

Padrões Bioacústicos como Identificadores Precisos da Presença de Rainha em Colmeias de Abelhas Melíferas

Ícaro de Lima Rodrigues¹, Davyd B. de Melo¹, Daniel de Amaral da Silva¹,
Yves Rybarczyk², Danielo G. Gomes¹

¹Programa de Pós-Graduação em Engenharia de Teleinformática
Grupo de Redes de Computadores Engenharia de Software e Sistemas (GREat)
Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza - CE

²School of Information and Engineering
Dalarna University, 79188, Falun, Sweden

{icarodelima,danielamaral}@alu.ufc.br

yry@du.se, {davydmelo,danielo}@ufc.br

Abstract. *The queen bee is responsible for her colony's growth, renewal and organizational stability. To know whether a honey queen is inside the hive, the beekeeper has to open it, which stresses the bees, destroys part of the nest and causes bee workers' death. Classifying the queen's presence through the colony audio is a non-invasive inspection method that can keep the colony well-being. However, bioacoustic patterns generate a considerable volume of data. Incremental classifiers with a daily recording ratio could guarantee efficiency while reducing the bottleneck. Here we evaluate the performance of three classifiers: Hoeffding Tree, Random Forest and Naive Bayes. Naive Bayes showed the best results with 10 windows of 1s/day, response time of 0.93s and average accuracy of 97%.*

Resumo. *A abelha rainha é a responsável pelo crescimento, renovação e estabilidade organizacional da sua colônia. Para saber se uma rainha melífera está presente na colmeia, o apicultor tem de abri-la, o que estressa as abelhas, destrói parte do ninho e provoca morte de operárias. Classificar a presença da rainha através do seu zumbido, por exemplo, é um método de inspeção não-invasivo e pode manter o bem-estar da colônia. Porém, padrões bioacústicos geram um volume considerável de dados. A utilização de classificadores incrementais com uma taxa de gravação diária pode manter a eficiência e reduzir este gargalo. Neste artigo, avaliamos de forma sistemática o desempenho de três classificadores incrementais: Hoeffding Tree, Random Forest e Naive Bayes. Destes três classificadores, o destaque foi o Naive Bayes com 10 janelas de 1 s/dia, tempo de resposta de somente 0,93 s e acurácia média de 97%.*

1. Introdução

Uma colônia de abelhas deve ter uma rainha jovem e saudável sob pena de sérios problemas. A ausência da rainha quebra a coesão da colônia devido à falta dos feromônios, leva à descontinuidade da produção de crias e desestrutura o trabalho normal das operárias. As abelhas têm a capacidade de reconhecer rapidamente a ausência de sua rainha e é

recomendável que o apicultor disponha de meios para também fazê-lo, o que tradicionalmente acontece de forma manual e invasiva com abertura de colmeias, cujo processo infelizmente estressa e pode até matar algumas abelhas [Winston 1991].

Por outro lado, nos últimos anos, pesquisadores têm buscado métodos não-invasivos de monitoramento remoto e em tempo real dos apiários a fim de ajudar apicultores a entender o que está acontecendo dentro das colmeias sem precisar abri-las [Dineva et al. 2018, Meikle et al. 2017]. Atenção especial tem sido dada ao monitoramento de variáveis físicas da colmeia, e.g. temperatura e umidade [Braga et al. 2021], peso [Silva et al. 2020, Braga et al. 2020], gases [Wilk et al. 2021], áudio [Rodrigues et al. 2021].

Particularmente com relação ao áudio (zumbido) das abelhas, um algoritmo de reconhecimento de padrões bioacústicos pode ser treinado para identificar adversidades em uma colônia, tais como enxameamento [Žgank 2018], infestação de parasitas [Hadjur et al. 2022] e ausência de rainha [Peng et al. 2020, Howard et al. 2013]. A título ilustrativo, o zumbido das abelhas difere quando a rainha está presente ou ausente ¹.

