

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Curso de Ciências Biológicas

CÉSAR AUGUSTO ARVELOS

**BUZZ TRAP: IDENTIFICAÇÃO DE ABELHAS USANDO
CARACTERÍSTICAS ACÚSTICAS E INTELIGÊNCIA ARTIFICIAL**

UBERLÂNDIA

2021

CÉSAR AUGUSTO ARVELOS

**BUZZ TRAP: IDENTIFICAÇÃO DE ABELHAS USANDO
CARACTERÍSTICAS ACÚSTICAS E INTELIGÊNCIA ARTIFICIAL**

Trabalho de Conclusão de Curso apresentado à coordenação do curso de Ciências Biológicas, da Universidade Federal de Uberlândia, como requisito para a obtenção do grau de Bacharelado no curso de Ciências Biológicas.

Orientador: Prof. Dr. Vinícius Lourenço Garcia de Brito (UFU)

UBERLÂNDIA

2021

CÉSAR AUGUSTO ARVELOS

**BUZZ TRAP: IDENTIFICAÇÃO DE ABELHAS USANDO
CARACTERÍSTICAS ACÚSTICAS E INTELIGÊNCIA ARTIFICIAL**

Trabalho de Conclusão de Curso aprovado para obtenção do grau de Bacharelado, no curso de Ciências Biológicas, da Universidade Federal de Uberlândia, pela banca examinadora formada por:

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

Profª. Dr. Patrícia Nunes-Silva (UNISINOS)

Dr. Carlos Eduardo Pereira Nunes (University of Stirling)

Uberlândia, 27 de maio de 2021.

“Se você quer encontrar os segredos do universo, pense em termos de energia, frequência e vibração.”

(Nikola Tesla)

RESUMO

Existem poucos estudos que abordam a identificação automática de abelhas através dos seus sons. Além disso, nenhum estudo conhecido utilizou o som de abelhas vibrando flores (*buzz*) para o reconhecimento automático de espécies. Nesse estudo nós conduzimos análises ecoacústicas e utilizamos um algoritmo de Floresta Aleatória para reconhecer automaticamente 5 espécies de abelhas (*Bombus pauloensis*, *Exomalopsis* sp. 1, *Oxaea flavescens*, *Ptiloglossa* sp. 1 e *Xylocopa suspecta*) através dos seus sons de voo e *buzz*. E testamos se os sons dos *buzzes* são melhores do que os do voo para o reconhecimento automático das abelhas. Não foi possível identificar com uma alta acurácia as espécies de abelhas através das análises ecoacústicas. A frequência fundamental se mostrou o parâmetro mais importante para a classificação dessas espécies e os modelos de aprendizado de máquina obtiveram uma acurácia de 90.94% e 82.22% na classificação através dos sons de voo e *buzz* respectivamente. Dentre as espécies de abelhas estudadas, *Bombus pauloensis* foi a pior classificada pelos modelos de aprendizado de máquina. Argumentamos que isso pode ter ocorrido por conta dessa espécie apresentar uma grande variação no tamanho corporal entre os indivíduos. Por conta disso, eles geram sons com características variadas que se sobrepõem aos sons das outras espécies, aumentando a confusão nos algoritmos classificadores. Mesmo assim, a classificação de abelhas pelos sons produzidos durante o voo e o *buzz* poderão futuramente ajudar em estudos envolvendo a riqueza e a diversidade de abelhas em comunidades hiper diversas.

Palavras-chave: Polinização por vibração. Ecoacústica. Aprendizado de máquina. Identificação de abelhas.

ABSTRACT

There are few studies that have addressed the automatic identification of bees through their sounds. In addition, no study known by us has used the sound that bees produce while vibrating flowers for the automatic recognition of bee species. In this study, we conducted ecoacoustic analyzes and used a Random Forest algorithm to automatically recognize 5 species of bees (*Bombus pauloensis*, *Exomalopsis* sp. 1, *Oxaea flavescens*, *Ptiloglossa* sp. 1 and *Xylocopa suspecta*) through their flight and buzz sounds. And we tested if the buzzing sounds are better than the flight sounds to the automatic recognition of bees. It was not possible to identify bee species with high accuracy through ecoacoustic analysis. The fundamental frequency is shown to be the most important parameter for the classification of the species and the machine learning models obtained an accuracy of 90.94% and 82.22% in the classification through the flight and buzz sounds, respectively. Among the bee species studied, *Bombus pauloensis* was the worst classified by the machine learning models. We argue that this may have occurred because there is great variation in body size among the individuals of this species. Therefore, they generate sounds with varied characteristics that overlap the sounds of other species, increasing the confusion in the classifying algorithms. Nevertheless, bee classification by flight and buzz sounds will potentially help studies involving species richness and abundance in high diverse bee communities.

Keywords: Buzz pollination. Ecoacoustics. Machine learning. Bee identification

LISTA DE FIGURAS

Figura 1 - Espécies de abelhas que tiveram os sons de voo e <i>buzz</i> gravados enquanto visitavam flores de <i>Solanum paniculatum</i>	5
Figura 2 - Espectrogramas de um sinal de voo e de <i>buzz</i> de um indivíduo de <i>Exomalopsis</i> sp. 1.	7
Figura 3 – Distribuição dos sinais de voo no espaço ecoacústico.	1
Figura 4 – Importâncias relativas dos parâmetros dos sinais de voo selecionados para o modelo de aprendizado de máquina.	1
Figura 5 – Importâncias relativas dos parâmetros dos sinais de <i>buzz</i> selecionados para o modelo de aprendizado de máquina.	1

LISTA DE TABELAS

Tabela 1 - Matriz de Confusão Média das classificações dos sons de voo em porcentagem.....	2
Tabela 2 - Matriz de Confusão Média das classificações dos <i>buzzes</i> em porcentagem.....	2

SUMÁRIO

RESUMO	iii
ABSTRACT.....	iv
LISTA DE FIGURAS	v
LISTA DE TABELAS	vi
1 INTRODUÇÃO	1
2 METODOLOGIA.....	4
2.1 Local de estudo e espécie de planta selecionada.....	4
2.2 Aquisição dos dados.....	4
2.3 Pré-processamento dos sinais.....	6
2.4 Extração dos parâmetros acústicos	6
2.5 Análises ecoacústicas	9
2.6 Análises de inteligência artificial.....	9
3 RESULTADOS	11
3.1 Análises ecoacústicas	11
3.2 Análises de inteligência artificial.....	1
4 DISCUSSÃO	3
4.1 Análises ecoacústicas	3
4.2 Análises de inteligência artificial.....	4
5 CONCLUSÃO	6
6 REFERÊNCIAS	7

1 INTRODUÇÃO

A identificação e classificação dos animais é um desafio em estudos que envolvem a biodiversidade (GASTON e O'NEILL, 2004). A escassez de especialistas (GASTON, 1992), a existência de espécies crípticas (LARA et al., 2010; JÖRGER e SCHRÖDL, 2013; PICKETT et al., 2020) ou polimórficas (WILSON, 1953; EHLINGER e WILSON, 1988; GALEOTTI et al., 2003), a dificuldade de identificação de espécies em campo ou laboratório e até mesmo a inacessibilidade física dos seus habitats (RYAN, 1998) estão entre os principais obstáculos para a correta identificação das espécies. Tendo isso em vista, modos de identificação automatizados podem ser um bom recurso para a solução de problemas como esses.

