
PARTIR DE PROPRIEDADES ACÚSTICAS DE VOO E VISITAS FLORAIS,
USANDO INTELIGÊNCIA ARTIFICIAL**

Uberlândia

2024

CAIQUE ROCHA RESENDE

**CARACTERIZAÇÃO DA DIVERSIDADE DE ABELHAS VIBRADORAS A
PARTIR DE PROPRIEDADES ACÚSTICAS DE VOO E VISITAS FLORAIS,
USANDO INTELIGÊNCIA ARTIFICIAL**

Dissertação apresentada ao Instituto de Biologia da Universidade Federal de Uberlândia (UFU) como requisito para a obtenção do título de mestre em Ecologia, Conservação e Biodiversidade

Orientador: Prof. Dr. Vinicius Lourenço Garcia de Brito

Uberlândia

2024

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

- R433c Resende, Caique Rocha, 1997-
2024 Caracterização da diversidade de abelhas vibradoras a partir de propriedades acústicas de voo e visitas florais, usando inteligência artificial [recurso eletrônico] / Caique Rocha Resende. - 2024.
- Orientador: Vinicius Lourenço Garcia de Brito.
Coorientadora: Sarah Arvelos Altino.
Dissertação (Mestrado) - Universidade Federal de Uberlândia, Programa de Pós-graduação em Ecologia, Conservação e Biodiversidade.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.di.2024.5148>
Inclui bibliografia.
Inclui ilustrações.
1. Ecologia. I. Brito, Vinicius Lourenço Garcia de, 1985-, (Orient.).
II. Altino, Sarah Arvelos, 1986-, (Coorient.). III. Universidade Federal de Uberlândia. Programa de Pós-graduação em Ecologia, Conservação e Biodiversidade. IV. Título.

CDU: 574

André Carlos Francisco
Bibliotecário Documentalista - CRB-6/3408

CAIQUE ROCHA RESENDE

**CARACTERIZAÇÃO DA DIVERSIDADE DE ABELHAS VIBRADORAS A
PARTIR DE PROPRIEDADES ACÚSTICAS DE VOO E VISITAS FLORAIS,
USANDO INTELIGÊNCIA ARTIFICIAL**

Dissertação apresentada ao Instituto de Biologia da Universidade Federal de Uberlândia (UFU) como requisito para a obtenção do título de mestre em Ecologia, Conservação e Biodiversidade

Uberlândia, 30/10/2024

Banca Examinadora:

Prof. Dr. Vinicius Lourenço Garcia de Brito (UFU)

Dr. Vanessa Gonzaga Marcelo - Uppsala University

Dr. Lilian Rodrigues Ferreira de Melo - Uppsala University



UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Ecologia,
Conservação e Biodiversidade

Av. Pará, 1720, Bloco 2D, Sala 26 - Bairro Umuarama, Uberlândia-MG, CEP 38405-320
Telefone: (34) 3225-8641 - www.ppgeco.ib.ufu.br - ecologia@umuarama.ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Ecologia, Conservação e Biodiversidade				
Defesa de:	Dissertação de Mestrado Acadêmico, número 352, PPGEBCB				
Data:	trinta de outubro de dois mil e vinte e quatro	Hora de início:	08:00	Hora de encerramento:	11:10
Matrícula do Discente:	12222ECR001				
Nome do Discente:	Caique Rocha Resende				
Título do Trabalho:	Caracterização da diversidade de abelhas vibradoras a partir de propriedades acústicas de voo e visitas florais usando inteligência artificial				
Área de concentração:	Ecologia				
Linha de pesquisa:	Ecologia comportamental e evolutiva				
Projeto de Pesquisa de vinculação:	Micro e macro-evolução do funcionamento das flores de pólen				

Reuniu-se por videoconferência a Banca Examinadora designada pelo Colegiado do Programa de Pós-graduação em Ecologia, Conservação e Biodiversidade assim composta pelos doutores: Lilian Rodrigues Ferreira de Melo - Uppsala University; Vanessa Gonzaga Marcelo - Uppsala University e Vinicius Lourenço Garcia de Brito - INBIO/UFU, orientador(a) do(a) candidato(a).

Iniciando os trabalhos o(a) presidente da mesa, Dr(a). Vinicius Lourenço Garcia de Brito, apresentou a Comissão Examinadora e o(a) candidato(a), agradeceu a presença do público e concedeu ao(à) Discente a palavra para a exposição do seu trabalho. A duração da apresentação do(a) Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o(a) senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(as) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Vinicius Lourenço Garcia de Brito, Professor(a) do Magistério Superior**, em 30/10/2024, às 11:09, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Vanessa Gonzaga Marcelo, Usuário Externo**, em 30/10/2024, às 11:39, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Lílian Rodrigues Ferreira de Melo, Usuário Externo**, em 30/10/2024, às 11:40, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site
https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5826694** e o código CRC **94DE8F70**.

Referência: Processo nº 23117.073354/2024-47

SEI nº 5826694

AGRADECIMENTOS

Agradeço a todos que me auxiliaram nesse processo que foi muito difícil devido a diversos contratemplos. Em especial para meus pais pela educação que me proporcionaram desde o inicio da minha vida, pelo amor e carinho que sempre tiveram por mim, pelo apoio que sempre me deram, muito obrigado Idalmo e Gisela! Ao resto da minha pequena família, Monique, Marta e Shirley, pelos momentos de descontração e conselhos.

Agradeço também minha companheira Cecilia que passou por todas as dificuldades do meu lado com muito amor e companheirismo, facilitando os momentos difíceis e me dando forças para finalizar este trabalho. Agradeço também a família de Cecilia pelos incentivos que sempre me deram, muitas conversas e estímulos!

Meus amigos de batuque por serem meu refúgio nos momentos de exaustão. Bem como o próprio samba, sendo uma luz no fim do túnel. Aos meus amigos do NERP, sempre tornando os campos, dias de laboratório e viagens mais interessantes e me abrindo visão para diversas questões do meu trabalho.

Aos meus orientadores, Vinicius e Sarah por toda a parceria no trabalho e pela oportunidade de realizar esta pesquisa. Agradecimento especial a Sarah por me fazer enxergar as possibilidades e as saídas dos momentos de desespero e descrença, bem como a ajuda paciente com as questões computacionais do trabalho e pela amizade.

Obrigado a banca examinadora pela disponibilidade e ótimos apontamentos!

RESUMO

A classificação correta de espécies é fundamental em estudos ecológicos e evolutivos, especialmente em regiões tropicais de alta diversidade. Este trabalho investigou a classificação de 11 espécies de abelhas utilizando técnicas de aprendizado de máquina, aplicadas a um banco de dados acústicos com vibrações de voo e *buzz* (visitas florais) das abelhas. Os algoritmos utilizados foram o *Random Forest*, *Support Vector Machine* e *Perceptron*, com o *Random Forest* se destacando ao obter uma acurácia de 78,95%. Esses resultados demonstram a robustez do modelo, mesmo em cenários com diversidade crescente. A frequência fundamental e os coeficientes do MFCC foram essenciais para a classificação, juntamente com o tipo de vibração realizado pelas abelhas. A matriz de confusão do *Random Forest* evidenciou que classes de tamanhos semelhantes foram mais confundidas entre si e a curva de acurácia do modelo demonstrou que apesar de existir uma queda na acurácia do teste à medida que o índice de diversidade das comunidades aumentava, essa queda não passou de 10%. O desempenho alcançado pelo modelo apresenta alto potencial para o desenvolvimento de ferramentas automáticas capazes de classificar espécies em comunidades diversas, contribuindo para a conservação e o monitoramento em regiões com grande diversidade, onde é essencial uma classificação precisa.

Palavras chave: Bioacústica; *Buzz pollination*; *Machine learning*, classificação de espécies

ABSTRACT

The correct classification of species is fundamental in ecological and evolutionary studies, especially in tropical regions with high diversity. This study investigated the classification of 11 bee species using machine learning techniques applied to an acoustic database with flight and buzz (floral visitation) vibrations of bees. The algorithms used were Random Forest, Support Vector Machine, and Perceptron, with Random Forest standing out by achieving an accuracy of 78.95%. These results demonstrate the robustness of the model, even in scenarios with increasing diversity. The fundamental frequency and the MFCC coefficients were essential for classification, along with the type of vibration performed by the bees. The confusion matrix of the Random Forest model showed that classes of similar sizes were more often confused with each other, and the model's accuracy curve demonstrated that, although there was a decrease in test accuracy as the diversity index of the communities increased, this decrease did not exceed 10%. The model's achieved performance presents high potential for the development of automatic tools capable of classifying species in diverse communities, contributing to conservation and monitoring in regions with great diversity, where precise classification is essential.

Keywords: Bioacustics; Buzz pollination, Machine learning, species classification

LISTA DE ILUSTRAÇÕES

Figura 1: Espectrograma das vibrações geradas por abelhas e a diferenciação entre <i>buzz</i> e voo. A região identificada como 'Buzz' representa a vibração emitida durante as visitas florais e a seção marcada como 'Voo' corresponde às vibrações registradas durante o deslocamento das abelhas, sendo que cada intervalo de voo foi segmentado em 1 segundo de duração para padronização da análise.....	21
Figura 2. Número de amostras por espécie estudada. A codificação das espécies se deu pela seguinte forma: <i>Bombus morio</i> C = 1, <i>Bombus morio</i> = 2, <i>Centris fuscata</i> = 3, <i>Eulaema nigrita</i> = 4, <i>Melipona</i> sp = 5, <i>Xylocopa hirsutíssima</i> = 6, <i>Xylocopa</i> sp = 7, <i>Ptiloglossa</i> = 8, <i>Bombus pauloensis</i> = 9, <i>Exomalopsis</i> = 10, <i>Oxaea flavescens</i> = 11 <i>Xylocopa suspecta</i> = 12	22
Figura 3:Matriz de confusão para o algoritmo <i>Random Forest</i> . O eixo vertical representa as classes verdadeiras e o eixo horizontal as classes previstas. Cada célula mostra o número de vezes que a classe real foi atribuída a classe predita. Quanto mais escura a célula, maior o número de acertos.....	32
Figura 4: Matrizes de confusão para os algoritmos SVM e <i>Perceptron</i> . O eixo vertical representa as classes verdadeiras e o eixo horizontal as classes previstas. Cada célula mostra o número de vezes que a classe real foi atribuída a classe predita. Quanto mais escura a célula, maior o número de acertos.....	33
Figura 5:Vinte variáveis mais importantes pela análise de permutação para os modelos RF. Fonte: Autoria própria.	34
Figura 6:Diferença nas médias de acurácia dos testes e acurácia mínima e máxima dos treinos para o algoritmo <i>Random Forest</i>	35
Figura 7:Diferença nas médias da Precisão e do Recall dos testes e das mínimas e máximas dos treinos para o algoritmo Random Forest.	35

LISTA DE TABELAS

Tabela 1: Adaptação de Truong et al. 2023 com uma revisão dos trabalhos atuais e suas metodologias e aplicações.	18
Tabela 2: Principais métricas de desempenho (acurácia, precisão e recall) dos modelos RF, SVM e PC, em conjuntos de treino e teste.	30

LISTA DE ABREVIATURAS E SIGLAS

ANN – *Artificial Neural Networks*

CNN – *Convolutional Neural Network*

DT – *Decision Tree*

IA – Inteligência Artificial

KNN – *K-Nearest Neighbors*

LG – *Logistic Regression*

LSTM – *Long Short-Term Memory*

MFCC – *Mel-Frequency Cepstral Coefficients*

ML – *Machine Learning*

MLP – *Multi-Layer Perceptron*

PC – *Perceptron*

RF – *Random Forest*

STFT – *Short-time Fourier transform*

SVM – *Support Vector Machine*

UFABC – Universidade Federal do ABC

USP – Universidade de São Paulo

SUMÁRIO

1. INTRODUÇÃO.....	14
2. OBJETIVOS.....	17
2.1. Objetivo Geral.....	17
2.2. Objetivos Específicos	17
3. TRABALHOS RELACIONADOS.....	17
4. METODOLOGIA.....	19
4.1. Locais de estudo e espécies	19
4.2. Coleta de Dados Acústicos	20
4.3. Processamento dos Dados de Áudio	20
4.4. Banco de dados.....	21
4.5. Caracterização acústica dos sons das abelhas.....	22
4.6. Frequência Fundamental e o MFCC	23
4.7. Preparação do Banco de Dados e Ambiente Computacional	24
4.8. Desenvolvimento dos Modelos de Aprendizado de Máquina	24
4.9. Validação e Teste dos Modelos	26
4.9.1. Acurácia, Precisão e Recall	26
4.9.2. Matriz de Confusão.....	27
4.9.3. Análise de Importância de Permutação de Variáveis	27
4.10. Comunidades artificiais com diversidade crescente	28
5. RESULTADOS	29
5.1. Comparação entre o desempenho dos modelos.....	29
5.1.1. Matrizes de confusão	31
5.1.2. Análise de permutação de variáveis.....	33
5.1.3. Desempenho do modelo Random Forest para comunidades diversas	34
6. DISCUSSÃO.....	36
6.1. Diferença entre modelos.....	36
6.2. Parâmetros acústicos	38
6.3. Variação da acurácia com a diversidade	38
6.4. Conclusões e perspectivas futuras	39
7. REFERÊNCIAS.....	40

