

Pendekatan Algoritma Tree dalam Prediksi Populasi pada Smart Poultry

Nicolaus Euclides Wahyu Nugroho¹, Nur Ghaniaviyanto Ramadhan², Merlinda Wibowo³, Sigit Pramono^{4,*}

^{1,3}Fakultas Informatika, Informatika, Institut Teknologi Telkom Purwokerto, Indonesia

²Fakultas Informatika, Rekayasa Perangkat Lunak, Institut Teknologi Telkom Purwokerto, Indonesia

⁴Fakultas Teknik Telekomunikasi dan Elektro, Teknik Telekomunikasi, Institut Teknologi Telkom Purwokerto, Indonesia

Email: ¹nico@ittelkom-pwt.ac.id, ²ghani@ittelkom-pwt.ac.id, ³merlinda@ittelkom-pwt.ac.id, ^{4,*}sigit@ittelkom-pwt.ac.id

Email Penulis Korespondensi: sigit@ittelkom-pwt.ac.id

Submitted: 01/12/2022; Accepted: 24/12/2022; Published: 30/12/2022

Abstrak—Sistem cerdas dalam monitoring unggas di dalam kandang saat ini sedang mengalami trend meningkat di beberapa penelitian. Monitoring unggas sangat penting dilakukan di dalam kandang supaya dapat mengetahui kondisi ayam dan lingkungan di kandang. Kondisi yang dapat dipantau antara lain berat ayam, ketersediaan air apakah cukup atau tidak dalam sehari, kadar CO₂ di dalam kandang, temperature udara dan kelembapan udara di kandang. Saat ini beberapa penelitian telah melakukan studi tentang monitoring kandang unggas menggunakan sensor-sensor berbasis IoT. Akan tetapi saat ini belum ada yang melakukan prediksi terkait populasi unggas untuk esok hari. Penelitian ini bertujuan untuk melakukan prediksi jumlah populasi unggas di dalam kandang berdasarkan parameter terkait. Metode prediksi yang digunakan penelitian ini yaitu decision tree dan Support Vector Machine (SVM) untuk melihat metode prediksi mana yang lebih baik. Teknik evaluasi hasil yang digunakan penelitian ini yaitu Mean Square Error (MSE), Root Mean Square Error (RMSE), Mean Absolut Error (MAE), dan R². Hasil eksperimen menunjukkan bahwa dengan menggunakan metode decision tree hasil MSE 61987.202, RMSE 248.972, MAE 85.086, dan R² 0.969. Secara keseluruhan hasil metode decision tree lebih unggul dibandingkan SVM.

Kata Kunci: IoT; Decision Tree; Smart Poultry; Prediction; RMSE

Abstract— Intelligent systems for monitoring poultry in kennels are experiencing an increasing trend in several studies. Monitoring poultry is very important in the cage so that you can find out the chickens' condition and environment in the cage. Conditions that can be monitored include the weight of the chickens, whether or not there is enough water in a day, CO₂ levels in the cages, air temperature, and humidity in the cages. Several studies have been conducted studies on monitoring poultry cages using IoT-based sensors. However, people have yet to predict the poultry population for tomorrow. So this study aims to predict the number of poultry populations in kennels based on related parameters. The prediction method used in this research is a decision tree and Support Vector Machine (SVM) to see which prediction method is better. The results evaluation techniques used in this study are Mean Square Error (MSE), Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and R². The experimental results show that using the decision tree method, and the results are MSE 61987.202, RMSE 248.972, MAE 85.086, and R² 0.969. Overall the results of the decision tree method are superior to SVM.

