

SISTEM PREDIKSI LONJAKAN HARGA PANGAN BERBASIS RANDOM FOREST UNTUK EARLY WARNING SYSTEM

Reihan Setya Banda Syah Putra^{1*}, Sopingi², Aprilisa Arum Sari³

^{1,2,3} Universitas Duta Bangsa Surakarta

^{1*}220101034@mhs.udb.ac.id, ²Sopingi@udb.ac.id, ³aprilisa_arumsari@udb.ac.id

DOI: <https://doi.org/10.46880/mtk.v12i2.5656>

ABSTRACT

Food prices are essential indicators of economic stability and public welfare. Uncontrolled fluctuations, particularly sudden spikes, lower purchasing power and drive inflation. Currently, food price information systems are largely descriptive and lack predictive capabilities for sudden anomalies. To address this gap, this research develops a web-based Early Warning System (EWS) featuring digital integration and automation to proactively detect price spikes. The study utilizes daily secondary time-series data from the Strategic Food Price Information Center (PIHPS) via Kaggle, spanning from 2022 to 2026. Feature engineering, including 7-day moving averages and percentage changes, was applied to enhance the Random Forest classification algorithm. To handle the extreme 95:5 data imbalance, a class-weight balancing technique was employed during modeling. The empirical findings demonstrate that the model achieved an overall accuracy of 74% and a recall of 56% for the minority 'spike' class, proving its capability to capture more than half of the actual market crises. Furthermore, feature importance analysis revealed that the 7-day moving average was the most dominant predictor, contributing 26.22% to the model's decisions, which indicates the system effectively recognizes historical market volatility rather than nominal values. This prediction engine was successfully integrated into an interactive Laravel-based dashboard equipped with automated alert notifications. However, the system's high sensitivity resulted in a low precision of 9%, generating frequent false positive alerts that require further architectural refinement to mitigate alert fatigue in future studies.

Keywords: *Early Warning System, Price Spike, Random Forest, Feature Engineering, Time Series*

I. PENDAHULUAN

Harga pangan merupakan salah satu indikator penting dalam menjaga stabilitas ekonomi dan kesejahteraan masyarakat. Perubahan harga pangan yang tidak terkendali, khususnya dalam bentuk lonjakan harga yang terjadi secara tiba-tiba, dapat berdampak langsung terhadap daya beli masyarakat serta memicu terjadinya inflasi. Oleh karena itu, pemantauan dan pengendalian harga pangan menjadi perhatian utama bagi pemerintah maupun pelaku ekonomi. Fluktuasi harga pangan memiliki pengaruh signifikan terhadap tingkat inflasi dan kestabilan ekonomi, terutama di Indonesia, di mana perubahan harga komoditas pangan terbukti berdampak terhadap kondisi ekonomi masyarakat dan ketahanan pangan nasional [1].

Harga komoditas pangan di pasaran sangat mudah mengalami perubahan (naik-turun) akibat pengaruh dari berbagai variabel penentu, mulai dari tingkat ketersediaan pasokan, kondisi cuaca di daerah penghasil, kelancaran jalur distribusi, hingga dinamika volume permintaan dari masyarakat. Pada situasi-situasi tertentu, terjadinya ketimpangan yang ekstrem antara ketersediaan barang dan kebutuhan konsumen berpotensi besar memicu lonjakan harga yang sangat tajam hanya dalam kurun waktu yang amat singkat. Banyaknya persoalan ini juga semakin meluas dengan hadirnya berbagai faktor eksternal, seperti dampak perubahan iklim, hambatan pada rantai pasok logistik, hingga siklus pergantian musim yang membuat nilai jual komoditas selalu berubah-ubah antara satu wilayah dengan wilayah lainnya dari waktu ke waktu. Menilik betapa dinamis dan tidak stabilnya kondisi pasar tersebut, upaya untuk memetakan maupun meramalkan

arah pergerakan harga pangan tentu menjadi suatu tantangan tersendiri yang sangat sulit untuk dilakukan secara akurat apabila tidak melibatkan pendekatan komputasi yang berbasis pada analisis data [2].

Seiring dengan perkembangan teknologi informasi, pemanfaatan data historis harga pangan menjadi salah satu pendekatan yang dapat digunakan untuk melakukan analisis dan prediksi. Berdasarkan *dataset* harga pangan dari Pusat Informasi Harga Pangan Strategis (PIHPS) yang diperoleh melalui platform Kaggle, data harga berbagai komoditas pangan di Indonesia menunjukkan fluktuasi yang cukup signifikan pada periode tahun 2022 hingga 2026. Sebagai contoh, harga beras berada pada kisaran Rp9.200 hingga Rp19.800 per kilogram. Sementara itu, komoditas cabai merah mengalami fluktuasi yang jauh lebih ekstrem, yakni berkisar antara Rp13.250 hingga Rp136.900 per kilogram, dan cabai rawit bahkan sempat mencapai Rp181.900 per kilogram. Variasi harga yang cukup besar antar komoditas dan waktu tersebut menunjukkan adanya dinamika pasar yang tinggi. Mengingat informasi harga yang tersedia saat ini umumnya masih bersifat deskriptif, diperlukan pendekatan komputasional untuk mendeteksi potensi lonjakan harga secara lebih akurat.

Berbagai penelitian telah dilakukan untuk memprediksi harga pangan menggunakan metode statistik maupun *machine learning*. Hasil kajian menunjukkan bahwa metode berbasis *machine learning* mampu meningkatkan akurasi prediksi karena kemampuannya menangkap pola *non-linear* dalam data [3]. Algoritma *Random Forest* secara spesifik memiliki performa yang baik dalam memprediksi data *time series*

karena mampu menggabungkan banyak pohon keputusan untuk meningkatkan akurasi dan mengurangi risiko *overfitting* [4]. Lebih lanjut, penerapan *Random Forest* terbukti dapat menghasilkan prediksi yang bermanfaat dalam pengelolaan stok dan pengambilan keputusan strategis, seperti penentuan waktu distribusi barang [5].