Diversas técnicas automatizadas de identificação animal já foram criadas para ajudar estudos ecológicos. Por exemplo, Ticay-Riva et al. (2013) desenvolveram um estudo sobre o reconhecimento automatizado de 4 espécies de aranhas utilizando técnicas de processamento de imagens de suas teias e Mayo & Watson (2007) estudaram a identificação automática de mariposas utilizando também a extração de parâmetros de imagens. Outra maneira de se trabalhar com a identificação animal automática é através de técnicas de reconhecimento acústico. Nos estudos ornitológicos, a bioacústica tem sido bastante utilizada na identificação das espécies (e. g. LOPES et al., 2011; LASSECK, 2015; HARMA, 2003; TYAGI et al., 2006) e atualmente técnicas semelhantes vêm sendo aplicadas para a identificação de outros grupos. Por exemplo, sons produzidos durante os comportamentos de reprodução, a comunicação e o voo já foram utilizados para o reconhecimento e monitoramento de anuros (BEDOYA et al., 2014) e insetos, como neurópteros (YANG et al., 2015), ortópteros e hemípteros (RIEDE, 2006; POTAMITIS et al., 2007).

O uso de informações acústicas para a identificação de espécies também já foi realizado com abelhas (GRADIŠEK et al., 2016; ROBLES-GUERRERO et al., 2017; KAWAKITA e ICHIKAWA, 2019). Gradišek et al. (2016) desenvolveram um modelo de aprendizado de máquina no qual buscaram diferenciar rainhas de operárias e identificar 9 espécies do gênero *Bombus* extraindo informações de gravações de seus voos e obtiveram uma acurácia de 82.7%. Robles-Guerrero et al. (2017) também estudaram o reconhecimento automático de abelhas. Eles conseguiram diferenciar em saudável e pouco saudável duas colônias de *Apis mellifera carnica*, com uma precisão

de 100% de acertos. Kawakita e Ichikawa (2019) utilizaram técnicas semelhantes para a identificação de 3 espécies de abelhas (*Apis mellifera*, *Bombus ardens* e *Tetralonia nipponensis*) com uma acurácia média de 72%. Entretanto, esses estudos extraíram características acústicas apenas dos voos das abelhas estudadas, além de considerar uma baixa diversidade de espécies ou gêneros por estudo, o que não representa a realidade hiper diversa da melito fauna das regiões tropicais.

A polinização por vibração (“buzz pollination”) é um tipo especial de polinização no qual uma abelha utiliza vibrações para extrair os grãos de pólen de uma flor (BUCHMANN, 1983). Durante a visita, as abelhas curvam o corpo sobre a flor, agarram-se aos estames com as pernas e mandíbula, cruzam as asas sobre o corpo e promovem rápidas contrações dos músculos indiretos do voo, os quais vibram o seu corpo e transmitem essas vibrações para as anteras (BUCHMANN e HURLEY, 1978). Embora isso possa ocorrer em flores com características morfológicas variadas, normalmente a polinização por vibração ocorre em flores com anteras poricidas (VALLEJO-MARÍN, 2019). Apesar da transmissão das vibrações mecânicas da abelha para a flor ocorrer por contato direto, elas também produzem um componente audível (*buzz*), resultado da irradiação das vibrações do exoesqueleto nas partículas de ar (BUCHMANN, 1983). Os *buzzes* 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). Normalmente os *buzzes* também apresentam vários harmônicos (múltiplos inteiros do valor da frequência fundamental, provocados pela ressonância do exoesqueleto; DE LUCA e VALLEJO-MARÍN, 2013). Assim, dadas essas características específicas, o *buzz* pode ser um componente audível melhor para o reconhecimento das abelhas por modelos de aprendizado de máquina e, desse modo, ajudar em estudos de monitoramento e diversidade de abelhas vibradoras em comunidades hiper diversas.

No presente estudo, nós buscamos desenvolver um método para reconhecer automaticamente 5 espécies de abelhas pertencentes a diferentes gêneros através dos sons produzidos durante o voo e o *buzz* nas flores de uma planta que é polinizada por vibração (*Solanum paniculatum*). Para isso, usamos métodos clássicos de ecoacústica e um algoritmo de aprendizado de máquina. Procuramos responder às seguintes perguntas: I) A identidade das abelhas explica as características ecoacústicas dos sons produzidos durante o voo e o *buzz*? Se isso for confirmado, é possível que análises

estatísticas tradicionais sejam suficientes para a identificação automatizada das abelhas. Também perguntamos, II) Os sinais acústicos das abelhas vibrando nas flores são melhores do que os sinais do voo para o reconhecimento automático das espécies quando utilizamos modelos de aprendizado de máquina? Se sim, nós teremos uma nova fonte de informação que servirá de base para o reconhecimento automático de abelhas.

2 METODOLOGIA

2.1 Local de estudo e espécie de planta selecionada

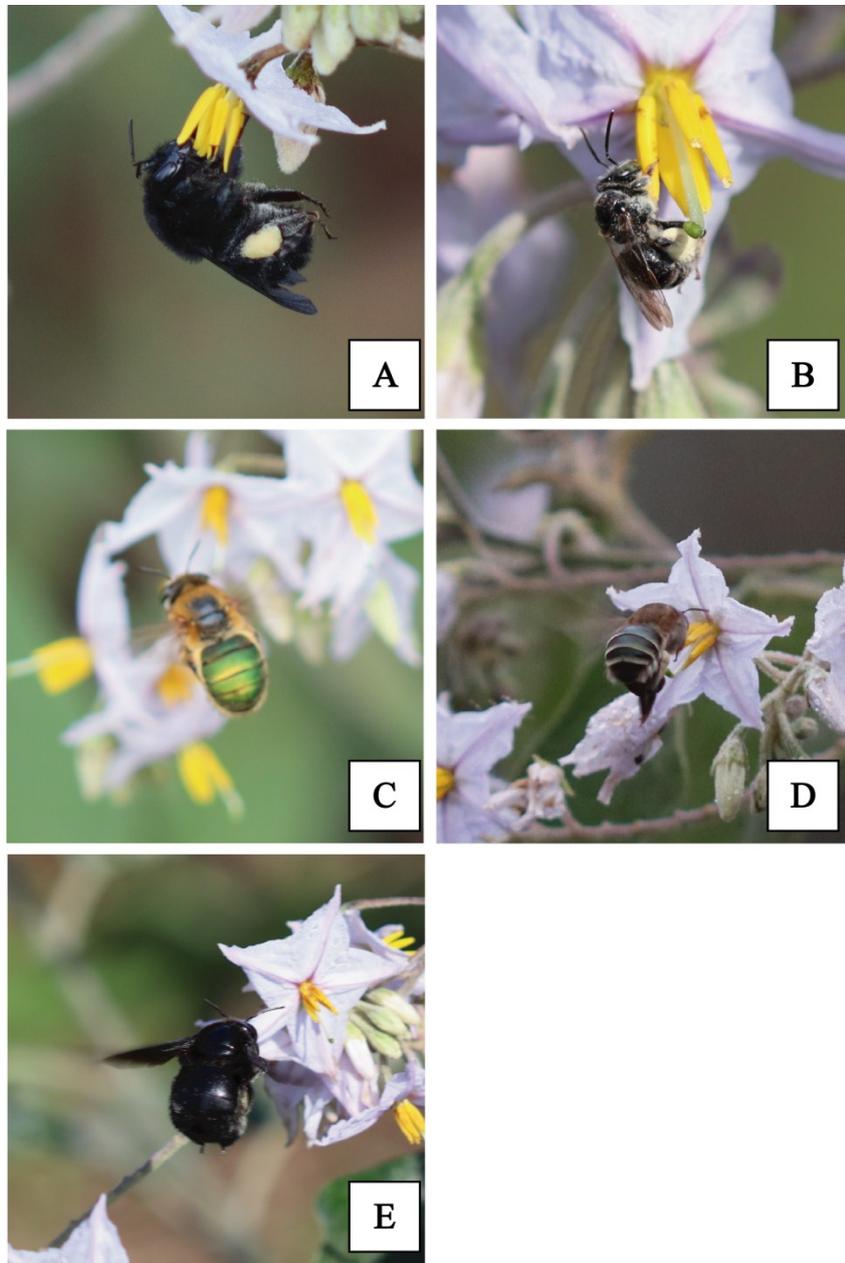
As gravações dos sons das abelhas foram feitas em uma população de *Solanum paniculatum* L. (Solanaceae), também conhecida como jurubeba, na beira da rodovia BR-455 (19°8'31''S, 048°22'47''W) próximo à Estação Ecológica do Panga no município de Uberlândia, Minas Gerais, Brasil. O local pertence a uma região com vegetação do tipo Cerrado, clima do tipo Aw segundo a classificação de Köppen, possuindo sazonalidade bem marcada, com ocorrência de chuvas no verão e seca durante o inverno (ROSA et al. 1991). A espécie *S. paniculatum* foi selecionada por possuir flores com anteras poricidas que oferecem apenas o pólen como recurso às abelhas e por serem polinizadas por vibração (FORNI-MARTINS, 1998). Além disso, a população de estudo possuía uma grande quantidade de indivíduos floridos e uma alta taxa de visitação floral, o que favorecia as gravações dos sons.

