

Aquisição e Classificação da Intensidade da Colmeia usando Características Cepstrais

Myllena C. de Oliveira², Fábía de M. Pereira³, Vanessa G. de Moura⁴,
Marcos A. G. B. Brito¹, Breno R. dos Santos¹, Mayra C. de Oliveira¹,
Deborah M. V. Magalhães^{1,2}

¹Sistemas de informação, Universidade Federal do Piauí, Picos, PI, Brasil

²Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Piauí,
Teresina, PI, Brasil

³Embrapa Meio-Norte, Teresina, PI, Brasil

⁴Instituto Federal do Piauí, Uruçuí, PI, Brasil

{myllenaoliveira,deborah.vm,marcos.brito}@ufpi.edu.br

{breno.santos,mayraoliveira}@ufpi.edu.br, fabia.pereira@embrapa.br

vanessa.moura@ifpi.edu.br

Abstract. *The management of hives is fundamental for the maintenance of the beekeeping chain. However, constant revisions, especially during the honey harvest period, cause stress and contribute to swarm loss during the food shortage period. Therefore, this management needs to be fast, safe and non-invasive. This work combines the audio processing produced by the colonies associated with machine learning techniques to identify the intensity of the hive. The results suggest that the coefficients are effective in describing the hive intensity achieving an average accuracy above 97% for three different classifiers, which can help the beekeeper in decision making about which hives to use in honey collection.*

Resumo. *O manejo de colmeias é fundamental para manutenção da cadeia apícola. Contudo, as revisões constantes, especialmente no período de colheita de mel, causam estresse e, no período de escassez de alimento, podem contribuir para a perda de enxame. Portanto, esse manejo precisa ser rápido, seguro e não invasivo. Este trabalho combina o processamento de áudio produzido pelas colônias associado a técnicas de aprendizado de máquina para identificar a intensidade da colmeia. Os resultados sugerem que os coeficientes se mostraram eficazes na descrição da intensidade da colmeia, tendo uma acurácia média acima de 97% para três classificadores distintos, podendo auxiliar o apicultor na tomada de decisão sobre quais colmeias utilizar na coleta de mel.*

1. Introdução

As abelhas desempenham um papel indispensável na agricultura, fornecendo produtos como mel e própolis, e gerando para economia brasileira aproximadamente US\$ 12 bilhões com o serviço de polinização [Vieira et al. 2021]. Para uma prática apícola produtiva as colmeias precisam estar fortes. Colmeias fracas não produzem mel e necessitam de

intervenção para se fortalecerem. A realização de manejos constantes com a finalidade de verificar a situação das colônias e providenciar as ações de manejo para fortalecimento das mesmas é imprescindível [Gorroi et al. 2020].

Contudo, as revisões constantes causam estresse e, no período de escassez de alimento, podem contribuir para a perda de enxame. Por outro lado, a falta de manejo e a presença de colônias fracas nos apiários impactam negativamente a atividade [Oliveira Costa et al. 2016]. Assim, o produtor está constantemente pressionado entre a decisão de realizar um manejo que estressa as colônias e a necessidade de avaliar as condições das colmeias para implementar as medidas necessárias.

O manejo compreende abrir cada colmeia e observar a situação dos favos, presença de rainha, padrão da postura, presença de predadores, quantidade de alimento armazenado [Gorroi et al. 2020]. Para grandes apicultores, as inspeções periódicas podem ser inviáveis, devido ao tempo demandado. Realizar essas revisões de forma rápida, segura e que não estresse as colônias é fundamental para o crescimento na atividade apícola.

Uma proposta existente é realizar o monitoramento por meio de uma rede de sensores e dispositivos da Internet das Coisas (IoT) apoiando a apicultura de precisão [Shaghghi et al. 2019]. No entanto, a aquisição desses equipamentos tem um custo elevado e não é possível obter informações precisas sobre os quadros prontos para coleta [Liakos et al. 2018]. Shostak and Prodeus 2019 buscaram uma forma de mitigar os problemas relacionados à identificação do período de colheita de mel e encontraram uma relação entre o nível de atividade das abelhas durante o período de colheita e a localização do pico de intensidade na faixa de frequência sonora, sendo possível então a utilização do processamento de áudio para realização desta tarefa.