Meskipun demikian, sebagian besar penelitian terdahulu masih berfokus pada peramalan nilai harga komoditas di masa mendatang menggunakan pendekatan regresi. Pendekatan tersebut umumnya bertujuan untuk memperkirakan besarnya harga yang akan terjadi, namun belum secara spesifik dirancang untuk mendeteksi lonjakan harga (*price spike*), yaitu kondisi ketika harga mengalami peningkatan yang signifikan dalam waktu singkat. Padahal, informasi mengenai potensi lonjakan harga memiliki nilai strategis yang lebih tinggi karena dapat digunakan sebagai dasar penyusunan langkah antisipatif sebelum dampak ekonomi yang lebih luas terjadi. Selain itu, hasil penelitian sebelumnya umumnya masih terbatas pada pengembangan model prediksi dan belum banyak yang mengintegrasikan model tersebut ke dalam sistem berbasis web yang dapat digunakan secara langsung sebagai sarana pemantauan dan peringatan dini. Kondisi ini menunjukkan adanya kesenjangan penelitian (*research gap*), yaitu belum tersedianya sistem yang mampu menggabungkan kemampuan prediksi lonjakan harga dengan penyajian informasi secara interaktif dan mudah diakses oleh pengguna [6].

Penerapan kecerdasan buatan, khususnya *machine learning*, telah terbukti memberikan kontribusi dalam menyelesaikan berbagai permasalahan pada sektor pangan dan pertanian. Algoritma *Random Forest* telah digunakan untuk memprediksi produktivitas pertanian, mengidentifikasi tingkat kerawanan pangan, serta mendukung pengambilan keputusan berbasis data dengan tingkat akurasi yang baik [7]. Selain mampu menangani data dalam jumlah besar, *Random Forest* juga relatif tahan terhadap *noise*, mampu memodelkan hubungan yang kompleks, dan menghasilkan performa yang stabil pada berbagai kondisi data [8]. Karakteristik tersebut menjadikan *Random Forest* sebagai metode yang sesuai untuk digunakan dalam membangun sistem prediksi lonjakan harga pangan yang memerlukan kemampuan analisis pola historis secara efektif [9].

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk merancang dan membangun sistem informasi peringatan dini (*Early Warning System*) berbasis web yang mampu memprediksi potensi lonjakan harga pangan menggunakan algoritma *Random Forest*. Lonjakan harga (*price spike*) yang dimaksud dalam penelitian ini secara spesifik didefinisikan sebagai anomali peningkatan harga harian yang menyimpang secara signifikan dari tren rata-rata pergerakannya selama satu minggu terakhir (*Moving Average* 7 hari). Ruang lingkup penelitian dibatasi pada penggunaan data historis sepuluh komoditas harga pangan Indonesia periode awal tahun 2022 hingga Februari 2026. Proses pembentukan model klasifikasi tidak hanya menggunakan harga mentah, melainkan memanfaatkan variabel turunan hasil rekayasa fitur (*feature engineering*) berupa selisih harga, persentase

perubahan, dan *Moving Average* sebagai prediktor utama. Sistem yang dikembangkan difokuskan pada deteksi otomatis potensi lonjakan harga esok hari (H+1) dan menyajikan hasil prediksinya melalui antarmuka web interaktif terpisah (*decoupled architecture*) menggunakan Laravel sebagai sarana pemantauan dan intervensi bagi pengguna.

II. METODE

1. Jenis dan Sumber Data

Data yang digunakan dalam penelitian ini merupakan data kuantitatif sekunder yang bersumber dari *dataset* historis harga pangan publik pada *platform* Kaggle. *Dataset* tersebut memiliki format deret waktu (*time series*) yang mencakup atribut waktu pencatatan (tanggal), jenis komoditas, dan nilai harga pasar dalam rentang periode tahun 2022 hingga 2026. Penerapan analisis data deret waktu ini menjadi landasan utama dalam membangun sistem peramalan harga komoditas yang terintegrasi secara web [10]. Seluruh kumpulan data historis tersebut dimanfaatkan sebagai acuan dasar untuk memetakan pola perubahan harga. Lebih lanjut, data ini juga menjadi instrumen inti pada tahap pelatihan (*training*) maupun pengujian (*testing*) algoritma *machine learning*, dengan tujuan akhir untuk membangun sebuah sistem pendukung keputusan yang mampu bekerja secara antisipatif [11]. Sebagai langkah untuk memperkuat dasar analisis dan landasan perancangan model, penelitian ini juga menggali informasi tambahan melalui tinjauan kepustakaan. Rujukan yang digunakan bersumber dari berbagai jurnal ilmiah maupun buku teks yang secara khusus mengkaji penerapan *machine learning* serta pengembangan sistem pemantauan harga pangan.

2. Metode Pengumpulan Data

Guna memperoleh rumusan data yang valid dan relevan, penelitian ini menerapkan dua pendekatan utama dalam proses pengumpulan data, yaitu:

a) Observasi

Difokuskan pada peninjauan langsung terhadap *dataset* harga pangan dari *platform* Kaggle. Langkah ini bertujuan untuk mengidentifikasi struktur data, memetakan jenis atribut yang tersedia, serta memvalidasi kelengkapan data sebelum memasuki fase pra-pemrosesan.


b) Studi literatur

Dilakukan dengan mengkaji berbagai referensi teoretis dari penelitian-penelitian terdahulu untuk memperkuat landasan analisis. Kajian literatur ini difokuskan pada penerapan *machine learning*, khususnya ketangguhan algoritma *Random Forest* dalam menangani pola data harga komoditas pangan yang bersifat *non-linear* dan dinamis [12]. Lebih lanjut, referensi tersebut juga diintegrasikan untuk memperdalam pemahaman terkait pemrosesan data *time series*, teknik *preprocessing*, serta parameter evaluasi kinerja model prediktif yang meliputi *accuracy*, *precision*, dan *recall*.

