



MODEL KLASIFIKASI BIOAKUSTIK TERNAK MENGGUNAKAN ARTIFICIAL NEURAL NETWORK UNTUK PRECISION LIVESTOCK FARMING

**Alfa Christian Rafael Sihite¹, Alvin Christian Gunawan², Glenn Emmanuel
Abraham³, Jeremy Natanael Setya Putra⁴, Marcel Maximillian Pandey⁵, Scolastika
Luiza Abuk Iru Bere⁶, Hendry Setiawan⁷**

^{1,2,3,4,5,6,7}Program Studi Teknik Informatika, Universitas Ma Chung, Villa Puncak Tidar Blok N no. 1, Doro, ,
Karangwido, Kec. Dau, Kabupaten Malang, Jawa Timur 65151

***Email korespondensi:** 312410018@student.machung.ac.id

Received: 27 05 2026 – Revised: 29 07 2026 - Accepted: 04 08 2026 - Published: 05 08 2026

Abstrak. Sektor industri peternakan saat ini sedang bertransisi menuju konsep *Precision Livestock Farming* (PLF) yang membutuhkan pemantauan kondisi hewan secara otomatis selama 24 jam penuh. Penggunaan sistem pemantauan berbasis visual sering mengalami kendala karena pencahayaan yang buruk dan tebalnya debu di lingkungan kandang. Oleh karena itu, pendekatan bioakustik menggunakan sensor suara menjadi alternatif solusi yang jauh lebih tangguh dan terjangkau. Permasalahan utamanya adalah bagaimana cara memproses data sinyal suara mentah yang sangat masif dan kompleks tersebut secara efisien agar dapat mengidentifikasi masalah kesehatan ternak sejak dini. Untuk memecahkan masalah ini, penelitian menggunakan metode ekstraksi fitur audio *Mel-Frequency Cepstral Coefficients* (MFCC) guna mengubah sinyal audio menjadi representasi numerik yang lebih sederhana. Selanjutnya, klasifikasi dilakukan dengan menerapkan algoritma komputasi *Artificial Neural Network* (ANN) pada sebuah dataset yang berisi 543 sampel audio dari 7 jenis hewan berbeda. Hasil dari implementasi model ini menunjukkan kinerja yang sangat baik, di mana akurasi validasi berhasil mencapai angka 92,66% pada pengujian akhir. Selain itu, model terbukti belajar secara stabil tanpa ada indikasi *overfitting*. Sebagai kesimpulan, model *Deep Learning* yang dikembangkan sangat layak digunakan untuk mendeteksi vokalisasi ternak secara *real-time*. Meski demikian, kelemahan sistem klasifikasi ini masih ditemukan pada hewan dengan jumlah rekaman yang terlampau sedikit, sehingga penambahan data dan proporsi sampel sangat disarankan untuk pengembangan ke depannya. **Untuk sitasi jika menggunakan Mendeley, pilihlah citation style: "American Psychological Association 7th Edition"**

Kata kunci: bioakustik, klasifikasi suara, MFCC, ANN, precision livestock farming

PENDAHULUAN

Sektor peternakan global saat ini tengah mengalami transisi besar menuju konsep Precision Livestock Farming (PLF) (Jiang, Wenjie, Lihang, & Xiaoshang, 2023) seiring dengan peningkatan skala industri peternakan, metode pemantauan hewan secara manual oleh pekerja manusia menjadi semakin tidak efisien, memakan biaya tinggi, dan rentan terhadap kesalahan manusia. Dalam lingkungan peternakan modern yang padat, kemampuan untuk memantau kesehatan dan kesejahteraan hewan secara real-time selama 24 jam penuh

merupakan kebutuhan mendesak. Hal ini mendorong pengembangan sistem otomatisasi yang mampu mengevaluasi kondisi ternak di level individu maupun kelompok tanpa mengganggu aktivitas alami hewan tersebut.

Selama ini, sistem pemantauan otomatis banyak bergantung pada teknologi Computer Vision atau sensor visual. Namun, berbagai literatur menyoroti keterbatasan krusial dari sensor kamera saat diterapkan di lingkungan kandang yang kompleks. Sistem visual sering kali mengalami penurunan akurasi yang signifikan akibat kondisi pencahayaan yang buruk, hewan yang saling menutupi (occlusion), serta tingginya tingkat debu dan kotoran di area peternakan. Sebagai alternatif yang lebih tangguh, pendekatan bioakustik menggunakan sensor suara (mikrofon) menawarkan keunggulan komparatif. Sensor akustik bersifat omni-directional, mampu menangkap sinyal dari berbagai arah tanpa terhalang objek fisik, beroperasi optimal dalam kondisi gelap, dan membutuhkan biaya implementasi serta pemeliharaan yang jauh lebih rendah (Rohan, et al., 2024).

