

Analisis Prediksi Harga Cabai Menggunakan Random Forest dengan Integrasi Data

^{1*}Alibi Galih Exsandi, ²Daniel Swanjaya, ³Resty Wulanningrum

^{1,2,3}Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ^{*1}alibigalih21@gmail.com, ²daniel@unpkdr.ac.id, ³restyw@unpkdr.ac.id

Penulis Korespondensi: Alibi Galih Exsandi

Abstrak— Fluktuasi harga cabai sering terjadi akibat pengaruh faktor produksi, kondisi cuaca, dan faktor musiman sehingga menyulitkan pelaku usaha maupun pemerintah dalam melakukan perencanaan. Penelitian ini bertujuan memprediksi harga cabai menggunakan algoritma *Random Forest* dengan memanfaatkan data historis harga, data agroklimat yang meliputi suhu, kelembapan, kecepatan angin, dan tutupan awan, serta faktor musiman berupa hari besar nasional. Data dari berbagai sumber diintegrasikan berdasarkan tanggal dan diproses melalui tahapan pembersihan data, transformasi variabel, pelatihan model, dan evaluasi. Kinerja model dievaluasi menggunakan *Mean Absolute Error*, *Root Mean Square Error*, *Mean Absolute Percentage Error*, dan koefisien determinasi. Hasil penelitian menunjukkan bahwa model *Random Forest* mampu menghasilkan prediksi yang akurat dengan nilai *Mean Absolute Percentage Error* sebesar 7,86% dan koefisien determinasi sebesar 0,9052. Hasil tersebut menunjukkan bahwa *Random Forest* efektif digunakan untuk memprediksi harga cabai dan berpotensi menjadi alat bantu pengambilan keputusan dalam pengelolaan komoditas pangan.

Kata Kunci— agroklimat, harga cabai, *machine learning*, prediksi harga, *Random Forest*.

Abstract— Chili pepper prices frequently fluctuate due to production factors, weather conditions, and seasonal influences, making planning difficult for businesses and government agencies. This study aims to predict chili pepper prices using the *Random Forest* algorithm by utilizing historical price data, agroclimatic data including temperature, humidity, wind speed, and cloud cover, as well as seasonal factors represented by national holidays. Data from multiple sources were integrated based on date and processed through data cleaning, variable transformation, model training, and evaluation stages. Model performance was evaluated using *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), and the coefficient of determination (R^2). The results show that the *Random Forest* model is capable of producing accurate predictions, achieving a *Mean Absolute Percentage Error* of 7.86% and a coefficient of determination of 0.9052. These findings indicate that *Random Forest* is effective for predicting chili pepper prices and has the potential to serve as a decision-support tool in food commodity management.

Keywords— agroclimate, chili pepper prices, *machine learning*, price prediction, *Random Forest*.

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Cabai merupakan salah satu komoditas hortikultura penting di Indonesia yang memiliki tingkat konsumsi tinggi dan berpengaruh terhadap inflasi pangan nasional [1]. Harga cabai sering mengalami perubahan yang cukup signifikan akibat faktor produksi, kondisi cuaca, distribusi, dan permintaan pasar [2]. Fluktuasi harga tersebut menyebabkan petani maupun pelaku pasar mengalami kesulitan dalam menentukan strategi penjualan hasil panen secara optimal.

Berdasarkan data historis yang digunakan dalam penelitian, harga cabai mengalami perubahan yang cukup tinggi dalam periode tertentu sehingga diperlukan analisis prediksi yang mampu membantu memahami pola perubahan harga pasar.

Perubahan harga cabai dipengaruhi oleh berbagai faktor eksternal seperti suhu udara, kelembapan, kecepatan angin, tutupan awan, serta momentum hari besar nasional yang meningkatkan permintaan pasar [3]. Fenomena kenaikan harga cabai umumnya terlihat lebih tinggi pada periode tertentu seperti menjelang bulan Ramadhan dan hari besar nasional. Pada kondisi normal, harga cabai cenderung berubah secara stabil mengikuti jumlah produksi dan distribusi pasar.

