

PREDIKSI HARGA PANGAN JAYAPURA MENGGUNAKAN ELM, LSTM, LIGHTGBM, DAN GB

Jeremia Pinnywan Immanuel ¹⁾ Teny Handhayani ²⁾

¹⁾ Teknik Informatika Universitas Tarumanagara
Jl. Letjen S. Parman No. 1, Jakarta, 11440, Indonesia
email : jeremia.535210095@stu.untar.ac.id

²⁾ Teknik Informatika Universitas Tarumanagara
Jl. Letjen S. Parman No. 1, Jakarta, 11440, Indonesia
email : tenyh@fti.untar.ac.id

ABSTRAK

Ketahanan pangan di wilayah Indonesia Timur menghadapi tantangan dari aspek geografis, fluktuasi harga, dan keterbatasan pasokan. Penelitian ini bertujuan untuk membandingkan empat algoritma pembelajaran mesin, yaitu *Extreme Learning Machine* (ELM), *Long Short-Term Memory* (LSTM), *LightGBM*, dan *Gradient Boosting* dalam memprediksi harga komoditas pangan strategis di Jayapura. Dataset yang digunakan berupa data deret waktu harga harian enam komoditas pangan yang dikumpulkan dari Januari 2018 hingga April 2025. Tahapan penelitian meliputi pra-pemrosesan data, analisis eksploratif (EDA), pelatihan model, dan evaluasi performa menggunakan metrik MAE, MAPE, RMSE, R^2 , dan waktu pelatihan. Hasil percobaan menunjukkan bahwa ELM merupakan model dengan performa terbaik secara keseluruhan dengan nilai MAE 0.21, MAPE 0.76%, RMSE 0.36, R^2 0.87, serta waktu pelatihan rata-rata 4.65 detik. Model LSTM menunjukkan akurasi yang baik namun memiliki waktu pelatihan yang jauh lebih tinggi. *LightGBM* dan *Gradient Boosting* memiliki performa keseluruhan yang kurang optimal. Dengan demikian, ELM direkomendasikan sebagai model utama untuk sistem prediksi harga komoditas pangan di Jayapura yang membutuhkan kombinasi antara akurasi dan efisiensi.

Key words

ELM, Gradient Boosting, Ketahanan Pangan, LightGBM, LSTM

1. Pendahuluan

Ketahanan pangan di wilayah Indonesia Timur menghadapi tantangan yang unik, mulai dari keterbatasan akses geografis hingga fluktuasi harga akibat musim dan distribusi. Ketahanan Pangan sendiri akan terwujud bila ketiga dimensinya dapat terpenuhi, mulai dari ketersediaan pangan, aksesibilitas, dan keterjangkauan [1].

Sebagai contoh, di Kampung Holtekamp, masyarakat setempat mengalami kesulitan mencari ikan akibat musim

gelombang, yang berdampak pada mahalnya harga ikan di pasar, dan membuat masyarakat tidak mampu memenuhi asupan protein pada musim tersebut. Dengan demikian inovasi dilakukan dengan budidaya ikan di dalam ember (budikdamber) sebagai solusi yang dapat menghemat biaya dan lahan dalam menangani permasalahan ini [2]. Di lain sisi, pemanfaatan lahan pertanian dan perkebunan di Desa Mosso memiliki potensi yang besar dikarenakan didominasi oleh banyak hutan, adanya ruang terbuka hijau, dan pemukiman kepadatan rendah. Namun demikian, keterbatasan perencanaan ruang dan regulasi membuat potensi tersebut belum dapat dimanfaatkan secara optimal [3]. Studi lain lebih lanjut menyoroti potensi produksi pertanian lokal di Jayapura menunjukkan bahwa komoditas tanaman palawija seperti ubi jalar memiliki prospek tinggi untuk meningkatkan ekonomi lokal yang akan berdampak pada pendapatan daerah dan masyarakat, namun dampaknya sendiri belum dirasakan secara signifikan dikarenakan permasalahan seperti jumlah luas lahan, teknologi pasca panen, aspek permodalan para petani, belum terwujudnya korelasi produksi terhadap permintaan pasar, dan lain-lain [4].

Dengan demikian, pemerintah memiliki andil dalam membuat keputusan dan kebijakan agar harga dari komoditas pangan dapat terjaga sehingga terjangkau oleh banyak kalangan, yang dapat dilakukan bila pemerintah memiliki pemahaman terhadap perubahan harga komoditas pangan [5].