O processamento de áudio associado a técnicas de aprendizado de máquina podem auxiliar na identificação das necessidades das colônias por meio da análise do som produzido pelas abelhas [Shostak and Prodeus 2019]. Algoritmos de classificação podem ser treinados para reconhecer padrões acústicos no período de colheita, permitindo uma identificação automatizada. Isso pode reduzir a necessidade de inspeções físicas diárias, diminuindo custos e aumentando a eficiência da produção apícola.

Com base nisso, esta pesquisa foi realizada com o objetivo de avaliar o desempenho de características cepstrais dos sons produzidos pelas colônias e classificar as colmeias como fraca, média e forte. Os resultados contribuem com: (i) disponibilização uma base pública com características cepstrais extraídas dos áudios coletados a partir de colmeias com diferentes intensidades; (ii) construção de modelos de aprendizado de máquinas que possam auxiliar o apicultor na tomada de decisão relacionada à seleção de colmeias para coleta de mel. Tais contribuições servem de base de conhecimento para a comunidade científica e dão suporte ao desenvolvimento de apiários inteligentes.

2. Trabalhos relacionados

A busca por métodos não invasivos para o monitoramento de colmeias tem sido objeto de estudo em diversos trabalhos, sendo a análise e o processamento de áudio utilizados em aplicações diversas: contagem da saída e chegada das abelhas na colmeia [Heise et al. 2020], detecção da abelha rainha [Ruvinga et al. 2021], enxameação [Zgank 2021], ritmo circadiano [Kim et al. 2021], presença de poluentes no ar [Sharif et al. 2020] e estimativa

do período de maior atividade forrageira das abelhas [Shostak and Prodeus 2019]. Além disso, Abdollahi et al. 2022 identificaram cerca de 60 trabalhos que também exploraram o processamento de áudio para o monitoramento de colmeias.

Os Coeficientes Cepstrais de Frequência Mel (*MFCCs*, do inglês *Mel Frequency Cepstral Coefficients*) têm se mostrado extremamente relevantes para a classificação sonora com abelhas, sendo amplamente utilizados em pesquisas recentes. Ruvina et al. 2021, por exemplo, alcançaram 92% de acurácia na classificação binária entre presença ou ausência de rainha utilizando 13 *MFCCs* e o *log energy*. Para classificação os autores utilizaram um modelo *LSTM*, também foi testado o modelo *MLP* que alcançou 90% de acurácia. Kulyukin 2021 também utilizou *MFCCs* como característica para classificar entre abelha, grilo ou ruído. O autor utilizou 13 *MFCCs* e obteve uma acurácia de 98,43% na classificação com *Random Forest (RF)* e 98% com *SVM*.

Conseguir determinar ritmo circadiano das abelhas permite ao apicultor realizar o deslocamento da colmeia com maior segurança. Cejrowski et al. 2020 apresentaram uma proposta de monitoramento que, através do nível de energia do sinal emitido pela colmeia, detecta o ritmo circadiano da abelhas, determinando seu período de intervalo noturno. Eles concluíram que o período da noite para as *Apis mellifera buckfast* está entre as 23 horas e as 4 horas. Para tanto, os autores extraíram os *MFCCs* e utilizaram como entrada para o classificador *SVM*, obtendo ao fim uma acurácia de 81,14%.

Durante as investigações realizadas por Bromenshenk et al. 2009, foi observado que o som emitido pelas abelhas não só permite detectar a presença de poluentes, como também, permite identificar o tipo de poluente presente. Pensando nisso Sharif et al. 2020 analisaram o desempenho de três diferentes conjuntos de características para realizar a detecção de poluentes dentro da colmeia, especificamente a detecção do composto orgânico *Triclorometano (CHCl3)*. Os conjuntos de características utilizados pelos autores foram *MFCCs* e índices de paisagem sonora. As características extraídas foram enviadas para o classificador *Random Forest* que alcançou 91,66% de acurácia com os índices de paisagem sonora e 80% de acurácia com os *MFCCs*. No entanto, os autores ressaltaram o fato de se tratar de um cenário de classificação binária.

Shostak and Prodeus 2019 identificaram o período de colheita de mel. O estudo extraiu a densidade espectral dos áudios para estimar se a colmeia estava pronta para coleta do mel. Como classificador, foi utilizada a equação da curva divisora que separa os agrupamentos de classes no plano espacial. A validação do modelo foi realizada por meio da probabilidade de classificação correta e um resultado de 96% foi alcançado.