1. INTRODUÇÃO

A classificação correta dos indivíduos é crucial para estudos em ecologia e evolução. Porém, esse processo enfrenta diversos obstáculos. Por exemplo, as chaves taxonômicas disponíveis muitas vezes são desatualizadas e incompletas, especialmente em áreas tropicais de alta diversidade (BALAKRISHNAN, 2005). Além disso, os diferentes métodos de delimitação das espécies, como as abordagens moleculares, morfológicas e ecológicas frequentemente resultam em conclusões divergentes (ROSELLÓ-MORA, 2003; DUFRESNES et al., 2023). Esses fatores, aliados com a falta de especialistas qualificados e as dificuldades na identificação de espécies em campo, comprometem ainda mais a precisão das classificações. (GASTON e O'NEILL, 2004; GASTON e MAY 1992; DE QUEIROZ, 2007). Outro desafio relevante é a presença de espécies crípticas, que são morfologicamente idênticas, mas geneticamente distintas, o que torna a identificação ainda mais complexa e necessária. Assim, tais obstáculos afetam diretamente as estimativas de diversidade local, uma vez que a diversidade biológica é definida pela riqueza de espécies e a abundância relativa de indivíduos em cada uma dessas espécies (LARA et al., 2010; MAURER et al., 2011; JÖRGER e SCHRÖDL, 2013). Esse desafio na identificação de espécies cria incertezas tanto na contagem quanto na catalogação, resultando em estimativas menos precisas da diversidade e, esse sentido, novas ferramentas que auxiliem na classificação de espécies podem ajudar na solução de alguns desses problemas (BERGMANN et al., 2009; MAURER et al., 2011; KIANIAN et al., 2024; SIMOVIĆ et al., 2024).

A bioacústica é um campo interdisciplinar que estuda a produção, transmissão e recepção de sons por organismos vivos, explorando como os sinais sonoros são utilizados para comunicação intraespecífica, detecção de presas, estruturação de comunidades ecológicas e interações afins. (PENAR et al., 2020) Além disso, os sinais sonoros emitidos pelos organismos durante diversos comportamentos, também podem ser usados para classificação. Especificamente, estudos em bioacústica de abelhas têm se tornado cada vez mais frequentes para entender a crucial importância destes insetos polinizadores para a manutenção da biodiversidade e dos ecossistemas.

As abelhas produzem vibrações em diversos contextos comportamentais e apesar de serem geradas através do mesmo mecanismo de contração dos músculos torácicos, essas vibrações comportamentais variam em suas propriedades mecânicas, tanto em frequência, como em amplitude e duração. Dessa forma as vibrações produzidas pelas abelhas possuem diferentes finalidades, como por exemplo o próprio voo ou até mesmo como mecanismo de defesa (HRNCIR et al., 2008; VALEJO-MARÍN, 2022). Através da análise dos sons emitidos por essas vibrações, pesquisadores conseguem, por exemplo, identificar padrões de comunicação, atividades de forrageamento, interações sociais, interações com flores e até detectar a saúde das colmeias (DI et al., 2023; RIBEIRO et al., 2021; ROBLES-GUERRERO et al., 2023; TRUONG et al., 2023). Entre os diversos contextos em que as abelhas produzem sons existe um comportamento conhecido como “buzz pollination”. Este comportamento é executado somente por fêmeas de diversos tamanhos que ao pousarem nas flores curvam a região ventral em torno das anteras, e com suas mandíbulas, agarram a base dos estames (BUCHMANN, 1985; DE LUCA; VALLEJO-MARÍN, 2013). Durante esse processo, as asas se fecham sobre a região dorsal do tórax, resultando no desacoplamento do mecanismo de voo. Em seguida geram vibrações a partir de rápidas contrações dos músculos indiretos de voo (VALLEJO-MARÍN, 2013; VALLEJO-MARÍN, 2019). Essas vibrações são transmitidas para a antera a partir de mordidas periódicas que reverberam os grãos de pólen, fazendo com que saiam pelo poro apical e se depositem no corpo da abelha (WOODROW et al. 2024). Durante a vibração floral, as abelhas também produzem um componente audível que se propaga pelas partículas de ar e que possuem as mesmas três propriedades fundamentais: duração, frequência e a amplitude (DE LUCA et al., 2020; KING; BUCHMANN; SPANGLER, 1996).

Os “buzzes” produzidos nas visitas florais possuem componentes de vibração diferentes daqueles que são produzidos durante o voo, pois suas durações são variáveis e a frequência é geralmente mais alta (entre 100 e 400 Hz) (DE LUCA e VALLEJO-MARÍN, 2013). Tal vibração também apresenta vários harmônicos que são os múltiplos inteiros do valor da frequência fundamental, provocados pela ressonância do exoesqueleto (DE LUCA e VALLEJO-MARÍN, 2013). Dessa forma, o buzz pode ser um bom componente acústico

para o reconhecimento automatizado das abelhas e, desse modo, pode ajudar em estudos de monitoramento e diversidade de abelhas vibradoras em diferentes comunidades.

O uso da inteligência artificial (IA) tem se tornado cada vez mais comum e já apresenta diversas aplicações no cotidiano, sendo uma ferramenta que auxilia em estudos, análise de dados e experimentos (SARKER, 2021; GIGNAC e SZODORAI, 2024). Já existem técnicas automatizadas para classificação de animais baseadas em IA, como por exemplo o reconhecimento automático de espécies de aranhas a partir da imagem de suas teias (TICAY-RIVAS, 2013; MAGALHÃES e HIRATA, 2023) e a categorização de espécies de peixes a partir de análises comportamentais utilizando IA (ABANGAN et al., 2023). Pesquisas em bioacústica também já utilizam modelos de IA. Por exemplo, estudos ornitológicos frequentemente utilizam sinais sonoros para identificação de aves (LASSECK, 2015; INDUMATHI et al., 2024). Além disso, em monitoramento de anuros também há análise acústicas para o reconhecimento das espécies (BEDOYA et al., 2014; AKBAL et al., 2023). Essas ferramentas têm sido aplicadas com sucesso em estudos de conservação, monitoramento de populações e no desenvolvimento de métodos automatizados para a identificação e classificação de espécies baseadas em suas características acústicas (BROWN e RIEDE, 2017, FERREIRA et al., 2023; TRUONG et al., 2023).

Existem diversas aplicações ecológicas dos trabalhos associando IA e bioacústica de abelhas, tal como os trabalhos que focam em identificar a saúde das colônias. Um estudo realizado com *Apis mellifera* diferenciou com uma precisão de 100%, colônias saudáveis de não saudáveis utilizando automação, também a partir da extração de parâmetros acústicos do voo (ROBLES-GUERRERO et al., 2017). Frequentemente a bioacústica associada a modelos de inteligência artificial também é utilizada como ferramenta de identificação de espécies de abelhas. Pesquisadores obtiveram uma acurácia de 82.7% na diferenciação entre rainha e operárias e na classificação de espécies do gênero *Bombus* a partir de informações extraídas de seus voos, utilizando um modelo de aprendizado de máquina. (GRADIŠEK et al. 2016). Metodologias semelhantes estão presentes em diversos trabalhos relacionados a este e apesar de tais trabalhos classificarem com boa precisão e acurácia as espécies de abelhas de seus estudos, não temos trabalhos que abrangem comunidades diversas (KAWAKITA e ICHIKAWA, 2019; RIBEIRO et al., 2021; TRUONG, 2023). Dessa forma

o presente trabalho tem como objetivo avaliar a viabilidade do uso de modelos de aprendizado de máquina no reconhecimento de espécies em comunidades com diferentes níveis de diversidade.

2. OBJETIVOS

2.1. Objetivo Geral

Utilizar diferentes modelos de *Machine Learning* para classificar abelhas a partir dos sons produzidos durante o voo e *buzz* em comunidades de diferentes tamanhos. Mais especificamente, testar a eficácia de três algoritmos em classificar 11 espécies de abelhas e a partir do melhor modelo entender como esse classificador se comporta em comunidades artificiais com diferentes índices de diversidade. Entender a relação entre a acurácia da classificação feita por *Machine Learning* através dos sons e a diversidade das comunidades de abelhas nos ajudará a desenvolver ferramentas úteis para utilização em campo, auxiliando no monitoramento e nos estudos de conservação em áreas com grande variedade de espécies, onde é necessário classificar com precisão em níveis reais de diversidade.

2.2. Objetivos Específicos

- Encontrar o melhor algoritmo para classificação das abelhas a partir de características acústicas, sendo eles: *Random Forest*, *Support Vector Machine* e *Perceptron*.
- Descrever como o melhor algoritmo se comporta em comunidades com valores de índices de diversidade crescente

3. TRABALHOS RELACIONADOS

Nos últimos anos, uma série de estudos têm utilizado técnicas avançadas de aprendizado de máquina para a análise acústica de sons de abelhas, aplicando metodologias como MFCC (*Mel Frequency Cepstral Coefficients*) para extração de características, e

modelos de classificação como SVM (*Support Vector Machine*), RF (*Random Forest*) e ANN (*Artificial Neural Networks*). Esses estudos visam identificar comportamentos e estados importantes das colmeias, como a presença da rainha, polinização e enxameação, com base em dados acústicos. Além do MFCC, técnicas de extração de características como a frequência fundamental e transformadas de Fourier são frequentemente empregadas. O trabalho de Truong (2023) realizou uma revisão abrangente dessas abordagens, destacando o uso de diferentes modelos e técnicas em vários estudos recentes. A Tabela 1 resume esses trabalhos, evidenciando a aplicabilidade das metodologias mencionadas e incluem modelos como SVM, *K-Nearest Neighbors* (KNN), *Random Forest* (RF), *Convolutional Neural Network* (CNN), *Long Short-Term Memory* (LSTM), *Multi-Layer Perceptron* (MLP), *Logistic Regression* (LG) e *Decision Tree* (DT), aplicados em diferentes tarefas de classificação de sons de abelhas.

Trabalho	Modelo utilizado	Parâmetros extraídos	Foco da classificação
Zhao et al. (2021)	SVM, KNN, RF	MFCC	Abelha sob diferentes impactos ambientais
Cejrowski et al. (2020)	SVM	MFCC	Comportamentos de abelhas a noite
Ribeiro et al. (2021)	SVM	MFCC	Polinização por abelhas
Ruvinga et al. (2022)	CNN	STFT, Espectrogramas de Mel	Enxameação de abelhas
Ruvinga et al. (2023)	LG, MLP, CNN, LSTM	STFT, MFCC	Estado da colmeia sem a presença da rainha
Robles-Guerrero et al. (2023)	LG, LR, SVM, KNN, RF, Rede Neural	MFCC	Estado da colmeia sem a presença da rainha
Ferreira et al. (2023)	LG, DT, SVM, RF	MFCC, Espectrograma de Mel	Polinização por abelhas
Di et al. (2023)	LG, KNN, SVM, RF	MFCC, VGGish embedding	Estado da colmeia sem a presença da rainha
Truong et al. (2023)	CNN-GRU	Espectrogramas de Mel	Abelhas, grilos e sons ambientes

Tabela 1: Adaptação de Truong et al. 2023 com uma revisão dos trabalhos atuais e suas metodologias e aplicações.