Namun, ketika memasuki periode tertentu dengan peningkatan permintaan masyarakat, harga cabai dapat mengalami kenaikan yang lebih signifikan dibandingkan hari biasa. Selain faktor musiman, perubahan cuaca ekstrem juga memengaruhi fluktuasi harga cabai di pasar. Curah hujan yang tinggi dan kelembapan udara yang meningkat dapat menyebabkan penurunan kualitas serta hasil produksi cabai sehingga pasokan di pasar menjadi berkurang [4]. Sebaliknya, kondisi cuaca yang terlalu panas juga dapat memengaruhi pertumbuhan tanaman dan menyebabkan produktivitas menurun.

Penelitian sebelumnya umumnya hanya memanfaatkan data historis harga tanpa mengintegrasikan faktor agroklimat secara menyeluruh. Padahal, faktor lingkungan memiliki pengaruh terhadap produktivitas tanaman dan ketersediaan pasokan cabai di pasar [4]. Oleh karena itu, diperlukan metode prediksi yang mampu mengolah berbagai variabel secara bersamaan untuk menghasilkan prediksi harga yang lebih baik.


Perkembangan teknologi machine learning memberikan peluang dalam membangun model prediksi harga berbasis data. Salah satu algoritma yang banyak digunakan adalah *Random Forest* karena mampu menangani data nonlinier dan menghasilkan prediksi yang lebih stabil melalui pendekatan ensemble learning [5]. Penelitian sebelumnya menunjukkan bahwa *Random Forest* termasuk salah satu algoritma yang memiliki performa baik dalam prediksi harga komoditas pertanian karena mampu memodelkan hubungan nonlinier dan menangani data dengan banyak variable [6]. Pada penelitian ini dilakukan analisis penggunaan algoritma *Random Forest* dengan integrasi data agroklimat untuk memprediksi harga cabai berdasarkan data historis dan faktor lingkungan yang memengaruhi perubahan harga pasar.

II. METODE

A. Alur Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode analisis berbasis machine learning. Data yang digunakan terdiri atas data *historis* harga cabai, data cuaca meliputi suhu, kelembapan, kecepatan angin, dan tutupan awan, serta faktor musiman berupa hari besar nasional. Seluruh data diintegrasikan berdasarkan atribut tanggal sebelum diproses ke dalam model prediksi. Metode utama yang digunakan adalah *Random Forest* [7]. *Random Forest* bekerja dengan membangun sejumlah pohon keputusan dari subset data yang berbeda

dan menggabungkan hasil prediksi setiap pohon sehingga mampu menghasilkan prediksi yang lebih stabil serta mengurangi risiko *overfitting* [7], [8].ditunjukkan pada Gambar 1.



Gambar 1. Tahapan penelitian prediksi harga cabai

B. Pengumpulan Data

Tahap pengumpulan data dilakukan dengan menggabungkan data historis harga cabai dan data agroklimat. Penggunaan variabel cuaca seperti suhu dan curah hujan dalam pemodelan harga komoditas pertanian telah terbukti meningkatkan kemampuan prediksi dibandingkan hanya menggunakan data historis harga [7]. Selain faktor iklim, variabel musiman juga digunakan karena dapat memengaruhi dinamika permintaan dan penawaran komoditas pangan.

C. Pra-Pemrosesan Data

Tahap *pra-pemrosesan* data dilakukan melalui pembersihan data duplikat, penanganan *missing value*, transformasi format tanggal, serta konversi variabel kategorikal menjadi numerik. Proses ini penting untuk meningkatkan kualitas data dan memastikan model *machine learning* dapat mempelajari pola secara optimal [9]. Faktor musiman seperti hari besar nasional dikonversi menjadi *variabel dummy* agar dapat diproses oleh algoritma prediksi.

D. Integrasi Dataset

Integrasi dataset dilakukan berdasarkan atribut tanggal sebagai kunci utama sehingga seluruh variabel historis dan agroklimat dapat digunakan secara bersamaan dalam proses pelatihan model. Pendekatan integrasi data multivariat telah banyak digunakan pada studi prediksi berbasis machine learning karena mampu menangkap hubungan *nonlinier antarvariabel* yang memengaruhi nilai target [10]. Contoh dataset hasil integrasi data historis harga dan data agroklimat ditunjukkan pada Tabel 1.