3. Metode Pengembangan

Pengembangan sistem ini dilakukan secara bertahap dan terstruktur. Alur pengerjaannya dimulai dari tahap identifikasi masalah di awal, lalu diakhiri dengan proses implementasi perangkat lunak. Fokus utama penelitian adalah mendeteksi potensi lonjakan harga pangan (*price*

spike) sebagai bentuk peringatan dini melalui klasifikasi biner, yaitu kondisi "Lonjakan" dan "Tidak Terjadi Lonjakan". Berikut adalah metode pengembangan dalam penelitian ini:



Gambar 1 Tahapan Penelitian

Gambar 1 merepresentasikan alur metodologi penelitian yang disusun secara sistematis dan terstruktur, menjabarkan tahapan rekayasa perangkat lunak mulai dari pemahaman masalah krisis harga hingga implementasi sistem peringatan dini. Tahapan pra-pemrosesan dan transformasi data pada diagram tersebut berperan krusial sebagai fondasi komputasional untuk menyiapkan dataset agar pola fluktuasi yang dinamis dapat direpresentasikan secara matematis. Selanjutnya, alur pemodelan mengandalkan algoritma Random Forest untuk mengeksekusi klasifikasi biner, yang kinerjanya kemudian dievaluasi secara ketat sebelum diwujudkan ke dalam bentuk integrasi digital berbasis web. Rangkaian tahapan ini memastikan bahwa sistem akhir tidak hanya beroperasi secara teoretis, tetapi juga memiliki keandalan teknis saat diimplementasikan secara nyata

a) Pemahaman Masalah

Pada tahap ini dilakukan analisis terhadap kebutuhan sistem, yaitu sistem harus mampu mengolah data harga pangan, melakukan prediksi menggunakan metode machine learning, serta menampilkan hasil prediksi dalam bentuk yang mudah dipahami oleh pengguna. Selain itu, ditentukan bahwa output sistem berupa klasifikasi kondisi harga, yaitu kategori lonjakan dan tidak lonjakan, serta penyajian informasi peringatan dalam bentuk status atau popup pada sistem.

b) Pra-pemrosesan Data

Data sekunder historis harga pangan diperoleh dari Pusat Informasi Harga Pangan Strategis (PIHPS) melalui repositori Kaggle. Data ini memiliki frekuensi pencatatan harian yang mencakup periode Januari 2022 hingga Februari 2026 untuk sepuluh komoditas bahan pokok utama. Tahap pra-pemrosesan data dilakukan dengan membersihkan anomali perekaman tanpa memotong nilai ekstrem, karena nilai ekstrem tersebut justru merupakan representasi dari krisis harga itu sendiri. Nilai kosong (*missing values*) ditangani menggunakan teknik interpolasi *Forward Fill* (FFill) untuk menjaga kontinuitas deret waktu harian secara berurutan. Selanjutnya, dilakukan rekayasa fitur (*feature engineering*) untuk mengekstraksi variabel prediktor baru yang merepresentasikan momentum pasar. Fitur turunan yang dibentuk meliputi selisih harga absolut dengan hari sebelumnya (*lag* harian), persentase perubahan harga, serta rata-rata pergerakan harga atau *Moving Average* dengan jendela observasi tujuh hari (MA-7) yang berfungsi menghaluskan fluktuasi harian dan menangkap tren mingguan secara otomatis.

c) Analisis dan Transformasi Data

Pada tahapan analisis dan transformasi, data yang telah bersih diolah lebih lanjut menggunakan teknik rekayasa fitur (*feature engineering*) untuk membentuk sejumlah variabel prediktor baru yang adaptif terhadap volatilitas pasar pangan. Atribut turunan yang diekstraksi meliputi nilai selisih harga absolut dengan hari sebelumnya (*lag* harian), persentase perubahan harga harian, serta nilai rata-rata pergerakan harga sepekan terakhir dengan rentang jendela observasi tujuh hari (*Moving Average* 7 hari). Setelah pembentukan fitur selesai, proses pelabelan kelas (*class labeling*) dieksekusi secara biner menggunakan metrik persentase perubahan harga dengan menetapkan nilai ambang batas (*threshold*) sebesar 2,0 persen. Kenaikan harga harian yang melampaui batas 2,0 persen otomatis diklasifikasikan sebagai kejadian "Lonjakan" (kelas 1), sedangkan pergerakan harga di bawah batas tersebut dikategorikan ke dalam kondisi "Stabil" (kelas 0). Akhir dari tahapan ini adalah memisahkan *dataset* berlabel menjadi proporsi data latih (*training*) sebesar 80 persen dan data uji (*testing*) sebesar 20 persen menggunakan metode pemisahan waktu (*time-split*) berdasarkan urutan kronologis kalender untuk menghindari risiko kebocoran data masa depan (*data leakage*).

d) Pemodelan (Modelling)

Fase pemodelan berfokus pada pembangunan arsitektur klasifikasi prediktif dengan mengimplementasikan algoritma *Random Forest* sebagai mesin komputasi utama dalam sistem. Algoritma *ensemble learning* ini dipilih karena keunggulannya yang tinggi dalam menggabungkan banyak pohon keputusan (*decision trees*) untuk menangkap pola hubungan data deret waktu yang bersifat non-linear sekaligus menekan risiko jenuh (*overfitting*). Karakteristik data dalam penelitian ini memiliki tingkat ketimpangan kelas (*imbalanced data*) yang sangat ekstrem, di mana label harga stabil mendominasi sebesar 95 persen sedangkan kejadian krisis lonjakan harga hanya terekam sebanyak 5 persen dari total populasi data. Sebagai bentuk otomatisasi penanganan data timpang tanpa

menggunakan metode luar seperti SMOTE, konfigurasi parameter algoritma *Random Forest* disesuaikan secara khusus dengan mengaktifkan fitur *class weight balanced*. Melalui parameter ini, model secara mandiri akan memberikan penalti bobot komputasional yang jauh lebih berat terhadap kelas minoritas selama proses pelatihan berlangsung, sehingga sistem dipaksa memiliki kepekaan ekstra dalam mengenali sinyal krisis.