4. METODOLOGIA

4.1. Locais de estudo e espécies

Os dados acústicos foram obtidos em três locais distintos, sendo Uberlândia e Diamantina em Minas Gerais e São Bernardo do Campo em São Paulo. Uberlândia apresenta um clima do tipo Aw segundo a classificação de Köppen e possui sazonalidade bem marcada, com ocorrência de chuvas no verão e seca durante o inverno (ROSA et al., 1991). Diamantina, possui clima do tipo Cwb, conforme a classificação Köppen, ou seja, temperado úmido, com inverno seco e chuvas no verão (VIEIRA et al., 2010) e ambas as regiões apresentam vegetação do tipo Cerrado. São Bernardo do Campo caracteriza-se de acordo com a classificação Köppen como Cfb, que caracteriza como subtropical úmido sem estação seca e com verão temperado (ALVARES et al. 2014) e possui vegetação do tipo Mata Atlântica (PASTORE, 1992).

O trabalho consistiu na classificação de 11 espécies de abelhas a partir de análises acústicas de *buzz* e voo. As espécies amostradas foram: *Bombus morio*, *Xylocopa hirsutíssima*, *Xylocopa suspecta*, *Eulaema nigrita*, *Centris fuscata*, *Bombus pauloensis*, *Oxaea flavescens*, *Xylocopa sp*, *Exomalopsis sp*, *Ptiloglossa sp* e *Melipona sp*. As gravações dos sons das abelhas foram feitas em três espécies de plantas diferentes, sendo elas: *Solanum paniculatum* L. (Solanaceae) coletadas na lateral da rodovia BR-455 (19°8'31"S, 048°22'47"W) próximo à Estação Ecológica do Panga,, *Rhynchanthera grandiflora* (Melastomataceae) coletadas no campus JK da Universidade Federal dos Vales do Jequitinhonha e Mucuri (18°12'09.8"S 43°34'46.1"W) e *Chamaecrista latistipula* (Fabaceae) coletadas na Universidade Federal do ABC (23°40'39.1"S 46°33'52.3"W). Tais espécies foram selecionadas por apresentarem flores com morfologias diferentes, oferecem apenas o pólen como recurso às abelhas e possuírem anteras poricidas, sendo, portanto, espécies polinizadas por vibração.

4.2. Coleta de Dados Acústicos

As gravações dos sons produzidos durante o voo e *buzz* foram obtidas utilizando um microfone direcional (Shotgun Yoga Ht 81) acoplado a um gravador de voz (Sony ICD-PX240 – Mono) com taxa de amostragem de 44,1 kHz e resolução de 16 bits. A metodologia da gravação consiste na aproximação cuidadosa do microfone aos indivíduos antes e durante as visitas, respectivamente, para obter dados do voo e de buzz, durante as visitas florais. Após a coleta do dado foi feita a captura de alguns dos indivíduos com rede entomológica e esses indivíduos foram sacrificados com acetato de etila para posterior identificação. As identificações referentes as coletas próximas a Estação Ecológica do Panga foram realizadas pelo especialista Danillo Cristian do Laboratório de Ecologia e Comportamento de Abelhas (LECA) da Universidade Federal de Uberlândia. As identificações das espécies referentes a coleta de Diamantina foi feita pela especialista Letícia Pataca. Para identificação das espécies relativas aos dados obtidos na UFABC (Universidade Federal do ABC), os indivíduos foram encaminhados para o Museu de Zoologia da USP (Universidade de São Paulo) e determinados até o menor grupo taxonômico com a orientação da Dr^a Kelli dos Santos Ramos. Após essa determinação de espécie todos os outros indivíduos foram morfotipados através de observações, coletas, análise de fotografias ou vídeos.

4.3. Processamento dos Dados de Áudio

Após a gravação, as análises bioacústicas envolvem várias etapas de processamento. Isso inclui: 1) a filtragem para remover ruídos não relacionados, 2) a segmentação para isolar vibrações individuais e 3) a extração de características acústicas relevantes, como frequência, duração e amplitude. Os dados coletados foram processados no programa de análises e edição de áudio Audacity v2.3.2 (disponível em: <https://www.audacityteam.org/>). Para padronização, os sons de voo foram manualmente cortados em segmentos de 1s. Por outro lado, os sons de *buzz* foram considerados em toda a sua duração. Para reduzir o ruído das gravações, foi aplicado um filtro passa-alta a 100 Hz com um roll off de 12 dB por oitava. A Figura 1 ilustra o espectrograma das vibrações das abelhas e o processo de segmentação.

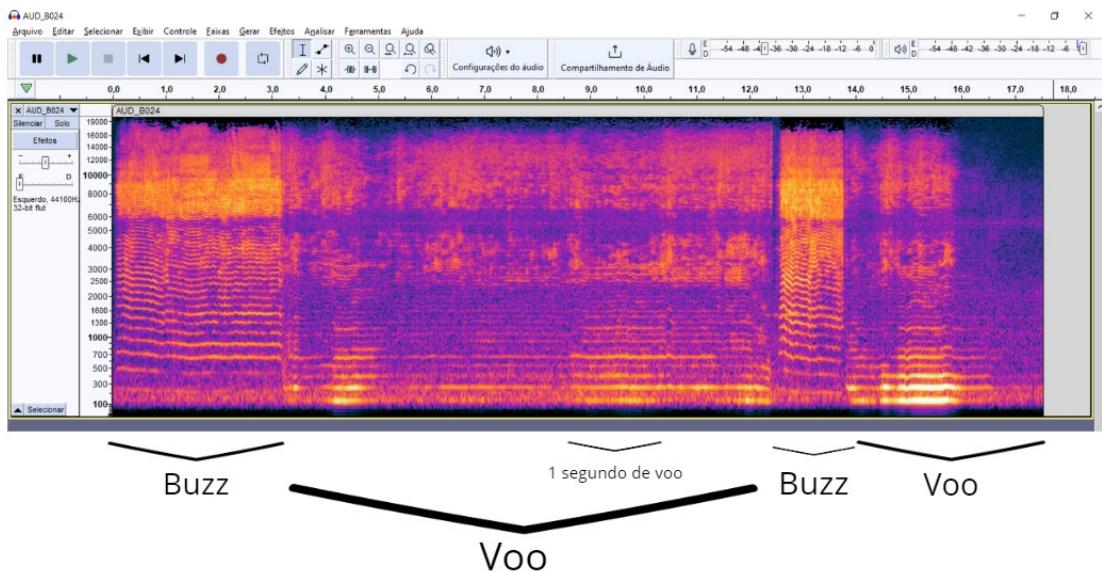
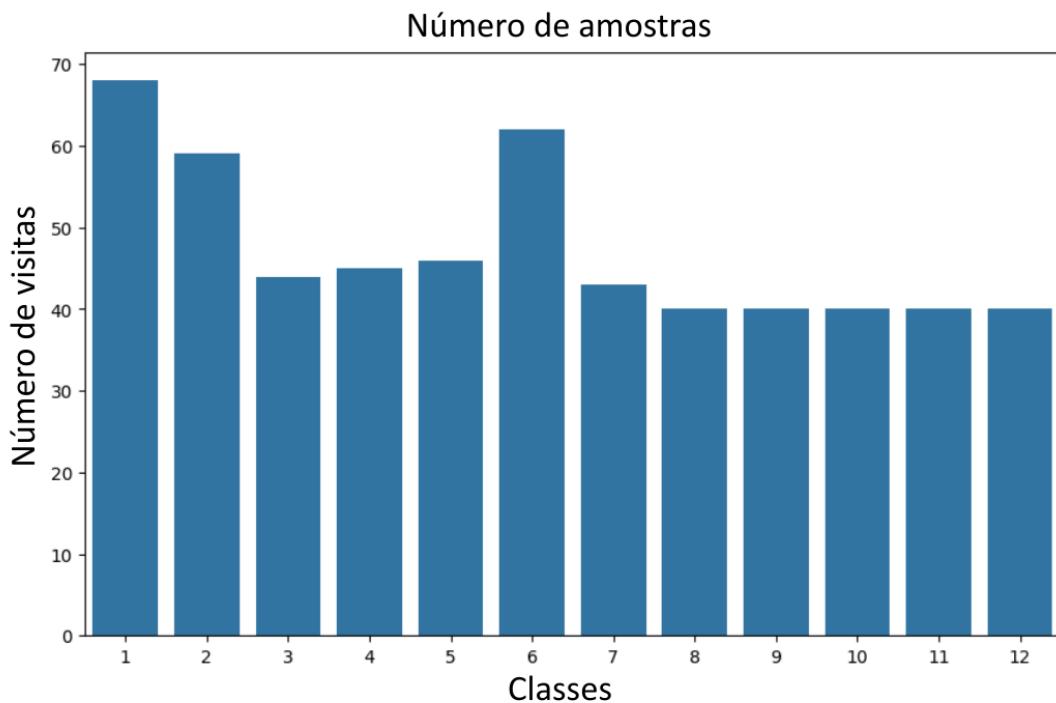


Figura 1: Espectrograma das vibrações geradas por abelhas e a diferenciação entre *buzz* e *voo*. A região identificada como 'Buzz' representa a vibração emitida durante as visitas florais e a seção marcada como 'Voo' corresponde às vibrações registradas durante o deslocamento das abelhas, sendo que cada intervalo de voo foi segmentado em 1 segundo de duração para padronização da análise.

4.4. Banco de dados

O banco de dados contou com 567 gravações totais, distribuídas entre sons de *buzz* e *voo* pra cada uma das 11 espécies. A distribuição de dados por espécie foi: *Bombus morio* C = 68, *Bombus morio* = 59, *Centris fuscata* = 44, *Xylocopa hirsutissima* = 62, *Xylocopa* sp = 43, *Melipona* sp = 46, *Eulaema nigrita* = 45, *Xylocopa suspecta* = 40, *Oxaea flavescens* = 40, *Exomalopsis* = 40, *Bombus pauloensis* = 40 e *Ptiloglossa* = 40 (Figura 2). A espécie *Bombus morio* foi coletada em duas flores diferentes e em locais diferentes e dessa forma foi considerada artificialmente como duas espécies separadas a fim de assegurar uniformidade aos dados (em termos de grupos) na análise e por suas diferenças de coleta. Assim, os dados de *Bombus morio* C referem-se aos coletados na espécie *Chamaecrista latistipula* e os de *Bombus morio* referem-se a espécie coletada em *Rhynchanthera grandiflora*.



Fonte: Autoria própria.

Figura 2. Número de amostras por espécie estudada. A codificação das espécies se deu pela seguinte forma:

Bombus morio C = 1, *Bombus morio* = 2, *Centris fuscata* = 3, *Eulaema nigrita* = 4, *Melipona* sp = 5, *Xylocopa hirsutissima* = 6, *Xylocopa* sp = 7, *Ptiloglossa* = 8, *Bombus pauloensis* = 9, *Exomalopsis* = 10, *Oxaea flavescens* = 11 *Xylocopa suspecta* = 12

4.5. Caracterização acústica dos sons das abelhas

Para a caracterização acústica das abelhas, após o processamento e filtragem do áudio foram extraídos parâmetros que serão utilizados posteriormente pelos algoritmos, que carregam informações importantes para identificação dos padrões utilizados na classificação. A partir da revisão da literatura, os parâmetros mais utilizados são a frequência fundamental e o MFCC. Ambos são frequentes em trabalhos de identificação automatizada através do som de animais, nos quais apresentam um bom desempenho (GRADIŠEK et al., 2016; KAWAKITA e ICHIKAWA, 2019; TRUONG, 2023). As análises ecoacústicas foram realizadas RStudio v. 4.0.5 (www.rstudio.com) de acordo com o livro *Sound Analysis and Synthesis with R*, de Sueur (2018).

4.6. Frequênci a Fundamental e o MFCC

A Frequênci a Fundamental é definida como o harmônico de menor valor no espectro de frequênci a de uma vibração (DE LUCA e VALLEJO-MARÍN, 2013). Harmônicos são componentes de frequênci a que correspondem a múltiplos inteiros da frequênci a fundamental, ou seja, se a frequênci a fundamental é 100 Hz, os harmônicos subseqüentes seriam 200 Hz, 300 Hz e assim por diante. Entre espéci es de abelhas, este valor varia entre 100 a 400 Hz e possui a maior energia entre os harmônicos, coincidindo com a frequênci a dominante (DE LUCA e VALLEJO-MARÍN, 2013). O *voo* e o *buzz* apresentam características sonoras distintas, com o *buzz* possuindo uma frequênci a fundamental mais alta e uma maior quantidade de harmônicos. A extração das frequênci es fundamentais foi feita através da análise visual dos espectros de frequênci a no programa Adobe Audition, disponível em <https://www.adobe.com/cl/products/audition>.