Keywords: IoT; Decision Tree; Smart Poultry; Prediction; RMSE

1. PENDAHULUAN

Smart poultry merupakan perkembangan teknologi saat ini untuk monitoring unggas seperti ayam di dalam kandang [1]. Bahkan menjelang tahun 2050, permintaan global akan daging unggas akan menjadi lebih dari dua kali lipat dibandingkan tahun 2005, dan permintaan telur ayam akan meningkat hampir 40% [2]. Permintaan telur ayam yang meningkat tersebut dapat menimbulkan persaingan di dunia peternakan unggas [3]. Berdasarkan hal tersebut, sehingga saat ini monitoring unggas dilakukan oleh beberapa peneliti dengan menggunakan sensor-sensor berbasis Internet of Things (IoT) untuk dapat melakukan control suhu kandang unggas ataupun prediksi berat dan populasi unggas. Pemantauan unggas di kandang dalam bidang peternakan penting dilakukan untuk memastikan permintaan pasar terpenuhi terkait telur ataupun ayam. Hal yang tidak diharapkan seperti ayam menjadi susah dicari dan telur menjadi sangat mahal tentu akan sangat berdampak bagi konsumsi protein masyarakat.

Saat ini penelitian terkait monitoring unggas sudah banyak dilakukan, seperti yang dilakukan oleh Astill, et al membahas tentang *precision livestock farming* (PLF) dengan menggunakan IoT dan big data [4]. Akhund, et al melakukan tujuan untuk membuat sistem peternakan unggas pintar berbasis IoT, yang dimana power supply dikembangkan dengan menggunakan energi terbarukan terutama dengan energi surya dan nanohidro [5]. Peneliti Bumanis, et al melakukan cyber-physical model diusulkan sebagai dasar untuk pengembangan sistem manajemen peternakan unggas pintar yang dapat disesuaikan dengan kebutuhan produksi tertentu, beberapa sensor CO₂ (karbon dioksida) dan NH₃ (amonia) dipasang untuk mengumpulkan data [6]. Corkery, et al memberikan ikhtisar pemantauan dan teknologi sensor kinerja dalam produksi unggas. Parameter lingkungan kritis yang relevan dengan produksi unggas antara lain suhu udara, kelembapan relatif, cahaya, kecepatan udara dan kualitas udara (khususnya konsentrasi CO₂ dan NH₃) [7].

Ada juga penelitian yang dilakukan terkait analisa pengaruh pertumbuhan maupun berat unggas dalam kaitannya dengan daun bubuk *Moringa oleifera* dan *azadirachta indica* [8]. Bahkan ada study yang secara khusus menerapkan smart poultry berbasis IoT pada sebuah negara yaitu Brunei [9]. Study lain menganalisis menggunakan aplikasi berbasis machine learning yaitu support vector machine (SVM) dalam melakukan prediksi pertumbuhan dan Kesehatan ayam dan kemampuan algoritma machine learning untuk mengatasi input data yang tinggi dan non-linear

[10]. Sedangkan penelitian yang dilakukan oleh Ahmad membahas modelling pertumbuhan unggas dan simulasi data yang digunakan berdasarkan algoritma neural network [11]. Study lain melakukan estimasi berat pada ayam broiler menggunakan algoritma machine vision dan artificial neural network (ANN) [12]. Ada juga sistem cerdas untuk unggas yang dapat mendeteksi jenis penyakit pada ayam [13]–[15].

Berdasarkan hal-hal di atas, penelitian ini memiliki kontribusi utama yaitu:

