

Evaluasi Kelayakan Penggunaan *Model Machine Learning* pada Klasifikasi Perilaku Ayam di Bawah Kondisi Suhu dan Kelembapan yang Bervariasi

Feasibility Evaluation of using Machine Learning Models on Chicken Behavior Classification under Varying Temperature and Humidity Conditions

Suhendra^{1,2*}, Firmansyah Firmansyah¹, Arina Fatharani¹, Yusuf Irfan¹

¹ Jurusan Teknologi Pertanian, Fakultas Pertanian, Universitas Bengkulu, Indonesia
²Departemen Program Doktor Internasional di Bidang Pertanian, Rekayasa Mekanika Bio-Industri, National Chung Hsing University, 145 Xingda Rd., Distrik Selatan, Taichung City 402, Taiwan

* Email: suhe@unib.ac.id

Naskah diterima: 15 Februari 2026; Naskah disetujui: 28 Juni 2026

ABSTRACT

This study investigates the application of machine learning models to classify chicken behaviors under varying temperature and humidity conditions, with the goal of optimizing poultry welfare and productivity through automated monitoring. The analysis focuses on key behaviors such as Resting, Feeding/Drinking, and Physical Activity, examining how environmental fluctuations influence chickens' physiological responses, particularly in thermoregulation. Over a 21-day observation period, data was collected from six chickens using temperature and humidity sensors, along with video recordings. A total of five machine learning models Random Forest, Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Multi-Layer Perceptron (MLP), and ensemble methods were tested to identify the most effective classifiers. The Random Forest model emerged as the top performer, achieving an accuracy of 98.65%, demonstrating its capability to effectively distinguish between different activities. Additionally, the findings emphasize the importance of incorporating real-time environmental data and enhancing feature extraction techniques to improve classification reliability. This study's insights contribute significantly to the development of adaptive smart monitoring systems, providing a foundation for future advancements in commercial poultry management by enabling timely welfare interventions and fostering efficient, welfare-oriented operations.

Keywords: Chicken Behavior, Machine Learning, Temperature, Humidity, Poultry Welfare

ABSTRAK

Penelitian ini mengkaji penerapan model pembelajaran mesin untuk mengklasifikasikan perilaku ayam pada kondisi suhu dan kelembapan yang bervariasi, dengan tujuan mengoptimalkan kesejahteraan dan produktivitas unggas melalui pemantauan otomatis. Analisis difokuskan pada perilaku utama seperti Beristirahat, Makan/Minum, dan Aktivitas Fisik, serta meneliti bagaimana fluktuasi lingkungan memengaruhi respons fisiologis ayam, khususnya dalam termoregulasi. Selama periode pengamatan selama 21 hari, data dikumpulkan dari enam ayam menggunakan sensor suhu dan kelembapan, disertai dengan rekaman video. Sebanyak lima model pembelajaran mesin diuji, yaitu *Random Forest*, *Support Vector Machine* (SVM), *K-Nearest Neighbors* (KNN), *Multi-Layer Perceptron* (MLP), dan metode *ensemble*, untuk mengidentifikasi model yang paling efektif di antara

lima model yang digunakan. Model *Random Forest* menunjukkan kinerja terbaik dengan akurasi sebesar 98,65%, membuktikan kemampuannya dalam membedakan berbagai aktivitas dengan efektif. Selain itu, temuan penelitian ini menekankan pentingnya mengintegrasikan data lingkungan secara *real-time* dan meningkatkan teknik ekstraksi fitur untuk meningkatkan keandalan klasifikasi. Wawasan dari penelitian ini berpotensi memberikan kontribusi terhadap pengembangan sistem pemantauan cerdas adaptif, meskipun masih memerlukan validasi lebih lanjut dengan jumlah sampel yang lebih besar, sekaligus menjadi landasan awal yang berpotensi mendukung kemajuan di masa depan dalam manajemen unggas komersial dengan memungkinkan intervensi kesejahteraan yang tepat waktu dan mendukung operasi yang efisien serta berorientasi pada kesejahteraan.

Kata kunci: Kelembapan, Kesejahteraan Unggas, Pembelajaran Mesin, Perilaku Ayam, Suhu

PENDAHULUAN

Analisis perilaku ayam dalam peternakan unggas merupakan hal yang mendasar untuk mengoptimalkan produktivitas dan memastikan kesejahteraan hewan, khususnya di bawah kondisi lingkungan yang berubah-ubah seperti suhu dan kelembapan. Fluktuasi lingkungan dapat memberikan dampak yang signifikan terhadap kesehatan dan produktivitas ayam. Suhu yang tinggi, misalnya, dapat menyebabkan stres panas, yang mengakibatkan penurunan konsumsi pakan, laju pertumbuhan yang lebih lambat, serta penurunan produksi telur, disertai dengan peningkatan risiko kematian (Hemant *et al.*, 2024; Kim *et al.*, 2024; Quintana-ospina *et al.*, 2023). Indikator perilaku seperti pernapasan dengan paruh terbuka dan gerakan seperti tersedak merupakan tanda stres panas dan memberikan peluang untuk melakukan intervensi secara tepat waktu (Yu *et al.*, 2023). Pola harian dalam makan, minum, dan beristirahat juga memberikan wawasan mengenai kesehatan ayam, karena penyimpangan dari pola tersebut sering kali menunjukkan adanya stres atau penyakit, sehingga memerlukan respons segera untuk mencegah penurunan produktivitas (Guo *et al.*, 2022).