Já o MFCC é uma técnica de extração de parâmetros utilizada para reconhecimento automático de fala e carregam informações a respeito do timbre do som (SUEUR, 2018). Além disso, tem seu uso frequente em trabalhos de identificação automatizada através do som de animais (CHENG et al., 2010; GRADIŠEK et al., 2016; ROBLES-GUERRERO et al., 2017; KAWAKITA e ICHIKAWA, 2019). A obtenção do MFCC envolve a segmentação do áudio em pequenas janelas e depois a conversão do sinal para o domínio da frequênci a usando a Transformada de Fourier. Em seguida, o espectro é filtrado na escala Mel, que se aproxima da percepção humana das frequênci es. O resultado é comprimido usando logaritmo e posteriormente a Transformada Discreta do Cosseno (DCT) é aplicada para obter os coeficientes. Apenas os primeiros coeficientes são selecionados, pois contêm as informações mais relevantes do áudio (SUEUR, 2018). Para este estudo, foram extraídos 13 MFCC's de cada um dos 567 sinais acústicos utilizando a função `melfcc` do pacote `tuneR` do *software* RStudio v. 4.0.5 (www.rstudio.com) (SUEUR, 2018). Após a extração dos MFCC's e seguindo a metodologia utilizada por Robles-Guerrero et al. (2017), foram sintetizados os valores obtidos na matriz de coeficientes através do cálculo dos seguintes descriptores estatísticos: média, média truncada (20%), curtose, desvio padrão, assimetria, mediana, variância, coeficiente de variação, e os quantis (2,5, 25, 50, 75, 97,5).

4.7. Preparação do Banco de Dados e Ambiente Computacional

O banco de dados foi tratado computacionalmente, analisado e modelado no ambiente online do Google Colaboratory (<https://colab.research.google.com/>), utilizando a linguagem de programação Python (versão 3.7.13). Essa plataforma, oferecida pela Google, tem manipulação facilitada em aplicações de Aprendizado de Máquina, fornecendo um ambiente de desenvolvimento integrado na web. Para realizar essas tarefas, foram empregadas diversas bibliotecas computacionais, incluindo scikit-learn, pandas, numPy, seaborn e matplotlib, para tratamento dos dados, execução da modelagem e visualização dos resultados.

4.8. Desenvolvimento dos Modelos de Aprendizado de Máquina

A escolha dos algoritmos e parâmetros utilizados neste trabalho foi influenciada por estudos anteriores, como os de Arvelos (2021) e Ribeiro (2021), que aplicaram características acústicas de voo e de *buzz* para classificar espécies de abelhas. Esses estudos selecionaram algoritmos como RF, SVM e DT, focando em espécies semelhantes, incluindo *Xylocopa suspecta*, *Eulaema nigrita* e *Bombus morio*. Atualmente, na metodologia de identificação de espécies de abelhas por meio de análises acústicas tem-se utilizado predominantemente modelos como RF, SVM, KNN e ANN (TRUONG et al., 2023), com frequência fundamental e valores de MFCC como parâmetros comuns (TRUONG et al., 2023). Para este estudo, optou-se por SVM, RF e *Perceptron* (PC) - uma rede neural de camada única -, por serem amplamente adotados em pesquisas semelhantes, apresentarem bom desempenho na classificação e serem adequados ao nosso conjunto de dados.

Atualmente, diversos estudos exploram a utilização MFCC em combinação com algoritmos de aprendizado de máquina para a identificação de espécies de abelhas (TRUONG et al., 2023). Um desses estudos aplica o MFCC em conjunto com o algoritmo SVM para a classificação de abelhas (KAWAKITA E ICHIKAWA, 2019). Outros trabalhos utilizam quatro algoritmos, incluindo SVM, DT, RF e KNN, a fim de avaliar a eficácia do MFCC na classificação de áudios coletados em colmeias (DI et al., 2023). A saúde de colônias de *Apis mellifera carnica* também foi analisada utilizando MFCC e RF, com resultados que demonstraram alta precisão na classificação entre colônias saudáveis e não saudáveis

(ROBLES-GUERRERO et al., 2017). Além disso, houve uma comparação de seis algoritmos de classificação para encontrar o modelo com o melhor desempenho e menor custo computacional na identificação dos estados das colônias por meio da análise de padrões acústicos (ROBLES-GUERRERO et al., 2023).

O RF geralmente têm boa precisão em tarefas de classificação devido à sua capacidade de combinar múltiplas árvores de decisão e reduzir o *overfitting* (sobreajuste). É um algoritmo robusto a *outliers* e ruídos nos dados devido à agregação de múltiplas árvores, o que reduz o impacto de exemplos atípicos e podem lidar eficientemente com conjuntos de dados grandes e com muitas *features*, sem a necessidade de pré-processamento extensivo das variáveis de entrada do modelo (ARIA, CUCCURULLO, GNASSO, 2021; AURET e ALDRICH, 2012; BREIMAN, 2001; HARB et al., 2009; SPEISER et al., 2019; ZHOU et al., 2019).

Já o SVM funciona bem mesmo em espaços de alta dimensionalidade, como é comum em problemas de aprendizado de máquina modernos. O mesmo tem uma boa capacidade de generalização, especialmente em problemas onde há uma margem clara de separação entre as classes. Além disso, o algoritmo é eficaz em conjuntos de dados com poucas amostras, proporcionando uma boa classificação com um número relativamente pequeno de exemplos de treinamento (FACELI et al., 2011; ÇAKIR et al., 2023; GERON, 2019; OTCHERE et al., 2021).

O PC é simples e eficiente para problemas de classificação linear, especialmente quando as classes são linearmente separáveis. Em problemas linearmente separáveis, o PC converge para uma solução ótima em um número finito de iterações. Além disso, os pesos associados às características no perceptron fornecem uma interpretação direta do impacto de cada uma delas na classificação (SINGH et al., 2019). Os algoritmos foram implementados pela biblioteca scikit-learn¹.

Para obter ajustes suficientes, foi selecionado 80% do banco de dados para treinamento dos modelos e 20% para teste. Durante o treinamento, dividiu-se o banco de dados em 5

¹ <https://scikit-learn.org/stable/modules/neighbors.html>

grupos para trabalhar a validação cruzada do treinamento modelo. A função objetivo de busca dos melhores parâmetros maximizou a média da acurácia dos 5 grupos.

A busca do ponto de máxima acurácia foi realizada utilizando-se o pacote computacional Optuna (AKIBA et al., 2019), realizando 200 passos iterativos. O modelo foi treinado 10 vezes a partir de diferentes sementes (*seeds*) para escolha aleatória dos conjuntos de treino e teste. Os resultados apresentados neste trabalho para as métricas de ajuste referem-se à média das simulações.

4.9. Validação e Teste dos Modelos

As métricas utilizadas para avaliar a capacidade dos modelos aplicados neste trabalho foram a acurácia, precisão e recall, além da matriz de confusão. Para interpretação do modelo, foram calculadas as importâncias de permutação das variáveis. A seguir, cada uma dessas métricas são apresentadas e explicadas brevemente.

4.9.1. Acurácia, Precisão e Recall

As métricas de avaliação são essenciais para medir o desempenho de modelos de aprendizado de máquina e podem variar de acordo com o tipo de problema. Acurácia, precisão e recall são amplamente utilizadas para avaliar a qualidade de modelos de classificação e são calculadas conforme as Equações (1–3). A acurácia representa a proporção de previsões corretas, tanto positivas quanto negativas, em relação ao total de previsões feitas, sendo uma medida geral de desempenho. A precisão, por sua vez, refere-se à proporção de previsões positivas que realmente são corretas. Ou seja, indica o quanto confiável é o modelo quando ele prevê uma determinada classe, sendo útil principalmente quando se deseja minimizar falsos positivos. Já o recall mede a capacidade do modelo de identificar corretamente os exemplos positivos, ou seja, a proporção de casos positivos reais que foram efetivamente reconhecidos. (FOODY, 2023; DALIANIS, 2018).

$$\text{Acurácia} = \frac{\text{Verdadeiros positivos} + \text{Verdadeiros negativos}}{\text{Verdadeiros positivos} + \text{Verdadeiros negativos} + \text{Falsos positivos} + \text{Falsos negativos}} \quad (1)$$

$$\text{Precisão} = \frac{\text{Verdadeiros positivos}}{\text{Verdadeiros positivos} + \text{Falsos positivos}} \quad (2)$$

$$\text{Recall} = \frac{\text{Verdadeiros positivos}}{\text{Verdadeiros positivos} + \text{Falsos negativos}} \quad (3)$$

4.9.2. Matriz de Confusão

Uma matriz de confusão é uma ferramenta fundamental para avaliar o desempenho de modelos de classificação em *machine learning*. Ela apresenta uma tabela que resume os resultados das predições feitas pelo modelo, comparando os valores preditos com os valores reais. A matriz é composta por quatro elementos: verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos. Esses valores são utilizados para calcular métricas essenciais como precisão, recall, acurácia, entre outras e fornece uma visão detalhada de como o modelo está acertando ou errando suas predições (MARKOULIDAKIS et al., 2021)

4.9.3. Análise de Importância de Permutação de Variáveis

Variáveis correlacionadas representam redundância para um banco de dados, uma vez que trazem, em essência, a mesma informação. Foi realizada a remoção de uma das variáveis de pares quando estas apresentavam correlação acima de 0,7 ou abaixo de -0,7. Assim,

partindo-se do banco de dados contendo 174 variáveis descritivas dos sons, efetuou-se a remoção das correlacionadas. Ao final do processo, a triagem reduziu o banco de dados para o conteúdo de 68 variáveis, incluindo a informação dos alvos (Espécies).

Explicar modelos de *machine learning* e usar técnicas de interpretabilidade são práticas essenciais por diversas razões, que incluem transparência, confiança, ética e melhoria do processo decisório. A explicabilidade permite validar se o modelo está aprendendo padrões corretos nos dados e identificar possíveis vieses ou erros sistemáticos. Isso facilita a melhoria contínua do modelo e dos dados utilizados (ARIA; CUCCURULLO; GNASSO, 2021; BREIMAN, 2001; MOLNAR, 2020). Para o presente trabalho, o modelo estudado foi analisado com a técnica de análise de importâncias de permutação.

A análise de importância de permutação de variáveis é uma técnica usada para avaliar a relevância de cada variável (ou característica) em um modelo de *machine learning*. É uma análise de sensibilidade, avalia as variáveis que mais afetam a previsão do modelo e as que menos afetam. As variáveis são aleatoriamente embaralhadas, enquanto o desempenho do modelo é monitorado. Se a permutação de uma variável específica reduzir significativamente a performance do modelo, essa variável é considerada importante, pois sua aleatoriedade afeta a capacidade do modelo de fazer previsões corretas. Para o *Random Forest*, essa análise é particularmente valiosa, já que o modelo trabalha com múltiplas árvores de decisão, e a permutação revela o impacto de cada variável na robustez do conjunto de árvores. Para SVM, que é um método mais sensível à separabilidade das classes, a permutação ajuda a identificar quais variáveis são cruciais para maximizar as margens de separação entre as classes (JANITZA et al., 2013; WEI et al., 2015).

4.10. Comunidades artificiais com diversidade crescente

Para avaliar a influência da diversidade das comunidades de abelhas no desempenho do modelo RF, foi conduzido um experimento sistemático utilizando conjuntos de dados com níveis crescentes de diversidade. Inicialmente, foi gerada uma lista de estados aleatórios para garantir a reproduzibilidade na divisão dos dados em conjuntos de treino e teste. A partir do

DataFrame original, foram criados dez conjuntos de dados filtrando as linhas com base em grupos de espécies, adicionando progressivamente novas espécies em cada conjunto, começando com grupos de três espécies e aumentando até incluir todas as onze espécies disponíveis. Essa abordagem permitiu simular comunidades artificiais com diversidade crescente.