Vokalisasi atau suara yang dihasilkan oleh hewan ternak merupakan sinyal biologis yang kaya akan informasi. Perubahan pola frekuensi dan durasi suara dapat menjadi indikator awal dari berbagai kondisi kritis, seperti stres akibat suhu (thermal stress), ketakutan, hingga infeksi penyakit saluran pernapasan (Nazim Reza, et al., 2022). Deteksi anomali suara, seperti intensitas batuk atau dengkur pada unggas dan babi, sering kali muncul jauh sebelum gejala klinis fisik dapat diamati oleh peternak. Oleh karena itu, analisis suara memberikan metrik yang obyektif untuk deteksi dini penyakit guna mencegah penyebaran wabah, sekaligus memastikan standar kesejahteraan hewan (animal welfare) tetap terjaga sesuai dengan standar industri.

Untuk mengolah data bioakustik yang masif dan kompleks tersebut, penerapan Machine Learning (ML) menjadi solusi yang sangat krusial. Melalui teknik ekstraksi fitur audio, data suara mentah dapat dikonversi menjadi representasi numerik. Berbagai algoritma klasifikasi, seperti Decision Trees, K-Nearest Neighbors (KNN), hingga ansambel kompleks, terbukti mampu mengidentifikasi dan mengklasifikasikan pola suara hewan dengan tingkat akurasi yang tinggi (Nasirahmadi et al., 2021). Integrasi Machine Learning dalam deteksi suara hewan ternak tidak hanya memecahkan masalah efisiensi komputasi, tetapi juga membuka

peluang untuk penerapan teknologi edge computing pada perangkat cerdas di peternakan terpencil, menjadikannya solusi masa depan yang adaptif dan skalabel.

MASALAH


Sektor industri peternakan saat ini menghadapi kebuntuan operasional dalam mewujudkan Precision Livestock Farming (PLF). Pemantauan hewan secara manual memakan biaya tinggi dan rentan human error, sementara sistem otomatisasi modern yang ada saat ini terlalu bergantung pada teknologi Computer Vision. Permasalahan faktualnya adalah sensor visual terbukti rentan dan mengalami penurunan akurasi drastis saat diimplementasikan di lingkungan kandang yang nyata akibat buruknya pencahayaan, posisi hewan yang saling menutupi, serta tingginya tingkat debu. Industri peternakan sangat membutuhkan alternatif sistem pemantauan 24 jam yang tangguh, murah, dan mampu mendeteksi dini anomali kesehatan (seperti stres termal dan infeksi pernapasan). Meskipun sensor bioakustik (suara) menawarkan solusi yang tahan terhadap kendala fisik lingkungan, sensor ini menghasilkan volume data mentah yang sangat masif dan kompleks secara terus-menerus.

Berdasarkan kondisi tersebut, persoalan saintifik pokok yang harus diselesaikan dalam penelitian ini adalah bagaimana memproses data bioakustik yang masif dan kompleks tersebut secara efisien. Sinyal vokalisasi hewan tidak dapat dianalisis secara mentah oleh perangkat komputasi. Oleh karena itu, tantangan utamanya adalah menerapkan teknik ekstraksi fitur audio tingkat lanjut untuk mereduksi dan mengonversi sinyal suara menjadi representasi numerik yang ringan tanpa menghilangkan informasi biologis penting. Selanjutnya, masalah keilmuan dikaitkan dengan integrasi algoritma Machine Learning, khususnya jaringan saraf tiruan untuk menemukan model klasifikasi yang mampu mengidentifikasi pola suara dengan akurasi tinggi. Penyelesaian masalah ekstraksi dan klasifikasi ini ditargetkan tidak hanya untuk memecahkan kendala efisiensi komputasi, tetapi juga menghasilkan arsitektur model yang adaptif dan skalabel agar ke depannya dapat diimplementasikan.

