



Acoustic Analysis of Beehives for Precision Beekeeping Based on the Internet of Things: A Case Study on Improving Hive Health and Productivity

Payam Faramarzi¹ | Reza Alimardani² | Hekmat Rabbani³ | Hossein Mousazadeh⁴

1. Department of Agricultural Machinery Engineering, Agriculture and Natural Resources Campus, University of Tehran,

Tehran, Iran, E-mail: payam.faramarzi@ut.ac.ir

2. Department of Agricultural Machinery Engineering, Agriculture and Natural Resources Campus, University of Tehran,

Tehran, Iran, E-mail: rmardani@ut.ac.ir

3. Department of Mechanical engineering of biosystems, Razi University, Kermanshah, Iran, E-mail:

h rabbani2010@gmail.com

4. Department of Agricultural Machinery Engineering, Agriculture and Natural Resources Campus, University of Tehran,

Tehran, Iran, E-mail: hmousazade@ut.ac.ir

Article Info

Article type: Research Article

Article history:

Received: Oct. 5, 2024

Revised: Jan. 30, 2025

Accepted: Feb. 3, 2025

Published online: Autumn 2024

Keywords:

*Internet of Things,
Precision beekeeping,
Common hive diseases,
Hive productivity,
Acoustic analysis*

ABSTRACT

Pollination is essential for the sexual reproduction of many crops, fruits, and most wild plants. Among animal pollinators, solitary and social bees play a major role. In addition to their role in pollinating wild plants, managed honeybee colonies are economically the most valuable group of pollinators for monoculture crops and fruits worldwide. This study presents a novel method for diagnosing honeybee colony diseases and problems using sound analysis and deep learning. First, the sounds produced by the honeybee colony were recorded by designing a smart beehive and placing a microphone in an optimal location. Then, by converting the audio signals into spectrograms and using convolutional neural networks, sound patterns associated with various diseases and problems such as queen less ness, varroa mite infestation, and fowlbrood and nosema diseases were identified. The results showed that this method is capable of diagnosing these problems with an accuracy of over 98%. For example, the model was able to detect queen less ness with 98.62% accuracy, the probability of varroa mite presence with 98.59% accuracy, and the probability of fowlbrood disease with 98.71% accuracy. Finally, by implementing the Internet of Things in the hive management system, a significant improvement in the quantity and quality of honey produced was observed. This research shows that sound analysis and deep learning can be used as a powerful tool for monitoring the health of honeybee colonies and increasing productivity in the beekeeping industry.

Cite this article: Faramarzi, P., Alimardani, R., Rabbani, H., & Mousazadeh, H. (2024) Acoustic Analysis of Beehives for Precision Beekeeping Based on the Internet of Things: A Case Study on Improving Hive Health and Productivity, *Iranian Journal of Biosystem Engineering*, 55 (3),49-71. <https://doi.org/10.22059/ijbse.2025.383049.665567>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijbse.2025.383049.665567>





EXTENDED ABSTRACT

Introduction

Pollination, achieved by insects, birds and other, is crucial for the sexual reproduction of numerous crops, fruits, and wildest plants. Among pollinators, insect pollination, particularly by solitary and social bees, plays a dominant role. Beyond their contribution to wild plant pollination, managed honey bees (primarily *Apis mellifera*) constitute the most economically valuable pollinator group in monocrops and fruits globally. The primary objective of this study was to develop a novel method for monitoring beehive health using sound analysis. By leveraging deep learning techniques, we aimed to accurately detect the presence or absence of a queen bee, as well as various diseases and pests within bee colonies.

Methodology

To achieve this, we initially designed a beehive and the optimal microphone placement within it using SOLIDWORKS 2022. Subsequently, we employed sound analysis to assess the health status of bee colonies. One-minute audio files were recorded from each hive and converted into spectrograms. These spectrograms were then analyzed using a Convolutional Deep Learning Neural Network (CDLNN). The performance of DenseNet121, EfficientNetB0, and InceptionV3 networks was generated and selected the best-performing one. The chosen network was further trained with six different combinations of batch size and epochs. Finally, spectrograms from healthy hives were compared with those from hives affected by various issues such as queen lessness, Varroa mites, tracheal mites, American/European foulbrood, and Nosema. This innovative system continuously records audio from beehives and analyzes the sounds to detect signs of illness. By using advanced techniques like the Fast Fourier Transform and deep learning, the system can identify various bee diseases with high accuracy. The collected audio data is processed on a cloud-based platform, where powerful artificial intelligence models analyze the sound patterns to identify any health issues within the bee colony. This technology provides beekeepers with a valuable tool to proactively monitor the health of their hives and take necessary steps to prevent colony collapse disorder.

GSMT represents the GSM transmitter modules and their associated circuitry, responsible for initiating calls to the GSM receiver. GSMR denotes the GSM receiver modules and their circuitry, designed to record audio transmitted from the beehives and store it. PC refers to the personal computer that serves as an interface between the GSM modules and Google Cloud. LAN signifies the local area network connecting the PC and the GSM receiver modules. Cloud Computing refers to the Google Cloud Platform, used for data storage and processing.

Ultimately, audio data is stored in Google Drive and processed on Google Colab using a deep learning system based on convolutional neural networks. If any of the defined problems occur (such as queen lessness, Varroa mites, tracheal mites, foulbrood, or Nosema disease), a message is sent to the beekeeper via Telegram. This message includes the audio file containing the detected disease, the processed spectrogram with the detection accuracy percentage, and a text message specifying the beehive number and the probability of the problem.

Results

Our findings demonstrated that sound analysis can accurately detect the presence or absence of a queen bee, as well as infestations by mites and diseases like foulbrood and Nosema. Each specific problem within a beehive produced a unique sound pattern that could be identified using neural networks. By analyzing the fast Fourier transform of one-minute audio recordings, spectrograms and extracted frequency features was generated to interpret the beehive's condition. The neural network achieved an accuracy of over 98% in identifying various issues (queen lessness 98.62%, Varroa mites 98.59%, tracheal mites 98.64%, American/European foulbrood 98.71%, and Nosema 98.80%). Moreover, the proposed Internet of Things system significantly improved the quality and quantity of honey produced compared to traditional beekeeping practices.

The neural networks achieved remarkably high accuracies in identifying various hive anomalies. Specifically, accuracies exceeding 98% were obtained for queenlessness (98.62%), Varroa mites (98.59%), tracheal mites (98.64%), American/European foulbrood (98.71%), and Nosema (98.80%).

Healthy hive with queen: Dominant frequencies were observed between 0 and 2000 Hz, indicative of a stable and healthy colony.

Queenless hive: Higher frequencies, ranging from 2000 to 4000 Hz, were detected, suggesting increased agitation and disorganization among the bees.

Varroa mite infestation: The dominant frequency range shifted to 1000-3000 Hz, indicating increased bee activity to combat the infestation.

Acariasis infestation: Lower frequencies, between 500 and 1500 Hz, were observed, suggesting decreased hive activity and a weakened colony.

American or European foulbrood: A significant decrease in the overall frequency range (400-1200 Hz) was noted, indicating a weakened colony and reduced bee activity.

Nosema infestation: Higher frequencies (800-2400 Hz) were observed, suggesting increased bee activity due to digestive system disturbances.

These results were validated through comprehensive evaluation using confusion matrices and receiver operating characteristic (ROC) curves. The InceptionV3 architecture exhibited the most robust performance, achieving an overall accuracy of 98.74%.

Performance Optimization

To optimize the performance of the InceptionV3 model, hyperparameter tuning was conducted. By systematically varying parameters such as batch size and epochs, the optimal configuration for training was determined. The results indicated that a batch size of 16 and 20 epochs yielded the best performance, balancing accuracy and training time.

A deep learning-based analysis of beehive sounds, using Fast Fourier Transform (FFT), revealed distinct acoustic patterns associated with various hive health conditions. The following are the quantitative and qualitative impacts of the employed research method on honey production:

Enhanced Honey Yield: Hives managed with acoustic monitoring produced significantly higher honey yields (12 kg on average) compared to conventionally managed hives (8-10 kg).

Improved Honey Quality:

Increased Invertase Activity: The honey from acoustically monitored hives exhibited higher invertase activity, resulting in a greater proportion of simple sugars and a sweeter taste.

Reduced Sucrose Content: Lower sucrose levels indicated more complete conversion of nectar into honey.

Favorable Fructose-to-Glucose Ratio: A lower fructose-to-glucose ratio contributed to a lower glycemic index, making the honey suitable for individuals with diabetes.

Elevated Proline Content: Higher proline levels indicated better quality and a stronger flavor.

Increased Diastase Activity: Greater diastase activity pointed to higher enzymatic activity and improved shelf life.

Lower Moisture Content: Reduced moisture content contributed to better honey quality and longer shelf life.

Conclusion

The CDLNN-based IoT system introduced in this study accurately detected the issues under investigation (with an accuracy of over 98%), reducing manual intervention in beehive management and positively impacting honey quality and quantity. Consequently, this system can be widely recommended for beehive management to enhance honey quality and quantity, as well as provide non-invasive and easy monitoring for beekeepers.

Author Contributions

Payam Faramarzi (P.F.); Conceptualization, Methodology, Data collection, Data processing, Software, Validation, Writing—original draft preparation. Reza Alimardani (R.A.); Supervision, Project administration, Technical Supervision, Writing, review and editing. Hekmat Rabbani (H.R.); Review and editing, Formal analysis, Technical Consultation. Hossein Mousazadeh (H.M.); Review and editing, Formal analysis, Technical Consultation.

All authors have read and agreed to the published version of the manuscript.

Data Availability Statement

For data and results access, please contact the corresponding author via the following email address or ResearchGate page:

Payam.faramarzi@ut.ac.ir

<https://www.researchgate.net/profile/Payam-Faramarzi-2>

Ethical considerations

The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Conflict of interest

The author declares no conflict of interest.

تحلیل صوتی کندوی زنبور عسل در زنبور داری دقیق مبتنی بر اینترنت اشیا (مطالعه موردی: بهبود سلامت و بهره‌وری کندو)

پیام فرامرزی^۱ | رضا علیمردانی^۲ | حکمت ربانی^۳ | حسین موسی زاده^۴

۱. گروه مهندسی ماشینهای کشاورزی-دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران، ایران، رایانامه: payam.faramarzi@ut.ac.ir

۲. گروه مهندسی ماشینهای کشاورزی-دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران، ایران، رایانامه: rmardani@ut.ac.ir

۳. گروه مهندسی مکانیک بیوسیستم-دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه رازی، ایران، رایانامه: hrabbani2010@gmail.com

۴. گروه مهندسی ماشینهای کشاورزی-دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران، ایران، رایانامه: hmousazade@ut.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	گرده افشانی برای تولید مثل جنسی بسیاری از محصولات، میوه‌ها و اکثر گیاهان وحشی مهم است. در میان گرده افشان‌های جانوری، گرده افشانی توسط زنبورهای منفرد و اجتماعی، نقش عمده‌ای را ایفا می‌کنند. علاوه بر نقش آنها در گرده افشانی گیاهان وحشی، زنبورهای عسل مدیریت شده از نظر اقتصادی با ارزش‌ترین گروه گرده افشان در گیاهان تک محصولی و میوه در سراسر جهان هستند. در این پژوهش، روشی نوین برای تشخیص بیماری‌ها و مشکلات کندوی زنبور عسل با استفاده از تحلیل صوتی و یادگیری عمیق ارائه شده است. ابتدا، با طراحی یک کندوی هوشمند و قرار دادن میکروفن در مکان بهینه، صداهای تولید شده توسط کلونی زنبور عسل ضبط شد. سپس، با تبدیل سیگنال‌های صوتی به اسپکتروگرام و استفاده از شبکه‌های عصبی کانولوشنی، الگوهای صوتی مرتبط با بیماری‌ها و مشکلات مختلف مانند نبود ملکه، آلودگی به کنه واروا و بیماری‌های فولبرد و نوزما شناسایی شد. نتایج نشان داد که این روش با دقت بیش از ۹۸ درصد قادر به تشخیص این مشکلات است. به عنوان مثال، این مدل توانست با دقت ۹۸/۶۲ درصد نبود ملکه، ۹۸/۵۹ درصد احتمال حضور کنه واروا، و ۹۸/۷۱ درصد احتمال بروز بیماری فولبرد را تشخیص دهد. در نهایت، با پیاده‌سازی اینترنت اشیا در سیستم مدیریت کندو، بهبود قابل توجهی در کمیت و کیفیت عسل تولید شده مشاهده شد. این پژوهش نشان می‌دهد که تحلیل صوتی و یادگیری عمیق می‌تواند به عنوان یک ابزار قدرتمند برای پایش سلامت کندوهای زنبور عسل و افزایش بهره‌وری در صنعت زنبورداری مورد استفاده قرار گیرد.
واژه‌های کلیدی: اینترنت اشیا، زنبورداری دقیق، بیماری‌های رایج کندو، بهره‌وری کندو، تحلیل صوتی.	
تاریخ دریافت: ۱۴۰۳/۷/۱۴	
تاریخ بازنگری: ۱۴۰۳/۱۱/۱۱	
تاریخ پذیرش: ۱۴۰۳/۱۱/۱۵	
تاریخ انتشار: پاییز ۱۴۰۳	

استاد: فرامرزی، پیام؛ علیمردانی، رضا؛ ربانی، حکمت؛ و موسی زاده، حسین (۱۴۰۳). تحلیل صوتی کندوی زنبور عسل در زنبور داری دقیق مبتنی بر اینترنت اشیا (مطالعه موردی: بهبود سلامت و بهره‌وری کندو). *مجله مهندسی بیوسیستم ایران ایران*، ۵۵ (۳)، ۴۹-۷۱.