Para cada conjunto de dados, foram separadas as variáveis independentes da variável dependente, que é a espécie de abelha a ser classificada. Os dados foram divididos em treino (80%) e teste (20%), empregando os valores de *random_state* da lista aleatória para assegurar a consistência nas divisões e utilizamos o pacote Optuna para maximizar a acurácia do modelo. Em cada iteração, foram executadas dez tentativas de otimização, aplicando validação cruzada com cinco *folds* para avaliar o desempenho durante o treinamento. Após a divisão, foram contabilizadas as abundâncias das espécies no conjunto de teste, construindo um *DataFrame* com o número de indivíduos por espécie presente em cada comunidade simulada. Com base nessas abundâncias, foi calculado o índice de Shannon (H') para quantificar a diversidade das comunidades testadas.

Com os melhores hiperparâmetros definidos após o treinamento do modelo *Random Forest*, foram avaliadas as métricas de desempenho do modelo (acurácia, precisão e recall), tanto nos dados de treino quanto nos de teste. Estes dados foram registrados em listas que armazenaram a acurácia média, máxima, mínima, desvio padrão e também o Índice de Shannon de cada conjunto de teste, obtidos nas validações cruzadas. Este procedimento foi repetido para cada um dos conjuntos de dados, o que nos permitiu realizar uma análise abrangente da relação entre a diversidade das comunidades de abelhas e a acurácia do modelo *Random Forest*.

5. RESULTADOS

5.1. Comparação entre o desempenho dos modelos

Os resultados obtidos para os três modelos – RF, SVM e PC – são apresentados na Tabela 2, contendo as métricas de desempenho: acurácia, precisão e recall, tanto no conjunto

de treino quanto no conjunto de teste, para determinar qual modelo apresentou o melhor desempenho geral.

Tabela 2: Principais métricas de desempenho (acurácia, precisão e recall) dos modelos RF, SVM e PC, em conjuntos de treino e teste.

Métrica	RF	SVM	PC
Acurácia Treino	0,788083	0,774725	0,587082
Acurácia Teste	0,789474	0,745614	0,614035
Precisão Treino	0,806301	0,783606	0,598741
Precisão Teste	0,816345	0,785029	0,680192
Recall Treino	0,806301	0,783606	0,569479
Recall Teste	0,789474	0,745614	0,614035

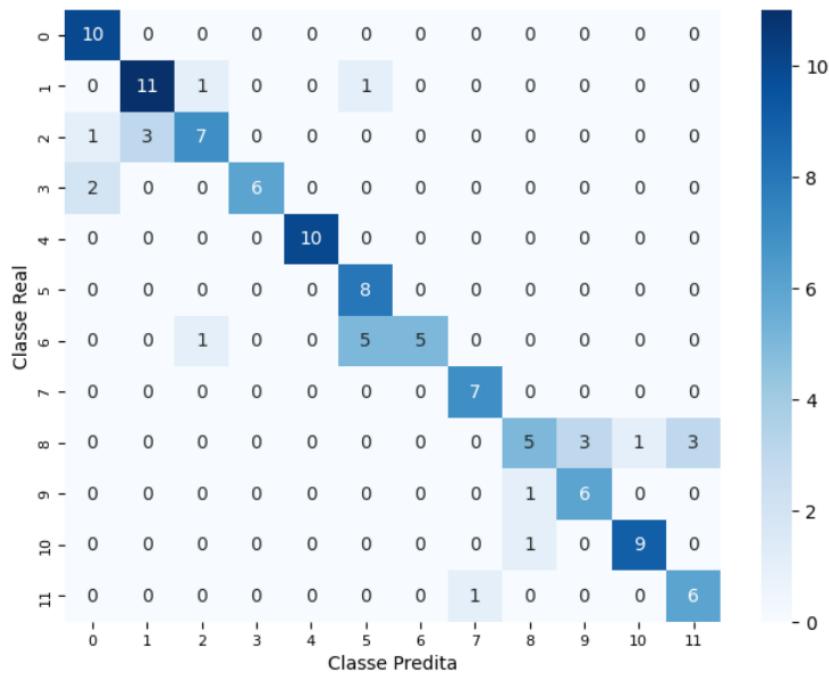
Os três modelos testados apresentaram desempenhos distintos em termos de acurácia, precisão e recall, tanto no treino quanto no teste. O RF se destacou como o modelo mais eficaz, seguido pelo SVM, enquanto o PC teve o pior desempenho. O RF obteve os melhores resultados em todas as métricas, com uma acurácia de 0,78 no treino e 0,78 no teste, demonstrando uma ótima capacidade de generalização. Além disso, suas altas precisões (0,80 no treino e 0,81 no teste) indicam que o modelo foi confiável na identificação dos casos positivos corretos, e o recall de 0,80 no treino e 0,78 no teste mostra que ele conseguiu capturar a maioria dos exemplos positivos. O SVM teve um desempenho intermediário. Com uma acurácia de 0,77 no treino e 0,74 no teste, o modelo apresentou uma leve queda na fase de teste, sugerindo que não generalizou tão bem quanto o RF. Apesar disso, sua precisão e recall foram consideráveis para um banco de dados diverso, embora inferiores aos do RF. Por outro lado, o PC teve o desempenho mais fraco, com acurácia de 0,58 no treino e 0,61 no teste, refletindo dificuldades em capturar padrões e generalizar bem os dados. Sua precisão e recall também foram baixos, indicando uma menor capacidade em identificar corretamente os casos positivos.

Dessa maneira, o RF foi o modelo mais bem-sucedido, equilibrando alto desempenho em todas as métricas. A acurácia demonstrou a capacidade geral do modelo em classificar corretamente os exemplos, enquanto a precisão indicou a confiabilidade das previsões positivas, ou seja, com que frequência o modelo acertou quando previu uma determinada espécie. Já o recall evidenciou a habilidade do modelo em identificar corretamente os exemplos reais de cada espécie. Por apresentar bom desempenho simultâneo nesses três aspectos, o Random Forest foi escolhido para a análise com variação de diversidade. O modelo ótimo foi obtido com os seguintes hiperparâmetros: `max_depth = 8`, que limita a profundidade máxima de cada árvore para evitar sobreajuste; `min_samples_leaf = 4`, que define o número mínimo de amostras em uma folha terminal; `min_samples_split = 10`, que especifica o número mínimo de amostras necessárias para dividir um nó; `n_estimators = 491`, representando o número total de árvores na floresta; e `criterion = entropy`, que indica que a divisão dos nós foi baseada no ganho de informação, visando maximizar a pureza das classes

5.1.1. Matrizes de confusão

Na matriz de confusão do RF, a espécie mais confundida foi a *Bombus pauloensis* (Classe 8). Ela foi confundida 3 vezes com *Exomalopsis* (Classe 9), 3 vezes com *Xylocopa suspecta* (Classe 10), e 1 vez com *Oxaea flavescens* (Classe 11). Isso demonstra que o modelo teve dificuldade em distinguir *Bombus pauloensis* das demais espécies. *Bombus morio* C (Classe 0), *Eulaema nigrita* (Classe 4) e *Ptiloglossa* (Classe 7) foram classificadas com 100% de acerto.

Matriz de confusão para o Random Forest

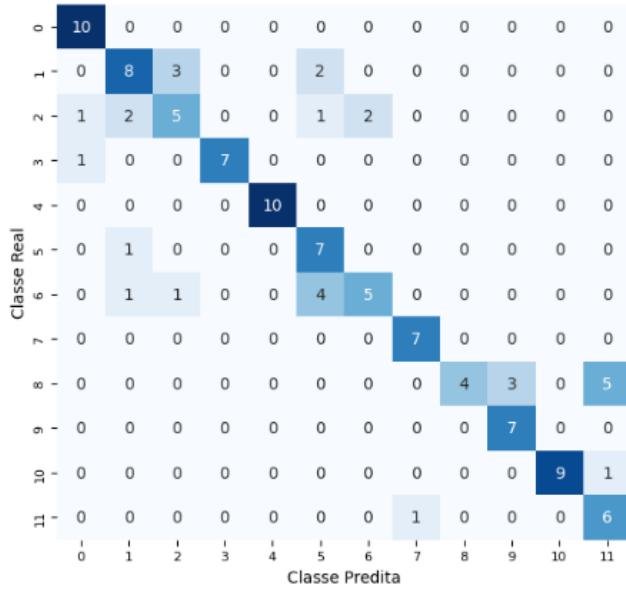


Classe 0: *Bombus morio C*, Classe 1: *Xylocopa hirsutissima*, Classe 2: *Bombus morio*, Classe 3: *Melipona sp*, Classe 4: *Eulaema nigrita*, Classe 5: *Centris fuscata*, Classe 6: *Xylocopa sp*, Classe 7: *Ptiloglossa*, Classe 8: *Bombus pauloensis*, Classe 9: *Exomalopsis*, Classe 10: *Oxaea flavescens*, Classe 11: *Xylocopa suspecta*

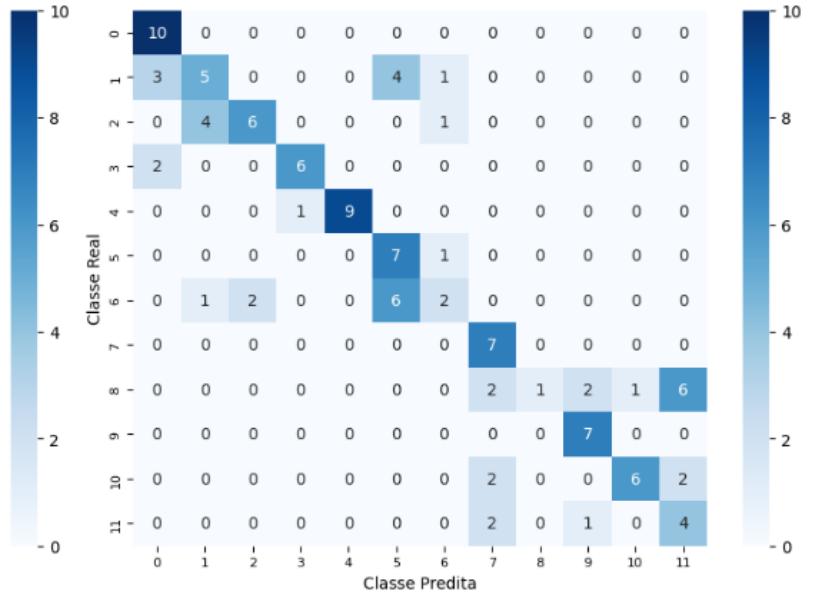
Figura 3: Matriz de confusão para o algoritmo *Random Forest*. O eixo vertical representa as classes verdadeiras e o eixo horizontal as classes previstas. Cada célula mostra o número de vezes que a classe real foi atribuída a classe predita. Quanto mais escura a célula, maior o número de acertos.

Na matriz de confusão para o SVM, *Bombus morio C*, *Eulaema nigrita* e *Ptiloglossa* também foram classificados com 100% de acertos, demonstrando que tais classes foram bem classificadas por ambos algoritmos e com adição da *Exomalopsis* (Classe 9) no SVM também sem confusão com nenhuma classe. A classe mais confundida no SVM foi a *Bombus morio* (Classe 2), o que indica que há diferenças nos dados de *Bombus morio* para diferentes morfotipos florais, pois apesar de se referirem a mesma espécie, os dados coletados em *Chamaecrista latistipula* tiveram acurácia máxima. A matriz de confusão do PC também teve 100% de acerto em *Bombus morio C*, *Ptiloglossa* e *Exomalopsis*, corroborando com os demais modelos. Porém diversas classes foram muito confundidas e demonstrou o pior desempenho entre os 3 algoritmos.

Matriz de confusão para o SVM



Matriz de confusão para o Perceptron



Classe 0: *Bombus morio* C, Classe 1: *Xylocopa hirsutissima*, Classe 2: *Bombus morio*, Classe 3: *Melipona* sp, Classe 4: *Eulaema nigrita*, Classe 5: *Centris fuscata*, Classe 6: *Xylocopa* sp, Classe 7: *Ptiloglossa*, Classe 8: *Bombus pauloensis*, Classe 9: *Exomalopsis*, Classe 10: *Oxaea flavescens*, Classe 11: *Xylocopa suspecta*

Figura 4: Matrizes de confusão para os algoritmos SVM e *Perceptron*. O eixo vertical representa as classes verdadeiras e o eixo horizontal as classes previstas. Cada célula mostra o número de vezes que a classe real foi atribuída a classe predita. Quanto mais escura a célula, maior o número de acertos.

