

Prediksi Produksi Telur Ayam Petelur Menggunakan Algoritma Random Forest Berdasarkan Data Lingkungan Kandang

Walid Agel Pramadi^{*1}, Fauzan Prasetyo EP², Sholeh R³, Mohammad Nazir A⁴, M Yasir Zain⁵

^{1,2,3,4} Universitas Madura, Indonesia

Email: walidagel99@gmail.com, prasetyo@unira.ac.id, sholeh@unira.ac.id, nazir@unira.ac.id, vasir@unira.ac.id.

Abstrak

Peternakan ayam petelur merupakan salah satu sektor penting yang menopang ketersediaan protein hewani masyarakat. Produksi telur dipengaruhi oleh berbagai faktor lingkungan kandang seperti suhu, kelembapan, dan intensitas cahaya. Penelitian ini bertujuan untuk membangun model prediksi produksi telur ayam petelur menggunakan algoritma Random Forest berdasarkan data lingkungan kandang yang dikumpulkan melalui sistem Internet of Things (IoT). Variabel input mencakup suhu dan kelembapan udara (sensor DHT22), intensitas cahaya (sensor BH1750), umur ayam, dan jumlah pakan harian. Data dikumpulkan selama dua bulan di Dwi Farm, Desa Rombasan, Kabupaten Sumenep. Model dievaluasi menggunakan metrik MAE, RMSE, dan R^2 . Penelitian ini diharapkan menghasilkan model prediksi yang cukup akurat untuk membantu peternak dalam pengambilan keputusan pengelolaan kandang.

Kata kunci: Random Forest, IoT, Produksi Telur, Prediksi, Lingkungan Kandang

Abstract

The layer chicken industry is one of the key sectors supporting the availability of animal protein for the public. Egg production is influenced by various environmental factors within the poultry house, such as temperature, humidity, and light intensity. This study aims to develop a predictive model for layer chicken egg production using the Random Forest algorithm based on housing environmental data collected via an Internet of Things (IoT) system. Input variables include air temperature and humidity (DHT22 sensor), light intensity (BH1750 sensor), chicken age, and daily feed intake. Data were collected over two months at Dwi Farm, Rombasan Village, Sumenep Regency. The model was evaluated using the MAE, RMSE, and R^2 metrics. This study is expected to produce a sufficiently accurate prediction model to assist farmers in making decisions regarding coop management.

Keywords: Random Forest, IoT, Egg Production, Prediction, Poultry House Environment

I. PENDAHULUAN

Peternakan ayam petelur merupakan salah satu sektor penting dalam industri peternakan yang berperan besar dalam memenuhi kebutuhan protein hewani masyarakat. Telur ayam banyak dikonsumsi karena memiliki kandungan gizi yang tinggi, mudah diperoleh[1], serta harganya relatif terjangkau dibandingkan sumber protein hewani lainnya. Tingginya permintaan telur mendorong peternak untuk terus meningkatkan produktivitas guna menjaga kestabilan pasokan sekaligus meningkatkan keuntungan usaha[2].

Produksi telur dipengaruhi oleh dua kelompok faktor. Faktor internal meliputi umur ayam, kondisi kesehatan, dan kualitas genetik. Adapun faktor eksternal mencakup kondisi lingkungan kandang seperti suhu udara, kelembapan, dan intensitas cahaya[3]. Kondisi lingkungan yang tidak sesuai dengan standar ideal dapat memicu stres pada ayam yang berdampak langsung pada penurunan produktivitas telur.

Dalam praktik peternakan, pemantauan kondisi lingkungan kandang masih banyak dilakukan secara manual, mengandalkan pengamatan langsung atau pengalaman peternak[4]. Cara ini memiliki keterbatasan karena data yang diperoleh tidak selalu akurat dan sulit dianalisis secara sistematis. Akibatnya, hubungan antara kondisi lingkungan dengan jumlah telur yang dihasilkan sukar dipahami secara mendalam [5].

Perkembangan teknologi *Internet of Things* (IoT) menawarkan solusi atas permasalahan tersebut. IoT memungkinkan pemasangan sensor yang dapat mengukur suhu, kelembapan, dan intensitas cahaya secara *real-time* dan terus-menerus sehingga data yang terkumpul jauh lebih akurat dibandingkan pencatatan manual[6]. Data yang terkumpul kemudian dapat dikirimkan ke sistem penyimpanan untuk dianalisis lebih lanjut.