<https://doi.org/10.22059/ijbse.2025.383049.665567>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijbse.2025.383049.665567>

مقدمه

گرده‌افشانی توسط حشرات، پرندگان و سایر عوامل، برای تولید مثل جنسی بسیاری از محصولات، میوه‌ها و اکثر گیاهان وحشی از اهمیت ویژه‌ای برخوردار است. در میان گرده‌افشان‌های جانوری، گرده‌افشانی حشرات، به ویژه زنبورهای منفرد و اجتماعی، نقش عمده‌ای ایفا می‌کند. علاوه بر نقش آن‌ها در گرده‌افشانی گیاهان وحشی، زنبورهای عسل مدیریت شده (به‌ویژه *Apis mellifera*) از نظر اقتصادی ارزشمندترین گروه گرده‌افشان در گیاهان تک‌محصولی و میوه در سراسر جهان هستند. زنبورهای عسل ارزان، کارآمد و در دسترس هستند و اغلب تنها راه حل کشاورزان برای اطمینان از گرده‌افشانی در زمانی که دیگر گونه‌های گرده‌افشان وجود ندارند یا کمیاب هستند، به شمار می‌روند. از این رو، زنبورهای عسل جزو مهم‌ترین دام‌های مولد محسوب می‌شوند. (Morse and Calderon, 2000) برای مثال، در ایالات متحده، ۱۰۰ درصد گرده‌افشانی بادام و ۹۰ درصد گرده‌افشانی سیب و زغال اخته توسط زنبورهای عسل انجام می‌شود. (Barrionuevo, 2007) ارزش این مسئله در سراسر جهان میلیاردها دلار است و کارشناسان بر این باورند که اگر زنبورها منقرض شوند، کشاورزی پایدار نخواهد بود. این مسئله به دلیل کاهش جدی تعداد زنبورهای عسل که تا حد زیادی به هجوم کندوها توسط کنه واروا (*Varroa Destructor*) و استفاده از آفت‌کش‌هایی مانند نتونیکوتینوئیدها نسبت داده شده، در بسیاری از کشورها در سال‌های اخیر به یک نگرانی جدی تبدیل شده است. (Morelle, 2013) تحقیقات زیادی به زبان رقص زنبورها (ارتعاش بال) (Frisch, 1993)، رفتار اجتماعی زنبورها و شناسایی مؤلفه عصبی هوش ازدحام (Seeley, 2010) در زنبورها اختصاص یافته است.

زنبورهای عسل توسط عوامل بیماری‌زای متعددی از جمله ویروس‌ها، باکتری‌ها، قارچ‌ها و انگل‌ها مورد حمله قرار می‌گیرند. این عوامل سلامت زنبورها را تهدید می‌کنند. با توجه به نقش حیاتی زنبورهای عسل در گرده‌افشانی محصولات، میوه‌ها و گل‌های وحشی، عوامل مؤثر بر سلامت زنبور عسل بر کشاورزی پایدار و سودآور و نیز بسیاری از اکوسیستم‌های غیرکشاورزی تأثیر می‌گذارند. پیش از ورود کنه انگلی واروا (*Varroa destructor*)، مهم‌ترین بیماری‌های اقتصادی زنبورهای عسل در سراسر جهان، بیماری‌های باکتریایی European Foulbrood (EFB) و American Foulbrood (AFB) بودند. (Genersch, 2010) کنه‌های واروا (*Varroa destructor*) مخرب‌ترین آفت جهانی زنبورهای عسل بالغ و نابالغ (*Apis mellifera* L.) به شمار می‌روند. این کنه‌ها با تغذیه از زنبورها، وزن بدن، طول عمر و ایمنی آن‌ها را در برابر عوامل بیماری‌زا کاهش می‌دهند. (Jong, 1982; Martin, 1994; Büchler, 2015; Roberts et al, 2017). (Roberts et al, 2017) کنه‌های ماده واروا از نظر فیزیکی، کنه‌های انگلی بزرگی (حدود ۱,۵ تا ۲,۰ میلی‌متر) هستند که با چسبیدن به زنبورهای کارگر و زنبورهای نر از طریق فوززی (جابه‌جایی توسط موجودات دیگر) پراکنده می‌شوند. کنه‌های واروا پیش از آنکه زنبورهای کارگر سلول‌ها را با موم پر کنند، به سمت سلول‌های نوزادی که توسط لاروهای بالغ زنبور عسل اشغال شده‌اند، حرکت می‌کنند و در نهایت از چربی بدن و همولف شفیره میزبان تغذیه می‌کنند. (McMenamin et al, 2015; Wallner, 1999) زنبورهای عسل به عنوان موجودات زنده در معرض تعدادی از آفات، عفونت‌ها، بیماری‌ها و اختلالات قرار دارند. شیوع بیماری‌ها یا انگل‌ها به سرعت رخ می‌دهد، زیرا زنبورهای عسل حشرات اجتماعی هستند که در کلنی‌ها زندگی می‌کنند. در حال حاضر، کاهش جمعیت زنبور عسل تهدیدی جدی برای امنیت کشاورزی و بهره‌وری جهانی به شمار می‌رود. (Gallai et al, 2009)

تشخیص به‌موقع و مدیریت این بیماری‌ها و آفات همواره چالش برانگیز بوده است. روش‌های سنتی مدیریت کندوها که مستلزم دخالت مکرر و بازرسی دستی است، ممکن است منجر به آسیب‌رسیدن به زنبورها و کاهش تولید عسل شود. همچنین، این روش‌ها صرفاً مبتنی بر تشخیص چشمی هستند و قادر به تشخیص زودهنگام و دقیق بیماری‌ها نیستند. از این رو، استفاده از تکنیک‌های هوشمند و داده‌محور می‌تواند راهکاری مؤثر برای پایش وضعیت سلامت کلنی‌های زنبور عسل باشد. تحلیل صوتی زنبورها در فضای ابری به عنوان یکی از این رویکردهای نوین، امکان ضبط و پردازش مستمر صداهای زنبورها را فراهم می‌کند. این امر می‌تواند منجر به تشخیص به‌موقع بیماری‌ها و آفات مهم کندوها و ارائه اخطار به زنبوردار شود، بدون نیاز به دخالت دستی و بازرسی فیزیکی کندوها. این رویکرد ضمن کاهش استرس و آسیب به زنبورها، به افزایش کمیت و کیفیت عسل تولیدی نیز کمک می‌کند.


تحقیقات بسیاری در زمینه آنالیز صوتی برای تشخیص بیماری‌ها و مشکلات رایج در کلنی‌های زنبور عسل انجام شده است که به مواردی از آن‌ها در ذیل اشاره می‌شود. سجروسکی و همکاران (۲۰۰۹) در تحقیقی برای تشخیص حضور ملکه در کندو از آنالیز صوتی استفاده کردند. (Cejrowski et al, 2009) کندور و همکاران در سال ۲۰۱۴ با استفاده از سیگنال‌های صوتی اقدام به نظارت از راه دور بر یک کندو کردند. (Qandour et al, 2014) اومان و همکاران در تحقیق خود شاخصی برای ارزیابی فعالیت‌های تغذیه‌ای زنبورهای

عسل با حسگر داپلر تعریف کردند (Aumann et al, 2017) نولاسکو و همکاران حالت‌های مختلف کندو را با استفاده از آنالیز صوتی شناسایی کردند (Nolasco et al, 2019) پولینیاک و همکاران در تحقیقی برای شناسایی سیگنال‌های صوتی کلنی زنبور عسل از الگوریتم تاب خوردگی زمان پویا استفاده کردند (Polyniak et al, 2019) آندری زگانک طبقه‌بندی آکوستیک فعالیت ازدحام زنبورها را برای یک سرویس مزرعه مبتنی بر اینترنت اشیا انجام داد (Zgank, 2020) شریف و همکارانش ویژگی‌های جدیدی برای طبقه‌بندی نمونه‌های صوتی کندو ارائه کردند (Sharif et al, 2020) کیم و همکاران با استفاده از الگوریتم‌های یادگیری ماشین و Grad-CAM اقدام به طبقه‌بندی صحنه آکوستیک و تجسم صداها در داخل کندو کردند (Kim et al, 2021) تحقیق جانتزکی و همکارانش منجر به شناسایی حضور نوعی گفتار در داده‌های صوتی به دست آمده از کندوها شد (Janetzky et al, 2021) یاو و همکارانش یک بررسی مبتنی بر صدای کندو برای تشخیص آلاینده‌های هوا با استفاده از یادگیری ماشین انجام دادند (Zhao et al, 2021)

هدف از انجام این پژوهش، طراحی و توسعه یک سامانه هوشمند مبتنی بر یادگیری عمیق است که قادر باشد رایج‌ترین و مخرب‌ترین بیماری‌ها و انگل‌های موجود در کندوی زنبور عسل را به صورت دقیق تشخیص دهد. این سامانه با استفاده از تحلیل صوتی زنبورها در فضای ابری عمل می‌کند، بدون نیاز به دخالت دست و بازکردن کندو. بدین ترتیب، امکان این فراهم می‌شود که زنبوردار در هر نقطه از جهان و با هر وسیله متصل به فضای ابری، به اطلاعات کندوی خود دسترسی داشته و در صورت بروز بیماری یا حضور انگل در کندو، بلافاصله مطلع شود. همچنین، میزان درگیری هر کندو به بیماری یا انگل به صورت طبقه‌بندی شده به همه وسایل تعریف شده در فضای ابری برای آن کندو منتقل می‌شود. این امر می‌تواند میزان دخالت دست در واریسی کندوها و در نتیجه، میزان تأثیرپذیری زنبورها و تولید آن‌ها از دخالت دست بشر را به حداقل برساند.

مواد و روش‌ها

برای این تحقیق ابتدا کندو و محل قرارگیری میکروفن در کندو در نرم افزار SOLIDWORKS 2022 طراحی و بهترین محل قرارگیری میکروفن جانمایی شد (شکل ۱).



شکل ۱- مدل سازی قاب حاوی میکروفن در کندو و محل قرارگیری آن در کندو

میکروفن در مرکز یک قاب قرار داده شده و آن قاب در وسط کندو (قاب شماره ۵ در کندوی ۹ قاب) نصب گردید، به طوری که نسبت به تمام جمعیت کندو در مرکز قرار گیرد. این روش قرارگیری میکروفن از تحقیق سجروفسکی و زیمانسکی (۲۰۲۱) الهام گرفته شده است. همچنین، یک مدار الکترونیکی طراحی شد تا صدای زنبورها را در کندو ضبط و ذخیره کند. چالش اصلی این دستگاه، عدم دسترسی یا ضعف اتصال اینترنت در زنبورستان‌ها بود که معمولاً در خارج از شهر قرار دارند. برای رفع این مشکل، یک مدار مبتنی بر GSM برای هر کندو در نظر گرفته شد تا با برقراری تماس تلفنی، که احتمالاً در تمام مناطق کشور آنتن‌دهی دارد، هر ساعت یک دقیقه با دستگاه تماس گرفته و آن یک دقیقه صدا ضبط و در یک فضای ذخیره‌سازی ذخیره شود. برای ساخت این مدار از برد GSM استفاده شد که امکان برقراری تماس را با بهره‌گیری از سیم کارت فراهم می‌کند. به طور خلاصه، صدای کندوها هر ساعت یک بار از طریق تماس



صوتی به یک پایگاه متصل به اینترنت ارسال شده و در آنجا با استفاده از کد پایتون، نمودار اسپکتروگرام فایل صوتی ترسیم و در فضای ابری گوگل کلود ذخیره می‌شود. این نمودار اسپکتروگرام با یک شبکه عصبی پیچشی مورد بررسی قرار گرفته و با استفاده از یک پایگاه داده شامل ۲۶۰۰۰ دقیقه صدای کندوها (۶ کندو به مدت ۱۸۰ روز) در شش حالت (کندوی سالم دارای ملکه، کندوی سالم بدون ملکه، کندوی مبتلا به واروآزیس، کندوی مبتلا به آکاریوپیس وودی، کندوی مبتلا به بیماری فول‌برد آمریکایی یا اروپایی و کندوی مبتلا به نزوما)، وجود هر یک از حالات در کندو با دقت بالا گزارش می‌شود. در ادامه، ابزارهای مورد استفاده برای پردازش صوتی و روش انجام کار به طور کامل توضیح داده شده است. لازم به ذکر است که صدای کندوهای بیمار با خرید کندوهای مبتلا از زنبوردارانی که قصد معدوم‌سازی آن‌ها را داشتند و نصب میکروفن در آن کندوهای بیمار در یک محل ایزوله ثبت شد تا قبل از معدوم‌سازی، از صدای کندوهای بیمار نمونه‌برداری شود. کندوهای مبتلا به واروآزیس و کنه تنفسی پس از ضبط صدا درمان شدند و کندوهای مبتلا به نزوما و فول‌برد پس از ضبط صدا طبق روال معمول معدوم شدند. ماژول GSM800L یک ماژول مخابراتی قدرتمند و کوچک است که از شبکه‌های GSM/GPRS پشتیبانی می‌کند. این ماژول امکانات و قابلیت‌های متعددی را برای طیف وسیعی از کاربردها ارائه می‌دهد (شکل ۲). برای ضبط صدا از میکروفن تولید شرکت JTR مدل CM-1000 PRO استفاده شد (شکل ۳). تصاویر مدارهای گیرنده و فرستنده طراحی شده در این تحقیق در شکل‌های ۴ آمده است.