Dos trabalhos discutidos, apenas Kulyukin 2021 utilizou uma base de dados pública. A carência de bases acústicas disponíveis publicamente é um desafio pois previne o desenvolvimento desta área de pesquisa. Apesar de existirem questões em aberto, a utilização do processamento de áudio para extração de *MFCCs* associado às técnicas de aprendizado de máquina, como *RF* ou *SVM*, tem apresentado resultados promissores em termos de acurácia para diferentes fins de monitoramento do apiário.

3. Materiais e Método

Nós visamos uma solução para processamento e classificação de sinais bio acústicos que caracterizem o estado da colmeia como forte, média ou fraca e auxiliar o apicultor a

conhecer o estado de suas colmeias. Dependendo das condições ambientais, colmeias fortes podem estar aptas para coleta de mel e colmeias fracas podem estar necessitando de manejo para fortalecimento. A Figura 1 ilustra os passos para identificar a colmeia.

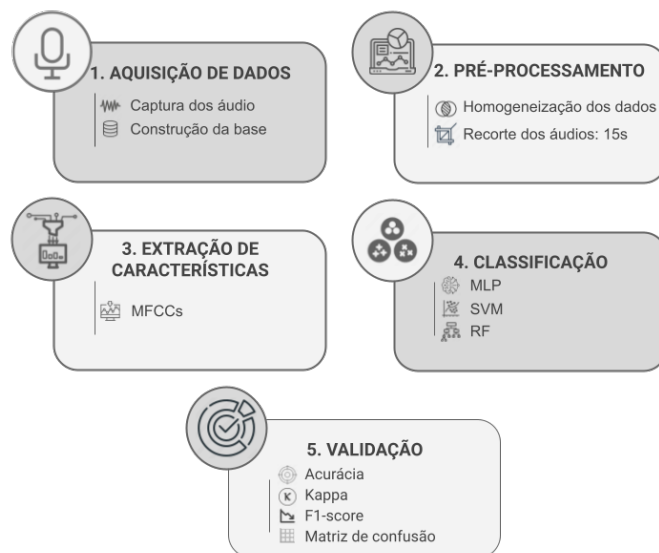


Figura 1. Passo a passo para classificação da intensidade da colônia.

3.1. Aquisição de dados

Motivados pela carência de bases públicas referente aos sons das colmeias, foi conduzida a construção de uma base de dados própria com foco na intensidade da colmeia. Inicialmente realizou-se uma revisão nas colmeias observando área de cria e alimento, postura da rainha, aspecto das crias, sintomas de infestação de inimigos naturais e tamanho da população de operárias e zangões. Essas características interferem na população das colmeias, quantidade de crias e disponibilidade de alimento e influenciam em sua ocupação. Posteriormente as colmeias foram analisadas quanto sua taxa de ocupação e contabilizou-se quantidade de quadros com abelhas adultas, cria e alimento. As colmeias em que foi observado de 75% a 100% de ocupação foram classificadas como forte. As colmeias em que a taxa de ocupação de 74% a 55% foram classificadas como médias e as colmeias com taxa de ocupação menor do que 54% foram classificadas como fracas. A presença de sintomas de ataques por inimigos naturais e postura da rainha (regular ou irregular) contribuíram na tomada de decisão dos casos em que a ocupação da colmeia estava no limiar das taxas estabelecidas. Portanto, as colmeias foram rotuladas conforme sua intensidade em: fraca, média e forte.

Para realizar a coleta dos áudios o apicultor responsável utilizou o próprio smartphone. O áudio foi gravado com o auxílio de um aplicativo de gravação *Voice Recorder*¹ com a seguinte configuração: taxa de amostragem 11000 Hz, canal único (mono) e formato de gravação *Windows Wave* (wav).

As gravações foram realizadas datas distintas: em novembro de 2022, foram realizadas três coletas nos dias 22 e 28. Entre os dias 1 e 6 de dezembro do mesmo ano foram realizadas mais cinco coletas. Por fim, cinco novas coletas foram conduzidas no dia 1 de

¹<https://play.google.com/store/apps/details?id=com.media.bestrecorder.audiorecorder>

fevereiro de 2023. Os áudios foram gravados entre 6h30 e 8h30 em dias ensolarados e sem vento. Os áudios foram coletados em dois apiários diferentes, 11 gravações pertencem ao apiário A e 2 gravações do apiário B, ambos localizados na cidade de Teresina-PI. No total, foram realizadas 13 gravações com duração média de 30 minutos e desvio padrão de 11,46. A distribuição do número de amostras por classe é apresentada na Tabela 1.