METODE PELAKSANAAN

1. Tahapan Penelitian

Dalam studi ini, sejumlah langkah metodologis telah dilaksanakan dalam memperoleh data, mengevaluasi informasi, dan mencapai sasaran penelitian. Setiap langkah memiliki perannya sendiri dalam memastikan bahwa penelitian dilakukan secara sistematis dan dapat diandalkan



Gambar 1. Diagram kerja penelitian

Berdasarkan alur pada diagram, proses penelitian dimulai dengan tahap Pengumpulan Data, di mana dataset berupa rekaman video dari 7 jenis hewan yang berbeda dikumpulkan. Mengingat durasi masing-masing video tersebut bervariasi, data kemudian diproses lebih lanjut pada tahap Preprocessing Data menggunakan bahasa pemrograman Python. Pada tahap ini, audio diekstraksi dan dilakukan proses pemotongan secara terprogram agar setiap data audio memiliki durasi yang seragam. Setelah itu, dilakukan ekstraksi fitur suara menggunakan metode MFCC (Mel-Frequency Cepstral Coefficients) untuk mengubah sinyal audio menjadi representasi data yang dapat dipahami oleh mesin. Dataset yang telah diproses kemudian dibagi menjadi data latih dan data uji

Setelah tahapan prapemrosesan selesai, langkah selanjutnya adalah Modelling. Pada tahap ini, model algoritma Artificial Neural Network (ANN) dibangun dan dilatih menggunakan dataset training. Setelah model berhasil mempelajari pola dari fitur MFCC, tahap Klasifikasi Suara dilakukan dengan memberikan dataset testing ke dalam model untuk memprediksi dan mengelompokkan suara ke dalam 7 kelas hewan yang telah ditentukan. Terakhir, dilakukan tahap Evaluasi Suara untuk mengukur kinerja dan tingkat akurasi dari model ANN yang telah dibuat. Evaluasi ini diukur menggunakan confusion matrix beserta metrik evaluasi seperti Precision, Recall, dan F1-score untuk mengetahui seberapa baik model dapat membedakan ketujuh suara hewan tersebut sebelum keseluruhan sistem dinyatakan selesai.

2. Data Collection

Data yang digunakan dalam penelitian ini merupakan data sekunder berupa sinyal vokalisasi hewan yang diperoleh dari dataset publik melalui platform Kaggle. Dataset tersebut mencakup total 7 (tujuh) kelas hewan, yang terdiri dari suara Burung, Sapi, Kuda, Babi, Domba, Ayam, dan Keledai. Seluruh rekaman audio di dalam dataset ini diunduh dalam format WAV guna menjaga keutuhan resolusi spektral yang sangat penting untuk proses ekstraksi fitur. Penggunaan data sekunder dari platform Kaggle ini memungkinkan perolehan variasi data suara hewan yang komprehensif dan representatif untuk melatih model, tanpa memerlukan proses perekaman audio secara langsung di lapangan.

3. Data Preprocessing

Pada sistem ini, proses diawali dengan memuat file audio ke dalam format mono menggunakan sample rate standar sebesar 22050 Hz. Selanjutnya, dilakukan penghapusan keheningan pada awal dan akhir rekaman untuk membuang bagian sinyal yang berada di bawah ambang batas desibel tertentu, sehingga sistem hanya berfokus pada aktivitas suara hewan yang dominan. Untuk memastikan keseragaman input pada model, setiap rekaman distandardisasi menjadi durasi tetap secara eksak, yakni 5 detik, rekaman yang durasinya lebih pendek akan diperpanjang dengan penambahan nilai nol, sedangkan yang melebihi durasi akan dipotong. Setelah data audio seragam, sinyal diubah menjadi representasi matematis menggunakan ekstraksi fitur *Mel-Frequency Cepstral Coefficients* (MFCC) beserta nilai Delta-nya. Nilai rata-rata dan standar deviasi dari fitur-fitur tersebut kemudian dikalkulasi dan digabungkan menjadi satu vektor fitur utuh. Terakhir, seluruh vektor fitur dinormalisasi menggunakan Standard Scaler untuk memastikan distribusi data memiliki rata-rata nol dan variansi satu guna mengoptimalkan konvergensi saat pelatihan model Artificial Neural Network (ANN).

4. Data Splitting


Guna memastikan objektivitas pengujian model komputasi, dataset klip audio dibagi menjadi beberapa *subset* yang independen. Pendekatan umum yang diaplikasikan adalah pembagian rasio 80:20, di mana 80% data dialokasikan sebagai *Training Data* untuk melatih bobot algoritma, dan 20% sisanya disimpan sebagai *Testing Data* (data uji). Data uji ini bertindak sebagai tolok ukur akhir yang belum pernah "dilihat" oleh model sebelumnya,

guna mengevaluasi sejauh mana sistem dapat menggeneralisasi pola suara hewan yang benar-benar baru.