Entretanto, o monitoramento em tempo real de uma colônia demanda classificadores incrementais ou do tipo *online*. Eles recebem, avaliam e se adaptam aos dados em tempo de execução sem a necessidade de *datasets* prévios para treinamento, como no caso dos classificadores *offline*. Além disso, grandes massas de dados, como áudio, são computacionalmente caras tanto em processamento quanto em tempo de transmissão pela rede. Este custo computacional pode atrasar uma tomada de decisão do apicultor trazendo riscos ao bem-estar das colônias. Portanto, há necessidade de encontrar uma forma eficaz de identificar a presença de rainha na colônia utilizando uma taxa de gravação diária aliado a classificadores *online*.

O objetivo deste artigo é detectar a presença da rainha em colmeias de abelhas melíferas através de padrões bioacústicos. Foi realizada uma avaliação de desempenho sistemática de 3 classificadores *online* para recomendar um método rápido e robusto de amostrar diariamente dados de áudio das abelhas.

2. Material e Métodos

Sobre o objeto de estudo, geramos um conjunto de dados de áudios de uma colônia de abelhas melíferas do tipo africanizada em uma colmeia de observação do Setor de Abelhas da UFC, localizado no Campus do Pici em Fortaleza-CE (Figura 1). O áudio da referida colmeia foi gravado durante seis dias sempre no período da tarde, sendo que a rainha esteve presente nos cinco primeiros dias e foi retirada da colmeia no sexto dia pela manhã. A coleta dos dados e a presença da rainha foram atestadas com auxílio de um apicultor local. Desta forma, foram obtidas amostras de áudio constituindo um delineamento entre a classe positiva (1 - rainha presente) e negativa (0 - rainha ausente)(Figura 2). Ao todo, foram coletadas mais de 23h de gravação.

2.1. Delineamento

O sistema sob estudo pode ser definido, de maneira geral, como um classificador de presença de rainha. O sistema tem como entrada *streamings* de áudio gravados dentro da colmeia. Na saída, o sistema retorna as métricas de avaliação do classificador (e.g.

¹<https://smartbee-ufc.github.io/bioacoustics/>

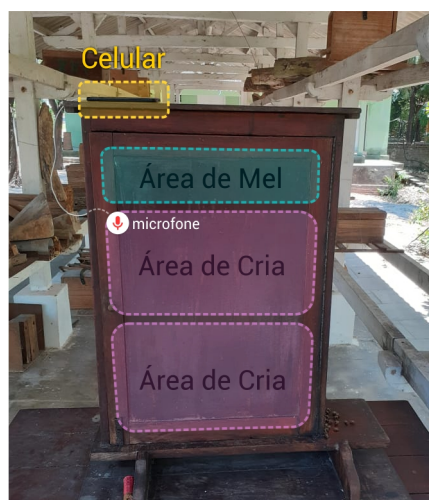


Figura 1. Colmeia de observação para captura dos áudios de abelhas melíferas.




Figura 2. Espectrograma durante 1 hora de gravação de um dia com a presença (esquerda) e um dia com a ausência (direita) da rainha na colmeia.

acurácia, precisão). Expandindo um pouco mais, o sistema é subdividido em três etapas: amostragem, extração de *features* e a classificação propriamente dita.

A etapa de amostragem está relacionada aos fatores do estudo. O número de janelas e tamanho de janela definem a dimensão dos dados de áudio que são transmitidos e processados pela rede diariamente e, conseqüentemente, o tamanho do conjunto de dados total. A seleção de cada janela no áudio original é feita de forma randomizada. Na segunda etapa, utilizou-se a biblioteca *pyAudioAnalysis* [Giannakopoulos 2015] para a extração de *features* do áudio. A biblioteca é *open-source* e feita para linguagem *python*. Permitindo extrair até 68 *features* do áudio. Dentre as características extraídas existem oito métricas do sinal (e.g. energia, entropia, centroide espectral), além dos *Mel Frequency Cepstral Coefficients* ou MFCCs, elementos *chroma*, etc. A última etapa é o classificador incremental que vai receber os dados amostra por amostra. Após percorrer todo o conjunto de dados, o classificador retorna as métricas de avaliação.