Antes da captura dos áudios, para evitar comportamentos defensivos de alta intensidade, as colmeias receberam jatos de fumaça no alvado e, com a tampa entreaberta, por cima dos quadros. Após a fumaça fazer efeito, o smartphone foi posicionado entre a tampa e os quadros, permanecendo a metade do aparelho que possui o microfone no interior da colmeia e a outra metade no exterior, para que se pudesse acionar o comando de gravação, como ilustrado na Figura 2. Ao iniciar a gravação, o smartphone permaneceu na colmeia por cerca de 30 minutos. Para evitar interferência no som capturado, os apicultores se afastaram do local de coleta.

Tabela 1. Distribuição do número e duração das amostras por nível de intensidade da colmeia.

Classe	Nº de amostras	Nº de amostras após o corte	Total de tempo (s)
Fraca	7	776	11640
Forte	3	571	8565
Média	2	203	3043



Figura 2. Posicionamento do smartphone no cenário de aquisição dos áudios.

3.2. Pré-processamento

A etapa de pré-processamento foi conduzida a fim de alcançar a uniformização dos dados adquiridos, de modo que todos possuam as mesmas configurações em termos de duração, taxa de amostragem, quantização e números de canais. Além disso, devido aos áudios capturados terem em média uma duração de 30 minutos, foi realizado um corte nos mesmos gerando novos áudios sem sobreposição com duração de 15 segundos, sendo os mesmos utilizados como amostras individuais nas etapas seguintes. O número de amostras após o corte pode ser observado na Tabela 1.

A manipulação dos áudios capturados na etapa anterior foi realizada utilizando a biblioteca *LibROSA* [McFee et al. 2015], que normaliza por padrão os dados no intervalo $[-1,1]$ e transforma os sinais em mono. Além disso, ela garante que todas as amostras

possuam uma mesma taxa de amostragem, de 11000 Hz, valor passado por parâmetro, e uma quantização de 16 bits [McFee et al. 2015].

3.3. Extração de características

Nesta fase, buscou-se extrair características que permitam o classificador melhor distinguir entre as classes a que o som pertence. Nós avaliamos o desempenho das características cepstrais para diferenciar as classes sonoras: forte, média ou fraca.

As características cepstrais tem relação com a forma com que a audição humana percebe os sons, principalmente a fala. As mais comuns são os coeficientes cepstrais de frequência mel (*MFCCs*, do inglês *Mel Frequency Cepstral Coefficients*) [Virtanen et al. 2018]. Os *MFCCs* descrevem de forma concisa a forma geral de um envelope espectral, ou seja, o limite em que o espectro do sinal está contido.

A biblioteca *LibROSA* também foi utilizada para a extração de características, onde foram extraídos um total de 40 *MFCCs*. Esse valor foi inspirado pelo trabalho [Soares et al. 2022], que utilizou *MFCCs*, dentre outras características, para classificar cenários sonoros envolvendo abelhas, especificamente a ausência ou presença da rainha na colmeia. Nesse estudo, os *MFCCs* estavam entre as 40 primeiras posições de características mais relevantes. As características extraídas estão publicamente disponível no github ².

3.4. Classificação

Foram adotados três classificadores distintos: *Multi-layer Perceptron (MLP)*, *Support Vector Machine (SVM)* e o *Random Forest (RF)*. O *RF* é baseado em árvores decisão e se apresenta menos susceptível ao sobre-ajuste [Breiman 2001]. O *SVM* maximiza a fronteira de decisão interclasse [Cortes and Vapnik 1995]. Já o *MLP* é uma rede neural capaz de aprender relações complexas e não lineares [Haykin 2001].

Os modelos foram avaliados utilizando uma divisão de 80% (1240) dos dados para treino e 20% (310) para teste. Também foi adotado o método de validação cruzada (k -fold=5) e a técnica de ajuste *gridsearch* foi utilizada para definir os parâmetro dos classificadores. No caso do *MLP*, foram testados diferentes números de épocas e *batch-size*. Já para o *SVM*, os parâmetros *C* e *kernel* foram variados. Para o *RF*, foram testados diferentes valores de *criterion* e *n-estimators*. Os valores utilizados para parametrizar os classificadores foram definidos através do Gridsearch e são apresentados na Tabela 2.