2.2 Aquisição dos dados

As gravações dos sons produzidos durante o voo e o *buzz* foram obtidas utilizando um microfone direcional (Shotgun Yoga Ht 81) acoplado a um gravador de voz simples (Sony ICD-PX240 – Mono), com taxa de amostragem de 44.1 kHz e resolução de 16 bits. Foram amostrados sons de 5 espécies de abelhas pertencentes a gêneros diferentes e que apresentaram alta frequência de visitação. As espécies amostradas foram: *Bombus pauloensis*, *Exomalopsis* sp. 1, *Oxaea flavescens*, *Ptiloglossa* sp. 1 e *Xylocopa suspecta* (Fig.1). Para todas essas espécies, as gravações de voo e de *buzz* foram obtidas aproximando cuidadosamente o microfone dos indivíduos antes e durante as visitas, respectivamente. Os sons do *buzz* foram capturados durante toda a sua duração. Além disso, um a dois indivíduos de cada espécie, exceto *Exomalopsis* sp. 1, foram capturados utilizando uma rede entomológica e mortos com acetato de etila para posterior identificação. No caso da espécie *Exomalopsis* sp. 1, a qual não foi coletado nenhum indivíduo, a identificação foi feita através de fotografias feitas no campo. Todas as identificações foram realizadas por um especialista do Laboratório de Ecologia e Comportamento de Abelhas (LECA) da Universidade Federal

de Uberlândia. Todas as gravações foram realizadas em um período de seis dias entre 19 e 31 de outubro de 2020, das 04:30h às 09:00h da manhã.

Figura 1 - Espécies de abelhas que tiveram os sons de voo e *buzz* gravados enquanto visitavam flores de *Solanum paniculatum*.



(A) *Bombus pauloensis*, (B) *Exomalopsis* sp. 1, (C) *Oxaea flavescens*, (D) *Ptiloglossa* sp. 1 e (E) *Xylocopa suspecta*.

Fonte: O autor (2021).

2.3 Pré-processamento dos sinais

Primeiramente, os sons de voo gravados em arquivos de áudio no formato .wav foram manualmente cortados em segmentos de 1s. Por outro lado, os sons de *buzz* foram considerados em toda a sua duração. Obtivemos 100 arquivos de áudio para cada um dos tipos de som (voo e *buzz*), totalizando, portanto, 200 sinais. Com a finalidade de reduzir o ruído das gravações, foi aplicado um filtro passa-alta a 100 Hz com um roll-off de 12 dB por oitava. Antes das análises ecoacústicas e de inteligência artificial, nós plotamos os oscilogramas e os espectros de frequência de cada um dos sinais para inspeção visual (Apêndice A). Este pré-processamento foi feito no programa de análises e edição de áudio Audacity v. 2.3.2 (www.audacityteam.org).

2.4 Extração dos parâmetros acústicos

Os parâmetros acústicos dos sons do voo e do *buzz* foram extraídos dos arquivos de áudio pré-processados. Extraímos diversos parâmetros estatísticos, como o valor de curtose, a média quadrática (RMS), o fator de crista, o desvio padrão e a assimetria. Além disso, também foram obtidos um parâmetro ecoacústico e parâmetros dos domínios do tempo e da frequência, como:

a) *Índice cumulativo de dissimilaridade acústica*

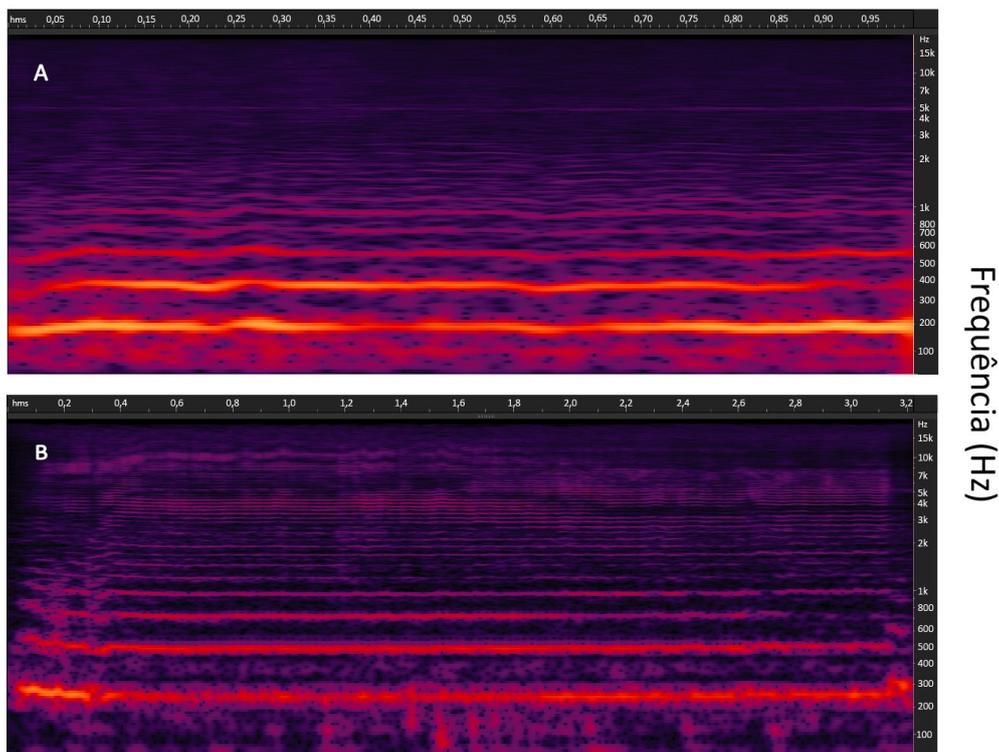
Assim como qualquer outro índice de dissimilaridade acústica, este índice estima o quanto dois sons são diferentes. Basicamente, ele computa a diferença absoluta entre pares de faixas de frequência correspondentes nos espectros de cada sinal.

b) *Frequência fundamental*

Define-se como frequência fundamental o harmônico de menor valor no espectro de frequência de uma vibração. Nos sinais acústicos de abelhas seu valor varia de 100 a 400 Hz, dependendo da espécie, e normalmente possui a maior energia entre os harmônicos, coincidindo, portanto, com a frequência dominante (DE LUCA e VALLEJO-MARÍN, 2013). Como já mencionado, o voo e o *buzz* apresentam características sonoras distintas, o *buzz* possui uma frequência fundamental mais alta e

uma maior quantidade de harmônicos (Figura 1). Extraímos os valores das frequências fundamentais dos sinais através de uma inspeção visual dos espectros de frequência e dos plots de frequência fundamental em função do tempo (Apêndice A).