Neste trabalho foram analisados três classificadores: *Hoeffding Tree* (HT) - uma árvore de decisão rápida, *Naive Bayes* (NB) - um classificador baseado no teorema de Bayes e *Adaptive Random Forest* (RF) uma adaptação do Random Forest tradicional para abordagem incremental. Todos usando a biblioteca *scikit-multiflow* e com os parâmetros predefinidos pela biblioteca. Para o RF foi utilizado um *random state* igual a 42, para fins

de reproducibilidade. A análise de desempenho é feita individualmente e, com os resultados obtidos, é feita uma comparação posterior entre os classificadores. Os experimentos foram executados em um computador com processador *Intel core i5* com 8GB RAM.

2.2. Avaliação de desempenho dos classificadores

Selecionamos dois fatores que tratam da etapa de amostragem do áudio: (i) número de janelas e (ii) tamanho da janela. Tendo em vista que as gravações de áudio geram arquivos pesados e extensos, é recomendável buscar uma melhor maneira de selecionar intervalos diários para que o áudio seja coletado e transmitido sem a necessidade de enviar extensas horas de gravação através da rede. Os níveis escolhidos para o fator (i) são 10, 100 e 200 janelas. Para o fator (ii) são 1, 2 e 3 segundos.

As métricas da análise são o (a) tempo de execução e (b) acurácia do classificador. Além destas, foram computadas outras medidas, como precisão, sensibilidade (*recall*) e a medida $F_{\beta=0,5}$. Muito embora, apenas com (a) e (b) foram realizadas análises estatísticas sistemáticas, as outras métricas são importantes para validação e escolha dos classificadores. Para os classificadores incrementais, neste caso, existem quatro grupos que compõem a matriz de confusão. Sendo estes:

- **VP** (Verdadeiros positivos) - amostras classificadas com a presença de rainha e que de fato a rainha estava presente na colônia;
- **FP** (Falsos Positivos) - amostras que foram classificadas como presença de rainha mas na verdade a rainha estava ausente (Erro do tipo I);
- **FN** (Falsos Negativos) - amostras classificadas como ausência de rainha mas a rainha na verdade estava presente (Erro do tipo II);
- **VN** (Verdadeiros negativos) - amostras classificadas como ausência de rainha e que de fato estavam sem rainha na colônia.

A acurácia é a taxa de acerto do classificador. Enquanto a precisão é calculada como $\frac{VP}{VP+FP}$ e o *recall* é $\frac{VP}{VP+FN}$. Logo, a precisão cai conforme existem mais erros do tipo I e o *recall* com erros do tipo II.

A medida F_{β} é a média harmônica ponderada entre precisão e *recall*. A ponderação é feita através do parâmetro β . Se $\beta = 1$, a medida é igual ao tradicional *f-score*. Porém, se $\beta \rightarrow 0$ considera-se apenas a precisão e se $\beta \rightarrow \infty$ considera-se apenas o *recall*. Para o problema abordado neste trabalho, erros do tipo I são muito mais preocupantes e representam mais riscos ao bem-estar da colônia. Por conseguinte, foi escolhido $\beta = 0,5$ já que a precisão é a métrica mais sensível aos erros do tipo I.

Para uma melhor avaliação e generalização dos classificadores, após amostrado o áudio de acordo com os fatores, o conjunto de dados resultante é embaralhado. Foi utilizado um *seed = 10* para garantir que todos os classificadores estejam lidando com o mesmo conjunto de dados, ou seja, embaralhados da mesma forma. Além disso, para cada combinação de fatores são realizadas 10 repetições do experimento. Com efeito, a amostragem do áudio original é refeita e as janelas são selecionadas randomicamente outra vez para cada repetição. Cada conjunto de dados gerado durante cada repetição é armazenada de forma que os classificadores sempre executam sob o mesmo conjunto de dados, para uma dada combinação de fatores e repetição. É importante ressaltar que, ao longo deste trabalho, é utilizada uma notação para as combinações de níveis entre os fatores da forma: (Número de Janelas & Tamanho da Janela). Por exemplo, a combinação de 200 janelas de 3 segundos, tem a notação (200 & 3).