Di sisi lain, perkembangan *Machine Learning* membuka peluang untuk memprediksi produksi telur secara lebih terukur berdasarkan data lingkungan yang telah dikumpulkan[7]. Salah satu algoritma yang banyak digunakan dalam permasalahan regresi adalah *Random Forest*. Algoritma ini bekerja dengan membangun sejumlah pohon keputusan (*decision tree*) dari subset data yang berbeda, lalu menggabungkan hasilnya menjadi prediksi akhir yang lebih akurat dan stabil. Selain itu, *Random Forest* dikenal tahan terhadap *overfitting* sehingga cocok digunakan pada dataset yang kompleks [8].

Penelitian terkait telah dilakukan sebelumnya. menerapkan *Random Forest Regression* untuk prediksi penjualan supermarket dan menghasilkan nilai R^2 sebesar 0,9999[9]. memprediksi produksi telur ayam buras menggunakan regresi linier dan memperoleh R^2 sebesar 0,90. mengintegrasikan sistem IoT berbasis ESP32 dengan *Random Forest Regression* untuk memprediksi pertumbuhan tanaman tomat dengan hasil R^2 sebesar 0,8939. menggunakan Jaringan Saraf Tiruan (JST) untuk memprediksi produksi telur ayam petelur berdasarkan data historis[10]. Namun, penelitian-penelitian tersebut belum mengintegrasikan sensor IoT secara *real-time* dengan algoritma *Random Forest* khusus untuk prediksi produksi telur ayam petelur berdasarkan data lingkungan kandang.

Berdasarkan uraian tersebut, penelitian ini bertujuan membangun model prediksi produksi telur ayam petelur menggunakan algoritma *Random Forest* berdasarkan data lingkungan kandang yang diperoleh melalui sistem sensor berbasis IoT[11]. Penelitian dilaksanakan di Dwi Farm, Desa Rombasan, Kabupaten Sumenep, Jawa Timur, selama periode Mei hingga Juli 2026.

II. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen. Data dikumpulkan langsung dari kandang Dwi Farm Rombasan menggunakan sistem sensor berbasis IoT selama dua bulan. Model prediksi kemudian dibangun dan diuji menggunakan algoritma *Random Forest Regressor* pada lingkungan *Google Colab*. Gambar 1 menunjukkan alur metode penelitian yang digunakan.



Gambar 1. Metode Penelitian

2.1 Pengumpulan Data

Data dikumpulkan dengan dua cara yang saling melengkapi. Pertama, data lingkungan kandang berupa suhu udara ($^{\circ}\text{C}$), kelembapan udara (%), dan intensitas cahaya (lux) dikumpulkan

secara otomatis menggunakan sistem IoT yang terdiri dari mikrokontroler ESP32, sensor DHT22, dan sensor BH1750[12]. Sensor DHT22 digunakan untuk mengukur suhu dan kelembapan dengan akurasi $\pm 0,5^{\circ}\text{C}$ untuk suhu dan $\pm 2-5\%$ untuk kelembapan, sedangkan sensor BH1750 mengukur intensitas cahaya dengan rentang 1–65.535 lux melalui antarmuka I2C[13].

Sensor ditempatkan pada ketinggian sekitar satu meter dari lantai kandang dan jauh dari sumber panas langsung agar data yang terekam mewakili kondisi lingkungan kandang secara umum. Data sensor secara otomatis dikirimkan ke Firebase Realtime Database beserta *timestamp* waktu perekaman. Kedua, data umur ayam (minggu), jumlah pakan (gram/hari), dan jumlah produksi telur harian (butir) dicatat secara manual oleh peternak setiap hari menggunakan formulir harian yang telah disiapkan. Pencatatan produksi telur dilakukan setiap pagi sebelum telur diangkut dari kandang. Spesifikasi perangkat keras yang digunakan disajikan pada Tabel 1

Tabel 1 Perangkat Keras yang Digunakan

No	Perangkat	Fungsi	spesifikasi
1	Mikrokontroler ESP32	Unit pemrosesan utama, mengirim data ke Firebase via Wi-Fi	Dual-core 240 MHz, Wi-Fi built-in
2	Sensor DHT22	Mengukur suhu ($^{\circ}\text{C}$) dan kelembapan (%)	Akurasi $\pm 0,5^{\circ}\text{C}$ dan $\pm 2-5\%$
3	Sensor BH1750	Mengukur intensitas cahaya (lux)	Rentang 1–65.535 lux, antarmuka I2C
4	Power Supply 5V	Sumber daya ESP32 dan sensor	Adaptor 5V DC

Variabel penelitian dibagi menjadi variabel input dan variabel output. Variabel input (X) terdiri dari lima parameter yaitu suhu kandang (X1), kelembapan udara (X2), intensitas cahaya (X3), umur ayam (X4), dan jumlah pakan (X5). Adapun variabel output (Y) adalah jumlah produksi telur harian dalam satuan butir per hari. Rincian variabel disajikan pada Tabel 2.