Meskipun telah ada upaya penelitian yang signifikan dalam bidang kesejahteraan dan produktivitas unggas, sebagian besar studi sebelumnya (Pearce *et al.*, 2024; Fujinami *et al.*, 2023; Guo *et al.*, 2022) dilakukan pada kondisi lingkungan yang konstan atau hanya menggunakan sensor gerak. Kebaruan penelitian ini terletak pada penggunaan data suhu dan kelembapan yang bervariasi secara dinamis sebagai fitur utama klasifikasi, yang secara khusus meneliti perilaku ayam di bawah kondisi suhu dan kelembapan yang berubah secara dinamis. Untuk mengatasi kesenjangan ini, penelitian ini menyelidiki pengaruh variabilitas lingkungan terhadap perilaku penting seperti beristirahat, makan/minum, dan aktivitas fisik. Berdasarkan literatur yang ada, model seperti *Random Forest* telah menunjukkan

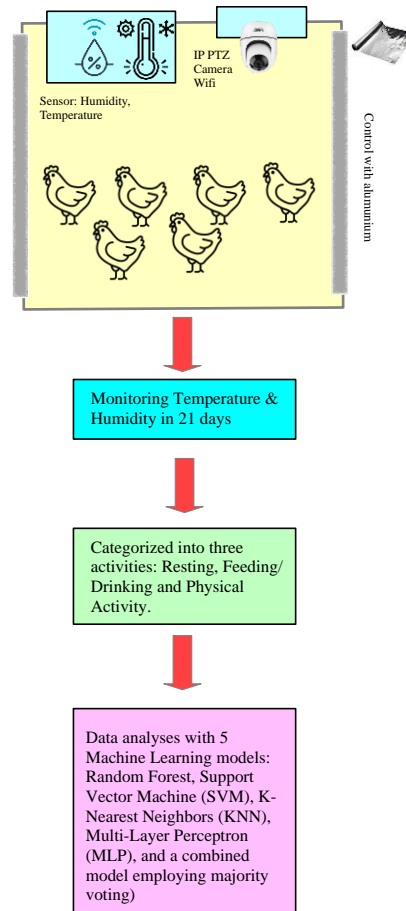
kemampuan kompetitif dalam mengklasifikasikan perilaku hewan (Pearce et al., 2024; Bergen et al., 2023), sehingga menjadi kandidat potensial yang dievaluasi dalam penelitian ini. Dengan memanfaatkan model canggih ini untuk klasifikasi perilaku, penelitian ini meletakkan dasar yang kuat bagi pengembangan sistem pemantauan cerdas yang mampu menyesuaikan pengendalian lingkungan secara dinamis. Sistem semacam ini diharapkan dapat meningkatkan kesejahteraan, memperbaiki produktivitas, dan menurunkan tingkat kematian di kandang unggas komersial. Dengan demikian, pendekatan dalam studi ini merupakan kemajuan penting dalam manajemen unggas yang adaptif, serta memberikan wawasan esensial bagi inovasi di masa depan dalam pengembangan sistem *real-time* yang responsif terhadap kondisi dan mampu memenuhi kebutuhan unggas yang kompleks di lingkungan yang terus berubah.

METODE PENELITIAN

Penelitian ini mengamati perilaku ayam selama periode 21 hari di dalam kandang berukuran 1×1 meter yang dilengkapi dengan sensor suhu dan kelembapan, dengan pencatatan data secara kontinu setiap 10 menit. Kandang tersebut sengaja dilapisi aluminium untuk memanipulasi dan meningkatkan fluktuasi lingkungan, sehingga memungkinkan analisis yang lebih rinci mengenai pengaruh kondisi yang bervariasi terhadap perilaku ayam. Enam ekor ayam jantan tipe petelur (layer-type male) diamati, dan sebuah kamera CCTV merekam aktivitasnya selama siklus 24 jam, dengan fokus pada perilaku yang dikategorikan ke dalam tiga aktivitas utama: beristirahat (1), makan/minum (2), dan aktivitas fisik (3). Dataset penelitian terdiri dari seluruh data suhu dan kelembapan yang dikumpulkan selama 21 hari dengan interval 10 menit, menghasilkan 3.024 titik data pengukuran lingkungan yang disertai dengan anotasi perilaku. Data tersebut kemudian dinormalisasi untuk memastikan representasi kondisi lingkungan yang akurat dan dibagi dengan rasio 70:30 untuk pelatihan dan pengujian model.

Analisis ini menggunakan lima model pembelajaran mesin, yaitu *Random Forest*, SVM, KNN, MLP, serta model gabungan yang menerapkan metode majority voting. Pemilihan kelima model tersebut didasarkan pada keragaman pendekatan algoritma, mulai dari model berbasis pohon keputusan (Random Forest), margin klasifikasi (SVM), berbasis jarak (KNN), hingga jaringan saraf tiruan (MLP), guna memungkinkan evaluasi komparatif yang komprehensif (Bergen et al., 2023; Pearce et al., 2024). Data suhu dan kelembapan yang bersifat kontinu, bersama dengan hasil pengamatan perilaku, digunakan sebagai fitur masukan untuk pelatihan model, dengan pembagian data sebesar 70% untuk pelatihan dan

30% untuk pengujian (train:test = 70:30). Kinerja model dievaluasi berdasarkan beberapa metrik, termasuk akurasi, presisi, recall, dan skor F1. Pendekatan metodologis ini bertujuan untuk memperoleh pemahaman mengenai hubungan antara faktor lingkungan dan aktivitas ayam, sekaligus menyediakan kerangka kerja yang kuat untuk pengambilan keputusan berbasis data dalam manajemen peternakan unggas.