Figura 2 - Espectrogramas de um sinal de voo e de *buzz* de um indivíduo de *Exomalopsis* sp. 1.
Tempo (s)



(A) Espectrograma do sinal de voo, (B) Espectrograma do sinal de *buzz*. Na figura, o calor das cores especifica a energia das bandas de frequência, sendo que cores mais quente indicam maior energia. O eixo x indica a duração do sinal em segundos e o eixo y representa os valores de frequência em Hz.

Fonte: O autor (2021).

c) *Mel-Frequency Cepstral Coefficients (MFCCs)*

O *Mel-Frequency Cepstral Coefficient* (MFCC) é uma técnica para a extração de parâmetros amplamente utilizada em estudos de reconhecimento automático de fala (SUEUR, 2018). Além disso, o seu uso também é frequente em trabalhos de identificação automatizada através do som de animais, nos quais apresenta um bom desempenho (LEE et al., 2008; CHENG et al., 2010; GRADIŠEK et al., 2016; ROBLES-GUERRERO et al., 2017; KAWAKITA e ICHIKAWA, 2019).

Os MFCC's carregam informações a respeito do timbre do som. São obtidos através de uma transformada discreta de cosseno (DCT) do logaritmo do espectro de

energia em segmentos curtos de tempo e expressos em uma escala de frequência subjetiva e logarítmica que se refere à percepção humana de volume e frequência, a escala mel (SUEUR, 2018). Extraímos 13 MFCC's de cada um dos 200 sinais acústicos utilizando a função *melfcc* do pacote *tuneR* do software de ambiente de desenvolvimento integrado RStudio v. 4.0.5 (www.rstudio.com; SUEUR, 2018). Os argumentos definidos para o cálculo dos MFCC's foram: duração de janela de 11 ms com uma sobreposição de ~5.8 ms (50%), frequência mínima de 100Hz para a conversão na escala mel e valores de pré-ênfase definidos em 0,97. Esses valores foram definidos com base nas propriedades de gravação e características acústicas próprias dos sinais trabalhados. No intuito de reduzir o custo computacional e o tamanho do conjunto de dados, após a extração dos MFCC's nós sintetizamos os valores obtidos na matriz de coeficientes através do cálculo dos seguintes descritores estatísticos: média, média truncada (20%), curtose, desvio padrão, assimetria, mediana, variância, coeficiente de variação, e os quantis (2.5, 25, 50, 75, 97.5) – seguindo a metodologia utilizada por Robles-Guerrero et al. (2017).

d) Parâmetros de bandas específicas do espectro de frequência do sinal bruto e do sinal demodulado

Também extraímos dos sinais pré-processados de voo e *buzz* as energias de determinadas bandas do espectro de frequência. Essas bandas foram definidas através de análises visuais dos espectrogramas e espectros de frequência. Selecionamos intervalos de frequência que continham as maiores energias. Além disso, para se avaliar o perfil da energia sonora contida em faixas de alta frequência, aplicou-se uma demodulação nos sinais filtrados em uma banda de 2000 a 15000 Hz. A extração do envelope (contorno do sinal) foi obtida através da transformada de Hilbert e os intervalos das frequências moduladas foram definidos através de análises visuais dos espectrogramas e espectros de frequência.

2.5 Análises ecoacústicas

As análises ecoacústicas aqui empregadas seguiram os passos indicados no item 16.2 do livro de Sueur (2018). Para responder se as espécies das abelhas podem explicar as características ecoacústicas dos sons produzidos durante o voo e o *buzz*, nós primeiramente estimamos os índices cumulativos de dissimilaridade acústica entre todos os pares de sinais de voo e entre todos os pares sinais de *buzz* utilizando a função *diffcumspec* do pacote *seewave* (SUEUR, 2018). As duas matrizes de dissimilaridade acústica foram então plotadas na forma de um mapa de calor para analisarmos visualmente a possível existência de qualquer estrutura de dissimilaridade. Além disso, nós rodamos uma análise de agrupamento hierárquica com a função *hclust* do pacote *seewave* (SUEUR, 2018) para verificar, a partir da topologia do dendrograma produzido, se os grupos formados a partir das características ecoacústicas seriam correspondentes às espécies das abelhas. Essa análise usa um método de agrupamento não-supervisionado que agrupa os sinais de acordo com as distâncias de Ward que, por sua vez, minimiza a variância dentro dos grupos e maximiza as variâncias entre os grupos (SUEUR, 2018). Por fim, nós rodamos uma análise de redundância para ordenar os sinais de voo e de *buzz* em um espaço multivariado usando as funções *dudi.pco* e *pcaiv* do pacote *ade4* (THIOULOUSE et al., 2018). A significância da ordenação levando em consideração os grupos formados pelas espécies de abelhas foi testada a partir de um teste de permutação com 1000 simulações usando a função *randtest* do pacote *ade4* (THIOULOUSE et al., 2018).

2.6 Análises de inteligência artificial

A inteligência artificial pode ser definida como uma ciência que estuda a confecção de máquinas com capacidade de aprender e resolver problemas (ANDERSON, 1990). O aprendizado de máquina, também conhecido como “machine learning”, é um subconjunto da inteligência artificial em que a máquina aprende com algum exemplo. Nesse caso, a máquina analisa um subconjunto de dados disponíveis previamente e através de algoritmos variados consegue identificar padrões que seriam irreconhecíveis para os humanos (EL NAQA e MURPHY, 2015; DAMACENO e VASCONCELOS, 2018; ZHANG, 2020). Para realizar a classificação das espécies de abelhas neste estudo, nós utilizamos o algoritmo de Floresta aleatória (“Random forest).

A Floresta aleatória é um dos principais algoritmos utilizados para o aprendizado de máquina. Ele é constituído por um conjunto de árvores de decisão criadas aleatoriamente. Essas árvores de decisão estabelecem regras para tomada de decisão, formando uma estrutura semelhante a um fluxograma. Em cada “nó” desta árvore, uma condição é avaliada e, se atendida, o fluxo segue por um ramo. Se a condição não for atendida, o fluxo segue para outro ramo. Estas escolhas se repetem sucessivamente até o final da árvore. Com os dados de treino, o algoritmo busca as melhores condições e decide onde introduzir cada um dos dados analisados dentro desse fluxo (SCHONLAU e ZOU, 2020).

O algoritmo de Floresta aleatória foi empregado nos nossos modelos utilizando o módulo *sklearn.ensemble* da biblioteca *Scikit-learn* v. 0.24.2 no ambiente de programação Visual Studio Code (VSC) em Python. Para os testes com os modelos, nós utilizamos 500 estimadores (árvores). Dividimos o conjunto de dados em 70% para treinar os modelos e 30% para testá-lo. Para garantir a robustez dos resultados, rodamos o teste 1000 vezes, dividindo aleatoriamente os subconjuntos de testes e treinamentos e iniciando em locais aleatórios do conjunto.