Tabel 1. Dataset hasil integrasi data historis harga dan data agroklimat

Tanggal	Harga	Bulan	Hari besar	Keterangan	Luas Lahan	suhu
2025-01-01	75333	1	1	Tahun Baru Masehi	11	29,14
2025-01-02	75333	1	0	-	11	24,36
2025-01-03	63333	1	0	-	11	24,99
2025-01-04	81833	1	0	-	11	24,58
2025-01-05	88667	1	0	-	11	24,13
2025-01-06	75333	1	0	-	11	26,62
2025-01-07	80667	1	0	-	11	25,99

Dataset tersebut kemudian digunakan sebagai data masukan dalam proses pelatihan model Random Forest dan SVR untuk memprediksi harga cabai berdasarkan faktor historis dan agroklimat.

E. Pelatihan Model

Pelatihan model dilakukan dengan membagi dataset menjadi data latih dan data uji. Random Forest dipilih karena memiliki kemampuan yang baik dalam menangani data berdimensi tinggi, hubungan nonlinier, serta tahan terhadap noise dan outlier [7], [8]. *Random Forest* menggunakan mekanisme pembentukan banyak pohon keputusan atau decision tree dari sejumlah subset data. Hasil akhir prediksi diperoleh melalui proses agregasi dari seluruh pohon yang dibangun sehingga model mampu menghasilkan prediksi yang lebih stabil dan mengurangi risiko *overfitting*.

F. Prediksi

Prediksi harga cabai dilakukan menggunakan model *Random Forest* yang telah dilatih sebelumnya. Hasil prediksi kemudian dibandingkan dengan data harga aktual untuk mengetahui tingkat kedekatan hasil prediksi terhadap kondisi sebenarnya di pasar. Model diharapkan mampu mengikuti pola perubahan harga cabai berdasarkan faktor *historis* dan kondisi agroklimat yang digunakan dalam penelitian.

Evaluasi model dilakukan menggunakan *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *koefisien determinasi* (R^2). Keempat metrik tersebut merupakan ukuran yang umum digunakan untuk menilai performa model prediksi pada data deret waktu dan regresi karena mampu menggambarkan tingkat kesalahan prediksi serta kemampuan model dalam menjelaskan variasi data aktual [9]. dihitung menggunakan Persamaan (1).

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

Mean Absolute Error Persamaan (1) digunakan untuk mengukur rata-rata kesalahan absolut antara nilai aktual dan nilai hasil prediksi. Semakin kecil nilai MAE, semakin baik kemampuan model dalam melakukan prediksi.

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

Root Mean Square Error (RMSE) Persamaan (2) digunakan untuk mengukur besarnya kesalahan prediksi dengan memberikan penalti yang lebih besar terhadap kesalahan yang tinggi. Nilai RMSE yang lebih kecil menunjukkan performa model yang lebih baik.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

Koefisien determinasi (R^2) Persamaan (3) digunakan untuk mengukur kemampuan model dalam menjelaskan variasi data aktual berdasarkan variabel yang digunakan dalam proses prediksi. Nilai R^2 berada pada rentang 0 sampai 1, di mana nilai yang semakin mendekati 1 menunjukkan kemampuan prediksi yang semakin baik.

Dengan y_i merupakan nilai aktual, $\hat{y}_i$ merupakan nilai prediksi, $\bar{y}$ merupakan rata-rata nilai aktual, dan n merupakan jumlah data pengujian. Nilai MAE dan RMSE yang kecil menunjukkan tingkat kesalahan prediksi yang rendah, sedangkan nilai R^2 yang mendekati 1 menunjukkan bahwa model mampu menjelaskan hubungan antarvariabel dengan baik.