شکل ۲- شکل ظاهری ماژول GSM800L



شکل ۳ - شکل ظاهری میکرفن JTR مدل CM-1000 PRO


ب

الف

شکل ۴- الف- ماژول GSM (برقراری تماس و ارسال صدا) مدار داخلی -ب- ماژول GSM (دریافت تماس و ضبط صدا)- مدار داخلی

ارتباط بین فرستنده (شکل ۴ الف) و گیرنده (شکل ۴ ب) هر ۶۰ دقیقه یک بار برقرار می‌شود و به مدت یک دقیقه ادامه می‌یابد. بدین ترتیب، در هر ۲۴ ساعت، یک پوشه حاوی فایل‌های صوتی با نام تاریخ همان روز ایجاد می‌شود که ۲۴ فایل صوتی یک دقیقه‌ای مربوط به آن روز را در خود جای می‌دهد. دستگاه‌های گیرنده همگی با استفاده از کابل LAN به یک رایانه متصل هستند تا اطلاعات ذخیره‌شده در فضای microSD را در فضای داخلی رایانه نیز ذخیره کنند. رایانه مذکور به اینترنت متصل است و داده‌های صوتی اولیه را در خود ذخیره می‌کند و به‌طور هم‌زمان، آن‌ها را با استفاده از یک کد پایتون در گوگل درایو بارگذاری می‌کند. همچنین، نمودار اسپکتروگرام این فایل‌های صوتی را پس از حذف نویز، رسم کرده و در گوگل درایو ذخیره می‌کند. شایان ذکر است که نمودار اسپکتروگرام فایل‌های صوتی با استفاده از تبدیل فوریه سریع (FFT) رسم می‌شود. با بهره‌گیری از فضای ابری گوگل، به‌ویژه گوگل درایو برای ذخیره‌سازی فایل‌ها و گوگل کولب برای پردازش داده‌ها در پایتون، امکان پردازش سریع داده‌ها در فضای ابری و با استفاده از پردازنده‌های قدرتمند گوگل فراهم می‌شود. همچنین، ذخیره نتایج در گوگل کلود (گوگل درایو) برای تمامی کاربرانی که به این شبکه ابری دسترسی دارند، قابل مشاهده است. علاوه بر این، در صورت بروز هرگونه اشکال، اعم از قطعی سامانه یا تشخیص بیماری‌های تعریف‌شده، یک پیام هشدار برای کلیه کاربران متصل به این شبکه ابری ارسال می‌شود. برای تحلیل داده‌ها در این تحقیق، از شبکه عصبی پیچشی و پروتکل SFTP برای انتقال داده‌ها در رایانش ابری استفاده می‌شود. جمع‌آوری داده‌ها بدین صورت است که ماژول‌های GSM صدا را از کدوها جمع‌آوری می‌کنند و داده‌ها از طریق LAN به رایانه ارسال می‌شوند. رایانه نیز داده‌ها را با استفاده از تبدیل فوریه سریع (FFT) پردازش کرده و پس از حذف نویز، نمودار اسپکتروگرام آن‌ها را رسم می‌کند تا برای پردازش نهایی در اختیار فضای ابری قرار دهد.

معماری اینترنت اشیا

در نهایت PC با استفاده از الگوریتم SFTP به گوگل درایو ارسال می‌کند. داده‌ها در فضای ابری مورد پیش پردازش‌هایی مانند حذف نویز و تغییر اندازه تصاویر اسپکتروگرام قرار می‌گیرد. داده‌ها برای آموزش مدل CNN استفاده می‌شوند. این مرحله با ۲۶۰۰۰ هزار دقیقه صدای زنبور برای آموزش شبکه عصبی CNN انجام شد. شبکه عصبی متشکل از داده‌های الگو در گوگل درایو ذخیره می‌شوند و داده‌های مورد تحلیل برای پردازش به گوگل کولب ارسال می‌شوند. CNN صداها را طبقه بندی می‌کند. در این مرحله داده‌ها توسط شبکه عصبی ای که آموزش داده شده، مورد بررسی قرار گرفته و با دقت بسیار بالایی (کمترین دقت گزارش شده % ۹۸/۶۱) تشخیص داده می‌شوند. نتایج طبقه بندی در گوگل کولب مجدداً در گوگل درایو ذخیره می‌شوند تا برای افراد دارای دسترسی به فضای ابری قابل مشاهده باشد. در نهایت در صورت تشخیص بیماری، نتایج به برای کاربرانی که به شبکه عصبی ابری دسترسی دارند ارسال می‌شود. ماژول‌های گیرنده GSM از طریق کابل LAN به رایانه متصل می‌شوند. رایانه وظیفه دریافت داده‌های صوتی از ماژول‌های گیرنده، ذخیره‌سازی اولیه آنها و سپس ارسال به گوگل درایو را بر عهده دارد. ماشین مجازی مورد استفاده در این پژوهش از نوع TPU^{v4}-32 pod، حافظه رم مورد استفاده در تحقیق ۳۲ گیگابایت و فضای ذخیره‌سازی ۱۵ گیگابایت در نظر گرفته شد. داده‌های پیش پردازش‌شده از گوگل درایو به گوگل کولب بارگذاری می‌شوند. کدهای مربوط به آموزش و ارزیابی شبکه عصبی در گوگل کولب اجرا می‌شوند. در این

سیستم، شبکه ارتباطی بین فرستنده و گیرنده مبتنی بر GSM بوده و برای انتقال داده‌ها به فضای ابری از پروتکل‌های ارتباطی استاندارد اینترنت استفاده شده است PC. از سیستم‌عامل ویندوز ۱۰ استفاده کرده و کدهای پردازشی چه در PC و چه در محیط گوگل کولب به زبان پایتون نوشته شده است. برای دسترسی به داده‌ها و مدیریت آن‌ها، از API های گوگل درایو و گوگل کولب استفاده می‌شود. برای این منظور، از مدل‌های پیش‌ساخته‌ای همچون DenseNet121، EfficientNetB0 و InceptionV3 استفاده شده است. این مدل‌ها بر روی پلتفرم گوگل کولب با استفاده از داده‌های آموزشی گسترده آموزش دیده و توانایی بالایی در تشخیص بیماری‌های مختلف زنبور عسل نشان داده‌اند. نتایج حاصل از این مدل‌ها در یک پایگاه داده MongoDB ذخیره شده و از طریق یک سرور وب Apache با استفاده از فریمورک Django در دسترس کاربران قرار می‌گیرد. فریمورک Django امکان ایجاد یک رابط کاربری وب کاربرپسند را فراهم کرده و به سادگی با پایگاه داده MongoDB در گوگل کلود ارتباط برقرار می‌کند.


در شکل ۴ الف، GSM نشان دهنده ماژول‌های GSM فرستنده و مدار طراحی شده برای آنهاست که وظیفه برقراری تماس با گیرنده GSM را بر عهده دارد. شکل ۴ ب، GSM نشان دهنده ماژول‌های GSM گیرنده و مدار طراحی شده برای آنهاست که برای ضبط صدای ارسالی از کندوها به گیرنده و ذخیره سازی آنها استفاده می‌شوند PC. نشان دهنده رایانه شخصی است که به عنوان واسط بین ماژول‌های GSM و Google Cloud عمل می‌کند. LAN نشان دهنده کابل شبکه محلی است که PC و ماژول‌های دریافت GSM را به هم متصل می‌کند Cloud Computing. نشان دهنده Google Cloud Platform است که برای ذخیره و پردازش داده‌ها استفاده می‌شود. در نهایت داده‌های صوتی در گوگل درایو ذخیره شده و در گوگل کولب با سامانه یادگیری عمیق مبتنی بر شبکه عصبی کانولوشن مورد پردازش قرار می‌گیرد. در صورت بروز هر یک از مشکلات تعریف شده (فقدان ملکه، احتمال حضور کله وارو در کندو، احتمال حضور کله تنفسی در کندو، احتمال بروز بیماری فولبرد در کندو و احتمال بروز بیماری نزوما در کندو) یک پیام حاوی فایل صوتی که بیماری در آن تشخیص داده شده، نمودار اسپکتروگرام فایل صوتی به صورت پردازش شده با درج درصد دقت تشخیص و یک متن با مضمون شماره کندوی دارای مشکل و درصد احتمال بروز مشکل برای زنبوردار در تلگرام ارسال می‌گردد. برای تحلیل داده‌های صوتی در هر بخش از ۳ الگوریتم شبکه عصبی مبتنی بر یادگیری عمیق DenseNet121، EfficientNetB0 و InceptionV3 استفاده شد.

DenseNET121 یک مدل یادگیری عمیق است که از حافظه و قدرت پردازش کمتری نسبت به مدل‌های دیگر استفاده می‌کند. این سیستم قادر است که در نظارت شرایط ترافیک، سیستم حمل و نقل هوشمند و غیره مورد استفاده قرار گیرد. یکی از مزایای اصلی شبکه عصبی DenseNet121، توانایی آن در مقابله با مشکل محو شدن گرادیان است. این ویژگی به مدل اجازه می‌دهد تا با کارایی بیشتر آموزش ببیند، از ویژگی‌های استخراج شده در لایه‌های قبلی به طور مؤثر استفاده کند و در مقایسه با برخی دیگر از شبکه‌های عصبی عمیق، به پارامترهای کمتری نیاز داشته باشد (Albelwi, 2022). مدل Inception v3 برای تشخیص تصاویر استفاده می‌شود، این مدل نقطه اوج ایده‌های توسعه یافته محققان در طول سال‌های اخیر می‌باشد Inception v3. از یک شبکه عصبی عمیق ۴۲ لایه تشکیل شده است که از کانولوشن‌ها، لایه‌های maxpooling، میانگین ادغام، حذف‌ها و لایه‌های کاملاً متصل تشکیل شده است (Demir et al, EfficientNet (2019). EfficientNet معماری از شبکه عصبی کانولوشن (CNN) است که برای بهبود دقت از روش مقیاس بندی ترکیبی استفاده می‌کند، به صورتی که با استفاده از ضریب ترکیبی، مقیاس بندی را در تمام ابعاد، عمق و وضوح به طور یکنواخت انجام می‌دهد. EfficientNet بخشی از مجموعه‌ای از مدل‌های EfficientNet است که مدل‌های EfficientNetB0 از EfficientNetB0 تا B7 است. معماری EfficientNetB0 مبتنی بر MobileNetV2 است (Pramudhita et al, 2023).

نتایج

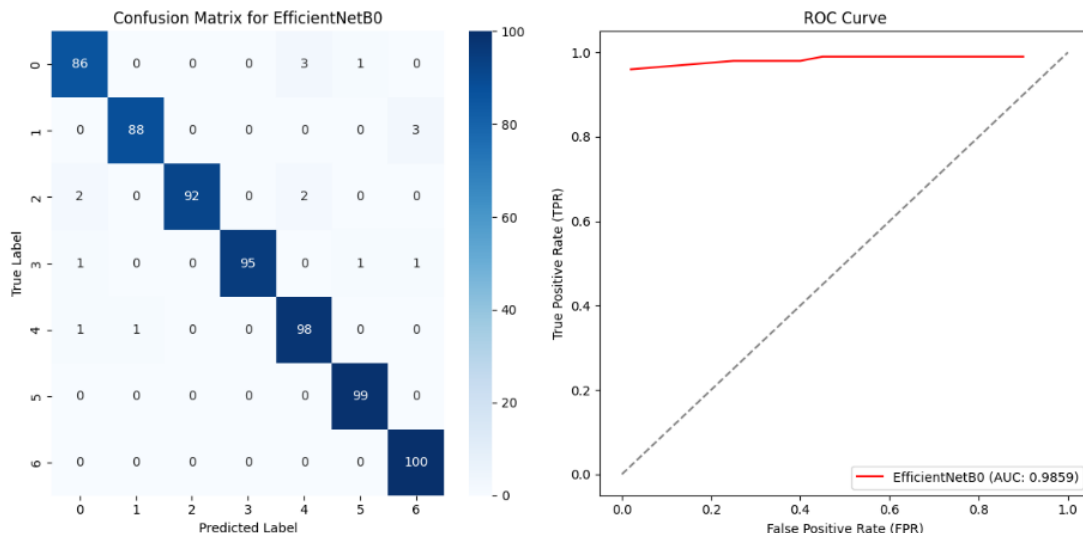
در تحلیل صوتی کندوی زنبور عسل با استفاده از تبدیل فوریه سریع نمودار اسپکتروگرام فایل‌های صوتی یک دقیقه‌ای ضبط شده از کندوی مورد بررسی ترسیم شد و سپس با استفاده از ویژگی‌های فرکانسی آنها به تفسیر وضعیت کندوی زنبور عسل می‌پردازیم. محدوده فرکانسی نشان داده شده در نمودار اسپکتروگرام بین صفر و ۸۱۹۲ هرتز متغیر است. نکته ی شایان ذکر اینکه در این تحقیق، تحلیل نمودارهای اسپکتروگرام توسط یک شبکه ی یادگیری عمیق کانولوشنی انجام شده است. برای پیدا کردن بهترین شبکه عصبی کانولوشنی مبتنی بر یادگیری عمیق از بین سه شبکه ی مطرح شده اقدام به یافتن ماتریس آشفتگی و منحنی عملکرد تشخیص (ROC) برای هر یک از شبکه‌ها در تحلیل تصاویر شد.

ماتریس آشفتگی ارائه شده در تصویر ۵ برای مدل DenseNet121، عملکرد مناسب این مدل در طبقه‌بندی داده‌ها را نشان می‌دهد. مقادیر بالای قطر اصلی ماتریس حاکی از آن است که اکثر نمونه‌ها به درستی به کلاس مربوط به خود تخصیص داده شده‌اند. با این حال، وجود مقادیر غیر صفر در سلول‌های خارج از قطر اصلی نشان‌دهنده برخی خطاهای طبقه‌بندی است که دلالت بر اشتباه در تخصیص برخی نمونه‌ها به کلاس‌های دیگر دارد.