e) *Evaluasi Sistem (Evaluation)*

Tahap evaluasi dilakukan secara ketat untuk mengukur tingkat performa, keandalan, dan stabilitas model prediksi melalui pengujian berbasis instrumen *Confusion Matrix*. Pengukuran kinerja teknis dari arsitektur model tidak hanya bersandar pada satu metrik tunggal seperti nilai akurasi global (*Accuracy*), melainkan dijabarkan secara mendalam melalui metrik tingkat presisi (*Precision*) serta nilai sensitivitas (*Recall*) untuk masing-masing kelas target. Dalam konteks pengembangan sistem peringatan dini (*Early Warning System*) ekonomi pangan, tolok ukur utama keberhasilan pengujian difokuskan pada pencapaian nilai *Recall* kelas lonjakan harga. Orientasi evaluasi ini dipilih untuk memastikan model mampu bekerja secara proaktif dalam menangkap persentase insiden krisis yang sesungguhnya di lapangan, guna meminimalkan risiko kelalaian fatal sistem (*False Negative*) sekaligus mengukur batasan toleransi pengguna terhadap kemunculan alarm palsu (*False Positive*).

f) *Implementasi Sistem (Deployment)*

Tahap akhir penelitian ini adalah mengintegrasikan model prediksi ke dalam sistem berbasis web sebagai *early warning system* menggunakan framework Laravel dan Python untuk pengolahan data. Penggunaan framework Laravel terbukti efektif dalam membangun *dashboard* monitoring harga pangan yang interaktif dan *real-time* [13]. Sistem ini memiliki fitur pengelolaan data harga pangan, prediksi lonjakan harga, visualisasi grafik, penyajian hasil klasifikasi, serta notifikasi peringatan, sehingga dapat membantu pengguna dalam memantau kondisi harga dan mendukung pengambilan keputusan.

III. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil dari implementasi dan pengujian sistem prediksi lonjakan harga pangan yang telah dirancang. Penjabaran dimulai dari hasil pengolahan data historis, analisis performa algoritma *Random Forest* dalam mendeteksi lonjakan harga, hingga demonstrasi fungsionalitas sistem peringatan dini berbasis web yang diintegrasikan menggunakan framework Laravel.

1. Hasil Pra Pemrosesan Data

Ekplorasi awal terhadap karakteristik data dilakukan melalui analisis statistik deskriptif terhadap sepuluh komoditas pangan utama yang menjadi objek penelitian. Analisis ini sangat krusial untuk memberikan gambaran menyeluruh mengenai sebaran data harian serta tingkat variabilitas harga sebelum memasuki tahapan pemodelan prediktif. Hasil rekapitulasi parameter statistik yang meliputi jumlah data bersih, nilai minimum, nilai maksimum, nilai rata-rata (*mean*), serta standar deviasi (*std*) untuk masing-masing komoditas disajikan secara

rinci pada Tabel 1. Penyusunan tabel ini dirancang secara ringkas guna menghindari penumpukan teks yang panjang dan memastikan seluruh informasi kuantitatif dapat diinterpretasikan dengan mudah oleh pembaca.

Tabel 1 Statistik Deskriptif Nilai Harga Komoditas Pangan Periode 2022–2026

Komoditas Pangan	Jumlah Data Mentah	Harga Minimum (Rp)	Harga Maksimu m (Rp)	Rata-rata Harga (Rp)	Standar Deviasi (Std) (Rp)
Bawang Merah	47,211	13,750	98,750	40,317	10.612
Bawang Putih	47,211	18,000	87,100	38,330	8.182
Beras	47,211	9,200	19,800	14,252	1.937
Cabai Merah	47,213	13,250	136,900	51,020	18.275
Cabai Rawit	47,213	17,000	181,900	55,906	20.738
Daging Ayam	47,211	19,600	70,150	36,865	5.974
Daging Sapi	47,210	84,850	218,750	134,883	12.044
Gula Pasir	47,211	11,700	32,250	17,154	2.079
Minyak Goreng	47,199	13,850	48,050	20,094	2.423
Telur Ayam	47,211	18,250	81,250	29,932	3.750

Berdasarkan Tabel 1, dataset yang digunakan mencakup sepuluh komoditas pangan utama, yaitu bawang merah, bawang putih, beras, cabai merah, cabai rawit, daging ayam, daging sapi, gula pasir, minyak goreng, dan telur ayam. Dari data tersebut, terlihat adanya rentang harga yang sangat ekstrem, dengan contoh lonjakan tertinggi terjadi pada komoditas cabai rawit yang angkanya sempat menembus Rp181.900. Karena tujuan utama penelitian ini adalah membangun *Early Warning System* (EWS) untuk mendeteksi lonjakan harga (*price spikes*), metode pembersihan data ekstrem (*outlier*) secara konvensional seperti pemotongan *Interquartile Range* (IQR) sengaja tidak banyak diterapkan. Hal ini dilakukan karena nilai-nilai harga yang melambung sangat tinggi tersebut justru merupakan cerminan dari kondisi krisis (kelas target) yang sangat penting untuk dipertahankan, agar polanya dapat dipelajari secara maksimal oleh algoritma *Random Forest*.