III. HASIL DAN PEMBAHASAN

A. Hasil Integrasi dan *Pra-pemrosesan* Data

Tahap awal penelitian dilakukan melalui proses *pra-pemrosesan* data untuk memastikan kualitas dataset yang digunakan dalam pelatihan model. Hasil *pra-pemrosesan* menunjukkan bahwa data berhasil dibersihkan dari data duplikat dan nilai yang hilang (*missing value*). Selain itu, variabel kategori seperti hari besar nasional berhasil dikonversi menjadi variabel numerik menggunakan metode *dummy encoding* sehingga dapat diproses oleh algoritma *machine learning*. Proses normalisasi juga dilakukan untuk menjaga kestabilan model selama proses pelatihan.

Setelah proses *pra-pemrosesan* selesai, dataset dibagi menjadi data latih dan data uji. Data latih digunakan untuk membangun model prediksi menggunakan algoritma *Random Forest*, sedangkan data uji digunakan untuk mengevaluasi kemampuan model dalam memprediksi data yang belum pernah dilihat sebelumnya. Variabel yang digunakan dalam proses pelatihan meliputi harga historis cabai, bulan, indikator hari besar nasional, suhu udara, kelembapan, kecepatan angin, dan tutupan awan.


Tabel 2. Hasil prediksi harga cabai pada data pengujian

Tanggal	Harga Aktual (Rp/kg)	Harga Prediksi (Rp/kg)	Selisih (Rp/kg)
6 Mei 2026	60.800	57.260	3.540
10 Mei 2026	68.200	61.185	7.015

Berdasarkan Tabel 2, model *Random Forest* mampu menghasilkan prediksi yang cukup mendekati harga aktual pada periode pengujian. Pada tanggal 6 Mei 2026, model menghasilkan prediksi sebesar Rp 57.260 dengan selisih sebesar Rp 3.540 dibandingkan harga aktual sebesar Rp 60.800. Selanjutnya, pada tanggal 10 Mei 2026, model memprediksi harga sebesar Rp 61.185, sedangkan harga aktual mencapai Rp 68.200 dengan selisih sebesar Rp 7.015. Meskipun masih terdapat selisih antara hasil prediksi dan harga aktual, model mampu menunjukkan arah perubahan harga yang sejalan dengan kondisi pasar.

B. Analisis Hubungan Variabel


Gambar 2. *Correlation Matrix* Variabel Penelitian



Berdasarkan Gambar 2, terlihat bahwa setiap variabel memiliki tingkat hubungan yang berbeda terhadap harga cabai. Variabel dengan nilai korelasi yang lebih tinggi menunjukkan kontribusi yang lebih besar terhadap perubahan harga cabai. Informasi ini menjadi dasar dalam proses pembentukan model *Random Forest* untuk mempelajari pola hubungan antara faktor historis dan faktor agroklimat terhadap harga cabai.

C. Hasil Prediksi Harga Cabai

Model *Random Forest* yang telah dilatih kemudian digunakan untuk memprediksi harga cabai pada data pengujian. Hasil prediksi dibandingkan dengan harga aktual untuk mengetahui kemampuan model dalam mengikuti pola perubahan harga cabai.



Gambar 3. Perbandingan Harga Aktual dan Harga Prediksi

Berdasarkan Gambar 3, model *Random Forest* mampu mengikuti pola perubahan harga cabai dengan cukup baik. Kurva hasil prediksi terlihat berada dekat dengan kurva harga aktual pada sebagian besar periode pengujian. Meskipun terdapat beberapa perbedaan nilai pada titik tertentu, secara umum model mampu menangkap tren kenaikan dan penurunan harga cabai yang terjadi selama periode pengamatan.

D. Evaluasi Model *Random Forest*

Evaluasi model dilakukan menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2). Hasil evaluasi model ditunjukkan pada Tabel 3.


Tabel 3 Hasil Evaluasi Model *Random Forest*

Metrik	Nilai
MAE	3878.41
RMSE	6130.38
MAPE	7.856926
R^2	0.905159

Berdasarkan hasil evaluasi pada Tabel 3, model *Random Forest* memperoleh nilai MAE sebesar 3878,41 dan RMSE sebesar 6130,39. Nilai tersebut menunjukkan bahwa rata-rata kesalahan prediksi yang dihasilkan model relatif rendah terhadap rentang harga cabai yang diamati. Selain itu, model memperoleh nilai MAPE sebesar 7,86%, yang termasuk dalam kategori sangat baik karena berada di bawah 10%. Nilai koefisien determinasi (R^2) sebesar 0,9052 menunjukkan bahwa model mampu menjelaskan sekitar 90,52% variasi harga cabai berdasarkan variabel yang digunakan dalam penelitian.