شکل ۵- منحنی ROC و ماتریس آشفتگی ارائه شده برای مدل DenseNet121 در تحلیل صوتی

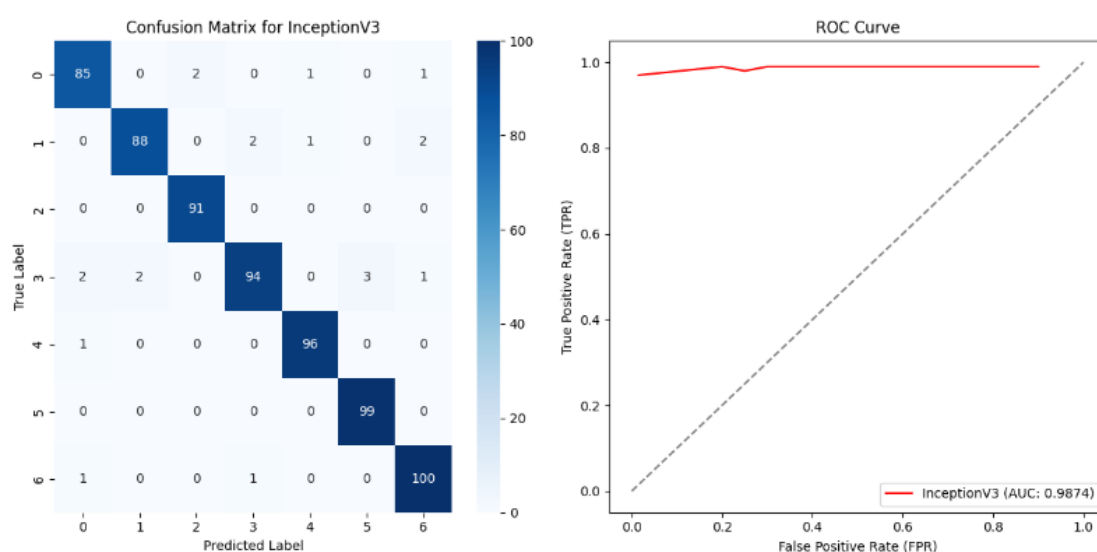
منحنی ROC ارائه شده نیز بیانگر توانایی خوب مدل در تشخیص نمونه‌های مثبت از نمونه‌های منفی است. مساحت زیر منحنی ROC برابر با 0.9810 محاسبه شده است که حاکی از عملکرد بسیار خوب مدل بوده و از دقت کلی مدل DenseNet121 که برابر با 99.1% محاسبه شده است، می‌توان نتیجه گرفت که این مدل به طور کلی عملکرد بسیار قابل قبولی دارد. به طور کلی، نتایج حاصل از ماتریس آشفتگی و منحنی ROC نشان می‌دهد که مدل DenseNet121 توانسته است با دقت بالایی داده‌ها را طبقه‌بندی کند. شکل ۶ ماتریس آشفتگی و منحنی ROC برای مدل EfficientNetB0 را نشان می‌دهد. ماتریس آشفتگی ارائه شده عملکرد بسیار خوب این مدل در طبقه‌بندی داده‌ها را نشان می‌دهد. مقادیر بالای قطر اصلی ماتریس حاکی از آن است که اکثر نمونه‌ها به درستی به کلاس مربوط به خود تخصیص داده شده‌اند. با این حال، وجود مقادیر غیر صفر در سلول‌های خارج از قطر اصلی نشان‌دهنده برخی خطاهای طبقه‌بندی است که دلالت بر اشتباه در تخصیص برخی نمونه‌ها به کلاس‌های دیگر دارد.



شکل ۶- منحنی ROC و ماتریس آشفتگی ارائه شده برای مدل EfficientNetB0 در تحلیل صوتی

منحنی ROC ارائه شده نیز بیانگر توانایی بسیار خوب مدل در تشخیص نمونه‌های مثبت از نمونه‌های منفی است. مساحت زیر منحنی (AUC) ROC برابر با ۰/۹۸۵۹ محاسبه شده است که حاکی از عملکرد بسیار خوب مدل بوده و از دقت کلی مدل EfficientNetB0 که برابر با ۹۸/۵۹٪ محاسبه شده است، می‌توان نتیجه گرفت که این مدل به طور کلی عملکرد بسیار قابل قبولی دارد. به طور کلی، نتایج حاصل از ماتریس آشفتگی و منحنی ROC نشان می‌دهد که مدل EfficientNetB0 توانسته است با دقت بسیار بالایی داده‌ها را طبقه‌بندی کند. با این حال، برای بهبود بیشتر عملکرد مدل، می‌توان اقداماتی نظیر جمع‌آوری داده‌های بیشتر، تنظیم پارامترهای مدل یا استفاده از تکنیک‌های افزایش یادگیری را انجام داد.

شکل ۷ ماتریس آشفتگی ارائه شده برای مدل InceptionV3 را نشان می‌دهد. این تصویر عملکرد بسیار خوب این مدل در طبقه‌بندی داده‌ها را نشان می‌دهد. مقادیر بالای قطر اصلی ماتریس حاکی از آن است که اکثر نمونه‌ها به درستی به کلاس مربوط به خود تخصیص داده شده‌اند. با این حال، وجود مقادیر غیر صفر در سلول‌های خارج از قطر اصلی نشان‌دهنده برخی خطاهای طبقه‌بندی است که دلالت بر اشتباه در تخصیص برخی نمونه‌ها به کلاس‌های دیگر دارد.



شکل ۷- منحنی ROC و ماتریس آشفتگی ارائه شده برای مدل InceptionV3 در تحلیل صوتی


منحنی ROC ارائه شده نیز بیانگر توانایی بسیار خوب مدل در تشخیص نمونه‌های مثبت از نمونه‌های منفی است. مساحت زیر منحنی (AUC) ROC برابر با ۰/۹۸۷۴ محاسبه شده است که حاکی از عملکرد بسیار خوب مدل بوده و از دقت کلی مدل InceptionV3 که برابر با ۹۸/۷۴٪ محاسبه شده است، می‌توان نتیجه گرفت که این مدل به طور کلی عملکرد بسیار قابل قبولی دارد. به طور کلی، نتایج حاصل از ماتریس آشفتگی و منحنی ROC نشان می‌دهد که مدل InceptionV3 توانسته است با دقت بسیار بالایی داده‌ها را طبقه‌بندی کند. با این حال، برای بهبود بیشتر عملکرد مدل، می‌توان اقداماتی نظیر جمع‌آوری داده‌های بیشتر، تنظیم پارامترهای مدل یا استفاده از تکنیک‌های افزایش یادگیری را انجام داد.

با بررسی نتایج حاصل از ماتریس‌های آشفتگی و منحنی‌های ROC برای مدل‌های DenseNet121، EfficientNetB0 و InceptionV3، عملکرد بسیار خوب این مدل‌ها در طبقه‌بندی داده‌ها مشاهده شده است. مقادیر بالای قطر اصلی ماتریس‌های آشفتگی و مساحت زیر منحنی‌های (AUC) ROC نزدیک به ۱، بیانگر آن است که اکثر نمونه‌ها به درستی به کلاس مربوطه خود تخصیص داده شده‌اند. هر سه مدل توانسته‌اند با دقت بسیار بالایی داده‌ها را طبقه‌بندی کنند. با این حال، بین این مدل‌ها تفاوت‌های جزئی مشاهده می‌شود. مدل EfficientNetB0 و InceptionV3 عملکردی اندکی بهتر از مدل DenseNet121 نشان داده‌اند. این امر می‌تواند به دلیل تفاوت در معماری این مدل‌ها و توانایی آن‌ها در استخراج ویژگی‌های پیچیده‌تر باشد. برای ادامه‌ی آزمایشات این پژوهش از شبکه‌ی کانولوشنی مبتنی بر یادگیری عمیق InceptionV3 استفاده شد.


تصویر ۸ روند همگرایی بین دقت و خطای مدل شبکه‌های عصبی مبتنی بر یادگیری عمیق مورد استفاده در این تحقیق

همگرایی در این شبکه ها پس از ۱۰۱۰ تکرار آموزش مدل، نرخ خطا و دقت مدل همگرا شدند. دقت مدل های یادگیری عمیق برای آموزش از در این تحقیق در همان تکرار های اولیه (برای DenseNet121 در تکرار ۱۷ام، برای EfficientNetB0 در تکرار ۲۲ ام و برای InceptionV3 در تکرار ۱۵ ام) به بیشینه مقدار خود رسید و این همگرایی نیز بلافاصله برای داده های ارزیابی مشاهده شد. خطای مدل نیز به همین ترتیب به صفر همگرا شد. به طور کلی، نتایج به دست آمده از شبکه های عصبی مبتنی بر یادگیری عمیق مورد استفاده در این تحقیق نشان داد که دقت آموزش و آزمایش این مدل ها برای طبقه بندی صوتی از دقت بالایی برخوردارند.


DenseNet121 - acoustic



EfficientNetB0 - acoustic



InceptionV3 - acoustic



شکل ۸- نمودار های همگرایی سه شبکه ی مورد استفاده در این تحقیق (InceptionV3 و EfficientNetB0 ، DenseNet121)

در ادامه ی این پژوهش شبکه ی کانولوشنی مبتنی بر یادگیری عمیق InceptionV3 با ۶ حالت تغییر مطابق جدول زیر استفاده شد و دقت شبکه ی یادگیری عمیق برای هر ۶ حالت مورد بررسی قرار گرفت.

جدول ۱- حالت‌های مورد بررسی شبکه‌ی یادگیری عمیق مورد استفاده در این تحقیق برای یافتن بهترین شیوه ی آموزش

تعداد داده‌های آموزش	اندازه دسته	تقسیم اعتبارسنجی	نرخ یادگیری	تعداد دوره	دقت آموزش	زمان آموزش (sec)
۱۰۱۰	۸	۳۶۵۲۶	۰/۰۱	۱۰	۸۴/۱۳	۲۹۲
۱۰۱۰	۸	۳۶۵۲۶	۰/۰۱	۲۰	۸۵/۱۷	۳۰۷
۱۰۱۰	۸	۳۶۵۲۶	۰/۰۱	۳۰	۸۴/۹۱	۳۱۸
۱۰۱۰	۱۶	۳۶۵۲۶	۰/۰۱	۱۰	۹۵/۳۲	۳۳۱
۱۰۱۰	۱۶	۳۶۵۲۶	۰/۰۱	۲۰	۹۸/۵۹	۳۹۲
۱۰۱۰	۱۶	۳۶۵۲۶	۰/۰۱	۳۰	۹۸/۴۷	۵۱۱
۱۰۱۰	۳۲	۳۶۵۲۶	۰/۰۱	۱۰	۹۸/۵۴	۵۳۹
۱۰۱۰	۳۲	۳۶۵۲۶	۰/۰۱	۲۰	۹۸/۶۱	۶۱۱
۱۰۱۰	۳۲	۳۶۵۲۶	۰/۰۱	۳۰	۹۸/۳۸	۶۹۴

```

modeltoh5.py
20 for filename in os.listdir(class_dir):
21     image_path = os.path.join(class_dir, filename)
22     image = cv2.imread(image_path)
23     image = cv2.resize(image, (224, 224)) # تغییر اندازه تصویر به اندازه مورد نیاز
24     X_train.append(image)
25     y_train.append(class_label)
26
27 # تبدیل آرایه‌ها به فرمت NumPy
28 X_train = np.array(X_train)
29 y_train = np.array(y_train)
30
31 # تعریف مدل
32 model = Sequential()
33 model.add(Conv2D(filters=32, kernel_size=(3, 3), activation='relu', input_shape=(224, 224, 3)))
34 model.add(MaxPooling2D(pool_size=(2, 2)))
35 model.add(Conv2D(filters=64, kernel_size=(3, 3), activation='relu'))
36 model.add(MaxPooling2D(pool_size=(2, 2)))
37 model.add(Flatten())
38 model.add(Dense(units=128, activation='relu'))
39 model.add(Dense(num_classes, activation='softmax'))
40
41 # تنظیمات بهینه‌سازی
42 optimizer = Adam(learning_rate=0.001)
43 model.compile(loss='categorical_crossentropy', optimizer=optimizer, metrics=['accuracy'])
44
45 # تبدیل یک‌گرمایی به فرمت one-hot encoding
46 y_train = np.eye(num_classes)[y_train]
47
48 # آموزش مدل
49 model.fit(X_train, y_train, batch_size=16, epochs=20, validation_split=0.01)
    
```

الف

```

172 - [====] 440/440s 391ms/step - loss: 0.0503 - accuracy: 0.9497 - val_loss: 0.0576 - val_accuracy: 0.9861
Epoch 13/20
161 - [====] 440/440s 366ms/step - loss: 0.0459 - accuracy: 0.9541 - val_loss: 0.0296 - val_accuracy: 0.9861
Epoch 14/20
160 - [====] 440/440s 364ms/step - loss: 0.0427 - accuracy: 0.9573 - val_loss: 0.0441 - val_accuracy: 0.9861
Epoch 15/20
160 - [====] 440/440s 364ms/step - loss: 0.0203 - accuracy: 0.9797 - val_loss: 0.0419 - val_accuracy: 0.9861
Epoch 16/20
159 - [====] 440/440s 361ms/step - loss: 0.0179 - accuracy: 0.9821 - val_loss: 0.0515 - val_accuracy: 0.9861
Epoch 17/20
159 - [====] 440/440s 362ms/step - loss: 0.0166 - accuracy: 0.9834 - val_loss: 0.0426 - val_accuracy: 0.9861
Epoch 18/20
177 - [====] 440/440s 402ms/step - loss: 0.0159 - accuracy: 0.9842 - val_loss: 0.0729 - val_accuracy: 0.9861
Epoch 19/20
181 - [====] 440/440s 411ms/step - loss: 0.0146 - accuracy: 0.9854 - val_loss: 0.0288 - val_accuracy: 0.9861
Epoch 20/20
265 - [====] 440/440s 604ms/step - loss: 0.0141 - accuracy: 0.9859 - val_loss: 0.0844 - val_accuracy: 0.9861
    
```


ب

شکل ۹- الف- معماری شبکه‌ی یادگیری عمیق ب- دقت نهایی شبکه


همانطور که از جدول (۱) مشخص است دو متغیر اندازه دسته و تعداد دوره برای آموزش شبکه‌ی عصبی کانولوشنالی پشتیبان این شبکه‌ی یادگیری عمیق مورد تغییر قرار گرفت و دقت و مدت زمان آموزش شبکه در هر ۹ حالت محاسبه شد. مشاهده شد که در معماری در نظر گرفته شده برای این شبکه‌ی یادگیری عمیق (شبکه ی عصبی کانولوشنی) بیشترین دقت در اندازه دسته برابر با ۱۶ رخ می‌دهد. همچنین مشاهده شد که اگر چه برای تغییر از تعداد دوره برابر با ۲۰ به تعداد دوره برابر با ۳۰ اختلاف میزان دقت به حد قابل قبولی

افزایش پیدا نکرده اما مدت زمان آموزش شبکه به مقدار چشم گیری تغییر کرد. مشخص شد که با افزایش اندازه دسته به ۳۲ زمان آموزش شبکه‌ی یادگیری عمیق افزایش چشمگیری داشت و دقت کاهش پیدا کرد. پس می‌توان نتیجه گرفت که حالت بهینه‌ی آموزش برای این شبکه‌ی یادگیری عمیق با اندازه دسته برابر با ۱۶ و تعداد دوره برابر با ۲۰ رخ می‌دهد. از این رو برای تحلیل داده‌های صوتی از این حالت بهره گرفته شد.