Di masa sekarang, pendekatan berbasis pembelajaran mesin telah banyak digunakan oleh peneliti dalam melakukan riset di dunia ekonomi dan finansial, salah satunya adalah untuk melakukan peramalan [6]. Oleh karena itu, metode untuk memprediksi pergerakan harga komoditas dapat digunakan, khususnya dengan pendekatan pembelajaran mesin dalam melakukan peramalan harga komoditas pangan. Pemilihan setiap algoritma didasarkan kepada keunggulan dari masing-masing algoritma, seperti *Extreme Learning Machine* (ELM) yang dapat melakukan eksekusi lebih cepat, membutuhkan parameter yang lebih sedikit untuk dilakukan pembelajaran, dan kemampuan generalisasi yang lebih baik bila dibandingkan metode *gradient-based*

tradisional [7], *Long Short-Term Memory* (LSTM) yang dapat dengan baik diimplementasikan terhadap data sekuensial sehingga cocok untuk melakukan peramalan data deret waktu [8], [9], *LightGBM* sebagai algoritma yang memanfaatkan *gradient boosting trees* dan berhasil menjadi algoritma yang memenangkan *M5 Forecasting-accuracy competition*, menjadikan algoritma ini berada di atas teknik yang lain [10], [11], dan *Gradient Boosting* sering dijadikan sebagai pembandingan dalam berbagai studi peramalan dikarenakan kestabilan performa dan terbukti kompetitif yang dibuktikan dari kompetisi yang diselenggarakan oleh platform *Kaggle*.

Penelitian sebelumnya telah dilakukan untuk melakukan peramalan pada harga pangan komoditas beras, daging ayam, telur ayam, bawang merah, bawang putih, dan cabai merah di Tasikmalaya dengan menggunakan metode LSTM dan ELM pada data deret waktu diambil dari pada April 2017 sampai Februari 2023, untuk LSTM mendapatkan skor *Mean Absolute Percentage Error* (MAPE) yang tidak lebih dari 3% dan untuk ELM mendapatkan skor MAPE yang tidak lebih dari 1% [12]. Penelitian lain juga melakukan peramalan pada data deret waktu harga pangan pada komoditas beras, daging ayam, telur ayam, bawang merah dan bawang putih yang diambil dari Januari 2018 sampai Februari 2023 dengan menggunakan GRU dan mendapatkan hasil *Mean Absolute Error* (MAE) masing-masing untuk setiap komoditas yang disebutkan sebesar 4.3, 133.1, 118.3, 341.8, dan 338.1 [13]. Penelitian menggunakan *LightGBM* dengan melakukan peramalan terhadap volum penumpang metro, sebagai contoh untuk salah satu stasiun, yakni stasiun 7, yang menghasilkan hasil MAE sebesar 14.34, MAPE sebesar 6.031, RMSE sebesar 25.360 pada 28 Januari 2019 di hari Senin dan MAE sebesar 21.451, MAPE sebesar 8.310, dan RMSE sebesar 36.668 pada 26 Januari 2019 di hari Sabtu [14].


Namun, belum ada penelitian yang secara sistematis membandingkan algoritma ELM, LSTM, *LightGBM*, dan *Gradient Boosting* secara bersamaan dalam memprediksi harga komoditas pangan di Jayapura. Oleh karena itu, penelitian ini akan melakukan perbandingan keempat algoritma bersamaan dan berfokus pada wilayah Jayapura yang memiliki tantangan dari segi geografis. Dengan demikian, kontribusi utama dari studi ini adalah untuk mendapatkan algoritma yang terbaik dari segi performa maupun waktu komputasi, sehingga dengan adanya pemilihan algoritma terbaik ini, hasil studi dapat menjadi dasar pertimbangan dalam pemilihan pendekatan prediktif yang efisien dan akurat bagi pemerintah dan lembaga instansi terkait dalam menetapkan kebijakan stabilisasi harga pangan di Jayapura.

2. Metode

2.1. Tahapan Penelitian

Penelitian ini diawali dengan pengumpulan dataset harga komoditas pangan yang mencakup enam jenis

bahan pokok, yaitu beras, daging ayam, telur ayam, bawang putih, bawang merah, dan minyak goreng. Data dikumpulkan secara manual dari sumber resmi website pemerintah dan dilakukan pengolahan menjadi format deret waktu. Setelah proses pengumpulan data, penelitian dilanjutkan dengan tahap pra-pemrosesan untuk menyiapkan data agar sesuai dengan kebutuhan input model. Selanjutnya, dilanjutkan dengan implementasi empat algoritma pembelajaran, yaitu ELM, LSTM, *LightGBM*, dan *Gradient Boosting*. Setiap hasil yang diperoleh dari pembelajaran algoritma akan dievaluasi dan dilakukan analisis komparatif hasil. Diagram alur penelitian secara lengkap ditunjukkan pada Gambar 1.