E. Analisis Feature Importance

Untuk mengetahui kontribusi variabel terhadap hasil prediksi, dilakukan analisis *feature importance* pada model *Random Forest*. Hasil analisis ditunjukkan pada Gambar 4.



Gambar 4. *Feature Importance Random Forest*

Berdasarkan Gambar 4, terlihat bahwa setiap variabel memiliki tingkat kontribusi yang berbeda dalam proses prediksi harga cabai. Variabel dengan nilai *importance* tertinggi memberikan pengaruh yang lebih besar terhadap pembentukan pohon keputusan dalam model *Random Forest*. Hasil ini menunjukkan bahwa faktor historis harga dan faktor agroklimat memiliki peran penting dalam meningkatkan kemampuan model dalam memprediksi harga cabai.

Secara keseluruhan, hasil penelitian menunjukkan bahwa algoritma *Random Forest* mampu digunakan untuk memprediksi harga cabai dengan performa yang baik. Integrasi data historis harga, data agroklimat, dan faktor musiman terbukti mampu meningkatkan kemampuan model dalam mengenali pola fluktuasi harga cabai. Nilai R^2 sebesar 0,9052 dan MAPE sebesar 7,86% menunjukkan bahwa model memiliki tingkat akurasi yang tinggi dan layak digunakan sebagai alat bantu prediksi harga cabai.

Hasil penelitian ini menunjukkan bahwa algoritma *Random Forest* mampu menghasilkan performa prediksi yang baik pada data harga cabai yang dipengaruhi oleh faktor historis dan agroklimat. Temuan ini sejalan dengan penelitian terdahulu yang menyatakan bahwa *Random Forest* efektif digunakan untuk memodelkan hubungan nonlinier pada data pertanian dan komoditas pangan. Integrasi variabel agroklimat dalam penelitian ini juga terbukti membantu meningkatkan kemampuan model dalam mengenali pola fluktuasi harga cabai.

IV. KESIMPULAN

Penelitian ini bertujuan untuk membangun model prediksi yang handal guna mengatasi permasalahan fluktuasi harga cabai yang kerap menyulitkan perencanaan. Melalui algoritma *Random Forest*, data historis harga diintegrasikan dengan faktor cuaca dan musiman untuk memberikan gambaran prediksi harga yang lebih akurat dan stabil. Berdasarkan penelitian yang telah dilakukan, diperoleh beberapa kesimpulan sebagai berikut:

1. Penelitian ini berhasil membangun model prediksi harga cabai menggunakan algoritma *Random Forest* dengan memanfaatkan data historis harga, data agroklimat yang meliputi suhu, kelembapan, kecepatan angin, dan tutupan awan, serta faktor musiman berupa hari besar nasional. Integrasi berbagai variabel tersebut memberikan informasi yang relevan dalam memprediksi fluktuasi harga cabai.
2. Berdasarkan hasil pengujian, model *Random Forest* memperoleh nilai MAE sebesar Rp3.878,41/kg, RMSE sebesar Rp6.130,38/kg, MAPE sebesar 7,86%, dan koefisien determinasi (R^2) sebesar 0,9052. Nilai MAPE yang berada di bawah 10% menunjukkan bahwa model memiliki tingkat akurasi prediksi yang sangat baik, sedangkan nilai R^2 sebesar 0,9052 menunjukkan bahwa model mampu menjelaskan sekitar 90,52% variasi harga cabai berdasarkan variabel yang digunakan dalam penelitian.
3. Hasil penelitian ini membuktikan bahwa algoritma *Random Forest* efektif digunakan untuk memprediksi harga cabai dengan memanfaatkan kombinasi data historis dan faktor agroklimat. Model yang dihasilkan berpotensi digunakan sebagai alat bantu dalam pengambilan keputusan terkait pengelolaan produksi, distribusi, dan stabilisasi harga komoditas cabai. Untuk penelitian selanjutnya, dapat ditambahkan variabel lain seperti curah hujan, volume produksi, data pasokan pasar, inflasi, serta dinamika berita ekonomi atau geopolitik guna meningkatkan performa dan kemampuan generalisasi model prediksi.