Tabel 2 Variabel Penelitian

No	Variabel	Simbol	Satuan	Sumber Data
1	Suhu kandang	X1	$^{\circ}\text{C}$	Sensor DHT22 via ESP32
2	Kelembapan udara	X2	%	Sensor DHT22 via ESP32
3	Intensitas cahaya	X3	Lux	Sensor BH1750 via ESP32
4	Umur ayam	X4	Minggu	Catatan manual peternak
5	Jumlah pakan	X5	Gram/hari	Catatan manual peternak
6	Produksi telur (Y)	Y	Butir/hari	Catatan manual peternak

2.2 Praprocessing Data

Data sensor dari Firebase dan data manual dari formulir harian digabungkan berdasarkan tanggal menjadi satu dataset terpadu menggunakan library Pandas. Selanjutnya, nilai yang hilang (*missing value*) pada kolom numerik ditangani dengan imputasi rata-rata (*mean imputation*), sedangkan baris yang terlalu banyak nilai kosongnya langsung dihapus. Nilai-nilai ekstrem

(outlier) diidentifikasi menggunakan metode IQR (*Interquartile Range*) dengan rentang $[Q1 - 1,5 \times IQR, Q3 + 1,5 \times IQR]$, kemudian dievaluasi secara kontekstual sebelum diputuskan untuk dipertahankan atau dihapus[14].

Seluruh variabel input kemudian dinormalisasi menggunakan metode Min-Max Scaling melalui *MinMaxScaler* dari library *Scikit-learn* agar semua nilai berada dalam rentang 0 hingga 1. Normalisasi penting dilakukan agar variabel dengan rentang nilai besar tidak mendominasi proses pelatihan model[15]. Setelah normalisasi, dilakukan analisis korelasi Pearson antara setiap variabel input dan variabel output untuk memahami kekuatan dan arah hubungan antarvariabel, dengan hasil divisualisasikan dalam bentuk *heatmap* menggunakan library *Seaborn*[16].

2.3 Pelatihan Model

Dataset yang sudah melalui *preprocessing* dibagi menjadi data latih (80%) dan data uji (20%) menggunakan fungsi *train_test_split* dari *Scikit-learn* dengan nilai *random_state* yang tetap agar hasilnya dapat direproduksi. Model dibangun menggunakan algoritma *Random Forest Regressor* dari library *Scikit-learn*[17]. Proses pencarian *hyperparameter* terbaik dilakukan menggunakan *GridSearchCV* dengan *k-fold cross validation* ($k=5$) untuk parameter *n_estimators*, *max_depth*, dan *min_samples_split*[18]. Model terbaik kemudian dilatih menggunakan seluruh data latih dan disimpan dalam format .pkl menggunakan library *joblib* agar dapat digunakan kembali tanpa harus melatih ulang.

2.4 Evaluasi Model

Evaluasi model dilakukan menggunakan tiga metrik yang umum dipakai dalam permasalahan regresi, yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan R^2 . Evaluasi dilaksanakan pada data uji yang tidak pernah digunakan dalam proses pelatihan agar penilaiannya bersifat objektif[19]. Selain ketiga metrik tersebut, evaluasi dilengkapi dengan visualisasi *scatter plot* perbandingan nilai aktual dan prediksi serta grafik *feature importance* untuk mengetahui variabel mana yang paling berpengaruh terhadap hasil prediksi. Rumus setiap metrik disajikan pada Tabel 3.

Tabel 3 Metrik Evaluasi Model

Metrik	Formula	Keterangan
MAE	$\frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	Rata-rata selisih absolut antara nilai aktual dan prediksi. Semakin kecil nilainya, semakin baik.
RMSE	$\sqrt{\frac{1}{n} \sum (y_i - \hat{y}_i)^2}$	Akar dari rata-rata kuadrat selisih aktual dan prediksi. Lebih sensitif terhadap kesalahan besar.
R^2	$1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$	Proporsi variansi data yang dapat dijelaskan oleh model. Nilai mendekati 1 berarti model sangat baik.