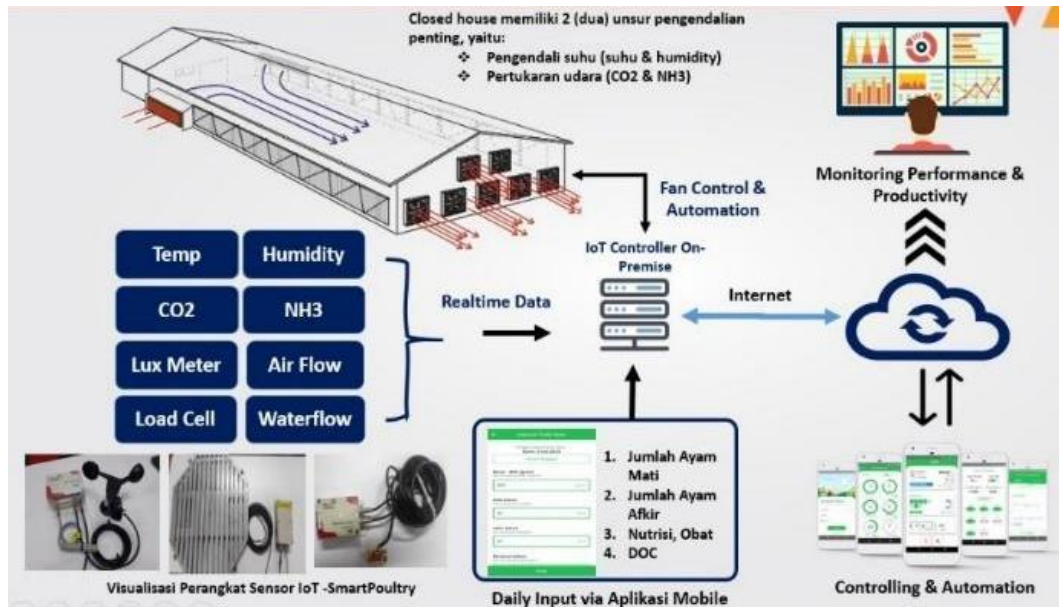
- a. Saat ini belum ada yang melakukan prediksi terkait jumlah populasi unggas di dalam kandang. Penelitian ini bertujuan melakukan pentingnya untuk melakukan prediksi jumlah populasi unggas di dalam kandang dengan menggunakan data-data yang diambil dari sensor IoT.
- b. Model prediksi populasi yang digunakan penelitian ini yaitu tree dan support vector machine (SVM).

Pada paper ini memiliki beberapa bagian yaitu, section 2 membahas tentang metode penelitian dan cara pengambilan data. Section 3 membahas hasil dan analisa. Section 4 melakukan kesimpulan hasil penelitian.

2. METODOLOGI PENELITIAN

2.1 Metode Penelitian

Pada gambar 1 merupakan framework sistem yang dibangun menggunakan untuk monitoring unggas di dalam kandang.



Gambar 1. Framework Penelitian

Pada framework di atas memiliki beberapa data yang dapat dipantau seperti temperature, humidity, CO2, NH3, Lux meter, tekanan air, jumlah ayam mati dalam sehari, dan berat unggas. Sensor-sensor tersebut mengambil data dari dalam kandang dan mengirimkan data tersebut ke cloud untuk disimpan. Data yang disimpan dalam cloud dapat dilakukan monitoring oleh user, monitoring data yang dilakukan dapat terkait performance dan produktivitas unggas. Ada juga data yang dilakukan input harian melalui aplikasi mobile seperti data jumlah ayam mati dan jumlah obatnya.

2.2 Dataset

Dataset penelitian ini didapatkan melalui platform website yang telah dibangun <http://sreeya.telkomiot.com>. Deskripsi dataset dapat dilihat pada tabel 1. Jumlah dataset yang digunakan sebanyak 315 yang diambil secara periodic dalam waktu 3 bulan.

Tabel 1. Deskripsi Dataset

No	Nama Variabel	Tipe Data
1	<i>Date</i>	Date
2	<i>Depletion (percent)</i>	Integer
3	<i>Average Bodyweight (gram)</i>	Integer
4	<i>FCR</i>	Integer
5	<i>Feed Intake (Kg)</i>	Integer
6	<i>Water Intake (Liter)</i>	Integer
7	<i>IP</i>	Integer
8	<i>Population (Tail)</i>	Integer

Depletion adalah ukuran kematian rata-rata dari ayam dalam satu hari. *Average Bodyweight* merupakan rata-rata berat unggas di dalam kandang. FCR adalah penambahan total bobot mingguan rata-rata ayam pedaging dibagi pakan yang dikonsumsi masing-masing kelompok sama dengan rasio konversi pakan ayam pedaging. FCR dihitung setiap minggu selama pengaturan eksperimental. Rasio Konversi Pakan (FCR) pada masing-masing kelompok dapat dihitung menggunakan formula (1).

$$FCR = \frac{\text{Total Konsumsi Pakan (TFC)}}{\text{Penambahan Berat Badan (BB)}} \quad (1)$$