Gambar 1. Desain penelitian pengamatan aktivitas ayam

HASIL DAN PEMBAHASAN

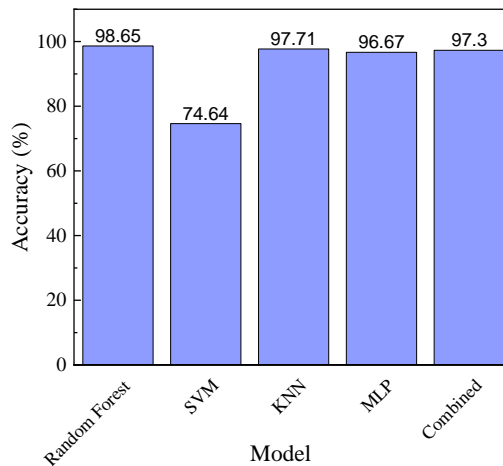
Analisis Kinerja Model

Tahapan ini menyajikan evaluasi rinci terhadap kinerja berbagai model pembelajaran mesin yang digunakan untuk mengklasifikasikan aktivitas ayam berdasarkan faktor lingkungan seperti suhu dan kelembapan. Model yang dievaluasi meliputi *Random Forest*, *Support Vector Machine (SVM)*, *K-Nearest Neighbors (KNN)*, dan *Multi-Layer Perceptron (MLP)*. Pemahaman terhadap tingkat akurasi model-model ini sangat penting untuk meningkatkan praktik manajemen peternakan unggas. Aktivitas ayam dikategorikan ke dalam tiga kelas: Kelas 1 mewakili aktivitas beristirahat, Kelas 2 berkaitan dengan

makan/minum, dan Kelas 3 menunjukkan aktivitas fisik.

Model *Random Forest* muncul sebagai model dengan kinerja terbaik, dengan mencapai tingkat akurasi sebesar 98,65% pada data uji. Tingginya nilai akurasi ini perlu diinterpretasikan secara hati-hati mengingat ukuran sampel yang relatif terbatas (6 ekor ayam), dan validasi pada dataset independen yang lebih besar disarankan untuk mengonfirmasi keandalan model serta menghindari potensi overfitting. Akurasi yang tinggi ini menunjukkan bahwa model tersebut mampu secara efektif mengidentifikasi dan membedakan berbagai aktivitas ayam di bawah kondisi lingkungan yang bervariasi. Model SVM, meskipun dikenal efektif dalam menangani data berdimensi tinggi, menunjukkan akurasi yang lebih rendah yaitu 74,64%, yang mengindikasikan adanya tantangan dalam membedakan aktivitas ayam dibandingkan dengan model lainnya. KNN menunjukkan kinerja yang sangat baik dengan akurasi sebesar 97,71%, serta mampu beradaptasi dengan cepat terhadap kondisi yang berubah-ubah. Sementara itu, MLP mencapai akurasi 96,67%, mampu memodelkan hubungan nonlinier yang kompleks dalam data, namun kinerjanya sedikit lebih rendah dibandingkan Random Forest dan KNN.

Selain akurasi keseluruhan, metrik presisi, recall, dan skor F1 juga dianalisis untuk setiap kelas guna memahami kinerja model. Model Random Forest menunjukkan hasil yang kuat, khususnya pada Kelas 1 (beristirahat) dengan presisi 0,95 dan recall 0,98, serta pada Kelas 2 (makan/minum) dengan presisi 0,94 dan recall 0,88. KNN juga mempertahankan presisi dan recall yang tinggi di seluruh kelas, yang menunjukkan efektivitasnya dalam menangkap perilaku istirahat dan secara akurat mengidentifikasi aktivitas makan/minum. MLP, meskipun secara keseluruhan berkinerja baik, mengalami kesulitan pada Kelas 3, dengan mencapai presisi sempurna namun recall yang rendah sebesar 0,48. Temuan ini menegaskan pentingnya pemilihan model dalam konteks pertanian, di mana pemahaman terhadap perilaku hewan dapat mendukung praktik manajemen yang lebih baik serta meningkatkan kesejahteraan hewan.