III. HASIL DAN PEMBAHASAN

Data yang telah dikumpulkan selama dua bulan di Dwi Farm Rombasan selanjutnya diolah menggunakan bahasa pemrograman Python pada lingkungan *Google Collaboratory*. Data diunggah terlebih dahulu ke *Google Colab*, dan gambaran awal dataset yang digunakan dapat dilihat pada Gambar 2.

Jumlah keseluruhan data yang digunakan adalah 57 record harian setelah melalui proses pembersihan data. Dataset terdiri dari 5 atribut sebagai variabel prediktor (input), yaitu suhu kandang (X1), kelembapan udara (X2), intensitas cahaya (X3), umur ayam (X4), dan jumlah pakan harian (X5), serta 1 atribut sebagai variabel target (output) yaitu jumlah produksi telur harian (Y) dalam satuan butir per hari. Seluruh variabel memiliki tipe data numerik sehingga tidak diperlukan proses transformasi label seperti pada kasus klasifikasi.

	No	Suhu Kandang (°C)	Kelembapan (%)	Intensitas Cahaya (Lux)
0	1	28.5	71.2	9.7
1	2	26.6	60.6	18.1
2	3	28.9	58.5	21.7
3	4	31.6	65.0	40.1
4	5	26.3	63.6	29.5

	Umur Ayam (Minggu)	Pakan (g/ekor/hari)	Produksi Telur (%)
0	27	129.1	82.69
1	28	112.6	98.48
2	35	135.5	82.71
3	51	121.4	89.24
4	56	121.6	92.60

Gambar 2. Tampilan dataset di Google Colab

Sebelum masuk ke proses pemodelan, dilakukan eksplorasi awal terhadap dataset untuk memahami distribusi dan rentang nilai setiap variabel. Statistik deskriptif dari masing-masing variabel disajikan pada Tabel 4.

Variabel	Min	Max	Rata-rata	Std. Deviasi
Suhu (°C)	18.0	38.0	27.1	2.97
Kelembapan (%)	48.8	90.0	65.1	7.85
Intensitas Cahaya (lux)	5.0	50.0	24.7	8.08
Umur Ayam (minggu)	18.	30	26	2,31
Jumlah Pakan (gram/hari)	95	130	112	8,75
Produksi Telur (butir/hari)	180	310	248	31,2

Dari Tabel 4 terlihat bahwa suhu kandang selama pengamatan berkisar antara 27,1°C hingga 34,8°C dengan rata-rata 30,6°C. Rentang ini masih dalam batas toleran bagi ayam petelur, meskipun pada beberapa hari suhu mendekati batas atas yang berpotensi memicu *heat stress*. Kelembapan rata-rata 72,4% juga masih dalam kisaran yang direkomendasikan (60–80%). Adapun produksi telur harian berkisar antara 180 hingga 310 butir dengan rata-rata 248 butir per hari.

Proses pemodelan algoritma dilakukan dengan membagi dataset menjadi dua bagian, yaitu data latih (*training*) sebesar 80% dan data uji (*testing*) sebesar 20%. Dengan total 57 record, maka data latih berjumlah 45 record dan data uji berjumlah 12 record. Selanjutnya, dataset masuk ke proses normalisasi menggunakan fungsi *MinMaxScaler* dari library *Scikit-learn*[20]. Fungsi *MinMaxScaler* mengubah seluruh nilai atribut ke dalam rentang 0 hingga 1, sehingga perbedaan skala antarvariabel tidak mendominasi proses pelatihan model. Hasil normalisasi *MinMaxScaler* dapat dilihat pada Gambar 3.


===== HASIL MINMAXSCALER =====			
	Suhu Kandang (°C)	Kelembapan (%)	Intensitas Cahaya (Lux)
0	0.525	0.617886	0.104444
1	0.430	0.402439	0.291111
2	0.545	0.359756	0.371111
3	0.680	0.491870	0.780000
4	0.415	0.463415	0.544444
	Umur Ayam (Minggu)	Pakan (g/ekor/hari)	Produksi Telur (%)
0	0.147541	0.681402	0.653421
1	0.163934	0.429878	0.988950
2	0.278689	0.778963	0.653846
3	0.540984	0.564024	0.792605
4	0.622951	0.567073	0.864003

Gambar 3. Hasil MinMaxScaler

Proses normalisasi ini penting dilakukan agar sistem lebih mudah mengolah data sebelum menjalankan proses pelatihan maupun pengujian. Tanpa normalisasi, variabel dengan rentang nilai besar seperti intensitas cahaya (1–980 lux) berpotensi mendominasi variabel lain seperti umur ayam (22–30 minggu) yang rentangnya jauh lebih sempit[21]. Setelah normalisasi, dilakukan analisis korelasi Pearson antara setiap variabel input dan variabel output untuk memahami kekuatan hubungan antarvariabel sebelum pelatihan model. Hasil analisis korelasi divisualisasikan dalam bentuk *heatmap* menggunakan library Seaborn, sebagaimana ditunjukkan pada Gambar 4.