Feed intake adalah kebutuhan makanan unggas di dalam kandang. Water intake adalah kebutuhan air pada unggas di dalam kandang. IP merupakan presentase ayam hidup dikali dengan berat rata-rata, lalu dibagi dengan hasil perkalian FCR dan usia ayam, dapat dilihat pada formula (2). Populasi adalah jumlah keseluruhan unggas di dalam kandang.

$$IP = \frac{\% \text{Ayam Hidup} \times \text{Berat Rata}}{FCR \times \text{Usia Ayam}} \quad (2)$$

2.3 Algoritma Prediksi

Penelitian ini menggunakan algoritma prediksi yaitu support vector machine (SVM), dan decision tree. Metode SVM banyak digunakan pada beberapa kasus seperti klasifikasi dan regresi [16]–[18]. SVM juga direkomendasikan dalam kasus pattern recognition [19], selain itu metode SVM juga dapat dilakukan dalam penerapan time series prediction [20]. Penelitian ini menggunakan analisis regresi, formula (3) dan (4) masing-masing mendefinisikan fungsi prediksi untuk aplikasi regresi linier dan non-linier [20].

$$f(x) = (w \cdot x) + b \quad (3)$$

$$f(x) = (w \cdot \phi(x)) + b \quad (4)$$

Jika data tidak linier dalam ruang "input", tujuannya adalah untuk memetakan data $x(t)$ ke ruang "fitur" dimensi yang lebih tinggi, melalui $\phi(x)$ (disebut sebagai Fungsi Kernel), kemudian melakukan linier regresi dalam ruang fitur dimensi yang lebih tinggi [21].

Tujuannya adalah untuk menemukan bobot "optimal" w dan ambang b serta menentukan kriteria untuk menemukan kumpulan bobot "optimal". Pertama adalah "kerataan" bobot, yang dapat diukur dengan norma Euclidean (yaitu, minimalkan $\|w\|^2$). Kedua adalah kesalahan yang dihasilkan oleh proses estimasi nilai, juga dikenal sebagai risiko empiris, yang harus diminimalkan. Tujuan keseluruhannya adalah meminimalkan risiko yang diatur $R_{reg}(f)$ (di mana f adalah fungsi dari $x(t)$) seperti yang didefinisikan sebagai (5):

$$R_{reg}(f) = R_{emp}(f) + \frac{\lambda}{2} \|w\|^2 \quad (5)$$

Faktor skala λ biasanya disebut sebagai konstanta regularisasi dan istilah ini sering disebut sebagai istilah kontrol kapasitas. Fungsinya untuk mengurangi "over-fitting" data dan meminimalkan efek generalisasi yang buruk. Risiko empiris didefinisikan sebagai (6).

$$R_{emp}(f) = \frac{1}{N} \sum_{i=0}^{N-1} L(x(i), y(i), f(x(i), w)) \quad (6)$$

Di mana, i adalah indeks untuk deret waktu diskrit $t = \{0, 1, 2, \dots, N-1\}$ dan $y(i)$ adalah data "kebenaran" (kumpulan pelatihan) dari nilai prediksi yang dicari. $L(\cdot)$ adalah "fungsi kerugian" atau "fungsi biaya" yang harus didefinisikan.

Metode decision tree adalah *classifier* yang mempartisi ruang secara rekursif. Simpul yang terdiri dari pohon berakar merupakan pohon keputusan [23]. Formula decision tree yang digunakan yaitu entropy (7) [24].

$$Entropy(S) = \sum_{i=1}^c P_i \log 2^{P_i} \quad (7)$$

Dimana P_i merupakan rasio jumlah angka dari subset sampel, sedangkan i merupakan nilai atribut.

3. HASIL DAN PEMBAHASAN

Penelitian ini untuk metode pengukuran hasil dan analisisnya menggunakan Mean Square Error (MSE), Root Mean Square Error (RMSE), Mean Absolute Error (MAE) dan R-squared (R^2). Berikut merupakan formula MSE (8), RMSE (9), MAE (10) dan R^2 (11) [25].