Durante os testes, um número elevado de épocas no MLP resultou em overfitting, onde o modelo apresentava uma boa capacidade de predizer as classes corretas durante o treinamento, mas falhava em generalizar para os dados de teste. Com base nesse resultado, durante o processo de gridsearch, foi estabelecido um limite de até 35 épocas.

3.5. Validação

Para avaliar os resultados da classificação dos áudios, foram adotadas medidas estatísticas amplamente utilizadas na literatura: Acurácia (*Acc*), Índice *kappa* (κ), *F1-score* e matriz de confusão, apresentando a proporção de erros e acertos obtidos pelos classificadores [Wardhani et al. 2019]. O *F1-score* é o equilíbrio entre as métricas *precision* e *recall*,

²<https://github.com/zumbeedo/zumbeedo-ia-training/tree/main/MFCCs-intensidade-colmeia-Forte-Media-Fraca>

Tabela 2. Faixa de valores adotada para parametrização dos classificadores.

Classificador	Parâmetros	Valores
MLP	Nº de épocas	20, 25, 30 , 35
	Batch-size	1, 4 , 8
SVM	Kernel	poly, rbf, sigmoid, linear
	C	1 - 11
RF	Criterion	gini, entropy
	N-estimators	10,20,30,40, 50 ,60

Em negrito, os valores selecionados através do gridsearch.

onde o valor ideal é 1. O *kappa* foi selecionado devido ao desbalanceio entre as classes, como pode ser observado na Tabela 1. Ainda, nós utilizamos a matriz de confusão para verificar quais classes estão sendo classificadas corretamente ou não.

4. Resultados e discussões

A Tabela 3 mostra que os três classificadores convergiram para um resultado estatisticamente semelhante, com valores médios significativos superiores à 96% e baixo desvio-padrão para todas as métricas. Em termos de valores médios, o *SVM* obteve os melhores resultados de classificação para as três métricas, com acurácia média de 99,16%, com desvio padrão de 0,0075. O valor médio do f1-score foi de 98,85%, com desvio padrão de 0,0100. O valor médio do *kappa* foi de 0,9860, com desvio padrão de 0,0125. Além de apresentar uma menor variabilidade nas diferentes interações do *cross-validation*.

O *RF* também apresentou resultados satisfatórios, sendo o melhor resultado alcançado com uma acurácia média de 98,45% e desvio padrão de 0,0024. O valor médio do F1-score foi de 97,69%, com desvio padrão de 0,0026, e o valor médio de Kappa foi de 0,9738, com desvio padrão de 0,0040, mostrando um desempenho melhor que o *MLP*.

A *MLP* apresentou uma acurácia média de 97,87%, com desvio padrão de 0,0107. O valor médio do f1-score foi de 96,80%, com desvio padrão de 0,0182. O valor médio do *kappa* foi de 0,9643, com desvio padrão de 0,0175. Esses resultados mostram que o *MLP* apresentou um desempenho razoável na tarefa de classificação, com boa precisão e baixa variabilidade entre as diferentes iterações do *cross-validation*. O valor elevado do f1-score indica que o modelo é capaz de obter um bom balanço entre a taxa de acertos e a taxa de falsos positivos e falsos negativos. Apesar de obter um desempenho satisfatório, o *MLP* ainda alcançou métricas menores que as abordagens *SVM* e *RF*. Destacamos que, para um melhor desempenho da *MLP*, podem ser necessários ajustes adicionais nos parâmetros ou no pré-processamento dos dados, como por exemplo a filtragem de ruídos.

Tabela 3. Resultados de classificação da intensidade da colmeia obtidos com k-fold=5.

Classificador	Acc	Kappa	F1-score
MLP	97,87% (0,0107)	0,96 (0,0175)	96,79% (0,0182)
SVM	99,16% (0,0075)	0,98 (0,0125)	98,85% (0,0100)
RF	98,45% (0,0024)	0,97 (0,0040)	97,69% (0,0026)

Os valores entre parênteses representam o desvio padrão.