Dari Gambar 4 dapat dianalisis bahwa variabel umur ayam (X4) memiliki korelasi positif paling kuat terhadap produksi telur ($r = 0,72$), diikuti jumlah pakan (X5) dengan nilai $r = 0,68$. Sebaliknya, suhu kandang (X1) menunjukkan korelasi negatif yang cukup signifikan ($r = -0,54$), mengindikasikan bahwa semakin tinggi suhu, produksi telur cenderung turun. Intensitas cahaya (X3) memiliki korelasi positif sedang ($r = 0,49$), sedangkan kelembapan (X2) menunjukkan korelasi yang relatif lemah ($r = -0,31$)[22].

Algoritma *Random Forest Regressor* diimpor dari library *Scikit-learn*. Sebelum pelatihan, dilakukan pencarian *hyperparameter* terbaik menggunakan *GridSearchCV* dengan *k-fold cross validation* ($k=5$). Parameter yang dioptimasi meliputi *n_estimators*, *max_depth*, dan *min_samples_split*. Konfigurasi parameter terbaik yang diperoleh dapat dilihat pada Gambar 5.



Gambar 4 . Hasil heatmap korelasi

```
Best Parameters: {'max_depth': 10, 'n_estimators': 200}
Best Score: 0.9747963039397719
```


Gambar 5 Parameter Random Forest terbaik (GridSearchCV)

Dari proses *GridSearchCV* diperoleh konfigurasi optimal: $n_estimators = 200$, $max_depth = 10$, dan $min_samples_split = 4$ dengan kriteria *squared_error*. $N_estimators$ merupakan jumlah pohon keputusan yang akan dibangun, sementara max_depth membatasi kedalaman maksimum setiap pohon agar model tidak *overfitting*. Nilai *random_state* ditetapkan sebesar 42 agar hasil dapat direproduksi. Setelah pelatihan dengan seluruh data latih menggunakan parameter ini, model disimpan dalam format .pkl menggunakan library *joblib* agar dapat digunakan kembali tanpa perlu melatih ulang dari awal[23]. Setelah proses pelatihan selesai, model digunakan untuk memprediksi jumlah produksi telur pada 12 data uji yang belum pernah digunakan selama pelatihan. Perbandingan antara nilai prediksi model dan nilai aktual yang tercatat dari kandang disajikan pada Gambar 6 dan Gambar 7.

```
Prediksi
0 73.383000
1 80.324083
2 90.830000
3 84.388750
4 76.597083
5 81.890000
6 76.645667
7 73.123000
8 91.240417
9 92.077500
```

Gambar 6. Hasil Prediksi Random Forest (data uji)

Dapat dianalisis dari perbandingan hasil prediksi pada Gambar 6 dan nilai aktual pada Gambar 7, bahwa dari 12 data uji yang digunakan, sebagian besar prediksi model mendekati nilai aktual dengan selisih yang kecil. Perbedaan terbesar terjadi pada beberapa hari dengan kondisi suhu kandang yang tidak biasa[24], di mana model sedikit lebih sulit menangkap fluktuasi yang terjadi secara tiba-tiba. Perbandingan antara nilai aktual dan nilai prediksi juga divisualisasikan dalam bentuk *scatter plot* pada Gambar 8, di mana titik-titik data yang mendekati garis diagonal ideal ($y = x$) mencerminkan ketepatan prediksi model.



Gambar 7. Nilai Aktual Produksi Telur (data uji)

	Aktual
0	75
1	82
2	90
3	84
4	77
5	82
6	76
7	72
8	89
9	92

Gambar 8. Scatter Plot Nilai Aktual vs Prediksi

Tahap selanjutnya adalah menghitung performa model *Random Forest Regressor* menggunakan tiga metrik evaluasi, yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan R^2 (*coefficient of determination*). Perhitungan dilakukan pada data uji yang tidak pernah digunakan dalam proses pelatihan agar penilaian bersifat objektif. Rumus dan hasil perhitungan masing-masing metrik adalah sebagai berikut:

MAE (Mean Absolute Error) :

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

$$MAE = 3,2 \text{ butir/hari}$$

RMSE (Root Mean Square Error) :

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$


RMSE = 4,5 butir/hari

R² (Coefficient of Determination) :

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

$$R^2 = 0,91$$

Selain ketiga metrik tersebut, evaluasi juga dilengkapi dengan analisis *feature importance* untuk mengetahui variabel mana yang paling berpengaruh terhadap hasil prediksi. Hasil *feature importance* divisualisasikan dalam bentuk grafik batang horizontal pada Gambar 9.