2.3. Testes estatísticos

Foi realizada uma análise fatorial tripla (classificador, número e tamanho das janela) e o método estatístico escolhido foi a ANOVA ART [Wobbrock et al. 2011] (AART, neste texto), o qual é mais apropriado para experimentos fatoriais múltiplos não-paramétricos como neste caso. Os testes foram executados utilizando a linguagem R. O nível de significância adotado para os testes estatísticos foi de 0,05 (5%).

3. Resultados

3.1. Hoeffding Tree




Figura 3. Comparativo do tempo de execução do algoritmo *Hoeffding Tree* (HT).

Combinação	Hoeffding Tree			
	Acurácia (%)	Precisão (%)	Recall (%)	$F_{\beta=0,5}$ (%)
(10 & 1)	96,8 ± 0,7	99,1 ± 0,5	97,3 ± 0,7	98,7 ± 0,4
(10 & 2)	97,2 ± 0,7	98,9 ± 0,6	97,8 ± 0,7	98,7 ± 0,5
(10 & 3)	97,5 ± 1,4	98,8 ± 0,4	98,4 ± 1,3	98,7 ± 0,6
(100 & 1)	97,7 ± 0,3	98,6 ± 0,3	98,6 ± 0,2	98,6 ± 0,2
(100 & 2)	98,1 ± 0,2	98,9 ± 0,1	98,8 ± 0,2	98,9 ± 0,1
(100 & 3)	98,3 ± 0,2	99,1 ± 0,2	98,9 ± 0,1	99,1 ± 0,1
(200 & 1)	98,0 ± 0,1	98,9 ± 0,1	98,7 ± 0,1	98,9 ± 0,1
(200 & 2)	98,3 ± 0,1	99,1 ± 0,1	98,9 ± 0,1	99,1 ± 0,1
(200 & 3)	98,5 ± 0,1	99,2 ± 0,1	99,0 ± 0,1	99,2 ± 0,1

Tabela 1. Resultado das métricas (média ± desvio-padrão) de HT.

O tempo de execução do HT (Figura 3) mostrou-se bastante eficiente. O classificador chegou a marcar um pouco mais de 70 segundos de tempo de execução para o caso máximo de (200 & 3). Para a Acurácia (Tabela 1), temos valores sempre acima de 96% para todas as combinações. Além disso, a métrica $F_{\beta=0,5}$ se manteve sempre acima de 98%, indicando uma baixa ocorrência de erros do tipo I. A AART mostrou que apenas as combinações (100 & 2) e (200 & 1) produzem tempos de execução iguais. Quanto

a acurácia, nem todas são iguais estatisticamente. Entretanto, como já mencionado, as acurácias são em todos os casos acima de 96%. Desta forma, optar por uma combinação que tenha acurácia menor que outra ainda é interessante porque ganha-se bastante tempo em troca de casas decimais de acurácia.

Sendo assim, para o HT, a melhor combinação de fatores seria (10 & 1) com tempo médio igual a 1,68s. Estatisticamente, esta combinação possui tempo de execução e acurácia menor que as demais combinações. Entretanto, a variação de acurácia média é mínima (< 2,0%), enquanto o ganho de tempo é muito maior (> 60 s).

3.2. Naive Bayes




Figura 4. Comparativo do tempo de execução do classificador *Naive Bayes* (NB).

Combinação	Naive Bayes			
	Acurácia (%)	Precisão (%)	Recall (%)	$F_{\beta=0,5}$ (%)
(10 & 1)	97,0 ± 1,2	99,7 ± 0,2	97,0 ± 1,4	99,0 ± 0,4
(10 & 2)	96,6 ± 0,9	99,8 ± 0,1	96,2 ± 1,0	99,1 ± 0,2
(10 & 3)	97,3 ± 1,7	99,8 ± 0,4	97,0 ± 1,7	99,2 ± 0,7
(100 & 1)	96,9 ± 0,5	99,7 ± 0,1	96,5 ± 0,6	99,0 ± 0,1
(100 & 2)	96,7 ± 0,4	99,6 ± 0,1	96,4 ± 0,4	99,0 ± 0,1
(100 & 3)	96,9 ± 0,4	99,7 ± 0,1	96,5 ± 0,5	99,0 ± 0,1
(200 & 1)	96,6 ± 0,2	99,7 ± 0,0	96,2 ± 0,3	99,0 ± 0,1
(200 & 2)	96,5 ± 0,3	99,7 ± 0,0	96,2 ± 0,4	99,0 ± 0,1
(200 & 3)	96,7 ± 0,2	99,7 ± 0,1	96,4 ± 0,2	99,0 ± 0,1

Tabela 2. Resultado das métricas (média ± desvio-padrão) de NB.