As três matrizes de confusão na Figura 3 mostram a distribuição de acertos e erros de cada modelo em relação às classes de interesse, após a execução utilizando os parâmetros definidos pelo *gridserch*. Para cada matriz, as colunas estão ordenadas em

Forte, *Fraca* e *Média* respectivamente. Quanto maior valor tiver as diagonais da matriz, melhor o desempenho do modelo. Na primeira matriz, correspondente ao modelo *MLP*, há uma classificação perfeita para a classe *Forte*, mas houve 1 erro de classificação na classe *Fraca* e 4 erros para a classe *Média*, sendo classificada 3 vezes como *Fraca* e uma como *Forte*. Já na segunda matriz, correspondente ao modelo *SVM*, houve uma classificação sem erros, indicando o bom desempenho do modelo. Na terceira matriz, correspondente ao modelo *RF*, houve 3 erros na classe *Média*, classificada erroneamente como *Forte* 2 vezes e 1 como *Fraca*, no entanto, o desempenho do modelo foi bom.

114	1	1	114	0	0	114	0	2
0	154	3	0	155	0	0	155	1
0	0	37	0	0	41	0	0	38
	MLP			SVM			RF	

Figura 3. Matriz de confusão dos modelos MLP, SVM e RF. Classes *Forte*, *Fraca* e *Média*, respectivamente, nas colunas das matrizes.

O gráfico de dispersão dos dados coletados, apresentado na Figura 4, indica que os dados da classe *Fraca* apresentam maior sobreposição com as outras classes, especialmente a classe *Média*, o que pode explicar a maior ocorrência de erros para tais classes. Apesar disso, há uma separabilidade significativa entre as classes justificando o bom desempenho dos classificadores. Portanto, em perspectiva futura, é importante ampliar a quantidade de amostras da base proposta, especialmente para as classes forte e média, cuja sobreposição têm maior impacto no apiário. Pois uma colmeia média classificada como forte pode implicar em perda de enxame para o apicultor.




Figura 4. Gráfico de dispersão dos dados por classe de intensidade da colônia.

Os resultados apontam que o *SVM* apresentou o melhor desempenho entre os modelos avaliados, apresentando uma acurácia média 0,71% superior ao *RF* e 1,29% superior ao *MLP*. Ainda, observamos que a diferenciação entre as classes fraca e média é mais complexa, enquanto a colmeia forte é mais facilmente discriminada. Esse é um achado

importante, visto que o identifica rapidamente para o apicultor quais as colmeias estão fortes e podem ser usadas na produção de mel, com redução no tempo de observação e custos de produção. Os *MFCCs* se mostraram eficazes na descrição das classes, com uma acurácia média acima de 97% para todos os classificadores. Esse resultado é significativo pois se trata de um descritor de baixa dimensionalidade e composto de característica única, reduzindo o número de cálculos e dependência de pacotes. Ademais, os modelos tradicionais de aprendizado de máquina tiveram melhor desempenho do que o modelo neural. Isso é relevante para aplicações de monitoramento embarcadas em dispositivos com poucos recursos, já que *RF* e *SVM* possuem menor custo computacional que a *MLP*.

5. Conclusões

Na presente pesquisa foi realizada a aquisição de áudios produzidos por colônias de abelhas em diferentes apiários. Ainda, investigou a utilização de *MFCCs* para descrever a intensidade da colmeia e, assim, auxiliar o apicultor na seleção das colmeias mais adequadas para extração do mel. Inspirados pela literatura, identificamos que os *MFCCs* aliados a modelos de aprendizado de máquina conseguem discriminar as colmeias em fraca, média e forte, permitindo a construção de uma base de dados rotulada e pública.

Para pesquisas futuras, sugere-se a aplicação da etapa de seleção de características com o objetivo de reduzir o tamanho do descritor, o que pode torná-lo mais eficiente. Além disso, uma investigação sobre como a filtragem de ruído pode ser incorporada ao pré-processamento para melhorar o desempenho da classificação e extrapolar o descritor para outros cenários de interesse da cadeia apícola. Ainda, avaliar o custo computacional de diferentes classificadores, incluindo cadeias de Markov, a fim de embarcar o modelo de classificação e buscar uma representação da intensidade da colmeia com valores numéricos que seja intuitiva para o apicultor. Por fim, ampliar o número de amostras da base proposta para um cenário de classificação com maior variabilidade.