5.1.2. Análise de permutação de variáveis

A Figura 5 apresenta a escala de importância de permutação considerando o modelo RF. Como esperado, a Frequência Fundamental e a média do MFCC 1 são as variáveis que mais aparecem nas decisões dos modelos. Parâmetros relativos às médias do MFCC são recorrentes nesta escala. O tipo de vibração também foi um fator importante na classificação, tendo valores semelhantes entre os dois tipos (*buzz* e *voo*).

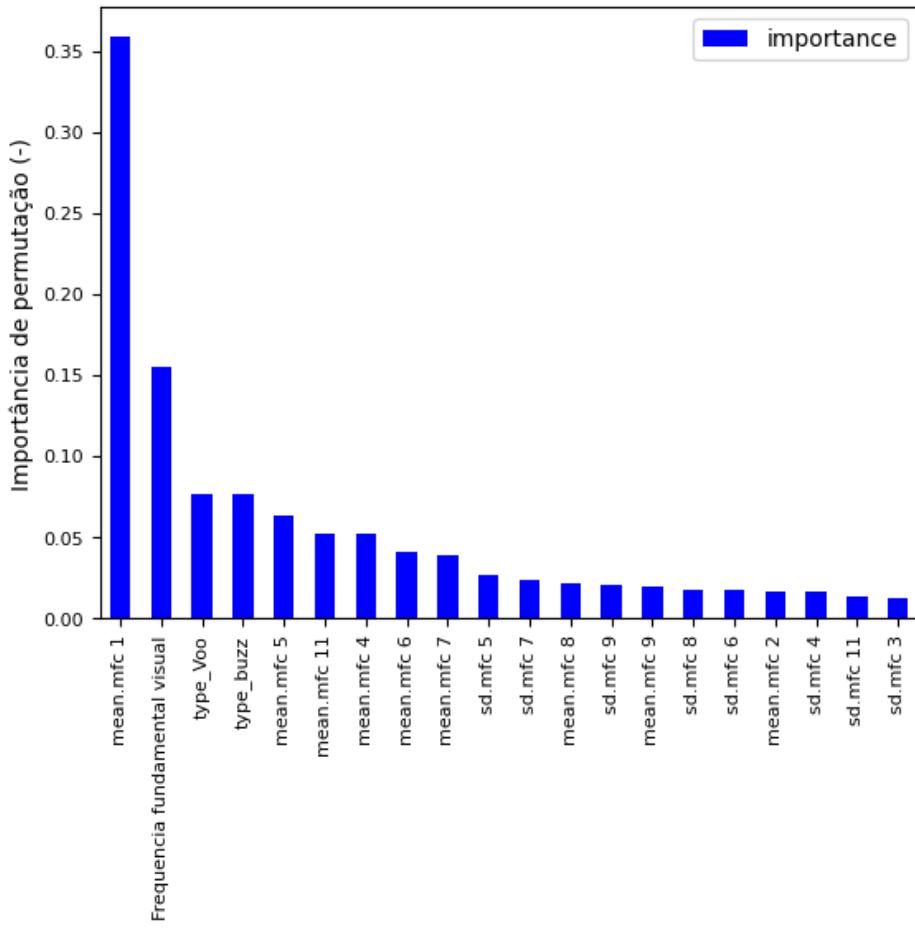


Figura 5: Vinte variáveis mais importantes pela análise de permutação para os modelos RF.
Fonte: Autoria própria.

5.1.3. Desempenho do modelo Random Forest para comunidades diversas

A Figura 6 demonstra o comportamento do modelo RF para classificar comunidades com diferentes índices de diversidade, indicados pela variação do índice de diversidade H' (Shannon). Os valores representam as médias das acurárias dos testes à medida que as comunidades vão ficando mais diversas.

A Figura 7 demonstra as variações nas médias de recall e precisão do modelo, tanto no conjunto de treino quanto no conjunto de teste, à medida que o índice de diversidade H' (Shannon) varia.

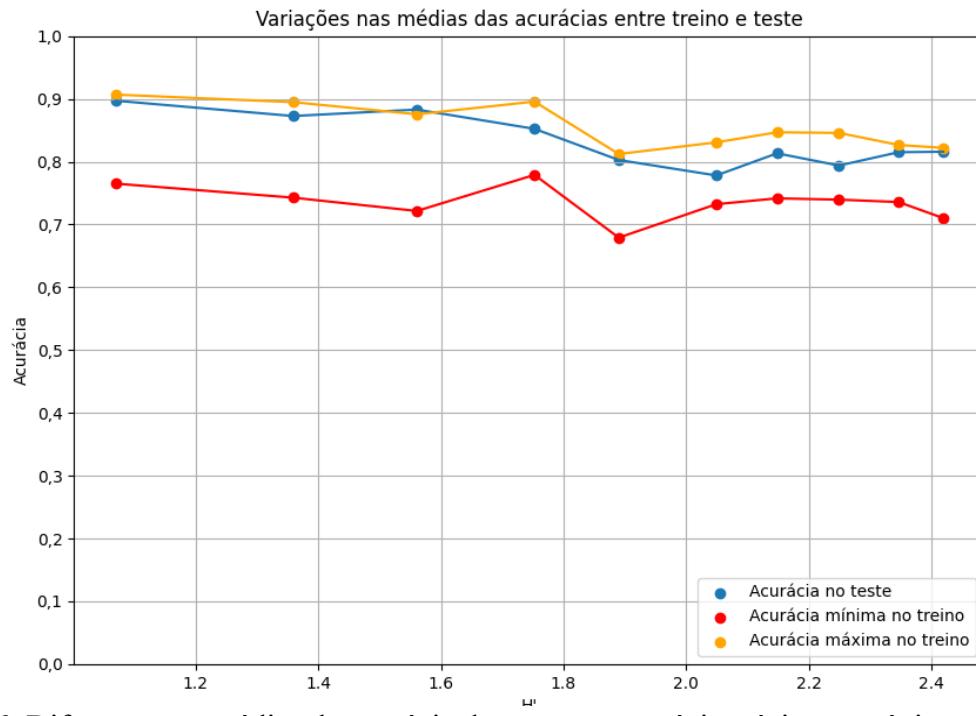


Figura 6: Diferença nas médias de acurácia dos testes e acurácia mínima e máxima dos treinos para o algoritmo *Random Forest*.

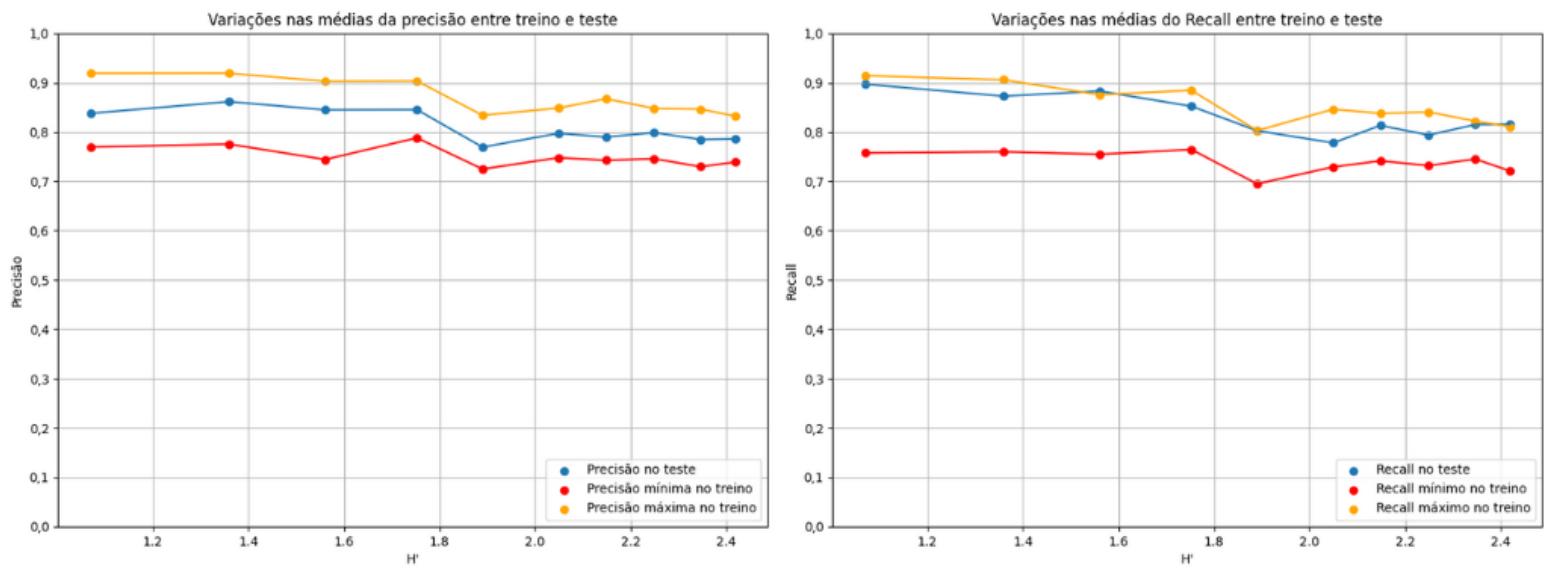


Figura 7: Diferença nas médias da Precisão e do Recall dos testes e das mínimas e máximas dos treinos para o algoritmo Random Forest.

Nos três parâmetros analisados no modelo (acurácia, precisão e recall) houve uma leve queda com o aumento da diversidade, porém essa queda foi inferior a 10%, o que indica que a acurácia da classificação se mantém alta mesmo com comunidades mais diversas.

6. DISCUSSÃO

Nossos resultados mostraram um desempenho promissor na classificação de 12 espécies de abelhas a partir dos sons produzidos durante as vibrações florais de *buzz* e *voo*. Entre os modelos estudados, o modelo RF foi o mais eficaz, alcançando uma acurácia de 78,9% superando tanto o SVM quanto o PC, que obtiveram acuráncias de 74,6% e 61,4% respectivamente. A matriz de confusão gerada a partir do RF demonstrou que, embora o modelo tenha sido eficiente na maioria das classificações, com classes obtendo 100% de acertos, como *Bombus morio C*, *Eulaema nigrita* e *Ptiloglossa*, houveram confusões principalmente entre espécies de tamanho corporal semelhante como *Bombus pauloensis*, *Xylocopa suspecta* e *Oxaea flavescens*, porém *Exomalopsis* também foi confundida com *Bombus pauloensis*, mesmo sendo menor em tamanho (dados relativos ao tamanho corporal das abelhas obtidos no site <https://www.coloradonativebee.com/>).

Trabalhos recentes demonstram que o tamanho da abelha tem influência em diversos aspectos de sua biologia e que tamanhos diferentes resultam em propriedades acústicas diferentes (DE LUCA et al. 2019; FITZGERALD et al. 2022) Além disso, a frequência fundamental e os valores do MFCC foram cruciais para a classificação entre as espécies, bem como o tipo de vibração das abelhas. Por fim, apesar da acurácia na classificação diminuir com o aumento da diversidade de abelhas a serem classificadas, o desempenho do modelo se manteve relativamente estável, sugerindo que o modelo *Random Forest* possui robustez mesmo em cenários com complexidades diferentes.

6.1. Diferença entre modelos

Os três modelos apresentaram desempenhos variados ao classificar as abelhas. O Random Forest destacou-se como o modelo de melhor desempenho, mostrando uma

capacidade robusta de generalização. O SVM apresentou um desempenho intermediário, com enquanto o Perceptron teve o pior desempenho. O Perceptron, com uma única camada oculta é uma rede neural simples e o desempenho inferior pode indicar que o problema requer uma rede neural mais profunda, que compreenda padrões mais complexos entre as classes. Além disso, com 567 amostras e 67 *features*, o dataset é relativamente pequeno em relação ao número de *features*. Isso pode favorecer modelos como SVM e RF, que tendem a ser mais robustos em situações com uma quantidade limitada de dados (SIEMERS et al., 2023), enquanto redes neurais, como o Perceptron, geralmente precisam de mais dados para treinar de maneira eficaz (ALWOSHEEL et al., 2018).