O tempo de execução do NB (Figura 4) mostra um ótimo desempenho do classificador, não ultrapassando a marca de 60 segundos nem mesmo com (200 & 3). A AART mostrou que todas as combinações de fatores geram respostas de tempo de execução diferentes entre si. Em relação a acurácia do NB (Tabela 2), temos valores muito próximos entre as combinações de fatores com pouca variação média. A menor acurácia média registrada ainda é bastante alta, mantendo a métrica sempre acima de 96%. A métrica

$F_{\beta=0,5}$ se mantém em torno dos 99% em todos os casos. Além disso, a AART também mostrou que as acurácias são iguais entre quaisquer combinações de fatores para o NB.

Conseqüentemente, com o NB, a melhor combinação de fatores é (10 & 1). Esta combinação possui tempo de execução médio igual a 0,93s. Mostrando ser muito rápido e estatisticamente diferente das demais combinações. Enquanto isso, (10 & 1) produz uma acurácia estatisticamente igual a todas as demais combinações avaliadas.

3.3. Adaptive Random Forest




Figura 5. Comparativo do tempo de execução do algoritmo *Random Forest* (RF).

Combinação	Adaptive Random Forest			
	Acurácia (%)	Precisão (%)	Recall (%)	$F_{\beta=0,5}$ (%)
(10 & 1)	96,4 ± 0,7	97,3 ± 0,5	98,6 ± 0,4	97,5 ± 0,5
(10 & 2)	97,6 ± 0,5	98,5 ± 0,4	98,9 ± 0,3	98,5 ± 0,3
(10 & 3)	98,0 ± 0,6	98,5 ± 0,4	99,2 ± 0,4	98,6 ± 0,3
(100 & 1)	98,4 ± 0,2	99,1 ± 0,1	99,0 ± 0,1	99,1 ± 0,1
(100 & 2)	98,7 ± 0,2	99,3 ± 0,1	99,1 ± 0,1	99,3 ± 0,1
(100 & 3)	98,8 ± 0,2	99,4 ± 0,1	99,2 ± 0,1	99,4 ± 0,1
(200 & 1)	98,7 ± 0,1	99,3 ± 0,1	99,2 ± 0,1	99,3 ± 0,1
(200 & 2)	98,8 ± 0,1	99,5 ± 0,1	99,2 ± 0,1	99,4 ± 0,1
(200 & 3)	98,9 ± 0,1	99,5 ± 0,1	99,2 ± 0,1	99,4 ± 0,0

Tabela 3. Resultado das métricas (média ± desvio-padrão) de RF.

O tempo de execução do RF (Figura 5) mostra o alto custo computacional do classificador. O tempo do RF é mais de 10 vezes maior que os outros classificadores avaliados nesse estudo. Este alto custo ocorre devido a complexidade do algoritmo de florestas aleatórias adaptativas. Por conta disso, só seria viável aplicar este classificador para o problema proposto utilizando apenas 10 janelas. Conforme os níveis dos fatores aumentam, o tempo escala drasticamente. Em relação a acurácia do NB (Tabela 3), temos valores muito altos. Entretanto, os valores de acurácia com apenas 10 janelas não se sobressaem dos demais classificadores, tornando o tempo ainda mais um fator limitante.

Desta forma, o RF não se mostra um classificador em condições de concorrer com os demais. É o mais robusto dentre os algoritmos, porém, para o problema em questão, não é eficiente como os anteriores. Utilizando o AART, os resultados mostram que as acurácias do RF são iguais em muitas combinações ao HT, por exemplo. Portanto, o alto tempo de execução não se torna proveitoso de nenhuma forma.