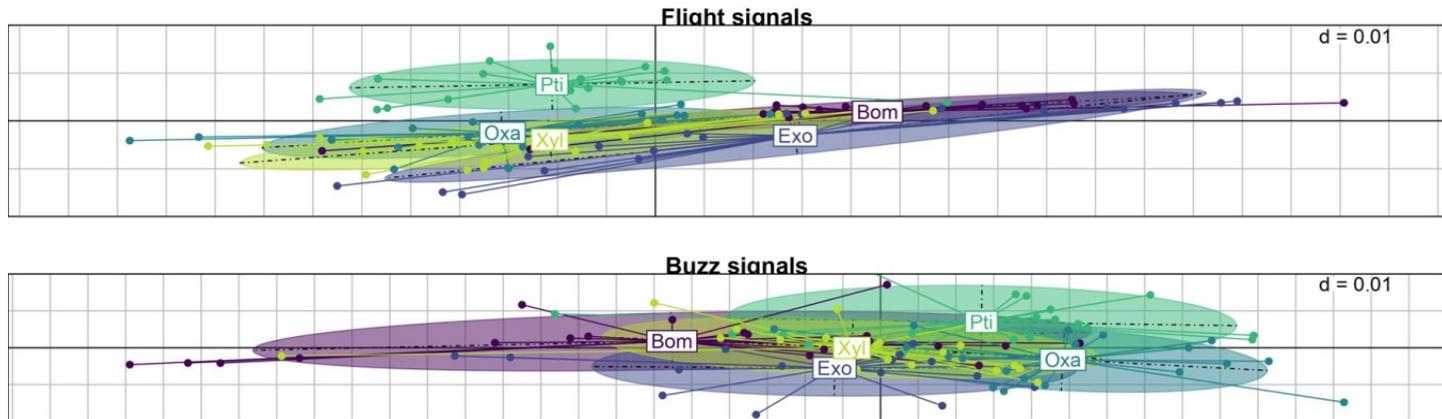
Obtivemos a importância dos parâmetros usados na classificação das abelhas por meio da técnica *Gini importance*, que atribui uma pontuação aos parâmetros de entrada com base na sua utilidade em prever uma variável de destino (NEMBRINI et al., 2018). Para essa análise, utilizamos a função *feature_importances_* do *Scikit-learn*. Através do resultado dessa análise de importância e de exames visuais de *box-plot* (Figuras B4 e B5), selecionamos 12 parâmetros de entrada para o modelo de classificação através dos sons produzidos durante o voo e 7 para o modelo de classificação através dos sons de *buzz*. Por fim, montamos uma matriz de confusão de cada classificação (voo e *buzz*; Tabelas 1 e 2) para avaliar a acurácia do algoritmo empregado. Nessa matriz nós podemos visualizar o desempenho do algoritmo em classificar os sons entre as diferentes espécies de abelhas.

3 RESULTADOS

3.1 Análises ecoacústicas

Analisando visualmente as matrizes de distâncias entre os pares de sinais de voo e *buzz* não é possível distinguir *a priori* nenhuma estrutura de diferenciação comum a todos os indivíduos de uma dada espécie de abelha (Figura B1 e B2). Considerando as características ecoacústicas dos voos, as espécies *Bombus pauloensis* e *Exomalopsis* sp. 1 são as que produzem sons mais diferentes das outras espécies (Figura B1). Em outras palavras, quando consideramos as características dos *buzzes*, essa diferenciação não fica evidente, exceto para alguns poucos indivíduos de *Bombus pauloensis* (Figura B2). Esse resultado é reforçado pela análise de agrupamento que mostra que os sons de voo e de *buzz* produzidos por espécies diferentes podem fazer parte do mesmo grupo ecoacústico (Figura B3). Apesar disso, a identidade das abelhas explica 35% das características ecoacústicas dos sons produzidos durante o voo (Monte-Carlo test = 0,35; $p < 0,01$; Figura 3) e 31% dos sons produzidos durante o *buzz* em flores de *S. paniculatum* (Monte-Carlo test = 0,31; $p < 0,01$; Figura 3). Nesse caso, é possível observar que a espécie *Ptiloglossa* sp. 1 é a que melhor se destaca no espaço ecoacústico, principalmente quando consideradas as características dos sons de voo (Figura 3).

Figura 3 – Distribuição dos sinais de voo no espaço ecoacústico.

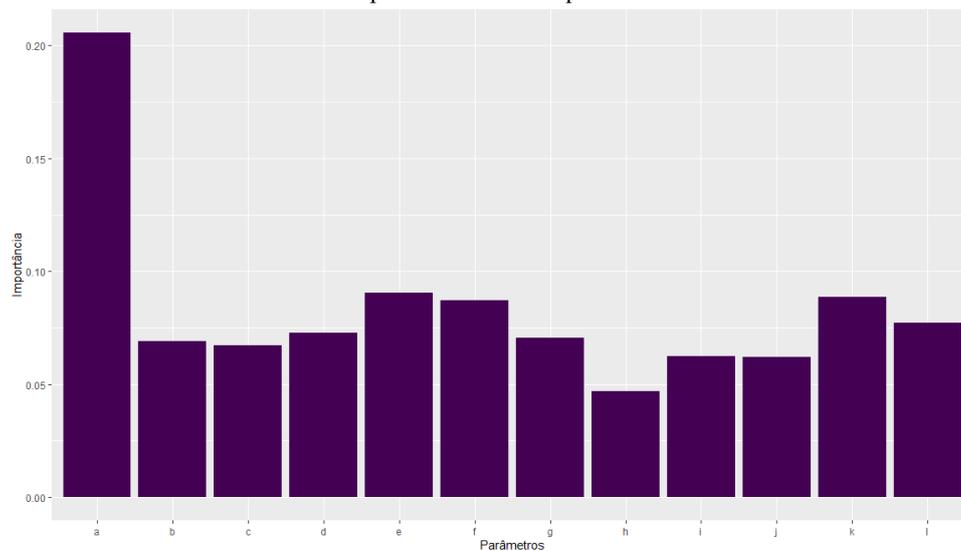


Fonte: O autor (2021).

3.2 Análises de inteligência artificial

Através da análise de importância constatamos que a frequência fundamental dos sons produzidos durante o voo e o *buzz* é o parâmetro mais relevante para a classificação das espécies de abelhas através dos nossos modelos de aprendizado de máquina (Figuras 4 e 5). Por meio dos parâmetros extraídos dos sons de voo, o modelo obteve uma acurácia global média de 90.94% com um desvio padrão de 5.15% na classificação (Tabela 1). De cada espécie de abelha, foi classificado corretamente nesse modelo 90.5% dos sinais de *Ptiloglossa* sp. 1, 84.1% de *Bombus pauloensis*, 92.6% de *Exomalopsis* sp. 1, 88.9% de *Oxaea flavescens* e 98.4% de *Xylocopa suspecta*. Por outro lado, através dos parâmetros acústicos do *buzz*, o modelo obteve uma acurácia global média de 82.22% com um desvio padrão de 6.65% (Tabela 2). Nesse caso, o modelo classificou corretamente 89.4% dos sinais *Ptiloglossa* sp. 1, 69.7% de *Bombus pauloensis*, 74.8% de *Exomalopsis* sp. 1, 100% de *Oxaea flavescens*, e 77% de *Xylocopa suspecta* (Tabela 2).