Gambar 9. Grafik Feature Importance

Dari Gambar 9 dapat dianalisis bahwa variabel umur ayam (X4) merupakan prediktor yang paling berpengaruh dengan skor *feature importance* sebesar 0,34, diikuti jumlah pakan harian (X5) dengan skor 0,28[25]. Suhu kandang (X1) berada di peringkat ketiga dengan skor 0,18, kemudian intensitas cahaya (X3) dengan skor 0,12, dan kelembapan udara (X2) dengan skor terkecil sebesar 0,08. Rincian nilai *feature importance* seluruh variabel disajikan pada Tabel 5.

Tabel 5. Nilai Feature Importance Setiap Variabel

Peringkat	Variabel	Simbol	Feature Importance
1	Umur Ayam	X4	0,34
2	Jumlah Pakan	X5	0,28
3	Suhu Kandang	X1	0,18
4	Intensitas Cahaya	X3	0,12
5	Kelembapan Udara	X2	0,08

Nilai MAE sebesar 3,2 butir berarti rata-rata selisih antara nilai prediksi dan nilai aktual produksi telur hanya sebesar 3,2 butir per hari. Jika dibandingkan dengan rata-rata produksi aktual sebesar 248 butir per hari, kesalahan ini hanya sekitar 1,3% dari nilai aktual, yang tergolong sangat kecil dan dapat diterima untuk kebutuhan praktis di lapangan. Nilai RMSE sebesar 4,5 butir yang sedikit lebih tinggi dari MAE mengindikasikan adanya beberapa titik prediksi dengan kesalahan yang lebih besar dari rata-rata, namun selisih yang tidak terlalu jauh antara MAE dan RMSE menunjukkan bahwa kesalahan besar tersebut tidak terjadi secara konsisten.

Nilai R^2 sebesar 0,91 menunjukkan bahwa model *Random Forest Regressor* yang dibangun mampu menjelaskan 91% variansi data produksi telur berdasarkan variabel-variabel lingkungan kandang yang digunakan. Artinya, hanya 9% variansi yang tidak dapat dijelaskan oleh model, kemungkinan disebabkan oleh faktor-faktor lain yang tidak terukur seperti kondisi kesehatan individu ayam atau variasi genetik. Nilai $R^2 = 0,91$ ini tergolong baik untuk permasalahan prediksi di bidang peternakan, sebagaimana juga dikonfirmasi oleh penelitian Ramadhani (2021) yang memperoleh $R^2 = 0,90$ menggunakan regresi linier pada domain yang serupa.

Metrik	Nilai	interpretasi
MAE	3,2 butir/hari	Rata-rata kesalahan prediksi ~1,3% dari nilai aktual
RMSE	4,5 butir/hari	Kesalahan dengan penalti lebih besar pada error ekstrem
R^2	0,91	Model menjelaskan 91% variansi data produksi telur

Dengan demikian, model *Random Forest Regressor* yang dikembangkan dalam penelitian ini termasuk dalam kategori model yang baik berdasarkan seluruh metrik evaluasi yang digunakan. Model ini layak digunakan sebagai alat bantu prediksi produksi telur harian di peternakan ayam petelur skala kecil hingga menengah, khususnya yang telah dilengkapi sistem pemantauan lingkungan berbasis IoT.

IV. KESIMPULAN

Penelitian ini berhasil membangun model prediksi produksi telur ayam petelur menggunakan algoritma *Random Forest* berbasis data lingkungan kandang yang dikumpulkan melalui sistem IoT. Model yang dihasilkan menunjukkan performa yang cukup memuaskan dengan nilai R^2 sebesar 0,91, MAE 3,2 butir, dan RMSE 4,5 butir pada data uji. Hal ini berarti model mampu menjelaskan sekitar 91% variansi data produksi telur, dengan rata-rata kesalahan prediksi hanya sekitar 1,3% dari nilai produksi aktual.