در پژوهش حاضر، از شبکه عصبی کانولوشنی (CNN) برای طبقه‌بندی حالات مختلف کندو (سالم با ملکه، فاقد ملکه، آلوده به کنه واروآ، کنه تنفسی و بیماری نوزما) بر اساس تحلیل صوتی بهره گرفته شد. سیگنال‌های صوتی کندو پس از تبدیل فوریه سریع (FFT) به صورت اسپکتروگرام نمایش داده شدند و به عنوان ورودی شبکه CNN قرار گرفتند. معماری شبکه از لایه‌های کانولوشنی برای استخراج ویژگی‌های طیفی، لایه‌های کاهش ابعاد (pooling) برای کاهش پیچیدگی محاسباتی و لایه‌های پر متصل برای یادگیری الگوهای پیچیده تشکیل شده است. لایه‌های کانولوشنی با اعمال فیلترهای مختلف بر روی اسپکتروگرام‌ها، ویژگی‌های محلی مانند فرکانس‌های غالب و الگوهای زمانی را استخراج می‌کنند. در نهایت، لایه‌های کاهش ابعاد با حفظ ویژگی‌های اصلی، ابعاد داده را کاهش داده و از بروز پدیده تطبیق بیش از حد جلوگیری می‌کنند. در نهایت، لایه‌های پر متصل با ترکیب ویژگی‌های استخراج شده، احتمال تعلق هر نمونه به هر یک از کلاس‌های کندو را محاسبه می‌کنند. شبکه با استفاده از الگوریتم پس انتشار آموزش داده شد. در فرآیند آموزش، شبکه به مجموعه‌ای از اسپکتروگرام‌های FFT صدای زنبورها و برجسب‌های مربوط به آن‌ها (کندوی سالم با ملکه یا بدون ملکه) داده می‌شد. شبکه با به‌روزرسانی مقادیر وزن در بین لایه‌ها، وظیفه‌ی یادگیری روابط بین ویژگی‌های فرکانسی و کلاس‌های مورد نظر را بر عهده داشت. پس از آموزش، شبکه می‌توانست اسپکتروگرام‌های FFT صدای زنبورهای جدید را بدون نیاز به برجسب‌گذاری دستی، به عنوان کندوی سالم با ملکه یا بدون ملکه و ... دسته‌بندی کند. تفسیر نمودارهای اسپکتروگرام صدای زنبور عسل در حالت‌های مختلف به شرح زیر می‌باشند. تحلیل صدا با استفاده از DL مبتنی بر FFT در تشخیص کندوی سالم دارای ملکه : بررسی اسپکتروگرام صدای زنبورهای کندوی سالم (شکل ۱۰ الف) نشان داده شده که فرکانس غالب در این حالت در محدوده ۰ تا ۲۰۰۰ هرتز قرار داشت. این امر، تمرکز صدا بر فرکانس‌های پایین را نشان می‌دهد که به دلیل استفاده معمول زنبورها از این فرکانس‌ها برای برقراری ارتباط و انتقال اطلاعات، به خصوص در مسافت‌های دور و با وجود موانع، است و نشان دهنده‌ی یک حالت بدون مشکل و پایدار در کندوی مورد بررسی می‌باشد. سامانه هوشمند یادگیری عمیق طراحی شده برای پروژه این مساله را با دقت بالایی (۹۸/۷۴٪) گزارش کرده است. (شکل ۱۰ ب)



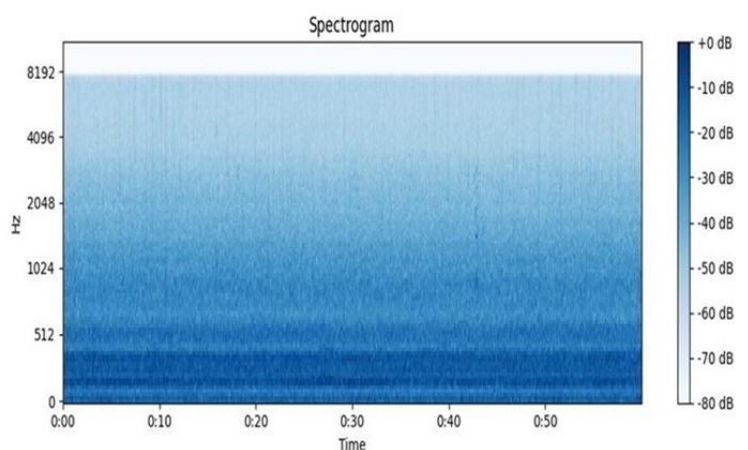
الف



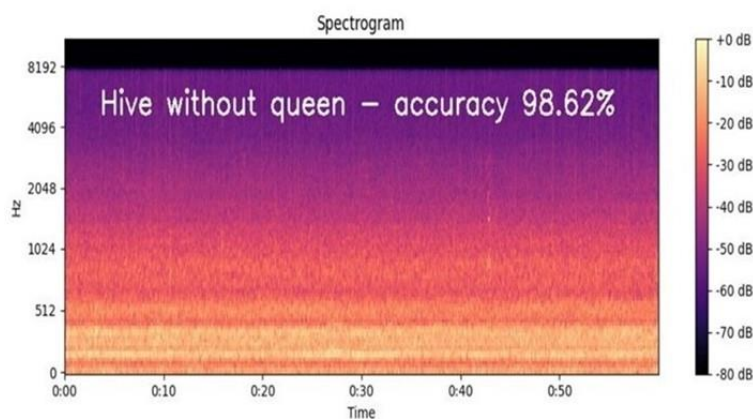
ب

شکل ۱۰- اسپکتروگرام کندوی سالم دارای ملکه الف پردازش نشده ب پردازش شده

بررسی اسپکتروگرام صدای زنبورهای کندوی بدون ملکه نسبت به اسپکتروگرام صدای زنبورهای کندوی سالم، چندین جنبه تفاوت آشکار شد. در اسپکتروگرام کندوی بدون ملکه، فرکانس غالب در محدوده ۲۰۰۰ تا ۴۰۰۰ هرتز قرار داشت (شکل ۱۱ الف). مطالعه حاضر نشان داده است که فقدان ملکه در کندو منجر به تغییرات قابل توجهی در الگوی صوتی زنبورها می‌شود. افزایش نسبی فرکانس صدا و کاهش طول موج آن در کندوی بدون ملکه مشاهده شده است. همچنین، شدت صدا در فرکانس‌های پایین‌تر کاهش یافته و نویز کلی اسپکتروگرام افزایش یافته است. این تغییرات به دلیل افزایش اضطراب، آشفتگی و تغییرات رفتاری زنبورها در نبود ملکه، مانند افزایش فعالیت و تولید صداهای بیشتر، تفسیر شده است. نتایج این مطالعه حاکی از آن است که تحلیل صوتی می‌تواند به عنوان یک ابزار مفید برای ارزیابی وضعیت کندو و تشخیص زود هنگام مشکلات مرتبط با فقدان ملکه مورد استفاده قرار گیرد. سامانه هوشمند یادگیری عمیق طراحی شده برای این پروژه نبود ملکه در کندو را هم با دقت بالایی (۹۸/۶۲٪) گزارش کرده است. (شکل ۱۱ ب)



الف

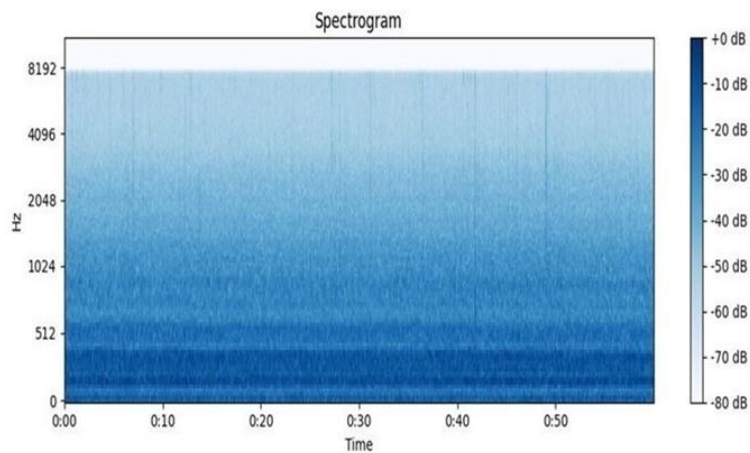


ب

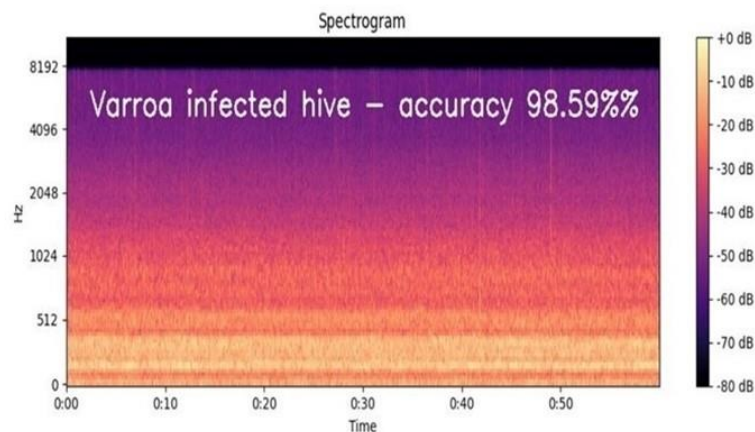
شکل ۱۱- اسپکتروگرام کندوی سالم فاقد ملکه الف پردازش نشده ب پردازش شده

اسپکتروگرام کندوی آلوده به کنه ی واروا (مبتلا به واروازیس)، فرکانس غالب در محدوده ۱۰۰۰ تا ۳۰۰۰ هرتز قرار داشت (شکل ۱۲ الف). بررسی اسپکتروگرام صدای زنبورهای عسل نشان داد که آلودگی به کنه واروا تغییرات قابل توجهی در الگوی صوتی کندو ایجاد می‌کند. افزایش فرکانس صدا و کاهش شدت در فرکانس‌های پایین‌تر در کندوی آلوده مشاهده شده است. به نظر می‌رسد این تغییرات به دلیل افزایش فعالیت زنبورها برای مقابله با آفات و ارتباطات پیچیده‌تر آن‌ها بود، چراکه کنه واروا باعث ضعف و تحریک زنبورها می‌شود. همچنین، افزایش نویز در کندوی آلوده به عنوان نشانه‌ای از آشفتگی و استرس در کلنی در نظر گرفته شده است. نتایج این مطالعه با مطالعات قبلی بر روی کندوهای بدون ملکه مقایسه شده است و شباهت‌هایی در تغییرات الگوی صوتی مشاهده شده است. با این حال،

تفاوت‌هایی نیز در فرکانس غالب صدا در دو نوع کندو مشاهده شده است. سامانه هوشمند یادگیری عمیق طراحی شده برای این پروژه حضور کنه ی واروآ در کندو را هم با دقت بالایی (۹۸/۵۹٪) گزارش کرده است (شکل ۱۲ ب).



الف



ب

شکل ۱۲- اسپکتروگرام کندوی مبتلا به وروآزیس الف پردازش نشده ب پردازش شده

در تحلیل صدا با استفاده از یادگیری عمیق مبتنی بر تبدیل فوریه سریع (FFT) در تشخیص کندوی مبتلا به آکاریویزیس، بررسی‌ها نشان داد که طیف‌نگاشت (اسپکتروگرام) صدای زنبورهای کندوی مبتلا به بیماری کنه تنفسی (آکاریویزیس وودی) در چندین جنبه با کندوی سالم تفاوت دارد. مطالعه طیف‌نگاشت کندوی آلوده نشان داد که فرکانس غالب در این حالت در محدوده ۵۰۰ تا ۱۵۰۰ هرتز قرار داشت. در این حالت، کاهش فرکانس غالب به محدوده ۵۰۰ تا ۱۵۰۰ هرتز، همراه با افزایش شدت در فرکانس‌های پایین و کاهش نویز کلی مشاهده شد. این تغییرات به عنوان نشانه‌ای از ضعف، کاهش فعالیت و استرس در کلنی آلوده تفسیر شده است. در مقایسه با کندوی بدون ملکه و کندوی آلوده به کنه واروآ، دریافتیم که الگوی تغییرات صوتی در بیماری‌های مختلف زنبور عسل متفاوت است. سامانه هوشمند یادگیری عمیق طراحی شده برای این پروژه، حضور کنه تنفسی (آکاریویزیس وودی) در کندو را با دقت بالایی (۹۸/۶۴٪) گزارش کرده است.