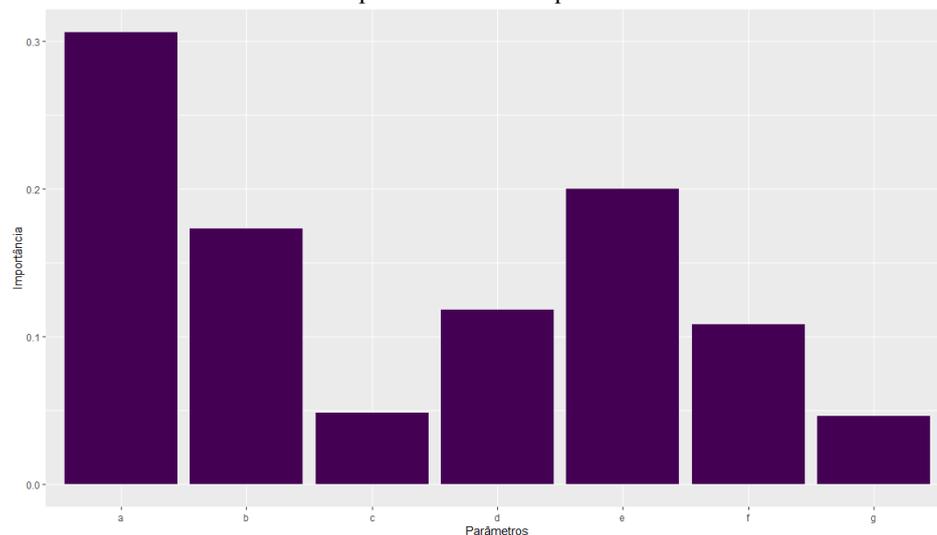
Figura 4 – Importâncias relativas dos parâmetros dos sinais de voo selecionados para o modelo de aprendizado de máquina.



(a) Frequência fundamental, (b) Quantil - 75 do MFCC 11, (c) Quantil - 97.5 do MFCC 11, (d) Quantil - 97.5 do MFCC 5, (e) Média do MFCC 11, (f) Banda de frequência de 143 - 153 Hz, (g) Média quadrática (RMS) do envelope filtrado em 2 - 15 kHz, (h) Banda de frequência de 450 - 590 Hz, (i) Quantil - 50 do MFCC 12, (j) Banda de frequência de 310 - 400 Hz do envelope filtrado em 2 - 15 kHz, (k) Banda de frequência de 110 - 130 Hz do envelope filtrado em 2 - 15 kHz, (l) Banda de frequência de 225 - 250 Hz.

Fonte: O autor (2021).

Figura 5 – Importâncias relativas dos parâmetros dos sinais de *buzz* selecionados para o modelo de aprendizado de máquina.



(a) Frequência fundamental, (b) Banda de frequência de 300 - 340 Hz do envelope filtrado em 2 - 15 kHz, (c) Média truncada do MFCC 3, (d) Banda de frequência de 600- 1000 Hz, (e) Banda de frequência de 450- 590 Hz, (f) Banda de frequência de 240 - 290 Hz do envelope filtrado em 2 - 15 kHz, (g) Variância do MFCC 10.

Fonte: O autor (2021).

Outro dado interessante apresentado nas matrizes de confusão (Tabela 1 e 2) é o quanto uma espécie de abelha foi confundida com outra pelo modelo. Por exemplo, nas classificações através dos sons de voo, algumas vezes *Bombus pauloensis* foi confundida com *Exomalopsis* sp. 1 (Tabela 1). Semelhantemente, nas classificações das espécies pelos buzzes, em alguns casos *Bombus pauloensis* foi confundida com *Exomalopsis* sp. 1 e *Xylocopa suspecta*, *Exomalopsis* sp. 1 foi confundida com *Bombus pauloensis* e *Xylocopa suspecta* foi confundida com *Ptiloglossa* sp. 1 (Tabela 2).

Tabela 1 - Matriz de Confusão Média das classificações dos sons de voo em porcentagem.

Verdadeira classificação	Classificação do modelo				
	<i>Ptiloglossa</i> sp. 1	<i>Bombus</i> <i>pauloensis</i>	<i>Exomalopsis</i> sp. 1	<i>Oxaea</i> <i>flavescens</i>	<i>Xylocopa</i> <i>suspecta</i>
<i>Ptiloglossa</i> sp. 1	90.5	0.3	4.4	04.8	0
<i>Bombus pauloensis</i>	0	84.1	9	2.9	3.9
<i>Exomalopsis</i> sp. 1	0	3.7	92.6	3.6	0
<i>Oxaea flavescens</i>	4.6	5.4	0	88.9	1.1
<i>Xylocopa suspecta</i>	0	1.5	0	0	98.4
Acurácia média: 90.94% / Desvio padrão: 5.15%					

Tabela 2 - Matriz de Confusão Média das classificações dos buzzes em porcentagem.

Verdadeira classificação	Classificação do modelo				
	<i>Ptiloglossa</i> sp. 1	<i>Bombus</i> <i>pauloensis</i>	<i>Exomalopsis</i> sp. 1	<i>Oxaea</i> <i>flavescens</i>	<i>Xylocopa</i> <i>suspecta</i>
<i>Ptiloglossa</i> sp. 1	89.4	4.5	1.3	4.6	0.2
<i>Bombus pauloensis</i>	3.5	69.7	13	2.5	11.3
<i>Exomalopsis</i> sp. 1	4.8	16.6	74.8	0	3.9
<i>Oxaea flavescens</i>	0	0	0	100	0
<i>Xylocopa suspecta</i>	11.4	6.2	4.8	0	77.6
Acurácia média: 82.22% / Desvio padrão: 6.65%					

4 DISCUSSÃO

Nossos resultados apontam que não é possível identificar com alta acurácia as espécies de abelhas estudadas através de análises estatísticas tradicionais utilizando o índice de dissimilaridade acústica. Portanto, a utilização de métodos mais robustos de análise, como por exemplo, os algoritmos de aprendizado de máquina pode ser uma solução melhor. Utilizando esse método, é possível identificar automaticamente, com uma acurácia global relativamente alta (82.22%), espécies de abelhas através dos sons de *buzz* produzidos durante as visitas às flores de *S. paniculatum*. No entanto, os sons produzidos durante o voo se mostraram ainda melhores para a classificação das espécies pelo mesmo método, atingindo uma acurácia global de 90.94%. Além disso, constatamos que a frequência fundamental foi o parâmetro mais importante para a classificação das espécies pelos nossos modelos e, portanto, é potencialmente o parâmetro mais relevante para outros classificadores de sinais acústicos de abelhas.

4.1 Análises Ecoacústicas

Os sons produzidos pelas abelhas durante o voo e a vibração floral são o resultado da irradiação das vibrações do exoesqueleto, geradas pelos músculos do voo, nas partículas de ar (BUCHMANN, 1983). Portanto, as características corporais das abelhas interferem nas suas propriedades acústicas. Assim como em outros insetos, o tamanho corporal é negativamente correlacionado com a frequência fundamental do voo em abelhas (BUKCART, 2011; DE LUCA et al., 2019). Tal correlação negativa sugere que a presença de uma variação no tamanho do corpo de indivíduos de uma mesma espécie gere diversas características de voo entre esses indivíduos. O gênero *Bombus* é formado por espécies de abelhas coloniais que se dividem em diferentes castas e funções dentro do ninho (GARÓFALO, 1978). Esse gênero exibe um conspicuo polimorfismo de tamanho, não apenas entre as rainhas e as operárias, mas também entre operárias (SAKAGAMI, 1976). Sendo assim, é possível que essa variação nas características corporais em *Bombus pauloensis* leve à produção de sons de voo muito diversos entre os indivíduos dessa mesma espécie. De fato, isso pode ser visualizado através das análises de dissimilaridade ecoacústica, principalmente do voo (Figura B1), onde os sons produzidos por essas abelhas foram igualmente diferentes entre os

indivíduos da própria espécie e os das outras espécies. Quanto às diferenças nas características ecoacústicas do voo de *Exomalopsis* sp. 1, pode se pensar que elas ocorrem devido a essa espécie apresentar o menor tamanho dentre o grupo de abelhas selecionado para o estudo.