5. Modeling

Tahap ini merupakan inti komputasi untuk mengenali pola suara hewan, yang terdiri atas teknik ekstraksi fitur dan klasifikasi:


- **Mel-Frequency Cepstral Coefficients (MFCC):**



Gambar 2. Mel-Frequency Cepstral Coefficients (MFCC)

Gelombang waktu dari sinyal audio mentah sulit diinterpretasikan secara langsung oleh jaringan saraf. Oleh karena itu, MFCC digunakan untuk mengubah sinyal audio menjadi representasi parameter spektral berdimensi rendah yang meniru respons biologis sistem pendengaran mamalia (skala Mel). Melalui serangkaian proses seperti *windowing*, *Fast Fourier Transform* (FFT), dan perhitungan logaritma, MFCC mengekstraksi koefisien-koefisien unik yang merepresentasikan "sidik jari" akustik dari setiap jenis vokalisasi ternak.

- **Artificial Neural Network (ANN):**



Gambar 3. Arsitektur *Artificial Neural Network* (ANN)

Matriks fitur MFCC yang telah diekstrak kemudian dimasukkan sebagai input ke dalam jaringan saraf tiruan atau *Artificial Neural Network* (ANN). Arsitektur ANN (yang terdiri dari *input layer*, beberapa *hidden layers*, dan *output layer*) dilatih menggunakan propagasi balik (*backpropagation*). Selama masa pelatihan (*epochs*), ANN menyesuaikan pembobotan internalnya untuk memetakan hubungan kompleks antara fitur MFCC dengan label kondisi spesifik ternak, sehingga mampu membedakan vokalisasi hewan stres dengan hewan sehat secara presisi.

6. Evaluasi Kinerja Model

Keandalan arsitektur ANN diuji secara kuantitatif menggunakan matriks kebingungan (*Confusion Matrix*). Tabel ini menyandingkan hasil prediksi model terhadap label aktual dari *Testing Data*. Kinerja klasifikasi divalidasi menggunakan empat metrik performa utama, yaitu: *Accuracy* (persentase total prediksi yang benar), *Precision* (kemampuan model menghindari deteksi palsu), *Recall* atau Sensitivitas (kemampuan model mendeteksi seluruh sinyal kelas target), dan *F1-Score* (rata-rata harmonik dari *precision* dan *recall* untuk mengatasi ketidakseimbangan jumlah data antar kelas).

HASIL DAN PEMBAHASAN

Ringkasan Dataset

Pemrosesan awal (*preprocessing*) dilakukan terhadap dataset audio suara hewan ternak menggunakan fitur *Mel-Frequency Cepstral Coefficients* (MFCC) (Zhang, et al., 2024). Dataset terdiri dari 543 sampel audio yang terbagi ke dalam 7 kelas dengan distribusi yang tidak seimbang (*imbalanced data*), dengan rincian sebagai berikut:

Tabel 1. Sampel Dataset Audio Hewan Ternak

Hewan	Jumlah Sampel
Burung	200
Sapi	113
Kuda	99
Babi	39
Domba	39

Ayam	29
Keledai	24
Total	543


Untuk memastikan model dievaluasi secara objektif dan tidak sekedar menghafal, dataset dibagi menjadi Data Latih & Data Uji. Hasilnya, 434 data dialokasikan sebagai Data Latih untuk mengajari model dan 109 Data Uji untuk mengukur performa model pada tahap evaluasi.

Arsitektur Model


Model dikembangkan menggunakan arsitektur *Deep Learning* bertipe *Sequential* yang terdiri dari lapisan *Dense* tersembunyi berukuran 256, 128, dan 64 *neuron*, yang didukung oleh *Batch Normalization* dan *Dropout*. Pendekatan komputasi saraf (*neural network*) ini telah diakui sebagai metode standar yang sangat efektif untuk membedakan pola frekuensi yang kompleks dari vokalisasi hewan ternak, jauh mengungguli algoritma konvensional (Shafiruzzaman, et al., 2026). Pemilihan arsitektur jaringan yang relatif ringan (*lightweight*) ini juga sejalan dengan tuntutan modern pada riset *Precision Livestock Farming*, dimana model klasifikasi suara diharapkan tidak memakan beban komputasi berlebih agar siap diimplementasikan (*deployment*) menggunakan perangkat *edge* di lingkungan perternakan secara *real time* (Yang, Chen, Ma, M. Duarte, & Zhang, 2024).