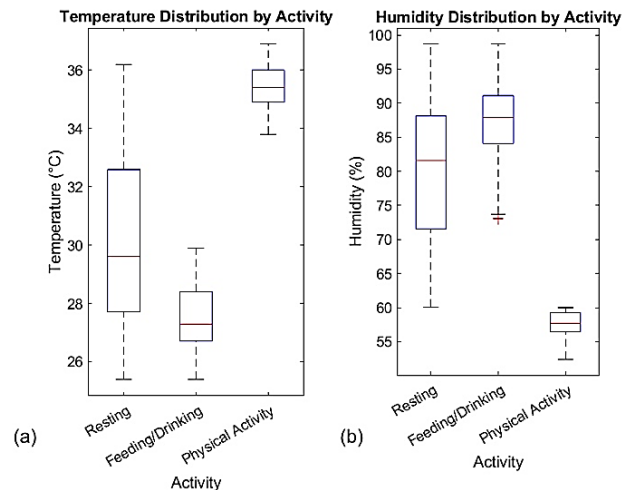
Gambar 2. Akurasi Model

Tabel 1. Komposisi Larutan Pewarna Kombinasi

<i>Model</i>	<i>Accuracy (%)</i>	<i>Class</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Random Forest</i>	98,65	Class 1	0,95	0,98	0,96
		Class 2	0,94	0,88	0,91
		Class 3	1,00	0,85	0,92
<i>SVM</i>	74,64	Class 1	0,72	1,00	0,84
		Class 2	NaN	0,00	NaN
		Class 3	1,00	0,81	0,90
<i>KNN</i>	97,71	Class 1	0,96	0,97	0,97
		Class 2	0,93	0,91	0,92
		Class 3	1,00	0,85	0,92
<i>MLP</i>	96,67	Class 1	0,92	0,98	0,95
		Class 2	0,95	0,85	0,89
		Class 3	1,00	0,48	0,65

Distribusi Perilaku pada Berbagai Kondisi Lingkungan

Diagram kotak (*box plot*) yang disajikan pada Gambar 3(a) dan (b) menggambarkan distribusi tingkat suhu dan kelembapan yang terkait dengan tiga aktivitas utama ayam, yaitu beristirahat, makan/minum, dan aktivitas fisik. Gambar 3(a) menunjukkan bahwa ayam yang sedang beristirahat memiliki preferensi suhu median sekitar 30°C, yang mengindikasikan kenyamanan mereka pada kondisi yang sedikit lebih hangat. Sebaliknya, ayam yang sedang makan/minum menunjukkan suhu median yang lebih rendah, sekitar 28°C, sedangkan ayam yang melakukan aktivitas fisik memiliki rentang suhu yang lebih sempit, yang mengisyaratkan preferensi terhadap lingkungan yang lebih sejuk saat aktif. Adaptasi perilaku ini penting untuk pengelolaan stres panas serta untuk mengoptimalkan respons fisiologis ayam terhadap variasi suhu.



Gambar 3. Distribusi perilaku ayam berdasarkan (a) suhu; (b) kelembapan

Gambar 3(b) menyoroti kecenderungan hubungan (perlu dikonfirmasi melalui uji statistik seperti ANOVA atau Kruskal-Wallis beserta uji lanjutan yang sesuai) antara tingkat kelembapan dan aktivitas ayam, yang menunjukkan bahwa ayam yang sedang beristirahat mengalami tingkat kelembapan yang lebih tinggi, dengan rata-rata sekitar 90%. Sebaliknya, tingkat kelembapan pada ayam yang melakukan aktivitas makan/minum dan aktivitas fisik menurun hingga sekitar 75%. Temuan ini menegaskan peran penting kelembapan dalam memengaruhi perilaku ayam, di mana peningkatan kelembapan berkaitan dengan kondisi istirahat. Perilaku yang diamati ini dapat dijelaskan secara konseptual melalui prinsip keseimbangan panas termoregulasi yang diadaptasi dari Brugaletta et al. (2022). Perlu dicatat bahwa persamaan berikut digunakan sebagai kerangka konseptual dan bukan sebagai model analitik dalam penelitian ini:

$$Q_{total} = Q_{metabolic} - (Q_{convective} + Q_{evaporative})$$

Persamaan ini menjelaskan adaptasi fisiologis yang diamati pada ayam. Sebagai contoh, perilaku minum meningkat pada kondisi kelembapan tinggi, di mana berkurangnya pendinginan melalui penguapan ($Q_{evaporative}$) menuntut peningkatan asupan air untuk mempertahankan tingkat hidrasi. Demikian pula, aktivitas fisik yang menghasilkan panas metabolik ($Q_{metabolic}$) cenderung terjadi pada kondisi yang lebih sejuk untuk mengimbangi pelepasan panas. Pemahaman mengenai keterkaitan antara suhu, kelembapan, dan aktivitas ayam ini sangat penting dalam manajemen peternakan unggas, karena dapat meningkatkan kesejahteraan dan produktivitas melalui praktik pengelolaan lingkungan yang disesuaikan dengan kebutuhan termoregulasi ayam.

Wawasan Model dalam Kaitannya dengan Kondisi Lingkungan

Evaluasi berbagai model pembelajaran mesin untuk mengklasifikasikan perilaku

ayam di bawah kondisi lingkungan yang bervariasi menghasilkan temuan penting terkait kinerja model dan akurasi klasifikasi. Di antara model yang diuji, model Random Forest menunjukkan akurasi tertinggi sebesar 98,65%, yang mencerminkan kemampuannya dalam mengklasifikasikan perilaku tertentu secara efektif di tengah fluktuasi faktor lingkungan, khususnya suhu dan kelembapan. Hasil ini sejalan dengan analisis metrik kinerja model, di mana Random Forest memperlihatkan nilai presisi dan recall yang kuat untuk Kelas 1 (beristirahat), masing-masing sebesar 0,95 dan 0,98. Metrik tersebut menegaskan efektivitas model dalam membedakan perilaku istirahat, yang penting untuk memahami respons ayam terhadap tekanan lingkungan.