Portanto, é plausível supor que a obtenção de um conjunto maior de dados sonoros melhoraria significativamente o desempenho dos modelos, especialmente no caso das redes neurais profundas. Com mais amostras disponíveis, seria possível selecionar gravações de maior qualidade e com menos interferências sonoras, que juntamente com a extração de um maior número de parâmetros, permitiria capturar uma gama mais ampla de padrões acústicos. Isso possibilitaria que os modelos aprendessem características mais representativas das diferentes espécies de abelhas, aprimorando a acurácia da classificação. (ALWOSHEEL et al., 2018). A padronização da coleta também pode ter influência no resultado geral, pois, a mesma metodologia aplicada em diferentes cenários pode sofrer alteração, principalmente por se tratar de dados acústicos (KEEN et al., 2021).

Embora estudos anteriores já tenham demonstrado que as abelhas são capazes de modular a frequência de suas vibrações de acordo com o contexto comportamental e com a espécie de planta visitada (Switzer e Combes 2017), os dados do presente estudo não permitem afirmar com segurança que existe uma modulação da vibração por *Bombus morio* em diferentes morfotipos florais. Apesar das duas classes referentes a essa espécie não terem sido confundidas entre si, o modelo apresentou acurácia de 100% para os dados coletados em *Chamaecrista latistipula*, mas houve confusões com outras espécies nas classificações baseadas em *Rhynchanthera grandiflora*. Isso pode indicar tanto uma diferença real na vibração da abelha em resposta à morfologia floral, como também pode refletir variações relacionadas ao viés de coleta ou à qualidade das gravações, pois o excesso de ruídos pode confundir o algoritmo. De qualquer forma, para analisar a diferença entre morfotipos florais,

seria necessário que houvessem mais dados referentes as mesmas abelhas visitando ambas espécies de planta.

6.2. Parâmetros acústicos

A presença significativa das variáveis de tipo *buzz* ou voo no início da lista de características importantes ao modelo indica que o tipo de dado gravado desempenha um papel crucial na classificação. Isso sugere que a interpretação dos sons produzidos pelas abelhas pode estar intimamente ligada ao comportamento, implicando que diferentes contextos acústicos podem ser fundamentais para distinção entre as classes. Diversos trabalhos demonstraram diferenças entre o tipo de vibração e suas características acústicas (DE LUCA e VALLEJO-MARÍN, 2013; DE LUCA et al., 2014; VALLEJO-MARÍN 2019; PRITCHARD e VALLEJO-MARÍN 2020). Estes trabalhos destacam a importância da frequência fundamental, amplitude e duração na diferenciação dos sons produzidos pelas abelhas, evidenciando que tais características estão diretamente relacionadas aos padrões comportamentais e propriedades acústicas desses insetos.

Embora a exploração do MFCC ainda seja recente no contexto de bioacústica de abelhas, é importante ressaltar sua relevância (CEJROWSKI et al., 2020; RIBEIRO et al., 2021; DI et al., 2023; RUVINGA et al. 2023), pois o MFCC pode estar associados à arquitetura corporal das abelhas, capturando particularidades entre diferentes espécies, que podem influenciar na produção sonora. Portanto, a classificação dos sons das abelhas está intimamente ligada tanto ao comportamento quanto às propriedades físicas e morfológicas dos insetos (PRITCHARD e VALLEJO-MARÍN, 2020).

6.3. Variação da acurácia com a diversidade

A análise da acurácia do *Random Forest* em função do índice de Shannon (H') revelou que, à medida que a diversidade das comunidades aumentava, o desempenho do modelo se manteve relativamente estável com a acurácia do teste variando em torno de 80% e 90%. Esses resultados indicam que, embora o aumento da diversidade torne o problema de classificação mais complexo, o *Random Forest* foi capaz de lidar com essa complexidade de

forma eficiente, mantendo um bom desempenho em cenários mais diversos. Embora esse conjunto de espécies não reflita totalmente a complexidade da diversidade encontrada em campo e represente uma baixa porcentagem de espécies que realizam *buzz pollination* (CARDINAL et al., 2018; RUSSELL et al., 2024) este trabalho nos motiva e nos aproxima de estudos mais abrangentes e de ferramentas capazes de classificar comunidades com diversidade elevada.

Os resultados aqui apresentados são um passo importante para a criação de sistemas de monitoramento automático da diversidade de abelhas. A partir do momento em que algoritmos como o *Random Forest* conseguem lidar com um banco de dados diverso, abrem-se possibilidades para o desenvolvimento de ferramentas aplicáveis a ambientes naturais, onde a diversidade de espécies é ainda maior.

6.4. Conclusões e perspectivas futuras

Concluindo, este trabalho demonstrou que um algoritmo relativamente simples como o *Random Forest*, pode ser eficaz na classificação de espécies em diferentes cenários de diversidade. Isso indica que, com a implementação de modelos mais robustos e com o aumento da disponibilidade de dados, é possível alcançar resultados cada vez mais precisos. Uma direção promissora para pesquisas futuras seria a formação de uma biblioteca global de sons de abelhas, que não apenas auxiliaria na melhoria dos modelos de classificação existentes, mas também contribuiria para o avanço dos estudos acústicos desses insetos, possibilitando melhor entendimento a respeito da bioacústica de abelhas e aplicações em monitoramento ambiental e conservação de espécies. Já existem bancos de dados acústicos disponíveis que fornecem acesso a gravações de sons de diferentes espécies, facilitando pesquisas em bioacústica e conservação de biodiversidade. O Xeno-canto (<https://xenocanto.org/>) é um exemplo de repositório global que concentra sons de aves de várias regiões, contribuindo para estudos ecológicos e taxonômicos. A *Macaulay Library* (<https://www.macaulaylibrary.org/>), gerida pelo *Cornell Lab of Ornithology*, é um dos maiores banco de dados de áudio e vídeo da vida selvagem, oferecendo uma vasta gama de vocalizações de diferentes espécies. Outro recurso é o *Animal Audiogram Database*

(<https://www.animalaudiograms.org/>), que fornece dados acústicos focados em pesquisas sobre percepção auditiva em animais. Além disso, o Global Biodiversity Information Facility (<https://www.gbif.org/>) integra informações de biodiversidade, incluindo dados acústicos de várias espécies, tornando esses recursos essenciais para pesquisas ecológicas e comportamentais. Portanto, uma biblioteca de sons de abelhas, aliada a técnicas de machine learning podem ser um grande passo para o desenvolvimento de ferramentas de classificação automática precisas e confiantes. Assim, este trabalho não apenas contribui para o avanço técnico na classificação de abelhas, mas também oferece uma base para futuros estudos que possam integrar esses modelos em sistemas de monitoramento ambiental, auxiliando na conservação e no estudo das comunidades de abelhas em diferentes ecossistemas.

7. REFERÊNCIAS

- ABANGAN, Alexa Sugpatan; KOPP, Dorothee; FAILLETTAZ, Robin. Artificial intelligence for fish behavior recognition may unlock fishing gear selectivity. **Frontiers in Marine Science**, v. 10, p. 1010761, 2023. <https://doi.org/10.3389/fmars.2023.1010761>
- AKBAL, E. et al. Explainable automated anuran sound classification using improved one-dimensional local binary pattern and Tunable Q Wavelet Transform techniques. **Expert Systems with Applications**, v. 225, p. 120089, set. 2023. <https://doi.org/10.1016/j.eswa.2023.120089>
- AKIBA, T. et al. **Optuna**. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. **Anais...** New York, NY, USA: ACM, 25 jul. 2019. <https://doi.org/10.1145/3292500.3330701>
- ALWOSHEEL, A., VAN CRANENBURGH, S., & CHORUS, C. G. Is your dataset big enough? Sample size requirements when using artificial neural networks for discrete choice analysis. **Journal of choice modelling**, 28, 167-182, (2018). <https://doi.org/10.1016/j.jocm.2018.07.002>
- ARIA, M.; CUCCURULLO, C.; GNASSO, A. A comparison among interpretative proposals for Random Forests. **Machine Learning with Applications**, v. 6, p. 100094, dez. 2021. <https://doi.org/10.1016/j.mlwa.2021.100094>

AURET, L.; ALDRICH, C. Interpretation of nonlinear relationships between process variables by use of random forests. **Minerals Engineering**, v. 35, p. 27–42, ago. 2012. <https://doi.org/10.1016/j.mineng.2012.05.008>

BALAKRISHNAN, Rohini. Species concepts, species boundaries and species identification: a view from the tropics. **Systematic biology**, v. 54, n. 4, p. 689-693, 2005. <https://doi.org/10.1080/10635150590950308>

BEDOYA, Carol et al. Automatic recognition of anuran species based on syllable identification. **Ecological Informatics**, v. 24, p. 200-209, 2014. <https://doi.org/10.1016/j.ecoinf.2014.08.009>

BERGMANN, T., HADRYS, H., BREVES, G., & SCHIERWATER, B. Character-based DNA barcoding: a superior tool for species classification. **Berliner und Münchener Tierärztliche Wochenschrift**, 122(11/12), 446-450, (2009).

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001. <https://doi.org/10.1023/A:1010933404324>

BROWN, C.; RIEDE, T. (EDS.). **Comparative Bioacoustics: An Overview**. [s.l.] BENTHAM SCIENCE PUBLISHERS, 2017. <https://doi.org/10.2174/97816810831791170101>

BUCHMANN, S. L. Bees Use Vibration to Aid Pollen Collection from Non-Poricidal Flowers. **Journal of the Kansas Entomological Society**, v. 58, n. 3, p. 517–525, 1985.

CARDINAL, S., BUCHMANN, S. L., & RUSSELL, A. L. The evolution of floral sonication, a pollen foraging behavior used by bees (Anthophila). **Evolution**, 72(3), 590-600, (2018). <https://doi.org/10.1111/evo.13446>

ÇAKIR, M. et al. Accuracy assessment of RFerns, NB, SVM, and kNN machine learning classifiers in aquaculture. **Journal of King Saud University - Science**, v. 35, n. 6, p. 102754, ago. 2023. <https://doi.org/10.1016/j.jksus.2023.102754>

CEJROWSKI, T., SZYMAŃSKI, J., & LOGOFĂTU, D. Buzz-based recognition of the honeybee colony circadian rhythm. **Computers and Electronics in Agriculture**, 175, 105586, (2020). <https://doi.org/10.1016/j.compag.2020.105586>

CHENG, Jinkui; SUN, Yuehua; JI, Liqiang. A call-independent and automatic acoustic system for the individual recognition of animals: A novel model using four passerines.

Pattern Recognition, v. 43, n. 11, p. 3846-3852, 2010.
<https://doi.org/10.1016/j.patcog.2010.04.026>

DALIANIS, H. Evaluation Metrics and Evaluation. In: Clinical Text Mining. **Springer**, Cham. https://doi.org/10.1007/978-3-319-78503-5_6 (2018). https://doi.org/10.1007/978-3-319-78503-5_6

DE LUCA, P. A.; VALLEJO-MARÍN, M. What's the 'buzz' about? The ecology and evolutionary significance of buzz-pollination. **Current Opinion in Plant Biology**, v. 16, n. 4, p. 429–435, ago. 2013. <https://doi.org/10.1016/j.pbi.2013.05.002>

DE LUCA, P. A., COX, D. A., & VALLEJO-MARÍN, M. Comparison of pollination and defensive buzzes in bumblebees indicates species-specific and context-dependent vibrations. **Naturwissenschaften**, 101, 331-338, (2014). <https://doi.org/10.1007/s00114-014-1161-7>

DE LUCA, P. A., BUCHMANN, S., GALEN, C., MASON, A. C., & VALLEJO-MARÍN, M. Does body size predict the buzz-pollination frequencies used by bees? **Ecology and evolution**, 9(8), 4875-4887, (2019). <https://doi.org/10.1002/ece3.5092>

DE LUCA, P. A. et al. How well do acoustic recordings characterize properties of bee (*Anthophila*) floral sonication vibrations? **Bioacoustics**, v. 29, n. 1, p. 1–14, 2 jan. 2020. <https://doi.org/10.1080/09524622.2018.1511474>

DE QUEIROZ, KEVIN. Species concepts and species delimitation. **Systematic biology**, v. 56, n. 6, p. 879-886, 2007. <https://doi.org/10.1080/10635150701701083>

DI, NAYAN et al. Applicability of VGGish embedding in bee colony monitoring: comparison with MFCC in colony sound classification. **PeerJ**, v. 11, p. e14696, 2023. <https://doi.org/10.7717/peerj.14696>

DUFRESNES, CHRISTOPHE; POYARKOV, NIKOLAY; JABLONSKI, DANIEL. Acknowledging more biodiversity without more species. **Proceedings of the national Academy of Sciences**, v. 120, n. 40, p. e2302424120, 2023. <https://doi.org/10.1073/pnas.2302424120>

FACELI, K. et al. **Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina**. 1th. ed. São Paulo: LTC, 2011.