Dinamika Pelatihan Model

Pelatihan model kita jadwalkan untuk berlangsung selama 100 epoch. Akan tetapi, mekanisme *Early Stopping* aktif dan menghentikan proses pelatihan pada epoch ke-65. Hal ini mengindikasikan bahwa model mencapai titik optimalnya sebelum epoch maksimum tercapai dan mencegah terjadinya *overfitting* lebih lanjut.



Gambar 4. Grafik *Training vs Validation Accuracy*



Gambar 5. Grafik *Training vs Validation Loss*

Dilihat dari grafik *Training vs Validation*, kurva akurasi dan loss menunjukkan pergerakan yang stabil (konvergen). Kurva validasi mengikuti kurva pelatihan dengan selisih yang wajar, membuktikan bahwa model dapat melakukan generalisasinya dengan baik pada data yang belum pernah model lihat sebelumnya.

Hasil Evaluasi Kinerja

Berdasarkan pengujian menggunakan 109 data uji, model menunjukkan kinerja dengan metrik evaluasi sebagai berikut:

- *Validation Accuracy*: 92.66%
- *VValidation Loss*: 0.2464
-

Tabel 2. Rincian Kinerja per kelas

Label	Precision	Recall	F1-Score	Jumlah Data Uji
Bird	0.95	0.97	0.96	40
Chicken	0.60	1.00	0.75	6
Cow	1.00	0.91	0.95	22
Donkey	1.00	0.80	0.89	5
Horse	1.00	0.90	0.95	20
Pig	0.86	0.75	0.80	8
Sheep	0.89	1.00	0.94	8
Rata-rata Akurasi			0.93	109


Analisis Matriks Kebingungan (*Confusion Matrix*)

Performa model dievaluasi lebih lanjut melalui *classification report* dan *confusion matrix*, sebagaimana disajikan pada Tabel 2 dan Gambar 4.

Tabel 3. Classification Report Hasil Klasifikasi Suara Hewan Ternak

Kelas	Precision	Recall	F1-Score	Support
Bird	0,95	0,97	0,96	40
Chicken	0,60	1,00	0,75	6
Cow	1,00	0,91	0,95	22
Donkey	1,00	0,80	0,89	5
Horse	1,00	0,90	0,95	20
Pig	0,86	0,75	0,80	8
Sheep	0,89	1,00	0,94	8
Accuracy			0,93	109
Macro avg	0,90	0,90	0,89	109
Wighted avg	0,94	0,93	0,93	109

Gambar 4. Confusion Matrix Hasil Klasifikasi Suara Hewan Ternak



Dari 109 data uji, model mencapai akurasi 92,66% dengan 101 prediksi benar dan 8 kesalahan klasifikasi: *Bird*→*Pig* (1), *Cow*→*Chicken* dan *Cow*→*Sheep* (masing-masing 1), *Donkey*→*Chicken* (1), *Horse*→*Bird* dan *Horse*→*Chicken* (masing-masing 1), serta *Pig*→*Bird* dan *Pig*→*Chicken* (masing-masing 1).

Temuan yang menonjol adalah kelas *Chicken*: *recall*-nya sempurna (1,00) namun *precision*-nya hanya 0,60, karena model kerap salah memprediksi suara *Cow*, *Donkey*, dan *Horse* sebagai *Chicken*. Pola ini konsisten dengan ketimpangan data latih, di mana *Chicken* dan *Donkey* hanya memiliki 29 dan 24 sampel jauh lebih sedikit dibandingkan *Bird* (200)

dan Cow (113). Kecenderungan kesalahan klasifikasi silang antar hewan berkaki empat (Cow, Horse, Donkey, Pig) juga sejalan dengan Jung et al. (2021), yang melaporkan bahwa fitur MFCC menghadapi tantangan ketika vokalisasi antar kelas memiliki rentang frekuensi fundamental yang berdekatan, sehingga model kesulitan membentuk *decision boundary* yang tegas terutama pada kelas dengan data latih terbatas. Hal ini menunjukkan bahwa class weighting saja belum cukup mengatasi *imbalanced dataset*; penambahan jumlah dan variasi sampel pada kelas minoritas tetap diperlukan untuk meningkatkan keandalan model.