Sebaliknya, perilaku seperti minum dan makan/minum menunjukkan tantangan klasifikasi yang cukup nyata. Meskipun model mencapai akurasi keseluruhan yang baik, perilaku minum menghadapi kesulitan, terutama pada *model Multi-Layer Perceptron* (MLP), yang melaporkan nilai recall rendah sebesar 0,48 untuk Kelas 3 (aktivitas fisik). Perbedaan ini menyoroti adanya kemiripan halus antara aktivitas dengan gerakan rendah seperti beristirahat dan minum, yang sering menyebabkan salah klasifikasi; bahkan, perilaku minum salah diklasifikasikan sebagai beristirahat pada 26,2% kasus. Studi sebelumnya menunjukkan bahwa model *Random Forest* cenderung mengalami kesulitan dalam membedakan aktivitas dengan gerakan rendah akibat kemiripan pembacaan sensor antara perilaku beristirahat dan minum (Pearce *et al.*, 2024). Model YOLO-HGP, yang efektif dalam mendeteksi perilaku stres panas, semakin menegaskan kompleksitas dalam mengklasifikasikan secara akurat perilaku halus dengan pergerakan minimal seperti beristirahat dan minum (Yu *et al.*, 2023). Selain itu, evaluasi model Narrow Neural Network, yang mencapai nilai AUC maksimum sebesar 0,6554 untuk klasifikasi aktivitas fisik, mendukung efektivitas model pembelajaran mesin dalam membedakan perilaku tersebut, sebagaimana tercermin dari tingginya nilai *Multi-Object Tracking Accuracy* (MOTA) pada model YOLOv8 dalam aktivitas fisik yang serupa (Yang *et al.*, 2016, 2024). Faktor lingkungan seperti suhu dan kelembapan semakin menambah variabilitas, sehingga mempersulit prediksi yang konsisten di tengah kondisi yang berfluktuasi (Massari *et al.*, 2024). Oleh karena itu, meskipun akurasi keseluruhan yang tinggi telah dicapai, kompleksitas perilaku tertentu masih memerlukan eksplorasi lebih lanjut serta penyempurnaan pendekatan model guna meningkatkan keandalan klasifikasi.

Respons Termoregulasi

Memahami perilaku ayam di bawah kondisi suhu dan kelembapan yang bervariasi sangat penting untuk mengoptimalkan kesejahteraan dan produktivitas. Model

pembelajaran mesin berperan penting dalam mengklasifikasikan perilaku seperti minum, beristirahat, dan aktivitas fisik, yang mencerminkan adaptasi termoregulasi ayam untuk mempertahankan keseimbangan panas tubuh. Berdasarkan keseimbangan panas termoregulasi, ayam menyesuaikan perilakunya sebagai respons terhadap tekanan lingkungan. Sebagai contoh, perilaku minum meningkat pada kondisi kelembapan tinggi, ketika berkurangnya pendinginan melalui penguapan ($Q_{evaporative}$) menuntut peningkatan asupan air untuk menjaga tingkat hidrasi (Massari *et al.*, 2024; Solis *et al.*, 2024). Perilaku beristirahat menjadi lebih sering terjadi pada kondisi yang lembap, sehingga ayam dapat menghemat energi dan menghindari produksi panas metabolik tambahan yang dapat memperburuk ketidaknyamanan termal (Hemanth *et al.*, 2024; Massari *et al.*, 2024).

Pada suhu yang lebih rendah, ayam cenderung melakukan aktivitas fisik untuk menghasilkan panas metabolik ($Q_{metabolic}$), yang membantu mengimbangi kehilangan panas dan mendukung proses termoregulasi. Perilaku ini selaras dengan prinsip kehilangan panas secara konvektif, di mana peningkatan gerakan memperlancar aliran darah dan distribusi panas yang diperlukan untuk menjaga kestabilan termal pada kondisi yang lebih dingin (Hemanth *et al.*, 2024). Model pembelajaran mesin, seperti YOLO-HGP dan termografi inframerah, telah terbukti efektif dalam mendeteksi respons stres seperti pernapasan dengan paruh terbuka, yang penting untuk menilai kesejahteraan ayam di bawah kondisi stres panas (Solis *et al.*, 2024; Yu *et al.*, 2023). Integrasi sensor yang dapat dikenakan dengan model seperti random forest meningkatkan akurasi dalam melacak perilaku termoregulasi pada berbagai kondisi lingkungan yang berubah-ubah (Fujinami *et al.*, 2023; Sozzi *et al.*, 2023).

Suhu dan kelembapan yang moderat juga mendukung peningkatan interaksi sosial, karena berkurangnya stres termal memungkinkan ayam terlibat dalam perilaku non-termoregulasi, yang menunjukkan bahwa kondisi lingkungan yang optimal mendorong keseimbangan fisiologis sekaligus kesejahteraan sosial (Evans *et al.*, 2023; Massari *et al.*, 2024). Variasi genetik, seperti ketahanan ayam Naked Neck terhadap panas, menunjukkan bahwa penggabungan seleksi genetik dengan manajemen perilaku dapat semakin meningkatkan kemampuan adaptasi terhadap stres termal (Hemanth *et al.*, 2024). Model canggih seperti CNN dan *random forest* memungkinkan klasifikasi perilaku sosial secara *real-time*, yang penting untuk mendukung kesejahteraan sosial ayam dalam lingkungan yang mendukung (Solis *et al.*, 2024).