همچنین، طیف‌نگاشت کندوی آلوده به لوک اروپایی و آمریکایی نشان داد که فرکانس غالب این حالت در محدوده ۴۰۰ تا ۱۲۰۰ هرتز قرار داشت. این مسئله نشان‌دهنده کاهش قابل توجه فرکانس صدای زنبورها و در عوض، افزایش شدت صدا در فرکانس‌های پایین‌تر در کندوهای آلوده بود. علت این مسئله این بود که بیماری لوک (اروپایی-آمریکایی) باعث آسیب به لاروها و کاهش جمعیت کندو می‌شود که به تغییر الگوی صدا منجر می‌شود. این تغییرات را می‌توان نشان‌دهنده ضعف و ناتوانی زنبورهای بیمار و تلاش آن‌ها برای برقراری ارتباط در شرایط بیماری دانست. همچنین، میزان نویز در کندوهای آلوده به لوک کاهش یافت که می‌تواند نشان‌دهنده کاهش فعالیت و

استرس در کلنی باشد. این الگوی تغییرات در صدا، تا حدودی مشابه با الگوی تغییرات مشاهده شده در کندوهای آلوده به کنه تنفسی بود. سامانه هوشمند یادگیری عمیق طراحی شده برای این پروژه، حضور بیماری لوک (آمریکایی یا اروپایی) در کندو را با دقت بالایی (۹۸/۷۱٪) گزارش کرده است.

در تحلیل صدا با استفاده از یادگیری عمیق مبتنی بر FFT در تشخیص کندوی مبتلا به نوزما نیز، فرکانس غالب در طیف‌نگاشت کندوی مبتلا به نوزما در محدوده ۸۰۰ تا ۲۴۰۰ هرتز قرار داشت. این مسئله نشان داد که فرکانس صدای این کندوها نسبت به کندوهای سالم افزایش یافته است. این افزایش فرکانس، به ویژه در محدوده ۸۰۰ تا ۲۴۰۰ هرتز، همراه با کاهش شدت صدا در فرکانس‌های پایین‌تر مشاهده شد. علت این مسئله این بود که بیماری نوزما باعث اختلال در سیستم گوارشی زنبورها و کاهش فعالیت آن‌ها می‌شود. همچنین، در طیف‌نگاشت این کندوها، نویز بیشتری نسبت به کندوهای سالم دیده شد که نشان‌دهنده افزایش آشفتگی و استرس در کندو است. این تغییرات در الگوی صدای کندو، احتمالاً به دلیل افزایش فعالیت زنبورهای بیمار و تلاش آن‌ها برای مقابله با بیماری است. سامانه هوشمند یادگیری عمیق طراحی شده برای این پروژه، حضور نوزما در کندو را با دقت بالایی (۹۸/۸٪) گزارش کرده است.

بررسی کمی و کیفی عسل تولیدی از کندوی معمولی و کندوی مورد بررسی: تغییر در مدیریت کندو و عدم باز کردن کندو جز در موارد احتمال بیماری‌های مورد بررسی (نبود ملکه، کنه واروا، کنه تنفسی، لوک آمریکایی-اروپایی و نوزما) هم بر کمیت عسل تولیدی و هم بر کیفیت عسل تولیدی اثر گذاشته است. به نحوی که مقدار عسل تولیدی در کندوهای با مدیریت سنتی و بازرسی چشمی ۲ روز یک بار به طور میانگین ۸ تا ۱۰ کیلوگرم در یک دوره می‌باشد. عسل تولیدی در ۵ کندوی مورد بررسی در این تحقیق (با تغذیه مشابه و حداقل بازرسی چشمی - کمتر از ۵ بار در یک دوره تولید - و بررسی فقط به صورت صوتی) به طور میانگین ۱۲ کیلوگرم بود که نشان‌دهنده افزایش قابل توجهی در مقدار عسل تولیدی است. همچنین کیفیت عسل نیز تغییر قابل توجهی نسبت به حالت معمول کندو داشت. نتایج آزمایش عسل تولیدی در کندوهای با مدیریت سنتی و کندوهای مورد بررسی در این تحقیق در جدول ۲ آمده است.

جدول ۲- مقایسه نتایج تحلیل کیفی عسل در کندوی مبتنی بر مدیریت سنتی با کندوی مبتنی بر تحلیل صوتی (شرایط تغذیه ای یکسان)

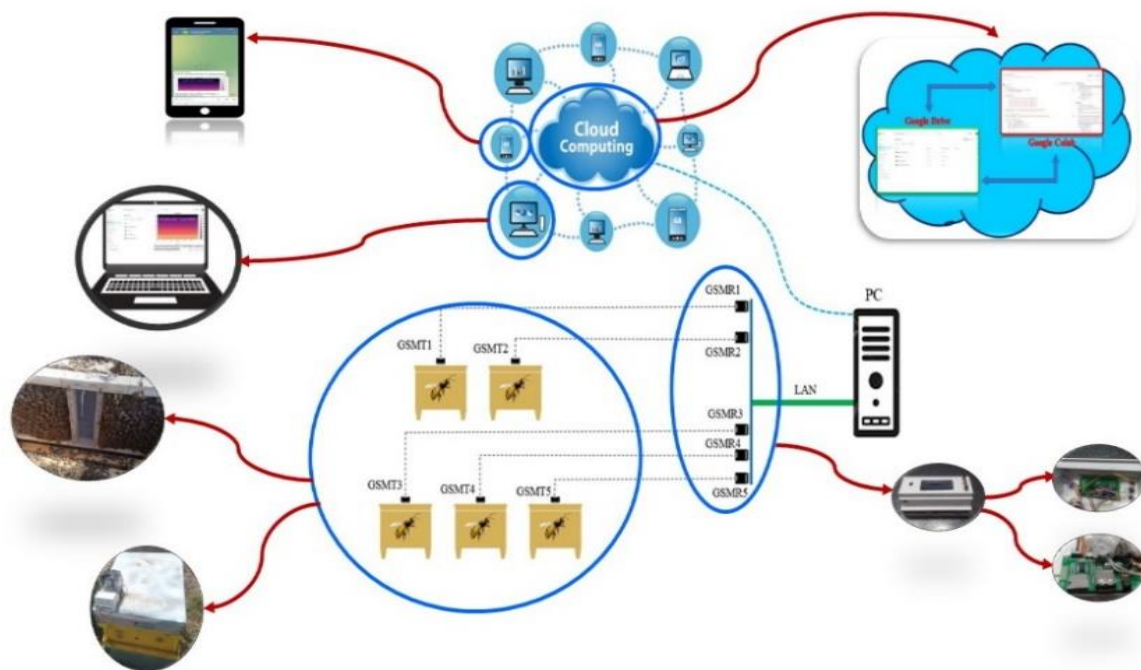
ردیف	عنوان آزمون	روش آزمون	واحد	حد قابل قبول	قاعده تصمیم گیری	احتمال انطباق (PC)	شرایط محیطی (دما)	کندوی مبتنی بر مدیریت سنتی	نتایج آزمون
۱	قندهای احیا کننده قبل از هیدرولیز	INSO 92 Clause 1-7	گرم درصد	۲۵-۲۲	عمده	۹۶/۹۰٪	۲۶/۵ °C	کندوی مبتنی بر مدیریت سنتی	۲۵/۷
۲	قندهای احیا کننده بعد از هیدرولیز	INSO 92 Clause 1-7	گرم درصد	۸۰-۷۵	عمده	۱۰۰/۰۰٪	۲۶/۵ °C	کندوی مبتنی بر مدیریت سنتی	۷۵/۷
۳	ساکارز	INSO 92 Clause 2-7	گرم درصد	۳۸-۳۵	عمده	۹۹/۹۰٪	۲۶/۵ °C	کندوی مبتنی بر مدیریت سنتی	۳۵/۳
۴	فروکتوز	INSO 92 Clause 2-7	گرم درصد	۳۸-۳۵	عمده	۹۹/۷۰٪	۲۶/۵ °C	کندوی مبتنی بر مدیریت سنتی	۳۶/۸
۵	گلوکوز	INSO 92 Clause 2-7	گرم درصد	--	--	۱۰۰/۰۰٪	۲۶/۵ °C	کندوی مبتنی بر مدیریت سنتی	۳۹/۲
۶	نسبت فروکتوز به گلوکز	ISIRI 11145	--	۱-۱/۰/۹	عمده	۱۰۰/۰۰٪	۲۶/۵ °C	کندوی مبتنی بر مدیریت سنتی	۰/۹۴
۷	پروپین	INSO 92 Clause 3-7	میلیگرم در کیلوگرم	۱۰۰۰-۸۰۰	SPC	۱۰۰/۰۰٪	۲۶/۵ °C	کندوی مبتنی بر مدیریت سنتی	۹۱۸
۸	فعالیت دیاستازی (کمی)	INSO 92 Clause 3-7	واحد دیاستاز DN	-Oct ۲۰	--	۱۰۰/۰۰٪	۲۶/۵ °C	کندوی مبتنی بر مدیریت سنتی	۲۳/۶
۹	رطوبت	INSO 92 Clause 3-7	گرم درصد	-Oct ۲۰	--	۱۰۰/۰۰٪	۲۶/۵ °C	کندوی مبتنی بر مدیریت سنتی	۱۵/۸۹

تفسیر نتایج آزمایش کیفیت عسل تولیدی در کندوها: نتایج مقایسه کیفی دو عسل مورد بررسی، طبق جدول ۲، به شرح زیر است. تغییر در مدیریت کندو و عدم باز کردن آن، مگر در موارد احتمال اختلال‌های مورد بررسی (نبود ملکه، کنه واروا، کنه تنفسی، لوک آمریکایی-اروپایی و نوزما)، هم بر کمیت و هم بر کیفیت عسل تولیدی اثرگذار بود. به نحوی که میانگین مقدار عسل تولیدی در کندوهای با مدیریت سنتی و بازرسی چشمی دو روز یک بار، ۸ تا ۱۰ کیلوگرم در یک دوره بود. در حالی که میانگین عسل تولیدی در کندوهای مورد بررسی در این تحقیق (با تغذیه مشابه و حداقل بازرسی چشمی - کمتر از ۵ بار در یک دوره تولید- و بررسی فقط به صورت صوتی)، ۱۲ کیلوگرم بود که نشان‌دهنده افزایش قابل توجهی در مقدار عسل تولیدی است. همچنین، کیفیت عسل نیز نسبت به حالت معمول کندو تغییر قابل توجهی داشت. با آزمایش دو نمونه عسل (عسل تولیدی در کندوی با مدیریت سنتی و عسل تولیدی در کندوی با مدیریت پیشنهادی در این تحقیق)، مشخص شد که در هر دو نمونه، مقدار قندهای احیا کننده قبل از هیدرولیز در محدوده قابل قبول (حداقل ۶۰ درصد) بود. با این حال، در نمونه عسل کندوی با تحلیل صوتی، مقدار قندهای احیا کننده بعد از هیدرولیز به طور معنی‌داری بیشتر از نمونه سنتی (۷۲٫۵ درصد در مقابل ۶۸٫۲ درصد) بود. این مسئله نشان می‌دهد که آنزیم‌های موجود در عسل کندوی با تحلیل صوتی به طور موثرتری عمل کرده و قندهای پیچیده را به قندهای ساده‌تر تبدیل کرده‌اند. مقدار ساکارز در هر دو نمونه عسل در محدوده قابل قبول (حداکثر ۳۵ تا ۳۸ درصد) بود. ساکارز نوعی قند است که به راحتی توسط زنبور عسل هضم نمی‌شود و می‌تواند برای سلامتی آن‌ها مضر باشد. مقادیر پایین ساکارز در عسل نشان می‌دهد که زنبورها به طور کامل شهد را به عسل تبدیل کرده‌اند. در هر دو نمونه عسل، مقدار فروکتوز و گلوکز در محدوده قابل قبول (فروکتوز: ۴۰ تا ۴۵ درصد، گلوکز: ۳۰ تا ۳۵ درصد) بود. نسبت گلوکز به فروکتوز در عسل کندوی با تحلیل صوتی کمی کمتر از نمونه سنتی (۰/۹۴ در مقابل ۰/۹۷) بود. این مسئله نشان می‌دهد که از آنجا که فروکتوز نسبت به گلوکز شاخص گلیسمی (GI) پایین‌تری دارد، عسل کندوی با تحلیل صوتی افزایش قند خون را پس از مصرف کاهش می‌دهد و برای افراد دیابتی مناسب‌تر است. مقدار پرولین در هر دو نمونه عسل در محدوده قابل قبول (حداقل ۱۸۰ میلی‌گرم در کیلوگرم) بود. پرولین یک اسید آمینه است که نشان‌دهنده کیفیت عسل است. مقادیر بالاتر پرولین نشان‌دهنده عسل با کیفیت‌تر است. در این مورد، عسل کندوی با تحلیل صوتی پرولین بیشتری (۲۱۰ میلی‌گرم در کیلوگرم در مقابل ۱۹۵ میلی‌گرم در کیلوگرم) داشت. مقادیر بالاتر پرولین نشان‌دهنده عسل با کیفیت‌تر و طعم قوی‌تر است. عسل کندوی با تحلیل صوتی به دلیل پرولین بیشتر، طعم قوی‌تر و کیفیت بهتری دارد. فعالیت دیاستازی در هر دو نمونه عسل در محدوده قابل قبول (حداقل ۸ واحد Schade) بود. فعالیت دیاستازی نشان‌دهنده قدرت آنزیمی عسل است. مقادیر بالاتر فعالیت دیاستازی نشان‌دهنده عسل با کیفیت‌تر است. در این مورد، عسل کندوی با تحلیل صوتی فعالیت دیاستازی بیشتری (۹/۵ واحد Schade در مقابل ۸/۸ واحد Schade) داشت. فعالیت دیاستازی نشان‌دهنده قدرت آنزیمی عسل است. مقادیر بالاتر فعالیت دیاستازی نشان‌دهنده عسل با کیفیت‌تر و فاسد شدن دیرتر آن است. عسل کندوی با تحلیل صوتی به دلیل فعالیت دیاستازی بیشتر، کیفیت بهتری دارد و دیرتر فاسد می‌شود. رطوبت در هر دو نمونه عسل در محدوده قابل قبول (حداکثر ۲۰ درصد) بود. رطوبت بالا در عسل می‌تواند باعث فاسد شدن آن شود. مقادیر پایین رطوبت نشان‌دهنده عسل با کیفیت‌تر است. در این مورد، عسل کندوی با تحلیل صوتی رطوبت کمتری (۱۵/۸۹ درصد در مقابل ۱۷/۲ درصد) داشت. رطوبت بالا در عسل می‌تواند باعث فاسد شدن آن شود. با بررسی رطوبت عسل‌ها مشخص شد که عسل کندوی با تحلیل صوتی به دلیل رطوبت کمتر، کیفیت بهتر و ماندگاری بیشتری دارد.