DAFTAR PUSTAKA

- [1] A. Dwi Lestari, E. Erlikasna, R. C. Simbolon, I. Breta, M. Daniyal, and R. S. Karo Karo, "Dampak Fluktuasi Harga Beras, Bawang Merah, Cabai Terhadap Inflasi Impact of Price Fluctuations of Rice, Shallots, Chilies on Inflation," 2024. [Online]. Available: <https://journal.unhas.ac.id/index.php/jsep>. doi: 10.20956/jsep.v20i2.35057.
- [2] I. R. A. S. Putri, Harianto, and N. Rosiana, "DISPARITAS HARGA CABAI RAWIT (*Capsicum frutescens* L.) ANTAR WAKTU DAN ANTAR WILAYAH DI INDONESIA," *Jurnal Agribisnis Indonesia*, vol. 13, no. 2, pp. 333–349, Dec. 2025, doi: 10.29244/jai.2025.13.2.333-349.
- [3] F. Nasirudin and A. A. Dzikrullah, "Pemodelan Harga Cabai Indonesia dengan Metode Seasonal ARIMAX," *Jurnal Statistika dan Aplikasinya*, vol. 7, no. 1, 2023. doi: 10.21009/JSA.07110.
- [4] G. Gunawan, W. Andriani, and N. T. Ujianto, "Prediksi Harga Cabai Musiman Menggunakan Model LSTM di Jawa Tengah," *Infomatek*, vol. 27, no. 2, pp. 243–254, Dec. 2025, doi: 10.23969/infomatek.v27i2.26460.
- [5] J. Permana, R. Naufal Sujana, K. Pradipa Komala, and B. Dwiyanto, "Jurnal Ilmu Komputer dan Sistem Informasi PREDIKSI HARGA CABAI RAWIT MENGGUNAKAN LGBM, RANDOM FOREST, DAN XGBOOST," 2026. doi: 10.24912/7nbfrp18.
- [6] D. R. Lestari, E. A. S. Bangun, F. L. Gaol, and T. Matsuo, "Machine Learning-Based Forecasting of Agricultural Commodity Prices Using Ensemble Models," *Journal of Human, Earth, and Future*, vol. 6, no. 4, pp. 887–899, Dec. 2025, doi: 10.28991/hef-2025-06-04-09.
- [7] V. M. Byraredddy, T. Shaik, L. Kouadio, U. Bhattarai, T. Nguyen-Huy, and S. Mushtaq, "Explainable machine learning approaches for climatedriven forecasting of global

- Arabica coffee prices,” *Smart Agricultural Technology*, vol. 14, Aug. 2026, doi: 10.1016/j.atech.2026.102146.
- [8] X. Kang, J. Qi, Z. Bai, W. Xu, and X. Kong, “Integrating heterogeneous user-generated contents into spatial modeling of agricultural landscape recreational services: A geographically weighted random forest approach,” *Ecol. Inform.*, vol. 96, Jun. 2026, doi: 10.1016/j.ecoinf.2026.103796.
- [9] D. Rey-Blanco, J. L. Zofío, and J. González-Arias, “Improving hedonic housing price models by integrating optimal accessibility indices into regression and random forest analyses,” *Expert Syst. Appl.*, vol. 235, Jan. 2024, doi: 10.1016/j.eswa.2023.121059.
- [10] S. Chowdhury, A. K. Saha, and D. K. Das, “Hydroelectric Power Potentiality Analysis for the Future Aspect of Trends with R2 Score Estimation by XGBoost and Random Forest Regressor Time Series Models,” in *Procedia Computer Science*, Elsevier B.V., 2025, pp. 450–456. doi: 10.1016/j.procs.2025.01.004.