Kesimpulan

Secara keseluruhan, model *Deep Learning* berbasis ekstraksi fitur MFCC dan Artificial Neural Network (ANN) yang dikembangkan pada penelitian ini telah berhasil dan layak digunakan untuk mengklasifikasikan suara hewan ternak. Model mampu mencapai akurasi validasi sebesar 92,66% (dibulatkan 93% pada evaluasi data uji) dan menunjukkan indikasi proses pembelajaran yang sehat, ditandai dengan kurva *validation loss* yang stabil tanpa tren peningkatan, sehingga tidak ditemukan indikasi *underfitting*, *overfitting* berlebih, maupun kebocoran data (*data leakage*). Kelemahan utama model terletak pada kelas dengan jumlah sampel minoritas, khususnya *chicken*, *donkey*, *pig*, dan *sheep*, yang menghasilkan *precision* atau *recall* lebih rendah dibandingkan kelas mayoritas akibat data latih yang tidak seimbang. Untuk pengembangan selanjutnya, performa kelas-kelas minoritas tersebut dapat ditingkatkan lebih lanjut dengan menambah proporsi sampel audio pada kelas-kelas tersebut agar distribusi dataset menjadi lebih seimbang, sehingga sistem klasifikasi suara ini semakin siap diterapkan sebagai modul pemantauan kondisi ternak secara *real-time*.

UCAPAN TERIMA KASIH

Ucapan terima kasih sebesar-besarnya ditujukan kepada semua pihak yang terlibat dalam pembuatan naskah ini, terutama kepada Bapak Hendry Setiawan, ST, M.Kom atas bimbingan yang telah diberikan mulai dari perencanaan program hingga penyusunan artikel ini. Ucapan terima kasih juga ditujukan kepada penyedia dana atau sponsor yang telah membantu mewujudkan terlaksananya penelitian ini dalam hal ini program studi Teknik Informatika Universitas Ma Chung.

DAFTAR PUSTAKA

- Jiang, B., Wenjie, T., Lihang, C., & Xiaoshang, D. (2023, June 24). *Precision Livestock Farming Research: A Global Scientometric Review*. Retrieved from mdpi.com: <https://www.mdpi.com/2076-2615/13/13/2096>
- Nazim Reza, M., Min-Gyeong, D., Jong-Bin, S., Minho, S., Sun-Ok, C., & Gookhwan, K. (2022, March 31). *Sound based approaches for pig diseases and crush symptoms monitoring in pig farms: a review*. Retrieved from researchgate.net:



https://www.researchgate.net/publication/364316163_Sound_based_approaches_for_pig_diseases_and_crush_symptoms_monitoring_in_pig_farms_a_review

Rohan, A., Saad Rafaq, M., Junayed Hasan, M., Asghar, F., Kashif Bashir, A., & Dottorini, T. (2024, June 27). *Application of deep learning for livestock behaviour recognition: A systematic literature review*. Retrieved from sciencedirect.com:

<https://www.sciencedirect.com/science/article/pii/S0168169924005064>

Shafiruzzaman, M., Hong-Seok, M., Eddiemar B, L., Md, K., Jin-Gu, K., Young-Hwa, K., . . . Chul-Ju, Y. (2026, January 18). *Advances in Audio Classification and Artificial Intelligence for Respiratory Health and Welfare Monitoring in Swine*. Retrieved from mdpi.com:

<https://www.mdpi.com/2079-7737/15/2/177>

Si, Q. (2024, April 29). *Advancements in Precision Livestock Farming: Technologies and Applications*. Retrieved from animalscipublisher.com:

<https://animalscipublisher.com/index.php/amb/article/html/3816/>

Yang, Q., Chen, X., Ma, C., M. Duarte, C., & Zhang, X. (2024, July 3). *Advanced Framework for Animal Sound Classification With Features Optimization*. Retrieved from arxiv.org:

<https://arxiv.org/abs/2407.03440>

Zhang, Q., Weihao, P., Hualong, L., Xiaobo, Z., Jun, J., Cheng, Z., & Qiang, Z. (2024, February 16). *Research on Pig Sound Recognition Based on Deep Neural Network and Hidden Markov Models*. Retrieved from mdpi.com: <https://www.mdpi.com/1424-8220/24/4/1269>



© 2026 by authors. Content on this article is licensed under a Creative Commons Attribution 4.0 International license. (<http://creativecommons.org/licenses/by/4.0/>).