Tahap pembersihan data (*data cleaning*) dikhususkan pada dua langkah operasional. Langkah pertama adalah menangani nilai kosong (*missing values*) menggunakan metode *Forward Fill* (FFill) demi menjaga kontinuitas data *time series*. Langkah kedua meliputi penghapusan anomali akibat kesalahan ketik (*typo*) pada sistem perekaman, seperti entri harga yang tercatat bernilai nol. Setelah dataset dipastikan bersih, proses dilanjutkan ke tahap *Feature Engineering* untuk membentuk sejumlah variabel baru, yaitu selisih harga harian, persentase perubahan harga, dan *Moving Average* 7 hari (MA-7). Seluruh atribut turunan ini nantinya berfungsi sebagai variabel penentu utama yang memandu model untuk menangkap pola ketidakstabilan pasar sebelum lonjakan harga terjadi.


2. Evaluasi Kinerja Model Random Forest

Setelah proses persiapan data selesai, dataset dibagi ke dalam dua kelompok, yakni 80 persen untuk data latih dan 20 persen untuk data uji. Satu hal yang perlu ditegaskan di sini adalah adanya ketimpangan proporsi yang sangat mencolok pada label klasifikasinya. Data harga stabil mendominasi dengan total 108.344 baris, sedangkan kejadian lonjakan harga hanya terekam sebanyak 4.825 baris. Kondisi ini memperlihatkan rasio perbedaan yang sangat ekstrem di kisaran 95 persen berbanding 5 persen.

Pada tahap persiapan awal, penelitian ini tidak menggunakan teknik penyeimbangan data apa pun, termasuk metode seperti SMOTE. Ketidadaan proses penyeimbangan ini diakui sebagai sebuah kelemahan metodologis yang berimbas langsung pada tingginya angka *False Positive* atau alarm palsu. Sebagai solusi atas ketimpangan tersebut, penyesuaian baru dilakukan ketika model mulai dibangun. Konfigurasi algoritma *Random Forest* dilengkapi dengan parameter *class weight balanced*. Melalui parameter ini, sistem secara komputasional akan memberikan penalti atau hukuman yang lebih berat jika algoritma gagal mendeteksi data lonjakan yang jumlahnya sangat sedikit. Penyesuaian bobot kelas inilah yang membuat model akhirnya memiliki kepekaan ekstra untuk menangkap setiap sinyal krisis. Kinerja dari model yang telah dilatih ini lalu diuji menggunakan *Confusion Matrix*. Tujuannya adalah melihat sejauh mana hasil tebakan sistem selaras dengan kondisi riil di pasar. Rincian hasil klasifikasinya disajikan selengkapnya pada Tabel 2.

Tabel 2 Evaluasi Kinerja Model

	Prediksi: Harga Stabil (0)	Prediksi: Lonjakan Harga (1)
Aktual: Harga Stabil (0)	81.258 (True Negative)	27.086 (False Positive)
Aktual: Lonjakan Harga (1)	2.123 (False Negative)	2.702 (True Positive)



Gambar 2 Matriks Evaluasi Kinerja Klasifikasi Algoritma Random Forest

Gambar 2 memvisualisasikan hasil pengujian performa klasifikasi model melalui instrumen *Confusion Matrix* untuk membandingkan antara hasil prediksi sistem dengan kondisi riil di pasar secara empiris. Gradien warna pada matriks tersebut memberikan representasi visual yang jelas mengenai distribusi kepadatan data hasil prediksi model, di mana konsentrasi data tertinggi berpusat pada kuadran *True Negative* yang mencerminkan ketepatan deteksi pada kondisi harga komoditas yang stabil. Di sisi lain, visualisasi ini

memperlihatkan sebaran data pada kuadran *False Positive* yang cukup signifikan sebagai konsekuensi logis dari optimalisasi parameter sensitivitas arsitektur model. Berdasarkan *Confusion Matrix* tersebut, diekstraksi metrik kinerja evaluasi yang menghasilkan tingkat akurasi keseluruhan sebesar 74%, presisi 9%, dan *recall* 56% untuk kelas target lonjakan harga. Sebagai perbandingan performa dasar (*baseline*), pemodelan prediktif standar tanpa penerapan penyeimbangan bobot kelas umumnya akan menghasilkan akurasi semu di atas 95% namun dengan nilai *recall* yang mendekati angka nol, karena sistem secara otomatis hanya mengklasifikasikan seluruh instans ke dalam kelas mayoritas harga stabil.

Oleh karena itu, pencapaian *recall* sebesar 56% pada sistem yang telah terkalibrasi parameter bobotnya ini merupakan sebuah lompatan kinerja yang sangat krusial. Dalam arsitektur sistem peringatan dini (*Early Warning System*), sensitivitas algoritma dalam menangkap 2.702 sinyal krisis dari lapangan menjadi tolok ukur utama yang jauh lebih bernilai secara ekonomi dibandingkan sekadar mengejar tingginya probabilitas akurasi global. Tingkat sensitivitas model yang dikonfigurasi secara proaktif ini memunculkan fenomena pertukaran nilai (*trade-off*) yang tajam antara *False Positive* dan *False Negative*. Pendekatan komputasional dalam penelitian ini secara sengaja dirancang untuk menekan angka *False Negative* atau kegagalan sistem dalam mendeteksi ancaman lonjakan yang sesungguhnya[14]. Kegagalan deteksi dini tersebut dinilai sebagai kondisi paling berbahaya yang dapat berakibat fatal berupa inflasi liar tak terkendali di tengah masyarakat. Sebagai konsekuensi logis dari tingginya kepekaan tersebut, sistem memicu lonjakan kasus *False Positive* (alarm palsu) yang menekan nilai presisi model hingga ke level 9%. Dari kacamata manajemen risiko krisis, skenario peringatan berlebih ini dipandang jauh lebih rasional dan dapat ditoleransi karena hanya sebatas meningkatkan kesiagaan operasional pemangku kebijakan, dibandingkan harus mengambil risiko menghadapi krisis lonjakan komoditas tanpa adanya peringatan sama sekali.