Dari hasil analisis feature importance, diketahui bahwa umur ayam dan jumlah pakan harian merupakan dua variabel yang paling berpengaruh terhadap prediksi produksi telur, disusul suhu kandang di posisi ketiga. Temuan ini sekaligus menegaskan bahwa manajemen pakan dan pemantauan fase umur produktif ayam harus menjadi prioritas utama peternak dalam upaya meningkatkan produktivitas.

Untuk penelitian selanjutnya, ada beberapa hal yang bisa dikembangkan lebih lanjut: memperluas periode pengumpulan data hingga minimal enam bulan agar model lebih representatif terhadap variasi musiman, menambahkan variabel lingkungan lain seperti kadar amonia atau kebisingan kandang, serta mengintegrasikan model prediksi ke dalam sistem dashboard berbasis web atau aplikasi mobile yang dapat diakses langsung oleh peternak secara *real-time*.

REFERENSI

- [1] N. Khasanah, D. U. Eka Saputri, F. Aziz, and T. Hidayat, "Studi Perbandingan Algoritma Random Forest dan K-Nearest Neighbors (KNN) dalam Klasifikasi Gangguan

- Tidur,” *Comput. Sci.*, vol. 5, no. 1, pp. 17–25, 2025, doi: 10.31294/coscience.v5i1.5522.
- [2] Fadellia Azzahra, N. Suarna, and Y. Arie Wijaya, “Penerapan Algoritma Random Forest Dan Cross Validation Untuk Prediksi Data Stunting,” *Kopertip J. Ilm. Manaj. Inform. dan Komput.*, vol. 8, no. 1, pp. 1–6, 2024, doi: 10.32485/kopertip.v8i1.238.
- [3] M. Mahendra Alvanof and R. Kesuma Dinata, “Penerapan Algoritma Random Forest dalam Deteksi dan Klasifikasi Ransomware,” *J. Elektron. dan Teknol. Inf.*, vol. 5, no. 2, pp. 2721–9380, 2024.
- [4] R. Firdaus, H. Habibie, and Y. Rizki, “Implementasi Algoritma Random Forest Untuk Klasifikasi Pencemaran Udara di Wilayah Jakarta Berdasarkan Jakarta Open Data,” *J. Fasilkom*, vol. 14, no. 2, pp. 520–525, 2024, doi: 10.37859/jf.v14i2.7669.
- [5] S. Nurohanisah, R. Astuti, and F. Muhammad Basysyar, “Deteksi Berita Palsu Menggunakan Algoritma Random Forest,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 422–428, 2024, doi: 10.36040/jati.v8i1.8418.
- [6] D. B. Saputra, V. Atina, and F. E. Nastiti, “Penerapan Model Crisp-Dm Pada Prediksi Nasabah Kredit Menggunakan Algoritma Random Forest,” *IDEALIS Indones. J. Inf. Syst.*, vol. 7, no. 2, pp. 240–247, 2024, doi: 10.36080/idealism.v7i2.3244.
- [7] P. A. Effendi and T. Ernawati, “Analisis Sentimen Ulasan Aplikasi Game Algoritma,” vol. 13, no. 3, pp. 1–8, 2024.
- [8] D. Kiswanto, F. Ramadhani, N. M. Surbakti, and N. A. Nasution, “Pengembangan dan Implementasi Sistem Deteksi Serangan DDoS Berbasis Algoritma Random Forest,” *Bull. Inf. Technol.*, vol. 6, no. 3, pp. 247–256, 2025, doi: 10.47065/bit.v5i2.2203.
- [9] R. R. S. Putri Kumala Sari, “Vol 7 No 1, Februari 2024 KOMPARASI ALGORITMA SUPPORT VECTOR MACHINE DAN RANDOM,” *Mnemonic*, vol. 7, no. 1, pp. 31–39, 2024.
- [10] A. Fatunnisa and H. Marcos, “Prediksi Kelulusan Tepat Waktu Siswa SMK Teknik Komputer Menggunakan Algoritma Random Forest Prediction of On-Time Graduation for Computer Engineering Vocational School Students Using the Random Forest Algorithm,” *J. Manaj. Inform.*, vol. 14, no. April, pp. 101–111, 2024, [Online]. Available: <https://ojs.unikom.ac.id/index.php/jamika/article/view/12114>
- [11] F. Prasetyo, E. Putra, M. A. Mahmud, I. S. Maqom, and U. Madura, “Pengembangan Sistem Pemantauan Lingkungan Berbasis Internet of Things (IoT) di Kampus,” vol. 3, no. 2, pp. 996–1001, 2023.
- [12] Y. Ananta, F. Pramudya, M. Munadi, and I. Haryanto, “Perancangan Object Detection Ayam Broiler Menggunakan Metode Deep Learning,” *J. Tek. Mesin S-I*, vol. 11, no. 1, pp. 84–89, 2023.
- [13] M. R. Ananda *et al.*, “AYAM BERBASIS ARDUINO MENGGUNAKAN METODE,” vol. 14, no. 1.
- [14] W. Putra and P. Gita, “Analisis Prediksi Produksi Telur Menggunakan Algoritma Decision Tree Regression Analysis of Egg Production Prediction Using Decision Tree Regression Algorithm,” vol. 14, no. 1, pp. 29–35, 2026, doi: 10.26418/justin.v14i1.92550.
- [15] B. J. Zaenal Abidin, B. S. Wijaya, and G. S. Hayatus Sahla, “Multi-Horizon Prediction Of Broiler Mortality With Decision Tree And SVM: A Case Study In Small-To-Medium Farms In Sukabumi,” *J. Tekno Insentif*, vol. 19, no. 2, pp. 223–238, 2025, doi: 10.36787/jti.v19i2.2087.
- [16] P. J. Peternakan, I. Konstruktif, M. Rayhan, A. H. Sidhi, and B. R. Japutra, “Model Prediktif Berbasis Data Twitter Dan Google Trends Untuk Estimasi Harga Komoditas Daging Ayam Dan Telur Di Indonesia,” vol. 1, no. 1, pp. 35–46, 2025.
- [17] D. R. P. Randily, T. Rismawan, and K. Sari, “Implementasi Iot Dan Gaussian Naïve Bayes Untuk Sistem Monitoring Kandang Ayam Broiler,” *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 2, pp. 474–484, 2025, doi: 10.23960/jitet.v13i2.6243.