بحث

در این پژوهش، از یک معماری اینترنت اشیا مبتنی بر تحلیل صوتی برای بررسی وضعیت سلامت کلونی‌های زنبور عسل استفاده شد. به این منظور، هرساعت یک دقیقه صدا از هر کندو ضبط و به اسپکتروگرام (نمودار فرکانس و شدت) تبدیل گردید. سپس، اسپکتروگرام‌های ایجاد شده پس از آپلود در فضای گوگل درایو در محیط گوگل کولب مورد تحلیل قرار گرفتند. در محیط گوگل کولب با استفاده از شبکه یادگیری عمیق کانولوشنی مبتنی بر یادگیری عمیق (CDLNN) مورد تجزیه و تحلیل قرار گرفتند. شبکه آموزش یافته با ۶ حالت مختلف (کندوی فاقد ملکه، آلودگی به کنه واروا، کنه تنفسی، فولبرد آمریکایی-اروپایی و نوزما) اسپکتروگرام صداهای دریافتی برای هر کندو را با دقت قابل قبولی مورد بررسی قرار داده و در نهایت در صورت بروز هر یک از حالت‌های نامطلوب (نبود ملکه، ابتلای کندو به کنه واروا، ابتلای کندو به کنه ی آکاریوپیس وودی، ابتلای کندو به بیماری فولبرد اروپایی یا آمریکایی و ابتلای کندو به بیماری نوزما) از طریق فضای ابری هم به گوگل درایو تعریف شده و هم ربات تلگرام تعریف شده برای اوبراتور کندوها (زنبوردار) یک پیام متنی با محتوای حاوی اطلاعات کندوی دچار اختلال تشخیص داده شده و تصویر اسپکتروگرام صدایی که کندو با آن صدا توسط شبکه دچار اختلال تشخیص

داده شده است ارسال میکند. در این مرحله زنبوردار امکان تایید یا رد ادعای سیستم مبتنی بر یادگیری عمیق معرفی شده در این تحقیق را دارد. به نحوی که تایید یا عدم تایید تصویری (ارسال تصویر و تحلیل تصاویر) یا کلامی (ارسال عبارتی مبتنی بر تایید و قابل تشخیص برای سیستم) باعث بهبود عملکرد تشخیصی و کاهش خطای سیستم مبتنی بر یادگیری عمیق معرفی شده در این تحقیق میگردد. خلاصه ی گرافیکی سامانه اینترنت اشیا طراحی شده در این تحقیق و شیوه ی ارائه ی نتایج آن در (شکل ۱۴) آمده است.



شکل ۱۴- خلاصه گرافیکی سامانه اینترنت اشیا طراحی شده در این تحقیق

در پژوهش‌های پیشین، سجروسکی و همکاران (۲۰۰۹) با استفاده از تحلیل صوتی، به تشخیص حضور ملکه در کندو پرداختند. در مقایسه با این مطالعه، پژوهش حاضر با بهره‌گیری از شبکه‌های عصبی کانولوشنی، گامی فراتر نهاده و بر تشخیص دقیق بیماری‌ها و آفات متمرکز شده است. این رویکرد امکان استخراج الگوهای پیچیده‌تری از داده‌ها و ارائه نتایج دقیق‌تر را فراهم می‌کند (Cejrowski et al, 2009). نولاسکو و همکاران (۲۰۱۹) نیز در تحقیق خود، با استفاده از تحلیل صوتی، به شناسایی حالت‌های مختلف کندو پرداختند. اگرچه پژوهش حاضر نیز به شناسایی وضعیت کلی کندو می‌پردازد، اما با تمرکز بر تشخیص بیماری‌های خاص، نتایج دقیق‌تری به دست آمده است. (Nolasco et al, 2019) همچنین، پولینیاک و همکاران (۲۰۱۹) با استفاده از الگوریتم تاب‌خوردگی زمان پویا، به شناسایی سیگنال‌های صوتی کلنی زنبور عسل پرداختند. در مقایسه با این مطالعه، پژوهش حاضر با بهره‌گیری از شبکه‌های عصبی کانولوشنی، توانسته است به نتایج دقیق‌تری در تشخیص بیماری‌ها دست یابد. (Yu, Polyniak et al, 2019) زگانک (۲۰۲۰) در تحقیق خود، به طبقه‌بندی آکوستیکی فعالیت ازدحام زنبورها برای یک سرویس مزرعه مبتنی بر اینترنت اشیا پرداخت. در حالی که هدف اصلی این مطالعه، بررسی رفتار گروهی زنبورها بود، پژوهش حاضر با تمرکز بر تشخیص بیماری‌ها و آفات، به تحلیل دقیق‌تر ویژگی‌های صوتی پرداخته است. ما با استفاده از شبکه‌های عصبی کانولوشنی، توانسته‌ایم الگوهای پیچیده‌تری از داده‌ها را استخراج کرده و به نتایج دقیق‌تری در تشخیص بیماری‌ها دست یابیم. (Zgank, 2020) کیم و همکاران (۲۰۲۱) در تحقیق خود، به طبقه‌بندی صحنه آکوستیک و تجسم صداهای کندو با استفاده از الگوریتم‌های یادگیری ماشین پرداختند. در حالی که هر دو مطالعه از الگوریتم‌های یادگیری ماشین استفاده می‌کنند، پژوهش حاضر با تمرکز بر تشخیص بیماری‌ها و آفات، به تحلیل دقیق‌تر ویژگی‌های صوتی پرداخته و از شبکه‌های عصبی کانولوشنی برای استخراج ویژگی‌های پیچیده‌تر استفاده کرده است. (Kim et al, 2021) در تحقیق دیگری، جانتزکی و همکاران (۲۰۲۱) به شناسایی حضور نوعی گرفتار در داده‌های صوتی به دست آمده از کندوها پرداختند. اگرچه هر دو مطالعه به تحلیل ویژگی‌های صوتی می‌پردازند، اما پژوهش حاضر با تمرکز بر تشخیص بیماری‌ها و آفات، به تحلیل عمیق‌تر ویژگی‌های صوتی پرداخته و از الگوریتم‌های پیشرفته‌تری استفاده کرده است. (Janetzky et al, 2021) ژائو و همکاران (۲۰۲۱) نیز با استفاده از یادگیری ماشین، به تشخیص آلاینده‌های هوا با استفاده از صداهای

کندو پرداختند. در حالی که هر دو مطالعه از یادگیری ماشین استفاده می‌کنند، پژوهش حاضر با تمرکز بر تشخیص بیماری‌های داخلی کندو، به تحلیل دقیق‌تر ویژگی‌های صوتی پرداخته و از شبکه‌های عصبی کانولوشنی برای استخراج ویژگی‌های پیچیده‌تر استفاده کرده است (Zhao et al, 2021).

در پژوهش حاضر، با بهره‌گیری از شبکه‌های عصبی عمیق و تحلیل طیفی پیشرفته، دقت تشخیص بی‌نظیر بیش از ۹۸٪ در شناسایی بیماری‌ها و آفات مهم زنبور عسل حاصل شده است. این دستاورد در مقایسه با مطالعات پیشین، بهبود چشمگیری در تشخیص به موقع و دقیق بیماری‌ها و آفات زنبور عسل ارائه می‌دهد و نشان‌دهنده‌ی پیشرفت قابل‌توجهی در این زمینه است. مطالعه کیم و همکاران (۲۰۲۱) بر طبقه‌بندی و تجسم صداهای کندو متمرکز بود (Kim et al, 2021)، در حالی که پژوهش حاضر با استفاده از شبکه‌های عصبی عمیق، دقت تشخیص به مراتب بالاتری را ارائه کرده است. این امر منجر به پایش و مدیریت مؤثرتر کندوها و در نتیجه بهبود کمیت و کیفیت تولید عسل می‌شود. به عبارت دیگر، توانایی تشخیص دقیق‌تر بیماری‌ها و آفات، امکان اتخاذ تصمیمات مدیریتی بهتری را برای زنبورداران فراهم می‌کند و به آن‌ها کمک می‌کند تا به طور مؤثرتری از کندوهای خود مراقبت کنند. همچنین، در مقایسه با پژوهش گوئرو و همکاران (۲۰۲۴) که بر طبقه‌بندی آنلاین الگوهای صوتی کندو با دقت ۹۰-۹۵٪ تمرکز داشتند (Guerrero et al, 2024)، پژوهش حاضر با تحلیل طیفی پیشرفته‌تر و شبکه‌های عصبی عمیق، دقت تشخیص بیش از ۹۸٪ را محقق ساخته است. این افزایش دقت، قابلیت اطمینان و اعتبار سیستم پیشنهادی را در شناسایی به موقع بیماری‌ها و آفات مهم زنبورها به طور چشمگیری افزایش می‌دهد. به این ترتیب، سیستم پیشنهادی در این پژوهش می‌تواند به عنوان یک ابزار قدرتمند و قابل‌اعتماد در اختیار زنبورداران قرار گیرد تا بتوانند به سرعت و با اطمینان، بیماری‌ها و آفات کندوهای خود را شناسایی و برای درمان آن‌ها اقدام کنند. مطالعه اقبال و همکاران (۲۰۲۴) بر تحلیل الگوهای صوتی به عنوان سیگنال‌های حسگر برای پیش‌بینی رفتار انبوهی زنبورها متمرکز بود (Iqbal et al, 2024)، در حالی که پژوهش حاضر با هدف تشخیص وضعیت سلامت کلونی‌ها و بیماری‌های مهم آن‌ها طراحی و اجرا شده است. رویکرد مبتنی بر یادگیری عمیق در مطالعه حاضر، در مقایسه با تحلیل تجربی الگوهای صوتی در پژوهش اقبال، دقت و قابلیت تعمیم‌پذیری بالاتری را به همراه داشته است. این بدان معناست که مدل توسعه‌یافته در این پژوهش، قادر است با دقت بیشتری بیماری‌ها و آفات زنبور عسل را شناسایی کند و در شرایط مختلف، عملکرد بهتری داشته باشد. علاوه بر این، در مقایسه با مقاله سیمون و همکاران (۲۰۲۴) که بر پایش ملکه زنبور با استفاده از سیگنال‌های صوتی تمرکز داشتند (Simone et al, 2024)، مطالعه حاضر با هدف جامع‌تر تشخیص طیف گسترده‌ای از بیماری‌ها و آفات مهم زنبورها، برتری قابل‌توجهی را نشان می‌دهد. این مزیت منجر به مدیریت هوشمندانه‌تر و پایدارتر کندوها با کاهش آسیب به زنبورها و افزایش تولید عسل می‌شود. به عبارت دیگر، پژوهش حاضر با ارائه یک سیستم جامع برای تشخیص بیماری‌ها و آفات زنبور عسل، به زنبورداران کمک می‌کند تا به طور مؤثرتری از کندوهای خود مراقبت کنند و از سلامت آن‌ها اطمینان حاصل کنند. به طور خلاصه، پژوهش حاضر با بهره‌گیری از تکنیک‌های پیشرفته یادگیری عمیق و تحلیل طیفی، گام مهمی در راستای تشخیص دقیق و به موقع بیماری‌ها و آفات زنبور عسل برداشته است. این دستاورد ارزشمند می‌تواند به بهبود مدیریت کندوها، افزایش تولید عسل و حفظ سلامت زنبورها کمک شایانی کند و نقش مؤثری در توسعه‌ی پایدار صنعت زنبورداری ایفا کند.