3.4. Comparando os 3 classificadores

A Figura 6 ilustra um comparativo dos tempos de execução dos classificadores *Hoeffding Tree (HT)*, *Random Forest (RF)* e *Naive Bayes (NB)*. Com relação ao tempo de execução, o classificador mais rápido foi o NB seguido bem de perto pelo HT em cada uma das combinações de fatores. De início, o classificador RF desempenha similar aos outros dois mas se torna muito custoso com o aumento dos níveis dos fatores, chegando ao ponto de ter um tempo de execução cerca de dez vezes maior.

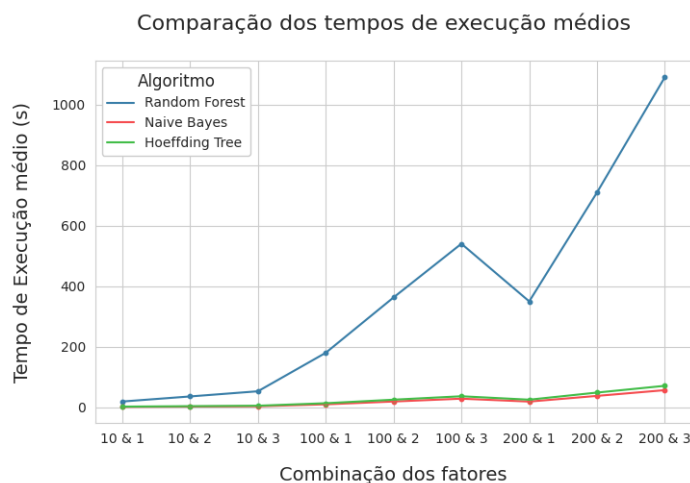


Figura 6. Tempos de execução dos classificadores.

Com relação à acurácia (Figura 7), os 3 classificadores apresentam acurácias bem elevadas (acima de 96 %) para todas as combinações de níveis dos fatores e sem grande elevação conforme os níveis aumentam.

Tanto para o NB, quanto para o HT, a melhor combinação de fatores é (10 & 1). O tempo do NB é 0,93 s e do HT é igual a 1,68 s. As acurácias são respectivamente 96,8 % e 97,0 %. A métrica $F_{\beta=0,5}$ é maior para o NB, indicando a menor ocorrência de erros do tipo I, o que é mais desejável para garantir o bem-estar das abelhas melíferas. A matriz de confusão média do NB e HT para 10 janelas de 1 segundo é mostrada na Figura 8. É possível notar que o NB identifica a ausência de rainha melhor que o HT, enquanto para presença de rainha é o contrário.

4. Conclusão

A principal contribuição deste artigo é identificar de maneira acurada ($\geq 96\%$) a presença de rainha em colmeias de abelhas melíferas utilizando uma taxa de amostragem bioacústica de 10 janelas de 1 segundo por dia. A partir desta taxa, o apicultor obtém uma resposta rápida e precisa da presença de rainha nas colônias de abelhas melíferas que




Figura 7. Comparação entre as acurácias médias entre os classificadores.

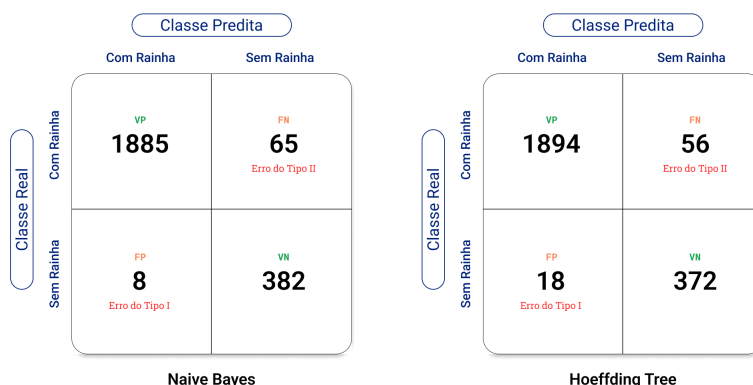


Figura 8. Matriz de confusão média para 10 janelas de 1 segundo com NB e HT.

ele maneja. Esta rápida identificação aliada ao baixo custo de recursos computacionais assegura uma tomada de decisão ágil para garantir o bem-estar da colônia monitorada.