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \tag{8}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \tag{9}$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \tag{10}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n e_i}{\sum_{i=1}^n b_i} \tag{11}$$

Dimana n adalah jumlah sampel, e adalah nilai bias pada hasil prediksi, dan b adalah nilai bias pada hasil pengurangan nilai sebenarnya dan nilai rata-rata prediksi.

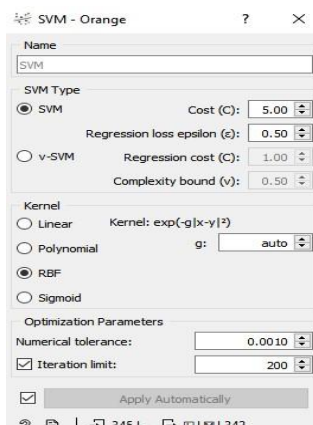
3.1 Implementasi/Pengujian

Penelitian ini menggunakan alat bantu orange3 untuk membantu dalam melihat metode yang lebih baik dalam melakukan prediksi. Gambar 2 menunjukkan workflow yang digunakan dalam aplikasi orange3.




Gambar 2. Workflow penelitian orange

Pada gambar 2 dilakukan pembacaan data, penggabungan data yang telah dibaca, pemodelan menggunakan SVM dan tree, lalu dilanjutkan dengan prediksi dari model yang sudah ada. Data yang digunakan pada penelitian ini adalah data pada periode ke-4 hingga periode ke-13 yang kemudian dibaca menggunakan widget File. Data yang telah terbaca kemudian digabungkan menjadi satu tabel utuh menggunakan widget concatenate. Seluruh data tersebut kemudian di masukkan pada model SVM yang telah dipersiapkan. Gambar 3 menunjukkan model SVM yang dipakai pada penelitian ini.



Gambar 3. Model SVM

Pada gambar 3 model SVM yang digunakan adalah SVM dengan nilai cost 5.00 dan nilai regression loss epsilon 0.50, kernel RBF dan iterasi sebanyak 200 iterasi. Model lain yang digunakan adalah model tree yang ditunjukkan pada gambar 4.



Gambar 4. Model Tree

Pada gambar 4 model tree menggunakan jumlah minimal daunnya sebanyak 2 dan pembagian subset minimal 5. Hasil prediksi yang didapat dari penelitian ini berupa data prediksi populasi menggunakan model SVM dan model tree, data eror atau selisih nilai dari nilai prediksi dan nilai aktual dari populasi yang ada pada model SVM dan tree. Tabel 2 menunjukkan data yang telah didapat.

Tabel 2. Hasil prediksi dan nilai eror

No	Population	SVM	Tree	SVM Error	Tree Error
1	9996	9831.14	11409	-164.86	1413
2	9983	9910.23	9315	-72.77	-668
3	9976	9915	9972	-61	-4
4	9960	9914.09	9952.5	-45.91	-7.5
5	9950	9912.3	11535.5	-37.7	1585.5
...
311	8813	9804.72	8833.33	991.72	20.33
312	8793	9796.13	8742	1003.13	-51
313	8759	9782.67	8820	1023.67	61
314	8691	9764.75	8742	1073.75	51
315	8631	9822.03	8629	1191.03	-2

Pada tabel 2 dapat dilihat nilai prediksi yang didapat dari model SVM dan model tree. Keduanya dapat memprediksi jumlah populasi yang akan diperoleh. Nilai eror dari masing-masing model juga terlihat dari tabel 2, dan dapat diketahui bahwa nilai eror menggunakan model tree lebih sedikit daripada Ketika menggunakan model SVM. Nilai eror yang kecil ini membuktikan bahwa model regresi menggunakan tree memiliki performa yang lebih baik dibandingkan Ketika menggunakan model SVM. Hal ini dapat dilihat melalui hasil perhitungan MSE, RMSE, MAE, dan R^2 yang dapat dilihat pada tabel 3.