Suhu ekstrem berdampak signifikan terhadap perilaku ayam, di mana suhu tinggi memicu respons stres panas seperti terengah-engah (*panting*) untuk membantu melepaskan panas (Brugaletta *et al.*, 2022). Sebaliknya, suhu yang lebih rendah menuntut peningkatan

aktivitas fisik untuk menghasilkan panas, meskipun hal ini memerlukan biaya energi yang tinggi. Penyesuaian kondisi lingkungan serta penerapan model pembelajaran mesin yang canggih dapat meningkatkan manajemen peternakan unggas yang berorientasi pada kesejahteraan, sehingga memastikan adaptasi yang efektif terhadap tantangan termal (Akter *et al.*, 2022; Fernandes *et al.*, 2023). Wawasan mengenai termoregulasi ini tidak hanya memvalidasi prediksi model, tetapi juga menawarkan strategi penting untuk meningkatkan kesejahteraan unggas dan praktik manajemen peternakan.

Temuan dari penelitian ini menyoroti efektivitas model pembelajaran mesin dalam mengklasifikasikan perilaku ayam di bawah kondisi suhu dan kelembapan yang bervariasi, serta memberikan wawasan yang berharga bagi manajemen peternakan unggas. Model pembelajaran mesin menunjukkan potensi yang signifikan dalam mengklasifikasikan perilaku ayam pada berbagai kondisi lingkungan, terutama unggul dalam mengidentifikasi perilaku dengan tingkat pergerakan tinggi seperti aktivitas fisik dan minum. Model seperti XGBoost dan CNN dikenal memiliki akurasi dan efisiensi yang baik, dengan XGBoost menunjukkan kinerja yang kuat pada dataset berukuran besar (Bergen *et al.*, 2023) serta YOLOv8 yang dikombinasikan dengan DeepSORT mencapai tingkat *Multi-Object Tracking Accuracy* (MOTA) sebesar 94% (Yang *et al.*, 2016). Model random forest yang diterapkan pada data akselerometer telah menunjukkan kemampuan adaptasi pada berbagai strain ayam pedaging, yang semakin menegaskan ketangguhan model tersebut (Pearce *et al.*, 2024). Selain itu, model yang memanfaatkan sensor inersial yang dapat dikenakan serta arsitektur CNN canggih seperti DenseNet-264 memberikan akurasi tinggi untuk perilaku dinamis, sehingga meningkatkan konsistensi klasifikasi di berbagai kelompok umur (Fujinami *et al.*, 2023; Guo *et al.*, 2022).

Namun, perilaku dengan pergerakan rendah seperti beristirahat dan interaksi sosial menimbulkan tantangan dalam klasifikasi karena gerakannya yang halus serta tumpang tindih sinyal sensor, terutama pada kondisi lingkungan yang serupa. Model seperti KNN dan SVM sering mengalami kesulitan dalam hal sensitivitas untuk mendeteksi perilaku-perilaku tersebut (Yang *et al.*, 2021). Faktor lingkungan seperti stres panas dan variasi kecepatan aliran udara dapat semakin mengubah perilaku-perilaku tersebut, sehingga mempersulit klasifikasi yang akurat (Akter *et al.*, 2022; Massari *et al.*, 2024). Meningkatkan sensitivitas sensor, khususnya pada akselerometer, dapat memperbaiki akurasi deteksi untuk perilaku-perilaku halus tersebut (Fujinami *et al.*, 2023; Pearce *et al.*, 2024).

Mengintegrasikan data lingkungan secara *real-time*, termasuk jejak termal dari termografi inframerah, juga menunjukkan potensi yang besar dalam mengidentifikasi

perilaku stres panas secara akurat, sehingga meningkatkan kemampuan adaptasi model pada kondisi yang berfluktuasi (Solis *et al.*, 2024). Model pembelajaran mendalam tingkat lanjut seperti YOLO-HGP, yang menunjukkan akurasi yang lebih baik dalam mendeteksi perilaku halus, memberikan potensi tambahan untuk meningkatkan klasifikasi dengan menangkap fitur perilaku yang lebih bernuansa secara lebih efektif (Yan *et al.*, 2024). Integrasi teknologi sensor yang ditingkatkan dengan pendekatan pemodelan canggih ini tidak hanya akan memperkuat keandalan klasifikasi perilaku pada berbagai kondisi, tetapi juga mendukung manajemen peternakan unggas serta pemantauan kesejahteraan yang lebih efektif di beragam lingkungan, yang pada akhirnya mengarah pada peningkatan kesejahteraan hewan.