- FERREIRA, A. I. S., DA SILVA, N. F. F., MESQUITA, F. N., ROSA, T. C., MONZÓN, V. H., & MESQUITA-NETO, J. N. Automatic acoustic recognition of pollinating bee species can be highly improved by Deep Learning models accompanied by pre-training and strong data augmentation. *Frontiers in Plant Science*, 14, 1081050, (2023). <https://doi.org/10.3389/fpls.2023.1081050>
- FITZGERALD, J. L., OGILVIE, J. E., & CARADONNA, P. J. Ecological drivers and consequences of bumble bee body size variation. *Environmental Entomology*, 51(6), 1055-1068 (2022). <https://doi.org/10.1093/ee/nvac093>
- FOODY, G. M. Challenges in the real world use of classification accuracy metrics: From recall and precision to the Matthews correlation coefficient. *Plos one*, 18(10), e0291908. (2023). <https://doi.org/10.1371/journal.pone.0291908>
- GASTON, K. J.; MAY, R. M. Taxonomy of taxonomists. *Nature*, v. 356, n. 6367, p. 281–282, mar. 1992. <https://doi.org/10.1038/356281a0>
- GASTON, K. J.; O’NEILL, M. A. Automated species identification: why not? *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, v. 359, n. 1444, p. 655–667, 29 abr. 2004. <https://doi.org/10.1098/rstb.2003.1442>
- GERON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and Tensorflow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 2nd. ed. Califórnia: O'Reilly Media, 2019.
- GIGNAC, G. E.; SZODORAI, E. T. Defining intelligence: Bridging the gap between human and artificial perspectives. *Intelligence*, v. 104, p. 101832, maio 2024. <https://doi.org/10.1016/j.intell.2024.101832>
- GRADIŠEK, A. et al. Predicting species identity of bumblebees through analysis of flight buzzing sounds. *Bioacoustics*, v. 26, n. 1, p. 63–76, 2 jan. 2016. <https://doi.org/10.1080/09524622.2016.1190946>
- HARB, R. et al. Exploring precrash maneuvers using classification trees and random forests. *Accident Analysis & Prevention*, v. 41, n. 1, p. 98–107, jan. 2009. <https://doi.org/10.1016/j.aap.2008.09.009>
- HRNCIR, M., GRAVEL, A. I., SCHORKOPF, D. L. P., SCHMIDT, V. M., ZUCCHI, R., & BARTH, F. G. Thoracic vibrations in stingless bees (*Melipona seminigra*): resonances of the

thorax influence vibrations associated with flight but not those associated with sound production. **Journal of Experimental Biology**, 211(5), 678-685, (2008).
<https://doi.org/10.1242/jeb.013920>

INDUMATHI, C. P.; DIVIYALAKSHMI, K. R.; MAHALAKSHMI, R. Bird Sound Identification System using Deep Learning. **Procedia Computer Science**, v. 233, p. 597-603, 2024. <https://doi.org/10.1016/j.procs.2024.03.249>

JANITZA, S., STROBL, C. & BOULESTEIX, AL. An AUC-based permutation variable importance measure for random forests. **BMC Bioinformatics** 14, 119 (2013).
<https://doi.org/10.1186/1471-2105-14-119>

JÖRGER, K. M.; SCHRÖDL, M. How to describe a cryptic species? Practical challenges of molecular taxonomy. **Frontiers in Zoology**, v. 10, n. 1, p. 59, 2013.
<https://doi.org/10.1186/1742-9994-10-59>

KEEN, S. C., ODOM, K. J., WEBSTER, M. S., KOHN, G. M., WRIGHT, T. F., & ARAYA-SALAS, M. A machine learning approach for classifying and quantifying acoustic diversity. **Methods in ecology and evolution**, 12(7), 1213-1225, (2021).
<https://doi.org/10.1111/2041-210X.13599>

KIANIAN, I. et al. Automated identification of toxigenic cyanobacterial genera for water quality control purposes. **Journal of Environmental Management**, v. 362, p. 121274, jun. 2024. <https://doi.org/10.1016/j.jenvman.2024.121274>

KING, M. J.; BUCHMANN, S. L.; SPANGLER, H. Activity of Asynchronous Flight Muscle From two Bee Families During Sonication (Buzzing). **Journal of Experimental Biology**, v. 199, n. 10, p. 2317–2321, 1 out. 1996. <https://doi.org/10.1242/jeb.199.10.2317>

LASSECK, Mario. Improved Automatic Bird Identification through Decision Tree based Feature Selection and Bagging. In: CLEF (Working Notes). 2015.

MAGALHÃES, A. T.; HIRATA, N. S. T. **Spider Species Classification Using Vision Transformers and Convolutional Neural Networks**. Anais Estendidos da XXXVI Conference on Graphics, Patterns and Images (SIBRAPI Estendido 2023). Anais...Sociedade Brasileira de Computação - SBC, 6 nov. 2023.
<https://doi.org/10.5753/sibgrapi.est.2023.27475>

MARKOULIDAKIS I, RALLIS I, GEORGULAS I, KOPSIAFTIS G, DOULAMIS A, DOULAMIS N. Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem. **Technologies**; 9(4):81, (2021). <https://doi.org/10.3390/technologies9040081>

MAURER, BRIAN A.; MCGILL, BRIAN J. Measurement of species diversity. Biological diversity: **frontiers in measurement and assessment**, p. 55-65, 2011.

MOLNAR, C. **Interpretable Machine Learning**. 1th. ed. Morrisville: Lulu.com, 2020.

OTCHERE, D. A. et al. Application of supervised machine learning paradigms in the prediction of petroleum reservoir properties: Comparative analysis of ANN and SVM models. **Journal of Petroleum Science and Engineering**, v. 200, p. 108182, maio 2021.

<https://doi.org/10.1016/j.petrol.2020.108182>

PASTORE, J. A., DE AGUIAR, O. T., ESTEVES, R., & DA SILVA, C. A. F. Flora arbóreo-arbustiva do Parque Chico Mendes, município de São Bernardo do Campo (SP). **Revista do Instituto Florestal**, 4(1), 269-273, (1992).

PENAR, W.; MAGIERA, A.; KLOCEK, C. Applications of bioacoustics in animal ecology. **Ecological Complexity**, v. 43, p. 100847, ago. 2020.

<https://doi.org/10.1016/j.ecocom.2020.100847>

PRITCHARD, D. J., & VALLEJO-MARÍN, M. Floral vibrations by buzz-pollinating bees achieve higher frequency, velocity and acceleration than flight and defence vibrations. **Journal of Experimental Biology**, 223(11), jeb220541, (2020).

<https://doi.org/10.1242/jeb.220541>

RIBEIRO, A. P., DA SILVA, N. F. F., MESQUITA, F. N., ARAÚJO, P. D. C. S., ROSA, T. C., & MESQUITA-NETO, J. N. Machine learning approach for automatic recognition of tomato-pollinating bees based on their buzzing-sounds. **PLoS computational biology**, 17(9), e1009426, (2021). <https://doi.org/10.1371/journal.pcbi.1009426>

ROBLES-GUERRERO, A. et al. Frequency Analysis of Honey Bee Buzz for Automatic Recognition of Health Status: A Preliminary Study. **Research in Computing Science**, v. 142, p. 89–98, 2017. <https://doi.org/10.13053/rccs-142-1-9>

ROSA, R.; LIMA, S. C.; ASSUNÇÃO, W. L. Abordagem preliminar das condições climáticas de Uberlândia (MG). **Sociedade e Natureza**, 3, 91-108, 1991. ROSELLÓ-

MORA, RAMON. Opinion: the species problem, can we achieve a universal concept? **Systematic and applied microbiology**, v. 26, n. 3, p. 323-326, 2003. <https://doi.org/10.1078/072320203322497347>

RUSSELL, A. L., BUCHMANN, S. L., ASCHER, J. S., WANG, Z., KRIEBEL, R., JOLLES, D. D., & HUGHES, A. C. Global patterns and drivers of buzzing bees and poricidal plants. **Current Biology**, 34(14), 3055-3063, (2024). <https://doi.org/10.1016/j.cub.2024.05.065>

RUVINGA, S., HUNTER, G., DURAN, O., & NEBEL, J. C. Identifying queenlessness in honeybee hives from audio signals using machine learning. **Electronics**, 12(7), 1627, (2023). <https://doi.org/10.3390/electronics12071627>

SARKER, I. H. Machine Learning: Algorithms, Real-World Applications and Research Directions. **SN Computer Science**, v. 2, n. 3, p. 160, 22 maio 2021. <https://doi.org/10.1007/s42979-021-00592-x>

SIEMERS, F. M., & BAJORATH, J. Differences in learning characteristics between support vector machine and random forest models for compound classification revealed by Shapley value analysis. **Scientific Reports**, 13(1), 5983, (2023). <https://doi.org/10.1038/s41598-023-33215-x>

SIMOVIC, P. et al. Automated identification of aquatic insects: A case study using deep learning and computer vision techniques. **Science of The Total Environment**, v. 935, p. 172877, jul. 2024. <https://doi.org/10.1016/j.scitotenv.2024.172877>

SINGH, Jaswinder; BANERJEE, Rajdeep. A study on single and multi-layer perceptron neural network. In: **3rd International Conference on Computing Methodologies and Communication (ICCMC)**. IEEE, 2019. p. 35-40, 2019. <https://doi.org/10.1109/ICCMC.2019.8819775>

SPEISER, J. L. et al. A comparison of random forest variable selection methods for classification prediction modeling. **Expert Systems with Applications**, v. 134, p. 93–101, nov. 2019. <https://doi.org/10.1016/j.eswa.2019.05.028>

SUEUR, J.; FARINA, A. Ecoacoustics: the Ecological Investigation and Interpretation of Environmental Sound. **Biosemiotics**, v. 8, n. 3, p. 493–502, 8 dez. 2015. <https://doi.org/10.1007/s12304-015-9248-x>

SWITZER, Callin M.; COMBES, Stacey A. Bumblebee sonication behavior changes with plant species and environmental conditions. **Apidologie**, v. 48, p. 223-233, 2017.

<https://doi.org/10.1007/s13592-016-0467-1>

TICAY-RIVAS, Jaime R. et al. Spider specie identification and verification based on pattern recognition of it cobweb. **Expert systems with applications**, v. 40, n. 10, p. 4213-4225, 2013. <https://doi.org/10.1016/j.eswa.2013.01.024>

TRUONG, T. H. et al. A deep learning-based approach for bee sound identification. **Ecological Informatics**, v. 78, p. 102274, dez. 2023.

<https://doi.org/10.1016/j.ecoinf.2023.102274>

VALLEJO-MARÍN, MARIO. Buzz pollination: studying bee vibrations on flowers. **New Phytologist**, v. 224, n. 3, p. 1068-1074, 2019. <https://doi.org/10.1111/nph.15666>

VALLEJO-MARÍN, MARIO. How and why do bees buzz? Implications for buzz pollination. **Journal of Experimental Botany**, v. 73, n. 4, p. 1080-1092, 2022. <https://doi.org/10.1093/jxb/erab428>

VIEIRA, J. P., DE SOUZA, M. J., TEIXEIRA, J. M., & CARVALHO, F. P. D. Estudo da precipitação mensal durante a estação chuvosa em Diamantina, Minas Gerais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 14, 762-767, (2010). <https://doi.org/10.1590/S1415-43662010000700012>

WEI, PENGFEI; LU, ZHENZHOU; SONG, JINGWEN. Variable importance analysis: A comprehensive review. **Reliability Engineering & System Safety**, v. 142, p. 399-432, 2015.

WOODROW, C., JAFFERIS, N., KANG, Y., & VALLEJO-MARÍN, M. Buzz-pollinating bees deliver thoracic vibrations to flowers through periodic biting. **Current Biology**, (2024). <https://doi.org/10.1016/j.cub.2024.07.044>

ZHOU, J. et al. Random Forests and Cubist Algorithms for Predicting Shear Strengths of Rockfill Materials. **Applied Sciences**, v. 9, n. 8, p. 1621, abr. 2019. <https://doi.org/10.3390/app9081621>