Tabel 3. Hasil Perhitungan MSE, RMSE, MAE, dan R^2

Model	MSE	RMSE	MAE	R^2
SVM	1968400.091	1402.997	1051.679	0.007
Tree	61987.202	248.972	85.086	0.969

Pada tabel 3 diperlihatkan untuk model SVM nilai MSE yang didapat sebesar 1968400,091, nilai RMSE sebesar 1402,997, nilai MAE sebesar 1051,679, dan nilai R^2 sebesar 0.007. Pada model tree didapat nilai MSE sebesar 61987,202, nilai RMSE sebesar 248,972, nilai MAE sebesar 85,086, dan nilai R^2 sebesar 0,969. Nilai MSE, RMSE dan MAE menunjukkan tingkat eror yang dimiliki masing-masing model yang berarti bahwa semakin kecil nilai eror yang didapat maka semakin baik performa dari model yang digunakan. Nilai R^2 menunjukkan tingkat baik atau tidaknya sebuah model yang digunakan. Jika nilai R^2 semakin mendekati 1 maka model tersebut dapat dikatakan baik, sebaliknya jika mendekati 0 maka model kurang baik. Hasilnya dapat disimpulkan bahwa model tree lebih baik dari pada model SVM.

4. KESIMPULAN

Kesimpulan pada penelitian ini adalah: telah dibuat pengujian untuk memprediksi jumlah populasi ayam pada sebuah kandang dengan periode tertentu yang menghasilkan nilai prediksi 95%. Data yang dipakai merupakan data pada periode ke-4 hingga periode ke-13. Data pertumbuhan populasi tersebut memiliki variabel-variabel yang memiliki

pengaruh terhadap pertumbuhan populasi diantaranya adalah date, depletion, a vera ge bodyweight, FCR, feed intake, water intake, IP, dan population. Menggunakan data yang dimiliki sejumlah 315 baris dengan 10 variabel telah dilakukan pengujian menggunakan model SVM dan model tree untuk memprediksi jumlah populasi pada satu hari tertentu. Model SVM yang digunakan adalah tipe SVM dengan nilai cost 5.00 dan nilai regression loss epsilon 0.50, kernel RBF dan iterasi sebanyak 200 iterasi. Hasil yang didapat menggunakan model SVM nilai MSE sebesar 1968400,091, nilai RMSE sebesar 1402,997, nilai MAE sebesar 1051,679, dan nilai R^2 sebesar 0.007. Model tree menggunakan jumlah minimal daunnya sebanyak 2 dan pembagian subset minimal 5. Hasil yang didapat menggunakan model tree Pada model tree didapat nilai MSE sebesar 61987,202, nilai RMSE sebesar 248,972, nilai MAE sebesar 85,086, dan nilai R^2 sebesar 0,969. Berdasarkan model yang telah diuji maka dapat disimpulkan bahwa model tree memiliki performa yang lebih baik daripada model SVM karena nilai MSE, RMSE, dan MAE yang kecil dan nilai R^2 yang semakin mendekati angka 1.