Meskipun demikian, kemunculan peringatan krisis yang berulang kali tanpa bukti nyata di lapangan ini tetap menjadi catatan evaluasi krusial karena rentan memicu sindrom *alert fatigue* atau kelelahan peringatan, di mana pengguna dasbor berisiko mengalami penurunan kepekaan psikologis dan mengabaikan rentetan notifikasi darurat[15]. Guna memberikan pemahaman yang komprehensif mengenai kemampuan klasifikasi model pada masing-masing kategori, evaluasi performa tidak hanya dijabarkan secara agregat melainkan dipecah secara detail untuk setiap kelas target. Pengujian ini memetakan nilai presisi (*precision*), sensitivitas (*recall*), dan nilai harmoni (*f1-score*) secara terpisah antara kondisi harga stabil (kelas 0) dan kondisi krisis lonjakan harga (kelas 1). Rincian metrik evaluasi kinerja algoritma untuk masing-masing kelas hasil ekstraksi *confusion matrix* tersebut dipaparkan secara terstruktur pada Tabel 3. Melalui penyajian data per kelas ini, karakteristik ketimpangan performa model akibat *trade-off* data yang tidak seimbang dapat terlihat secara transparan tanpa memerlukan deskripsi tekstual yang rumit di dalam sel tabel.

Tabel 3 Metrik Evaluasi Kinerja Klasifikasi Model Berdasarkan Kelas Target

Label Kelas Target	Presisi (Precision)	Sensitivitas as Recall)	F1 Score
Harga Stabil (Kelas 0)	97%	75%	85%
Lonjakan Harga (Kelas 1)	9%	56%	16%

3. Analisis Feature Importance

Untuk memahami mekanisme pengambilan keputusan oleh algoritma *Random Forest* dalam mendeteksi anomali harga pangan, dilakukan ekstraksi nilai *Feature Importance*. Analisis ini mengukur seberapa besar kontribusi masing-masing variabel prediktor dalam mengurangi *impurity* (ketidakmurnian) pada setiap percabangan pohon keputusan. Hasil pembobotan fitur disajikan pada Gambar 3.



Gambar 3 Grafik Tingkat Kepentingan Variabel Prediktor dalam Klasifikasi.

Gambar 3 mengilustrasikan kontribusi dan tingkat signifikansi dari masing-masing variabel prediktor dalam meminimalkan ketidakmurnian nilai pembagian pada percabangan pohon keputusan algoritma *Random Forest*. Berdasarkan grafik hirarki kepentingan fitur tersebut, terlihat secara transparan bahwa fitur-fitur turunan yang dibentuk melalui proses rekayasa data mendominasi keseluruhan mekanisme pengambilan keputusan komputasional. Keberhasilan algoritma dalam memetakan anomali pasar tersebut sangat dipengaruhi oleh ekstraksi variabel prediktor pada tahap rekayasa fitur secara terotomatisasi.


Variabel rata-rata pergerakan harga sepekan terakhir (*Moving Average* 7 hari) menempati urutan teratas sebagai indikator paling dominan dengan kontribusi sebesar 26,22%, diikuti oleh nominal harga aktual sebesar 25,67% dan harga kemarin sebesar 21,56%. Fakta analitik ini mengonfirmasi bahwa kecerdasan algoritma tidak didasarkan pada hafalan angka harian secara kaku, melainkan berhasil mengidentifikasi momentum volatilitas serta tren pergerakan pasar melalui integrasi data komprehensif. Fluktuasi harga yang tajam serta deviasi yang melenceng jauh dari nilai rata-rata historis terbukti menjadi sinyal empiris terkuat yang memvalidasi tingginya probabilitas terjadinya lonjakan harga pada keesokan harinya. Visualisasi ini menegaskan bahwa arsitektur model secara cerdas mengandalkan konteks riwayat dinamika pasar untuk menghasilkan

keputusan prediktif yang akurat. Kendati arsitektur sistem ini terbukti sangat layak untuk diimplementasikan secara digital, terdapat sejumlah keterbatasan operasional yang harus diakui sebagai celah perbaikan pada riset lanjutan.

Untuk mereduksi dampak kelelahan peringatan (*alert fatigue*) akibat tingginya tingkat *False Positive*, pengembangan sistem peringatan dini di masa depan perlu difokuskan pada optimalisasi kalibrasi ambang batas (*thresholding*) probabilitas algoritma. Selain itu, diperlukan integrasi variabel eksternal secara lebih komprehensif, seperti penarikan otomatis untuk data cuaca harian, indeks pasokan logistik, maupun sentimen pasar. Penambahan dimensi data tersebut diharapkan mampu meningkatkan presisi klasifikasi model tanpa harus mereduksi nilai *recall*, sehingga peringatan dini yang disajikan dapat menjadi semakin akurat, efisien, dan optimal dalam menjaga stabilitas ketahanan pangan nasional.

4. Implementasi Web dan EWS

Tahapan akhir dari penelitian ini adalah mengimplementasikan model *Random Forest* yang telah dievaluasi ke dalam sebuah sistem informasi peringatan dini (*Early Warning System*) berbasis web. Pengembangan sistem ini menggunakan pendekatan arsitektur *Decoupled* (terpisah), di mana fungsionalitas *Machine Learning* berjalan pada *environment* Python (sebagai *Application Programming Interface* / API), sementara antarmuka pengguna (*frontend*) dan manajemen basis data dikembangkan menggunakan *framework* Laravel (PHP).