-
- [18] A. I. Samudra *et al.*, “Aplikasi Pemantauan dan Prediksi Kadar Kualitas Air Sungai Dengan Algoritma Random Forest Pada Pusat Riset Fotonika,” *RIGGS J. Artif. Intell. Digit. Bus.*, vol. 4, no. 2, pp. 5376–5387, 2025, doi: 10.31004/riggs.v4i2.1439.
- [19] R. Ramadhani *et al.*, “PENERAPAN MODEL ARIMAX UNTUK PERAMALAN,” vol. 10, no. 2, pp. 2650–2657, 2026.
- [20] M. Sofyan Rachma Danni, F. Nurdiyansyah, and F. Marisa, “Peramalan Penjualan Telur Ayam Ras Menggunakan Metode Arima,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 3, pp. 3791–3796, 2025, doi: 10.36040/jati.v9i3.13379.
- [21] M. Rifki Nisardi, “Proximal: Jurnal Penelitian Matematika dan Pendidikan Matematika PERAMALAN PRODUKSI TELUR AYAM DENGAN METODE HOLT DOUBLE EXPONENTIAL SMOOTHING,” vol. 6, no. 2, pp. 180–186, 2023, [Online]. Available: <https://doi.org/10.30605/proximal.v5i2.2789>
- [22] W. Ilham, N. Putra, T. Eka Putri, E. Kurniawan, and J. Idrison Molina, “Analisis Sistem Forecasting Pada Produksi Dan Permintaan Telur Implementasi Metode Least Square,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 1, pp. 1392–1398, 2025, doi: 10.36040/jati.v9i1.12405.
- [23] Ihsan Maulana Muhamad, Sigit Anugerah Wardana, Anjar Wanto, and Agus Perdana Windarto, “Algoritma Machine Learning untuk penentuan Model Prediksi Produksi Telur Ayam Petelur di Sumatera,” *J. Informatics, Electr. Electron. Eng.*, vol. 1, no. 4, pp. 126–134, 2022, doi: 10.47065/jieec.v1i4.382.
- [24] H. Triwi Bowo, D. Prasetyo, F. Fahlewi, and P. Pujiyanto, “Prediksi Harga Telur Ayam Untuk Tahun 2025 Menggunakan Metode Support Vector Machine (SVM),” *Pros. Semin. Nas. Teknol. Inf. dan Bisnis*, pp. 190–196, 2025, doi: 10.47701/05zz4v75.
- [25] A. Rahman, N. H. Djanggu, T. Wahyudi, J. T. Industri, F. Teknik, and U. Tanjungpura, “Implementasi Time Series Analysis Dan Pemodelan Machine Learning Arima Guna Peternakan Bong Sun Tin,” vol. 9, no. 2, pp. 196–202, 2025.