REFERENCES

- [1] Mahale, Rupali B., and S. S. Sonavane, "Smart Poultry Farm Monitoring Using IOT and Wireless Sensor Networks," *Int. J. Adv. Res. Comput. Sci.*, vol. 7, no. 3, 2016.
- [2] Smith, Daniel, et al, "Internet of animal health things (IoAHT) opportunities and challenges," Univ. Cambridge Cambridge, UK, 2015.
- [3] Godfray, H. Charles J., et al, "Food security: the challenge of feeding 9 billion people," *Science* (80-.), vol. 327, no. 5967, pp. 812–818, 2010.
- [4] Astill, Jake, et al, "Smart poultry management: Smart sensors, big data, and the internet of things," *Comput. Electron. Agric.*, vol. 170, p. 105291, 2020.
- [5] Akhund, Tajim Md, et al, "Self-powered IoT-based design for multi-purpose smart poultry farm," in *International Conference on Information and Communication Technology for Intelligent Systems*. Springer, Singapore, 2020, vol. May, pp. 43–51.
- [6] Bumanis, Nikolajs, et al, "Data Conceptual Model for Smart Poultry Farm Management System," in *Procedia Computer Science*, 2022, pp. 517–526.
- [7] Corkery, Gerard, et al, "Incorporating smart sensing technologies into the poultry industry," *J. World's Poult. Res.*, vol. 3, no. 4, pp. 106–128, 2013.
- [8] Kanwal, Aroosa, et al, "Growth performance of poultry in relation to Moringa oliefera and Azadirachta indica leaves powder," *J. King Saud Univ.*, vol. 34, no. 7, p. 102234, 2022.
- [9] Hambali, Muhammad Faiz Haji, Ravi Kumar Patchmuthu, and Au Thien Wan, "IoT Based Smart Poultry Farm in Brunei," in *2020 8th International Conference on Information and Communication Technology (ICoICT)*. IEEE, 2020, pp. 1–5.
- [10] Milosevic, B., et al, "Machine learning application in growth and health prediction of broiler chickens," *Worlds. Poult. Sci. J.*, vol. 75, no. 3, pp. 401–410, 2019.
- [11] H. A. Ahmad, "Poultry growth modeling using neural networks and simulated data," *J. Appl. Poult. Res.*, vol. 18, no. 3, pp. 440–446, 2009.
- [12] Amraei, S., S. Abdanan Mehdizadeh, and S. Salari, "Broiler weight estimation based on machine vision and artificial neural network," *Br. Poult. Sci.*, vol. 58, no. 2, pp. 200–205, 2017.
- [13] Ahmed, Ghufuran, et al, "An approach towards IoT-based predictive service for early detection of diseases in poultry chickens," *Sustainability*, vol. 13, no. 23, p. 13396, 2021.
- [14] Huang, Junduan, Wenqing Wang, and Tiemin Zhang, "Method for detecting avian influenza disease of chickens based on sound analysis," *Biosyst. Eng.*, vol. 180, pp. 16–24, 2019.
- [15] Zhuang, Xiaolin, et al, "Development of an early warning algorithm to detect sick broilers," *Comput. Electron. Agric.*, vol. 144, pp. 102–113, 2018.
- [16] Chandra, Mayank Arya, and S. S. Bedi, "Survey on SVM and their application in image classification," *Int. J. Inf. Technol.*, vol. 13, no. 5, pp. 1–11, 2021.
- [17] Ramadhan, Nur Ghaniaviyanto, and Azka Khoirunnisa, "Klasifikasi Data Malaria Menggunakan Metode Support Vector Machine," *J. MEDIA Inform. BUDIDARMA*, vol. 5, no. 4, pp. 1580–1584, 2021.
- [18] Yue, Shihong, Ping Li, and Peiyi Hao, "SVM classification: Its contents and challenges," *Appl. Math. J. Chinese Univ.*, vol. 18, no. 3, pp. 332–342, 2003.
- [19] Byun, Hyeran, and Seong-Whan Lee, "A survey on pattern recognition applications of support vector machines," *Int. J. Pattern Recognit. Artif. Intell.*, vol. 17, no. 3, pp. 459–486, 2003.
- [20] Sapankevych, Nicholas I., and Ravi Sankar, "Time series prediction using support vector machines: a survey," *IEEE Comput. Intell. Mag.*, vol. 4, no. 2, pp. 24–38, 2009.
- [21] Müller, K-R., et al, "Predicting time series with support vector machines," in *International conference on artificial neural networks*. Springer, Berlin, Heidelberg, 1997, pp. 999–1004.
- [22] Chai, Tianfeng, and Roland R. Draxler, "Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature," *Geosci. Model Dev.*, vol. 7, no. 3, pp. 1247–1250, 2014.
- [23] Charisma, Rifqi Alfinnur, et al, "Analisis Penerapan Metode Ensembled Learning Decision Tree Pada Klasifikasi Virus Hepatitis C," *J. Comput. Syst. Informatics*, vol. 3, no. 4, pp. 405–409, 2022.
- [24] Charbuty, Bahzad, and Adnan Abdulazeez, "Classification based on decision tree algorithm for machine learning," *J. Appl. Sci. Technol. Trends*, vol. 2, no. 1, pp. 20–28., 2021.