Gambar 4 Antarmuka Grafik Pemantauan Tren Pergerakan Harga Historis

Gambar 4 menampilkan antarmuka pemantauan analitis yang mengimplementasikan integrasi digital secara penuh dalam memvisualisasikan tren fluktuasi harga komoditas historis. Dasbor interaktif ini tidak sekadar menyajikan rekapitulasi data mentah, melainkan mentransformasikan data deret waktu selama tiga puluh hari terakhir menjadi representasi grafis yang komprehensif. Melalui pemanfaatan pustaka visualisasi yang dinamis, sistem mampu memetakan pergerakan kurva harga secara presisi berdasarkan variabel wilayah dan jenis komoditas, sehingga memberikan landasan observasi komparatif yang kuat bagi para pemangku kebijakan.

Visualisasi ini berfungsi sebagai instrumen analitis awal yang krusial sebelum sistem mengeksekusi proses otomatisasi prediktifnya, memastikan pengguna dapat membedah konteks volatilitas dan riwayat dinamika pasar secara mendalam. Fitur ini dirancang secara dinamis menggunakan pustaka *Chart.js*, sehingga

pengguna dapat secara visual memantau pola pergerakan harga (*Moving Average*) sebelum mengambil keputusan strategis. Selain fungsi pemantauan historis, inti dari *Early Warning System* diimplementasikan melalui modul "Simulasi Prediksi" dan "Update Harga Harian". Alur kerja (*workflow*) dari fitur peringatan dini ini didesain agar responsif terhadap interaksi pengguna. Ketika aktor (Admin) memasukkan data harga aktual harian melalui form dasbor, sistem akan secara otomatis mengirimkan *request* ke *API Machine Learning* untuk memproses atribut fitur (seperti selisih harga dan persentase perubahan) dan melakukan klasifikasi kondisi hari esok (H+1).



Gambar 5 Dasbor Antarmuka Peringatan Dini dan Hasil Potongan Visual Panel Notifikasi Krisis Pangan

Gambar 5 merepresentasikan wujud nyata dari otomatisasi sistem peringatan dini yang beroperasi secara seketika (*real-time*) sebagai respons langsung terhadap hasil komputasi algoritma kecerdasan buatan. Pada antarmuka ini, setiap data harga terkini yang diinputkan ke dalam sistem akan secara otomatis memicu proses integrasi digital melalui Application Programming Interface (API) untuk mengekstraksi probabilitas kondisi harga pada hari esok. Sistem dirancang secara khusus untuk memberikan umpan balik visual seketika, yang diwujudkan melalui kemunculan panel peringatan bergradasi merah tegas manakala terdeteksi adanya potensi krisis lonjakan. Pendekatan desain antarmuka berbasis urgensi ini ditujukan untuk memicu tingkat kesiagaan tinggi, memastikan bahwa sinyal bahaya hasil terjemahan dari arsitektur matematis Random Forest dapat langsung diidentifikasi secara kasat mata guna mempercepat perumusan langkah intervensi pasar. Selain itu, status pada tabel riwayat pemantauan juga akan diperbarui dengan indikator label berwarna merah bertuliskan "LONJAKAN". Sebaliknya, jika harga diprediksi stabil, indikator pada tabel riwayat pemantauan akan menampilkan label berwarna hijau bertuliskan "AMAN". Desain antarmuka yang informatif ini memastikan bahwa hasil komputasi matematis yang kompleks dari algoritma *Random Forest* dapat ditranslasikan menjadi sinyal peringatan yang mudah dipahami (*user-friendly*) bagi pemangku kebijakan dalam menentukan intervensi pasar.

IV. KESIMPULAN

Penelitian ini menyimpulkan bahwa algoritma *Random Forest* layak diimplementasikan sebagai mesin

klasifikasi utama dalam Sistem Peringatan Dini (*Early Warning System*) untuk memprediksi potensi lonjakan harga pangan secara digital. Melalui pendekatan rekayasa fitur turunan dan kalibrasi penyeimbangan bobot kelas pada *dataset* yang timpang, model berhasil mencatatkan tingkat akurasi keseluruhan sebesar 74% dengan nilai sensitivitas (*recall*) sebesar 56% dalam mendeteksi kelas target lonjakan harga. Meskipun nilai presisi model masih tergolong rendah di angka 9% akibat tingginya tingkat *False Positive* atau alarm palsu, arsitektur ini secara strategis lebih diutamakan guna menekan angka kegagalan deteksi (*False Negative*) yang berisiko memicu inflasi tidak terkendali. Secara fungsionalitas, pemodelan berbasis Python ini telah berhasil diintegrasikan ke dalam antarmuka sistem informasi web menggunakan *framework* Laravel, sehingga integrasi antarplatform tersebut menghasilkan sebuah dasbor interaktif yang mampu memvisualisasikan tren pasar serta menyajikan notifikasi peringatan lonjakan secara otomatis bagi pengguna.

Secara akademis, kontribusi keilmuan dari penelitian ini terletak pada pergeseran paradigma pemodelan fluktuasi harga pangan, dari yang sebelumnya didominasi oleh pendekatan regresi untuk estimasi nilai nominal masa depan, menjadi pendekatan klasifikasi biner yang berorientasi spesifik pada deteksi ambang batas lonjakan (*price spike*) sebagai basis mitigasi krisis. Penelitian ini memperkaya literatur kecerdasan buatan terapan dengan memberikan bukti empiris mengenai efektivitas implementasi parameter *class weight balancing* dalam mengatasi ketimpangan data deret waktu yang ekstrem (95:5) tanpa mendistorsi karakteristik asli dari rekam jejak krisis pasar. Selain itu, kajian ini memberikan sumbangsih metodologis berupa pembuktian bahwa variabel turunan hasil rekayasa fitur, seperti rata-rata pergerakan harga sepekan terakhir (*Moving Average* 7 hari) dan persentase perubahan harian, memiliki pengaruh matematis yang jauh lebih dominan dalam memandu keputusan model untuk menangkap pola volatilitas ketidakstabilan pasar dibandingkan sekadar menganalisis nilai nominal harga mentah. Integrasi arsitektur terpisah (*decoupled architecture*) antara lingkungan komputasi Python dan sistem informasi web Laravel dalam penelitian ini juga menjadi referensi arsitektural penting dalam menjembatani kesenjangan antara model teoritis *machine learning* dan aplikasi praktis sistem pendukung keputusan (*decision support system*) di sektor ekonomi pangan.