نتایج این پژوهش نشان می‌دهد که تحلیل صوتی با استفاده از تبدیل فوریه سریع (FFT) و شبکه‌های عصبی کانولوشنی مبتنی بر یادگیری عمیق (CDLNN) می‌تواند به عنوان یک ابزار مفید برای تشخیص وضعیت سلامت کلونی‌های زنبور عسل مورد استفاده قرار گیرد. این رویکرد قادر است با دقت بالایی (بیش از ۹۸٪) بیماری‌ها و آفات مختلف را در کندوها شناسایی کند. در مقایسه با مطالعات گذشته، پژوهش حاضر با بهره‌گیری از شبکه‌های عصبی کانولوشنی گامی فراتر نهاده و به تشخیص دقیق بیماری‌ها و آفات پرداخته است. این رویکرد امکان استخراج الگوهای پیچیده‌تری از داده‌های صوتی را فراهم می‌کند و نتایج دقیق‌تری را ارائه می‌دهد. در مطالعات قبلی، اگرچه تشخیص وضعیت کلی کندو مورد توجه بوده است، اما تحقیق حاضر با تمرکز بر بیماری‌های خاص، به نتایج دقیق‌تری دست یافته است. یکی از مزایای اصلی سیستم پیشنهادی در این پژوهش، کاهش دخالت دستی در مدیریت کندوها و نظارت غیرمخرب بر وضعیت آن‌هاست. این امر منجر به افزایش کمیت و کیفیت عسل تولیدی شده است. همچنین، امکان اخطار به موقع زنبوردار در صورت بروز هر یک از اختلالات مورد بررسی، می‌تواند به بهبود مدیریت و افزایش بازده تولید عسل کمک کند. با استفاده از این سیستم، زنبورداران قادر خواهند بود به طور دقیق و سریع بیماری‌ها و آفات را تشخیص داده و اقدامات لازم را برای حفظ سلامت کندوها انجام دهند. این امر نه تنها منجر به افزایش تولید عسل می‌شود، بلکه از خسارات ناشی از بیماری‌ها و آفات نیز جلوگیری می‌کند. به عبارت دیگر، سیستم پیشنهادی در این پژوهش، یک ابزار کارآمد و قابل‌اعتماد برای مدیریت هوشمندانه و پایدار کندوها به شمار می‌رود. این سیستم با ارائه اطلاعات

دقیق و به موقع، به زنبورداران کمک می‌کند تا تصمیمات بهتری در مورد مدیریت کندوها اتخاذ کنند و از سلامت و بهره‌وری آن‌ها اطمینان حاصل کنند.

نتیجه گیری

پژوهش حاضر، با بهره‌گیری از تحلیل صوتی و شبکه‌های عصبی عمیق، گامی بلند در راستای تشخیص دقیق و زودهنگام بیماری‌ها و آفات زنبور عسل برداشته است. نتایج به دست آمده نشان می‌دهد که الگوریتم توسعه‌یافته قادر است با دقت بیش از ۹۸٪، وضعیت سلامت کلونی‌های زنبور عسل را شناسایی و بیماری‌ها و آفات گوناگون را تشخیص دهد. این دقت بی‌نظیر، در مقایسه با روش‌های سنتی و مطالعات پیشین، پیشرفتی چشمگیر در این حوزه به شمار می‌رود.

در این پژوهش، تحلیل صوتی کندوی زنبور عسل با استفاده از تبدیل فوریه سریع انجام و نمودار اسپکتروگرام فایل‌های صوتی یک دقیقه‌ای ضبط شده از کندو ترسیم گردید. سپس، با استفاده از ویژگی‌های فرکانسی، وضعیت کندوی زنبور عسل مورد بررسی قرار گرفت. نکته قابل توجه در این تحقیق، تحلیل نمودارهای اسپکتروگرام توسط یک شبکه یادگیری عمیق کانولوشنی بود. برای یافتن بهترین شبکه عصبی کانولوشنی مبتنی بر یادگیری عمیق از میان سه شبکه مطرح شده (DenseNet121)، EfficientNetB0 و InceptionV3، ماتریس آشفتگی و منحنی عملکرد تشخیص (ROC) برای هر یک از شبکه‌ها در تحلیل تصاویر محاسبه شد. نتایج نشان داد که هر سه مدل عملکرد بسیار خوبی در طبقه‌بندی داده‌ها داشتند. با این حال، مدل‌های EfficientNetB0 و InceptionV3 عملکردی اندکی بهتر از مدل DenseNet121 نشان دادند که می‌تواند به دلیل تفاوت در معماری این مدل‌ها و توانایی آن‌ها در استخراج ویژگی‌های پیچیده‌تر باشد. در نهایت، شبکه کانولوشنی مبتنی بر یادگیری عمیق InceptionV3 برای ادامه آزمایش‌ها انتخاب شد.

بررسی اسپکتروگرام صدای زنبورهای کندوی سالم نشان داد که فرکانس غالب در محدوده فرکانسی پایین قرار دارد. این امر، تمرکز صدا بر فرکانس‌های پایین را نشان می‌دهد که به دلیل استفاده معمول زنبورها از این فرکانس‌ها برای برقراری ارتباط و انتقال اطلاعات است. در مقابل، در کندوی بدون ملکه، فرکانس غالب به محدوده فرکانسی بالاتری منتقل می‌شود که نشان‌دهنده افزایش اضطراب و آشفتگی در کلنی است. در کندوی مبتلا به واروآزیس، فرکانس غالب نیز افزایش می‌یابد که نشان‌دهنده افزایش فعالیت زنبورها برای مقابله با آفت است. در کندوی مبتلا به آکاریوزیس، فرکانس غالب کاهش می‌یابد که نشان‌دهنده ضعف و کاهش فعالیت در کلنی آلوده است. در کندوی مبتلا به فولبرد، فرکانس غالب کاهش می‌یابد و در نهایت، در کندوی مبتلا به نزوما، فرکانس غالب افزایش می‌یابد که نشان‌دهنده افزایش آشفتگی و استرس در کندو است. نتایج تحلیل صوتی با استفاده از DL مبتنی بر FFT در تشخیص انواع کندو به اختصار در جدول ۳ آمده است.

جدول ۳- خلاصه‌ی نتایج تحلیل صوتی با استفاده از DL مبتنی بر FFT در تشخیص انواع کندو

نوع کندو	محدوده فرکانس غالب (هرتز)	طول موج	شدت صدا در فرکانس‌های پایین	نویز	شماره تصاویر مرتبط	دقت شبکه CDLNN در تشخیص (%)
سالم	۰-۲۰۰۰	بلند	بالا	کم	۱۶	۹۸/۷۴
فاقد ملکه	۲۰۰۰-۴۰۰۰	کوتاه	پایین	زیاد	۱۷	۹۸/۶۲
آلوده به واروآ	۱۰۰۰-۳۰۰۰	کوتاه	پایین	زیاد	۱۸	۹۸/۵۹
آلوده به آکاریوزیس	۵۰۰-۱۵۰۰	بلند	بالا	کم	۱۹	۹۸/۶۴
آلوده به فولبرد (اروپایی-آمریکایی)	۴۰۰-۱۲۰۰	بلند	بالا	کم	۲۰	۹۸/۷۱
آلوده به نزوما	۸۰۰-۲۴۰۰	کوتاه	پایین	زیاد	۲۱	۹۸/۰۸

تغییر در مدیریت کندو و عدم باز کردن آن، جز در موارد احتمال بیماری‌های مورد بررسی، هم بر کمیت و هم بر کیفیت عسل تولیدی تأثیر گذاشته است. مقدار عسل تولیدی در کندوهای مورد بررسی در این تحقیق (با تغذیه مشابه و حداقل بازرسی چشمی)، به طور میانگین، افزایش قابل توجهی در مقایسه با کندوهای با مدیریت سنتی داشت. همچنین، کیفیت عسل نیز تغییر قابل توجهی را نشان داد. نتایج آزمایش عسل تولیدی حاکی از آن بود که در نمونه عسل کندوی با تحلیل صوتی، مقدار قندهای احیا کننده پس از هیدرولیز بیشتر و نسبت گلوکز به فروکتوز کمتر از نمونه سنتی بود. مقدار پرولین و فعالیت دیاستازی در عسل کندوی با تحلیل صوتی بیشتر بود که نشان‌دهنده کیفیت بهتر آن است. همچنین، رطوبت عسل کندوی با تحلیل صوتی کمتر بود که نشان‌دهنده ماندگاری بیشتر آن است. در آینده، توسعه

یک سیستم جامع متمرکز بر تحلیل صوتی به جای استفاده از سنسورهای متعدد (دما، رطوبت، تصویر و غیره) و یک پلتفرم یکپارچه برای جمع‌آوری و تحلیل داده‌ها مورد توجه قرار خواهد گرفت. هدف اصلی، استفاده از تحلیل دقیق و هوشمندانه صداهای کندو به عنوان تنها منبع اطلاعات برای تشخیص وضعیت سلامت و پیش‌بینی مشکلات احتمالی است. به‌کارگیری الگوریتم‌های پیشرفته‌تر هوش مصنوعی و یادگیری عمیق به منظور افزایش دقت و سرعت تشخیص و پیش‌بینی بروز بیماری‌ها و آفات با تکیه بر داده‌های صوتی، در اولویت قرار دارد. توسعه نسخه‌های تجاری این سیستم مبتنی بر تحلیل صوتی برای استفاده در صنعت زنبورداری و مزارع بزرگ با هدف افزایش بهره‌وری و کاهش هزینه‌ها، از اهداف آتی این پژوهش است. در مجموع، پژوهش حاضر با ارائه یک روش نوآورانه و کارآمد برای تشخیص بیماری‌ها و آفات زنبور عسل صرفاً از طریق تحلیل صدا، گامی مهم در راستای حفظ سلامت زنبورها و توسعه پایدار صنعت زنبورداری برداشته است. توسعه و تجاری‌سازی این فناوری مبتنی بر تحلیل صوتی می‌تواند نقش بسزایی در بهبود عملکرد و افزایش بهره‌وری صنعت زنبورداری در سطح ملی و بین‌المللی ایفا کند.

REFERENCES

- Aumann, H., Tautz, J., & Tscheulin, T. (2017). Measuring honeybee foraging activity with Doppler radar. *Journal of Apicultural Research*, 56(4), 417–425.
- Barrionuevo, A. (2007, February 27). Honeybees vanish, leaving keepers in peril. *The New York Times*. Retrieved from <https://www.nytimes.com/2007/02/27/science/27bees.html>
- Büchler, R. (2015). Varroa tolerance in honey bees—Occurrence, characters and breeding. *Bee World*, 96(2), 54–70.
- De Jong, D., De Jong, P. H., & Gonçalves, L. S. (1982). Weight loss and other damage to developing worker honeybees from infestation with *Varroa jacobsoni*. *Journal of Apicultural Research*, 21(3), 165–167.
- De Simone, A., Barbisan, L., Turvani, G., & Riente, F. (2024). Advancing beekeeping: IoT and TinyML for queen bee monitoring using audio signals. *IEEE Transactions on Instrumentation and Measurement*, 73, 2502214.
- Frisch, K. v. (1993). *The dance language and orientation of bees* (2nd ed.). Harvard University Press. (Original work published 1886)
- Gallai, N., Salles, J. M., Settele, J., & Vaissière, B. E. (2009). Economic valuation of the vulnerability of world agriculture confronted with pollinator decline. *Ecological Economics*, 68(3), 810–821.
- Genersch, E. (2010). American foulbrood in honeybees and its causative agent, *Paenibacillus larvae*. *Journal of Invertebrate Pathology*, 103(Suppl. 1), S10–S19.
- Iqbal, K., Alabdullah, B., Al Mudawi, N., Algarni, A., Jalal, A., & Park, J. (2024). Empirical analysis of honeybees acoustics as biosensors signals for swarm prediction in beehives. *IEEE Access*, 12, 115167–115181.
- Janetzky, P., Davidson, P., Steininger, M., Krause, A., & Hotho, A. (2021). Detecting presence of speech in acoustic data obtained from beehives. In *Detection and Classification of Acoustic Scenes and Events 2021*.
- Kim, J., Oh, J., & Heo, T. Y. (2021). Acoustic scene classification and visualization of beehive sounds using machine learning algorithms and Grad-CAM. *Mathematical Problems in Engineering*, 2021, Article 6671575.
- Martin, S. J. (1994). Ontogenesis of the mite *Varroa jacobsoni* Oud. in worker brood of the honeybee *Apis mellifera* L. under natural conditions. *Experimental & Applied Acarology*, 18(2), 87–100.
- McMenamin, A. J., & Genersch, E. (2015). Honey bee colony losses and associated viruses. *Current Opinion in Insect Science*, 8, 121–129.
- Morelle, R. (2013, March 27). Neonicotinoid pesticides ‘damage brains of bees’. *BBC News*. Retrieved from <https://www.bbc.com/news/science-environment-21958547>
- Morse, R. A., & Calderon, N. W. (2000). The value of honey bee pollination in the United States. *Bee Culture*, 128(1), 1–15.
- Nolasco, I., Terenzi, A., Cecchi, S., Orcioni, S., Bear, H. L., & Benetos, E. (2019). Audio-based identification of beehive states. In *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*.
- Polyniak, Y., Kretschmar, M., & Sylvestre, J. P. (2019). Dynamic time warping for honeybee colony sound classification. *Ecological Informatics*, 50, 100983.
- Qandour, A., Ahmad, I., Habibi, D., & Leppard, M. (2014). Remote beehive monitoring using acoustic signals. *Acoustics Australia*, 42(3), 204–209.

- Roberts, J. M. K., Anderson, D. L., & Durr, P. A. (2017). Absence of deformed wing virus and Varroa destructor in Australia provides unique perspectives on honeybee viral landscapes and colony losses. *Scientific Reports*, 7, Article 42824.
- Robles-Guerrero, A., Gómez-Jiménez, S., Saucedo-Anaya, T., López-Betancur, D., Navarro-Solís, D., & Guerrero-Méndez, C. (2024). Convolutional neural networks for real time classification of beehive acoustic patterns on constrained devices. *Sensors*, 24(19), Article 6384.
- Seeley, T. D. (2010). *Honeybee democracy*. Princeton University Press.
- Sharif, M. Z., Wario, F., Di, N., Xue, R., & Liu, F. (2020). Soundscape indices: New features for classifying beehive audio samples. *Sociobiology*, 67(4), 566–571.
- Wallner, K. (1999). Varroacides and their residues in bee products. *Apidologie*, 30(2-3), 235–248.
- Zhao, Y., Deng, G., Zhang, L., Di, N., Jiang, X., & Li, Z. (2021). Based investigate of beehive sound to detect air pollutants by machine learning. *Ecological Informatics*, 61, Article 101246.
- Zgank, A. (2021). IoT-based bee swarm activity acoustic classification using deep neural networks. *Sensors*, 21(3), Article 676.