Referências

- Abdollahi, M., Giovenazzo, P., and Falk, T. H. (2022). Automated beehive acoustics monitoring: a comprehensive review of the literature and recommendations for future work. *Applied Sciences*, 12(8):3920.
- Breiman, L. (2001). Random forests. *Machine learning*, 45:5–32.
- Bromenshenk, J. J., Henderson, C. B., Seccomb, R. A., Rice, S. D., and Etter, R. T. (2009). Honey bee acoustic recording and analysis system for monitoring hive health. US Patent 7,549,907.
- Cejrowski, T., Szymański, J., and Logofătu, D. (2020). Buzz-based recognition of the honeybee colony circadian rhythm. *Computers and Electronics in Agriculture*, 175:105586.
- Cortes, C. and Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20:273–297.
- Gorroi, G., Freitas, L. P. V. d., and Assis, D. C. S. d. (2020). Apicultura: o manejo das abelhas do gênero apis. *Cad. técn. Vet. Zoot.*, pages 9–36.
- Haykin, S. (2001). *Redes neurais: princípios e prática*. Bookman Editora.

- Heise, D., Miller, Z., Wallace, M., and Galen, C. (2020). Bumble bee traffic monitoring using acoustics. In *2020 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, pages 1–6. IEEE.
- Kim, J., Oh, J., and Heo, T.-Y. (2021). Acoustic scene classification and visualization of beehive sounds using machine learning algorithms and grad-cam. *Mathematical Problems in Engineering*, 2021:1–13.
- Kulyukin, V. (2021). Audio, image, video, and weather datasets for continuous electronic beehive monitoring. *Applied Sciences*, 11(10):4632.
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., and Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8):2674.
- McFee, B., Raffel, C., Liang, D., Ellis, D. P., McVicar, M., Battenberg, E., and Nieto, O. (2015). librosa: Audio and music signal analysis in python. In *Proceedings of the 14th python in science conference*, volume 8, pages 18–25.
- Oliveira Costa, R., Bezerra, A. H. A., Ferreira, A. C., Pereira, B. B. M., Pimenta, T. A., and de Andrade, A. B. A. (2016). Análise hierárquica dos problemas existentes na produção de mel do estado da paraíba. *Revista Verde de Agroecologia e Desenvolvimento Sustentável*, 11(2):24–28.
- Ruvinga, S., Hunter, G. J., Duran, O., and Nebel, J.-C. (2021). Use of lstm networks to identify “queenlessness” in honeybee hives from audio signals. In *2021 17th International Conference on Intelligent Environments (IE)*, pages 1–4. IEEE.
- Shaghghi, N., Liang, L., Yabe, Y., Lama, S., Mayer, J., and Ferguson, P. (2019). Identifying beehive frames ready for harvesting. In *2019 IEEE Global Humanitarian Technology Conference (GHTC)*, pages 1–4. IEEE.
- Sharif, M. Z., Wario, F., Di, N., Xue, R., and Liu, F. (2020). Soundscape indices: new features for classifying beehive audio samples. *Sociobiology*, 67(4):566–571.
- Shostak, S. and Prodeus, A. (2019). Classification of the bee colony condition using spectral features. In *2019 IEEE International Scientific-Practical Conference Problems of Infocommunications, Science and Technology (PIC S&T)*, pages 737–740. IEEE.
- Soares, B. S., Luz, J. S., de Macêdo, V. F., e Silva, R. R. V., de Araújo, F. H. D., and Magalhães, D. M. V. (2022). Mfcc-based descriptor for bee queen presence detection. *Expert Systems with Applications*, 201:117104.
- Vieira, F. R., Andrade, D. C., and Ribeiro, F. L. (2021). A polinização por abelhas sob a perspectiva da abordagem de serviços ecossistêmicos (ase). *Revista Ibero-Americana de Ciências Ambientais*, 12(4):544–560.
- Virtanen, T., Plumbley, M. D., and Ellis, D. (2018). *Computational analysis of sound scenes and events*. Springer.
- Wardhani, N. W. S., Rochayani, M. Y., Iriany, A., Sulistyono, A. D., and Lestantyo, P. (2019). Cross-validation metrics for evaluating classification performance on imbalanced data. In *International conference on computer, control, informatics and its applications*, pages 14–18. IEEE.
- Zgank, A. (2021). Iot-based bee swarm activity acoustic classification using deep neural networks. *Sensors*, 21(3):676.