Sebagai rekomendasi praktis, sistem peringatan dini yang telah dibangun ini siap untuk dimanfaatkan oleh pemangku kebijakan terkait, seperti tim pengendali inflasi daerah, sebagai instrumen pendukung operasional dalam merumuskan langkah intervensi pasar yang lebih responsif dan tepat sasaran. Pengguna sistem disarankan untuk memadukan hasil analitik peringatan dasbor dengan observasi langsung di lapangan agar pengambilan keputusan mitigasi krisis menjadi lebih komprehensif. Untuk penelitian lanjutan, disarankan agar fokus pengembangan diarahkan pada optimalisasi kalibrasi ambang batas (*thresholding*) probabilitas algoritma guna mereduksi frekuensi alarm palsu yang berisiko memicu kelelahan peringatan (*alert fatigue*). Selain itu, arsitektur prediksi berpotensi untuk ditingkatkan keandalannya

dengan cara mengintegrasikan pelibatan variabel eksternal secara lebih holistik, seperti parameter cuaca curah hujan, indeks ketersediaan rantai pasok, maupun data sentimen ekonomi makro. Penambahan parameter tersebut diharapkan mampu mengasah tingkat presisi klasifikasi peringatan dini di masa depan tanpa harus mengorbankan nilai sensitivitas sistem secara keseluruhan

IV. REFERENSI

- [1] M. S. Akbar, "Ketahanan Pangan Indonesia Dalam Pencapaian Sdg 2 (Zero Hunger) Ketahanan Pangan Indonesia Dalam Pencapaian," Vol. 4, No. 2, 2026.
- [2] K. Auliasari, F. Qurrotuna, M. Orisa, and P. M. Mirenty, "Analisis Fluktuasi Harga Pangan Antar Provinsi di Indonesia Menggunakan Pendekatan Data Mining dan Big Data," vol. 4, no. 2, pp. 1184–1191, 2024.
- [3] D. H. Ni Putu Erica Puspita Adriani, Roy Rudolf Huizen, "A Machine Learning-Based Approach for Retail Demand Forecasting : The Impact of Spending Score and Algorithm Optimization," vol. 11, no. 2, pp. 169–183, 2025, doi: 10.26555/jiteki.v11i2.30630.
- [4] A. Zulfia, T. N. Ilfa, Z. Damia, T. S. A. Sukiman, and A. Karima, "AI Decision Support Using Random Forest for Demand Forecasting and Stock," vol. 5, no. 2, pp. 800–805, 2025.
- [5] A. Muluk and A. Nugraha, "PENGEMBANGAN SISTEM PREDIKSI PERMINTAAN UNTUK," vol. 01, 2025.
- [6] A. Rifai, A. Wulandari, and A. Hikmaturokhman, "Design and Implementation of a Machine Learning-Based Network Optimization Recommendation System with Web Performance Evaluation," vol. 23, no. 2, pp. 76–91, 2025.
- [7] E. Najwa *Et Al.*, "Penerapan Machine Learning Untuk Rekomendasi Konsumsi Makanan Sehat Berdasarkan Data Gizi Pangan Indonesia," vol. 10, no. 1, pp. 341–348, 2026.
- [8] M. Isnaini *et al.*, "Evaluasi Perbandingan Model XGBoost , Random Forest , LightGBM , dan Artificial Neural Network dalam Klasifikasi Kerawanan Pangan Evaluasi Perbandingan Model XGBoost , Random Forest , LightGBM , dan Artificial Neural Network dalam Klasifikasi Kerawanan Pangan," vol. 14, no. 1, pp. 30–48, 2026.
- [9] A. Hura, T. Informasi, and U. Nias, "Penerapan Machine Learning Untuk Prediksi Produktivitas Pertanian Berbasis Data Cuaca Di," vol. 02, pp. 26–33, 2026.
- [10] R. Hidayat and A. Pratama, "Penerapan Analisis Data Deret Waktu untuk Peramalan Harga Komoditas Menggunakan Sistem Berbasis Web," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 7, no. 4, pp. 850–858, 2023, doi: 10.29207/resti.v7i4.5123.
- [11] H. Hafid, A. Arisandi, and R. W. Yanti, "Implementation of Random Forest Algorithm for Shallot Price Forecasting in Makassar City," vol. 8, no. 2, pp. 400–407, 2025.
- [12] N. Hasanah and S. Riyadi, "Integrasi Data Mining pada Sistem Pendukung Keputusan Berbasis Web untuk Pemantauan Komoditas Pangan," *J. Rekayasa Perangkat Lunak dan Data Min.*, vol. 8, no. 1, pp. 67–78, 2024, doi: 10.25124/jrpdm.v8i1.4011.
- [13] D. A. Putri and S. Ramadhani, "Pengembangan Dashboard Monitoring Harga Pangan Real-Time Menggunakan Framework Laravel dan Filament," *J. Sist. Inf. dan Teknol.*, vol. 12, no. 3, pp. 310–322, 2024, doi: 10.35870/jsit.v12i3.5521.
- [14] K. R. Stifan, C. Fauzi, T. Informatika, and B. Lampung, "Perbandingan Algoritma Machine Learning untuk Prediksi Potensi Tsunami di Pesisir Barat Lampung," pp. 2236–2246, 2025.
- [15] A. I. Putriani, "Analisis Spasial Kerentanan Tanah Longsor Melalui Pendekatan Algoritma Machine Learning," pp. 157–169, 2026.