Apesar da identidade de cada uma das abelhas estudadas explicar 35% e 31% das suas características ecoacústicas de voo e de *buzz*, respectivamente, tanto a análise de agrupamento quanto a análise de ordenação não revelaram grupos bem definidos de acordo com as espécies. Isso indica que, embora essas abelhas sejam de espécies de gêneros diferentes, existe uma alta sobreposição nas características ecoacústicas dos sons que elas produzem, e que métodos tradicionais de estatística multivariada dificilmente poderão ajudar na identificação automatizada de espécies de abelhas. Apesar disso, através da análise de ordenação, a espécie *Ptiloglossa* sp. 1 constitui um grupo destacado das demais quando considerado seus sons de voo. Isso mostra que o voo dessa espécie potencialmente possui características sonoras particulares. Assim, é necessário se estudar futuramente essas características tanto em estudos de identificação automática através dos sons quanto em estudos sobre a influência da arquitetura corporal na produção desses sons.

4.2 Análises de inteligência artificial

A frequência fundamental dos sons de voo e *buzz* foi o parâmetro mais relevante para a classificação das espécies de abelhas pelos nossos modelos. Esse parâmetro está diretamente relacionado à contração dos músculos indiretos do voo (KING et al., 1996; JANKAUSKI, 2019). De fato, as frequências fundamentais do batimento das asas das abelhas e a contração dos músculos do voo são correspondentes (JANKAUSKI, 2019). Durante a vibração nas flores, esses músculos têm um papel igualmente importante. Porém, ainda não se sabe ao certo o que promove o aumento da frequência fundamental e do número de harmônicos nessas vibrações (KING et al., 1996). Estudos supõem que esse aumento possa se dar em virtude da redução da inércia do sistema asa-tórax quando as asas são desacopladas (KING et al., 1996), devido a um aumento na frequência de excitação dos músculos do voo (ESCH e BASTIAN, 1968) ou mesmo em função de uma deformação do tórax (JANAKUSI, 2019). Entretanto, apesar da alta relevância para os nossos modelos, a frequência fundamental sozinha não foi suficiente para a classificação das espécies. Por isso, a utilização de outros parâmetros é importante para

se obter uma classificação mais acurada. Embora bandas específicas de alta frequência (2kh – 15kh) não terem um significado biológico até então reconhecido, inesperadamente esse parâmetro obteve uma alta relevância em nossas análises. Futuramente, uma investigação da relação da excitação dessas bandas de alta frequência com a arquitetura corporal das abelhas ou o seu papel na polinização por vibração poderá indicar se de fato existe algum significado biológico para essas características.

Os modelos de aprendizado de máquina classificaram as espécies com alta acurácia tanto através dos sons produzidos no voo quanto dos sons produzidos durante a vibração das flores de *S. paniculatum*. No entanto, os sons de voo apresentaram maior acurácia nessa classificação. As abelhas voam em um sistema livre, onde não mantêm contato com nenhum elemento além do ar. Por outro lado, durante a vibração floral, as abelhas estão em contato direto com as flores e as características dessa vibração dependem do sistema abelha-flor como um todo (VALLEJO-MARÍN, 2019). Naturalmente, as flores de *S. paniculatum* apresentam variações morfológicas entre os indivíduos da população e também dentro dos indivíduos (FORNI-MARTINS, 1998). Apesar de ser contrário ao que esperávamos, essa variação entre as flores e a maior variabilidade dos sinais de *buzz* podem ter contribuído para a menor acurácia na classificação das espécies de abelhas por esses sons específicos.

Entre as espécies estudadas nesse trabalho, *Bombus pauloensis* foi a teve que a pior classificação pelo modelo de aprendizado de máquina quando consideramos ambos os sons de voo e *buzz*. Como já mencionado, as abelhas desse gênero possuem uma alta variação no tamanho corporal entre os indivíduos de uma mesma espécie, o que reflete em uma maior variedade nas características acústicas dos voos desses indivíduos (SAKAGAMI, 1976; BUKCART, 2011; DE LUCA et al., 2019). Além disso, alguns estudos também encontraram uma correlação negativa entre o tamanho corporal e o *buzz* de espécies desse gênero enquanto visitavam flores de outras espécies de *Solanum* spp. (ARROYO-CORREA et al., 2019; PRITCHARD e VALLEJO-MARÍN, 2020). Por isso, *Bombus pauloensis* possivelmente têm uma maior variedade nas características sonoras de voo e *buzz* entre os seus indivíduos. Se isso de fato ocorre, é possível que essa variação gere uma sobreposição com os sons das outras espécies de abelhas, o que faz com que o modelo confunda *Bombus pauloensis* com as espécies que não possuem alguma possível característica particular que as distingam (Tabelas 1 e 2). Por outro lado, os modelos classificaram com alta acurácia as outras espécies de abelhas, seja através dos sons do voo ou do *buzz*. Porém, ainda não sabemos quais características

particulares, além da frequência fundamental, contribuíram para a discriminação dessas espécies através dos algoritmos classificadores. Contudo, estudos futuros poderão analisar quais outros parâmetros são determinantes na classificação de cada espécie e se a junção dos dois tipos de sons (voo e *buzz*) em um único modelo aumentaria a acurácia de classificação dessas espécies.

5 CONCLUSÃO

Neste trabalho, mostramos que os sons de voo e *buzz* podem ser utilizados para a classificação automática de abelhas usando algoritmos de aprendizagem de máquina. Futuramente, a adição de outras características, como por exemplo as características visuais das abelhas, poderão aumentar ainda mais a acurácia desses algoritmos. Assim, nossos resultados podem ter grande impacto no desenvolvimento futuro de ferramentas de identificação de abelhas que poderão auxiliar estudos que abordam a riqueza e abundância de abelhas em comunidades hiper diversas como aquelas nas regiões tropicais.

6 REFERÊNCIAS

ANDERSON, John Robert. **Machine learning: An artificial intelligence approach**. Morgan Kaufmann, 1990.

ARROYO-CORREA, Blanca; BEATTIE, Ceit; VALLEJO-MARÍN, Mario. Bee and floral traits affect the characteristics of the vibrations experienced by flowers during buzz pollination. **Journal of Experimental Biology**, v. 222, n. 4, 2019.

BEDOYA, Carol et al. Automatic recognition of anuran species based on syllable identification. **Ecological Informatics**, v. 24, p. 200-209, 2014.

BUCHMANN, Stephen L. et al. Buzz pollination in angiosperms. **Buzz pollination in angiosperms.**, p. 73-113, 1983.

BUCHMANN, Stephen L.; HURLEY, James P. A biophysical model for buzz pollination in angiosperms. **Journal of Theoretical Biology**, v. 72, n. 4, p. 639-657, 1978.

BURKART, Andreas; LUNAU, Klaus; SCHLINDWEIN, Clemens. Comparative bioacoustical studies on flight and buzzing of neotropical bees. **Journal of Pollination Ecology**, v. 6, 2011.

CHEEMA, Gullal Singh; ANAND, Saket. Automatic detection and recognition of individuals in patterned species. In: **Joint European Conference on Machine Learning and Knowledge Discovery in Databases**. Springer, Cham, p. 27-38, 2017.

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.

DAMACENO, Siuari Santos; VASCONCELOS, Rafael Oliveira. Inteligência artificial: uma breve abordagem sobre seu conceito real e o conhecimento popular. **Caderno de Graduação-Ciências Exatas e Tecnológicas-UNIT-SERGIPE**, v. 5, n. 1, p. 11, 2018.

DE LUCA, Paul A. et al. Does body size predict the buzz-pollination frequencies used by bees?. **Ecology and evolution**, v. 9, n. 8, p. 4875-4887, 2019.