Keterbatasan Penelitian dan Rekomendasi Penelitian Selanjutnya

Penelitian ini mengidentifikasi kesenjangan kritis dalam penelitian terkait perilaku ayam sebagai respons terhadap fluktuasi lingkungan, sekaligus membangun dasar yang kuat untuk investigasi lebih lanjut di bidang ini. Model-model yang dievaluasi menunjukkan tingkat akurasi yang tinggi, dengan model Random Forest mencapai 98,65%, yang menandakan kemampuan signifikan dalam mengklasifikasikan aktivitas ayam pada kondisi suhu dan kelembapan yang bervariasi. Penelitian di masa depan sebaiknya fokus pada peningkatan kinerja model lebih lanjut dengan menyempurnakan arsitektur dan memperluas cakupan data lingkungan yang dikumpulkan, terutama untuk meningkatkan klasifikasi perilaku halus seperti Beristirahat dan Interaksi Sosial, yang menimbulkan tantangan lebih besar pada analisis saat ini.

Mengintegrasikan teknik-teknik canggih, termasuk metode deteksi objek dan karakterisasi seperti YOLOv8 untuk *computer vision*, dapat secara substansial meningkatkan akurasi prediktif dengan memfasilitasi pemantauan dan analisis berkelanjutan terhadap seluruh aktivitas ayam sepanjang hari. Pengumpulan data yang mendetail tersebut tidak hanya memungkinkan pemahaman yang lebih mendalam mengenai pola perilaku, tetapi juga mendukung pengembangan sistem manajemen unggas otomatis yang mutakhir. Sistem ini dapat menyesuaikan kondisi lingkungan secara dinamis dalam waktu nyata (*real-time*), mengoptimalkan kesejahteraan sekaligus produktivitas berdasarkan kebutuhan spesifik ayam dalam berbagai kondisi. Selain itu, untuk penelitian selanjutnya disarankan untuk mengeksplorasi penerapan Independent Component Analysis (ICA), Principal Component Analysis (PCA), atau Probabilistic Principal Component Analysis (PPCA) sebagai metode ekstraksi fitur sebelum tahap klasifikasi, guna

meningkatkan kemampuan model dalam memisahkan sinyal perilaku yang independen serta mengurangi potensi overfitting. Dengan memanfaatkan teknologi ini, manajemen unggas dapat beralih ke praktik yang lebih efisien dan responsif, yang pada akhirnya mengarah pada peningkatan standar kesejahteraan hewan dan efisiensi operasional dalam skala komersial.

KESIMPULAN

Penelitian ini memberikan gambaran yang sangat menarik tentang bagaimana teknologi *Machine Learning* (ML) dapat secara positif mendukung pengelolaan cara kita mengelola peternakan. Berikut adalah terjemahan dalam bahasa Indonesia yang tetap menjaga nuansa teknis dan formalnya: Studi ini menyoroti peran krusial machine learning dalam mengklasifikasikan perilaku ayam secara efektif di bawah berbagai kondisi lingkungan, serta menunjukkan potensi signifikannya untuk meningkatkan kesejahteraan dan produktivitas unggas. Dengan menganalisis perilaku kunci termasuk Istirahat, Makan/Minum, dan Aktivitas Fisik yang dikaitkan dengan perubahan suhu dan kelembapan, penelitian ini menekankan bagaimana *machine learning* dapat memberikan wawasan tepat waktu mengenai *respons termoregulasi* ayam. Hal ini memfasilitasi intervensi manajemen adaptif yang mendukung kesejahteraan hewan. Model *Random Forest* dalam studi ini mencapai akurasi yang luar biasa sebesar 98,65%, menunjukkan ketangguhannya dalam membedakan berbagai aktivitas. Namun, tantangan yang dihadapi dalam mengklasifikasikan perilaku dengan pergerakan rendah seperti Istirahat dan Interaksi Sosial menjadi area kritis untuk perbaikan di masa depan. Temuan ini meletakkan landasan yang kokoh bagi pengembangan sistem pemantauan otomatis yang cerdas dan mampu merespons perubahan lingkungan secara dinamis. Penelitian selanjutnya harus fokus pada peningkatan sensitivitas model, penyempurnaan teknik ekstraksi fitur, dan integrasi umpan balik lingkungan secara *real-time* untuk meningkatkan adaptivitas sistem, sehingga membuka jalan bagi manajemen kesejahteraan hewan yang efektif di peternakan komersial.

DAFTAR PUSTAKA

Akter, S., Cheng, B., West, D., Liu, Y., Qian, Y., Zou, X., Classen, J., Cordova, H., Oviedo, E., & Wang-li, L. (2022). Impacts of Air Velocity Treatments under Summer Condition: Part I — Heavy Broiler' s Surface Temperature