O uso de classificadores incrementais se mostrou igualmente eficaz para o problema. Os fatores (quantidade e tamanho das janelas) são estatisticamente significantes tanto para o tempo de execução quanto para a acurácia dos classificadores. Dentre os três classificadores avaliados, sugerimos o uso do *Naive Bayes* cujo tempo de execução médio foi de 0,93 s, garantindo 97% de acurácia e 99% de medida $F_{\beta=0,5}$.

Agradecimentos

O presente artigo foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Agradecimentos a Isac Gabriel Abrahão Bomfim pelas sugestões concenatuais sobre as abelhas. Danielo G. Gomes agradece o suporte financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) via processos 432585/2016-8 e 310317/2019-3.

Referências

- Braga, A. R., Freitas, B. M., Gomes, D. G., Bezerra, A. D., and Cazier, J. A. (2021). Forecasting sudden drops of temperature in pre-overwintering honeybee colonies. *Biosystems Engineering*, 209:315–321.
- Braga, A. R., Gomes, D. G., Rogers, R., Hassler, E. E., Freitas, B. M., and Cazier, J. A. (2020). A method for mining combined data from in-hive sensors, weather and apitary inspections to forecast the health status of honey bee colonies. *Computers and Electronics in Agriculture*, 169:105161.
- Dineva, K., Atanasova, T., et al. (2018). Osemn process for working over data acquired by iot devices mounted in beehives. *Curr. Trends Nat. Sci*, 7(13):47–53.
- Giannakopoulos, T. (2015). pyaudioanalysis: An open-source python library for audio signal analysis. *PLOS ONE*, 10(12):1–17.
- Hadjur, H., Ammar, D., and Lefèvre, L. (2022). Toward an intelligent and efficient beehive: A survey of precision beekeeping systems and services. *Computers and Electronics in Agriculture*, 192:106604.
- Howard, D., Duran, O., Hunter, G., and Stebel, K. (2013). Signal processing the acoustics of honeybees (*apis mellifera*) to identify the "queenless" state in hives. *Proceedings of the Institute of Acoustics*, 35:290–297.
- Meikle, W. G., Weiss, M., Maes, P. W., Fitz, W., Snyder, L. A., Sheehan, T., Mott, B. M., and Anderson, K. E. (2017). Internal hive temperature as a means of monitoring honey bee colony health in a migratory beekeeping operation before and during winter. *Apidologie*, 48(5):666–680.
- Peng, R., Ardekani, I., and Sharifzadeh, H. (2020). An acoustic signal processing system for identification of queen-less beehives. In *2020 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC)*, pages 57–63.
- Rodrigues, I., Melo, D., Freitas, B., and G. Gomes, D. (2021). Detecção de anomalias em padrões acústicos, de temperatura e umidade sazonais para abelhas melíferas (*apis mellifera* l.). In *Anais do XII Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais*, pages 69–78, Porto Alegre, RS, Brasil. SBC.
- Silva, D., Ícaro Rodrigues, Braga, A., Nobre, J., Freitas, B., and Gomes, D. (2020). An autonomic, adaptive and high-precision statistical model to determine bee colonies well-being scenarios. In *Anais do XI Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais*, pages 31–40, Porto Alegre, RS, Brasil. SBC.
- Wilk, J. T., Bak, B., Artiemjew, P., Wilde, J., and Siuda, M. (2021). Classifying the biological status of honeybee workers using gas sensors. *Sensors*, 21(1).
- Winston, M. L. (1991). *The biology of the honey bee*. harvard university press.
- Wobbrock, J. O., Findlater, L., Gergle, D., and Higgins, J. J. (2011). The aligned rank transform for nonparametric factorial analyses using only anova procedures. In *Proceedings of the SIGCHI conference on human factors in computing systems*, pages 143–146.
- Žgank, A. (2018). Acoustic monitoring and classification of bee swarm activity using mfcc feature extraction and hmm acoustic modeling. In *2018 ELEKTRO*, pages 1–4.