DE LUCA, Paul A.; VALLEJO-MARÍN, Mario. 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, 2013.

EHLINGER, Timothy John; WILSON, David Sloan. Complex foraging polymorphism in bluegill sunfish. **Proceedings of the National Academy of Sciences**, v. 85, n. 6, p. 1878-1882, 1988.

ESCH, Harald; BASTIAN, Joseph. Mechanical and electrical activity in the indirect flight muscles of the honey bee. **Zeitschrift für vergleichende Physiologie**, v. 58, n. 4, p. 429-440, 1968.

EL NAQA, Issam; MURPHY, Martin J. What is machine learning?. In: **machine learning in radiation oncology**. Springer, Cham, p. 3-11, 2015.

FORNI-MARTINS, Eliana Regina; MARQUES, Marcia Cristina Mendes; LEMES, Maristerra R. Biologia floral e reprodução de *Solanum paniculatum* L.(Solanaceae) no estado de São Paulo, Brasil. **Brazilian Journal of Botany**, v. 21, n. 2, p. 117-124, 1998.

GALEOTTI, Paolo et al. Colour polymorphism in birds: causes and functions. **Journal of evolutionary biology**, v. 16, n. 4, p. 635-646, 2003.

GARÓFALO, Carlos Alberto. Bionomics of *Bombus (Fervidobombus) morio* 2. Body size and length of life of workers. **Journal of Apicultural Research**, v. 17, n. 3, p. 130-136, 1978.

GASTON, Kevin J. Taxonomy of taxonomists. **Nature**, v. 356, n. 6367, p. 281-282, 1992.

GASTON, Kevin J.; O'NEILL, Mark 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, 2004.

GRADIŠEK, Anton et al. Predicting species identity of bumblebees through analysis of flight buzzing sounds. **Bioacoustics**, v. 26, n. 1, p. 63-76, 2017.

HARMA, Aki. Automatic identification of bird species based on sinusoidal modeling of syllables. In: **2003 IEEE International Conference on Acoustics, Speech, and Signal Processing, 2003. Proceedings.(ICASSP'03)**. IEEE, p. V-545, 2003.

JANKAUSKI, Mark A. Flapping at Resonance: Measuring the Frequency Response of the Hymenoptera Thorax. **bioRxiv**, 2019.

JÖRGER, Katharina M.; SCHRÖDL, Michael. How to describe a cryptic species? Practical challenges of molecular taxonomy. **Frontiers in zoology**, v. 10, n. 1, p. 1-27, 2013.

KAWAKITA, Satoshi; ICHIKAWA, Kotaro. Automated classification of bees and hornet using acoustic analysis of their flight sounds. **Apidologie**, v. 50, n. 1, p. 71-79, 2019.

KING, Marcus J.; BUCHMANN, Stephen L.; SPANGLER, Hayward. Activity of asynchronous flight muscle from two bee families during sonication (buzzing). **Journal of Experimental Biology**, v. 199, n. 10, p. 2317-2321, 1996.

LARA, Ariagna et al. DNA barcoding of Cuban freshwater fishes: evidence for cryptic species and taxonomic conflicts. **Molecular ecology resources**, v. 10, n. 3, p. 421-430, 2010.

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

LEE, Chang-Hsing; HAN, Chin-Chuan; CHUANG, Ching-Chien. Automatic classification of bird species from their sounds using two-dimensional cepstral coefficients. **IEEE Transactions on Audio, Speech, and Language Processing**, v. 16, n. 8, p. 1541-1550, 2008.

LOPES, Marcelo T. et al. Automatic bird species identification for large number of species. In: **2011 IEEE International Symposium on Multimedia**. IEEE, p. 117-122, 2011.

MAYO, Michael; WATSON, Anna T. Automatic species identification of live moths. **Knowledge-Based Systems**, v. 20, n. 2, p. 195-202, 2007.

NEMBRINI, Stefano; KÖNIG, Inke R.; WRIGHT, Marvin N. The revival of the Gini importance?. **Bioinformatics**, v. 34, n. 21, p. 3711-3718, 2018.

PICKETT, Brandon D. et al. Lingering taxonomic challenges hinder conservation and management of global bonefishes. **Fisheries**, v. 45, n. 7, p. 347-358, 2020.

POTAMITIS, Ilyas; GANCHEV, Todor; FAKOTAKIS, Nikos. Automatic acoustic identification of crickets and cicadas. In: **2007 9th International Symposium on Signal Processing and Its Applications**. IEEE, p. 1-4, 2007.

PRITCHARD, David J.; VALLEJO-MARÍN, Mario. Floral vibrations by buzz-pollinating bees achieve higher frequency, velocity and acceleration than flight and defence vibrations. **Journal of Experimental Biology**, v. 223, n. 11, 2020.

RIEDE, Klaus et al. Automated annotation of Orthoptera songs: first results from analysing the DORSA sound repository. **Journal of Orthoptera Research**, v. 15, n. 1, p. 105-113, 2006.

ROBLES-GUERRERO, Antonio et al. Frequency Analysis of Honey Bee Buzz for Automatic Recognition of Health Status: A Preliminary Study. **Res. Comput. Sci.**, v. 142, p. 89-98, 2017.

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

RYAN, Peter G. The taxonomic and conservation status of the Spectacled Petrel *Procellaria conspicillata*. **Bird Conservation International**, v. 8, n. 3, p. 223-235, 1998.

Sakagami S.F. Specific differences in the bionomic characters of bumblebees. A comparative review, **Journal of the Faculty of Science, Hokkaido University**, v. 20, n. 3, p. 390–447, 1976.

SCHONLAU, Matthias; ZOU, Rosie Yuyan. The random forest algorithm for statistical learning. **The Stata Journal**, v. 20, n. 1, p. 3-29, 2020.

SUEUR, Jérôme et al. **Sound analysis and synthesis with R**. Culemborg, the Netherlands: Springer, 2018.

THIOULOUSE, Jean et al. **Multivariate analysis of ecological data with ade4**. New York, NY: Springer, 2018.

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.

TYAGI, Hemant et al. Automatic identification of bird calls using spectral ensemble average voice prints. In: **2006 14th European Signal Processing Conference**. IEEE, p. 1-5, 2006.

VALLEJO-MARÍN, Mario. Buzz pollination: studying bee vibrations on flowers. **New Phytologist**, v. 224, n. 3, p. 1068-1074, 2019.

WILSON, Edward O. The origin and evolution of polymorphism in ants. **The Quarterly Review of Biology**, v. 28, n. 2, p. 136-156, 1953.

YANG, He-Ping et al. A tool for developing an automatic insect identification system based on wing outlines. **Scientific reports**, v. 5, n. 1, p. 1-11, 2015.

ZHANG, Xian-Da. Machine learning. In: **A Matrix Algebra Approach to Artificial Intelligence**. Springer, Singapore, p. 223-440, 2020.

Apêndice A: Oscilograma, espectro de frequência e frequências fundamentais no domínio do tempo para cada som das abelhas gravado durante voo e *buzz* nas flores de *Solanum paniculatum*.

Apêndice B: Lista de figuras dos resultados das análises ecoacústicas e das análises de aprendizado de máquina:

Figura B1 - Matriz de dissimilaridade ecoacústica dos sons voo.

Figura B2 - Matriz de dissimilaridade ecoacústica dos *buzzes*.

Figura B3 - Dendrogramas das análises de agrupamento dos sinais de voo e *buzz*.

Figura B4: Boxplots dos parâmetros extraídos dos sinais de voo selecionados para o modelo de aprendizado de máquina.

Figura B5: Boxplots dos parâmetros extraídos dos sinais de *buzz* selecionados para o modelo de aprendizado de máquina.