- Response. *Animals*, *12*(3), 1–18.
<https://doi.org/https://doi.org/10.3390/ani12030328>
- Bergen, S., Huso, M. M., Duerr, A. E., Braham, M. A., Schmuecker, S., Miller, T. A., Katzner, T. E., & Bergen, S. (2023). A review of supervised learning methods for classifying animal behavioural states from environmental features. *Methods in Ecology and Evolution*, *14*(1), 189–202.
<https://doi.org/10.1111/2041-210X.14019>
- Brugaletta, G., Teyssier, J., Rochell, S. J., Dridi, S., & Sirri, F. (2022). A review of heat stress in chickens. Part I: Insights into physiology and gut health. *Frontiers in Physiology*, *13*, 1–15.
<https://doi.org/10.3389/fphys.2022.934381>
- Evans, L., Brooks, G. C., Anderson, M. G., Campbell, A. M., & Jacobs, L. (2023). Environmental Complexity and Reduced Stocking Density Promote Positive Behavioral Outcomes in Broiler Chickens. *Animals*, *13*(13), 1–17.
<https://doi.org/https://doi.org/10.3390/ani13132074>
- Fernandes, E., Raymundo, A., Martins, L. L., Lordelo, M., & Almeida, A. M. de. (2023). The Naked Neck Gene in the Domestic Chicken : A Genetic Strategy to Mitigate the Impact of Heat Stress in Poultry Production — A Review. *Animals*, *13*(6), 1–15. <https://doi.org/https://doi.org/10.3390/ani13061007>
- Fujinami, K., Takuno, R., Sato, I., & Shimmura, T. (2023). Evaluating Behavior Recognition Pipeline of Laying Hens. *Sensors*, *23*(11), 1–27.
<https://doi.org/https://doi.org/10.3390/s23115077>
- Guo, Y., Aggrey, S. E., Wang, P., & Oladeinde, A. (2022). Monitoring Behaviors of Broiler Chickens at Different Ages with Deep Learning. *Animals*, *12*(23), 1–12. <https://doi.org/https://doi.org/10.3390/ani12233390>
- Hemanth, M., Venugopal, S., Devaraj, C., Shashank, C. G., Ponnuvel, P., Mandal, P. K., & Sejian, V. (2024). Comparative assessment of growth performance, heat resistance and carcass traits in four poultry genotypes reared in hot-humid tropical environment. *Journal of Animal Physiology and Animal Nutrition*, *108*(5), 1510–1523.
<https://doi.org/https://doi.org/10.1111/jpn.13994>Digital Object Identifier (DOI)
- Kim, H., Ryu, C., Lee, S., Cho, J., & Kang, H. (2024). Effects of Heat Stress on the Laying Performance, Egg Quality, and Physiological Response of Laying Hens. *Animals*, *14*(1076), 1–12.
<https://doi.org/https://doi.org/10.3390/ani14071076>
- Massari, J. M., Moura, D. J. De, Nääs, I. D. A., Pereira, D. F., Robson, S., Oliveira, D. M., Branco, T., Souza, J. De, & Barros, G. (2024). Sequential Behavior of Broiler Chickens in Enriched Environments under Varying Thermal Conditions Using the Generalized Sequential Pattern Algorithm : A Proof of

- Concept. *Animals*, 14(13), 1–14.
<https://doi.org/https://doi.org/10.3390/ani14132010>
- Pearce, J., Chang, Y., Xia, D., & Abeyesinghe, S. (2024). Classification of Behaviour in Conventional and Slow-Growing Strains of Broiler Chickens Using Tri-Axial Accelerometers. *Animals*, 14(13), 1–21.
<https://doi.org/https://doi.org/10.3390/ani14131957>
- Quintana-ospina, G. A., Alfaro-wisaquillo, M. C., Oviedo-rondon, E. O., Ruiz-ramirez, J. R., Bernal-arango, L. C., & Martinez-bernal, G. D. (2023). Effect of Environmental and Farm-Associated Factors on Live Tropical Conditions. *Animals*, 13(3312), 1–21.
<https://doi.org/https://doi.org/10.3390/ani13213312>
- Solis, I. L., Oliveira-boreli, F. P. De, Sousa, R. V. De, Martello, L. S., & Pereira, D. F. (2024). Using Thermal Signature to Evaluate Heat Stress Levels in Laying Hens with a Machine-Learning-Based Classifier. *Animals*, 14(13), 1–12. <https://doi.org/https://doi.org/10.3390/ani14131996>
- Sozzi, M., Pillan, G., Ciarelli, C., Marinello, F., Pirrone, F., Bordignon, F., Bordignon, A., Xiccato, G., & Trocino, A. (2023). Measuring Comfort Behaviours in Laying Hens Using Deep-Learning Tools. *Animals*, 13(1), 1–11. <https://doi.org/https://doi.org/10.3390/ani13010033>
- Yan, Y., Sheng, Z., Gu, Y., Heng, Y., Zhou, H., & Wang, S. (2024). Research note : A method for recognizing and evaluating typical behaviors of laying hens in a thermal environment. *Poultry Science*, 103(11), 1–6.
<https://doi.org/10.1016/j.psj.2024.104122>
- Yang, X., Bist, R. B., Paneru, B., & Chai, L. (2024). Deep Learning Methods for Tracking the Locomotion of Individual Chickens. *Animals*, 14(6), 1–13.
<https://doi.org/https://doi.org/10.3390/ani14060911>
- Yang, X., Bist, R., Paneru, B., & Chai, L. (2016). Monitoring activity index and behaviors of cage-free hens with advanced deep learning technologies. *Poultry Science*, 103(11), 104193. <https://doi.org/10.1016/j.psj.2024.104193>
- Yang, X., Zhao, Y., Street, G. M., Huang, Y., To, S. D. F., & Purswell, J. L. (2021). Animal The international journal of animal biosciences Classification of broiler behaviours using triaxial accelerometer and machine learning. *Animal*, 15(7), 1–11. <https://doi.org/10.1016/j.animal.2021.100269>
- Yu, Z., Liu, L., Jiao, H., & Chen, J. (2023). Leveraging SOLOv model to detect heat stress of poultry in complex environments. *Frontiers in Venterinary Science*, 9, 1–13. <https://doi.org/https://doi.org/10.3389/fvets.2022.1062559>