Gambar 1. Langkah penelitian yang dilakukan

2.2. Dataset

Dataset yang digunakan merupakan data deret waktu harga harian enam komoditas pangan strategis di Kota Jayapura. Data ini dikumpulkan dari Januari 2018 hingga April 2025 dan disimpan dalam format Excel. Setiap komoditas direpresentasikan sebagai satu fitur kolom dalam dataset, dengan indeks waktu pada sumbu baris. Sumber data berasal dari catatan harga pangan harian yang dipublikasikan dalam website Pusat Informasi Harga Pangan Strategis Nasional [15].

2.3. Pra-pemrosesan Data

Pra-pemrosesan data adalah proses mentransformasi data sebelum diberikan kepada algoritma. Proses ini penting untuk dilakukan dalam lingkup pembelajaran mesin, karena kualitas dari sebuah data begitu penting bagi model untuk melakukan pembelajaran terhadap pola pada data [16]. Bila pada data deret waktu tidak dilakukan proses pra-pemrosesan data, misal terdapat data hilang, maka akan merusak pola keteraturan alami dalam data [17]. Untuk itu, beberapa pendekatan pra-pemrosesan data dilakukan pada penelitian ini.

2.3.1. Interpolasi

Kehilangan dari sebuah data bisa disebabkan oleh beberapa faktor, seperti kesalahan dari manusia atau dari sebuah sistem. Data yang hilang bisa terjadi sepenuhnya secara acak, hilang secara acak, ataupun hilang secara tidak acak [18]. Kehilangan data bisa diatasi dengan berbagai cara seperti, melakukan imputasi, interpolasi

data, dan masih banyak pendekatan lainnya. Berikut merupakan salah satu pendekatan interpolasi dengan interpolasi linear dalam bentuk persamaan.

$$f_1(x) = b_0 + b_1 (X - X_0) \dots\dots\dots(1)$$

Persamaan (1) menunjukkan fungsi interpolasi, $b_0 = f(x_0)$ dan $b_1 = \frac{f(x_1) - f(x_0)}{x_1 - x_0}$, X_1 dan X_0 adalah dua titik yang sudah diketahui dan X adalah titik di antaranya yang ingin diinterpolasikan.

2.3.2. Normalisasi Data

Normalisasi data merupakan pendekatan pra-pemrosesan yang sangat penting untuk membuat data berada di skala yang sama [19], [20]. Sebagai langkah untuk memastikan hasil prediksi dan peramalan tetap stabil, normalisasi data diperlukan dan salah satu metode yang paling populer adalah normalisasi *min-max* [21]. Teknik normalisasi ini akan mentransformasi data berada di antara 0 dan 1 [20], [21]. Adapun persamaan normalisasi min-max dapat dituliskan sebagai berikut:

$$X' = \frac{(X - X_{min})}{(X_{max} - X_{min})} \dots\dots\dots(2)$$

X' adalah hasil yang telah diperoleh dari perhitungan, X adalah target data yang ingin dinormalisasi, X_{min} dan X_{max} masing-masing merupakan nilai minimum dan maksimum dari keseluruhan data.

2.3.3. Sliding Window

Sliding window merupakan teknik dalam menentukan fitur yang akan digunakan dengan membaginya berdasarkan urutan waktu (nilai *window*), dan menjadikan data setelah urutan waktu berdasarkan pembagian dari *window* menjadi target [22]. Penetapan nilai *window* yang tetap memberikan fokus yang mendalam terhadap hubungan antar langkah waktu dalam cakupan lokal, sehingga tidak diperlukan untuk memproses setiap urutan sekaligus dalam satu waktu [23]. Oleh karena manfaat yang diberikan, pendekatan ini menjadi pilihan dalam penelitian ini, yang mana nilai *window* yang ditentukan adalah sebesar 3.

2.3.4. Pembagian Data Latih dan Data Uji

Pendekatan dalam membagi pada kasus data deret waktu dilakukan dengan pembagian data menjadi data yang dijadikan pelatihan dan data yang akan di uji terhadap model menggunakan metode *Out-of-sample*. Metode ini akan menjadikan data latih yang berada pada periode awal dan data uji pada periode berikutnya secara temporal [24]. Pada penelitian ini, akan digunakan pembagian data latih menjadi 80% periode awal dan data uji 20% periode berikutnya.

2.4. Analisis Eksploratif Data

Analisis Eksploratif Data atau EDA merupakan pendekatan dalam pemahaman dataset yang digunakan dalam penelitian dengan melakukan analisis dan interpolasi informasi yang biasa ditampilkan dalam bentuk grafik atau visualisasi [25]. Prosedur analisis eksploratif data pada penelitian ini akan dilakukan untuk memahami karakteristik data deret waktu, seperti identifikasi tren jangka panjang, fluktuasi musiman, korelasi antar komoditas, dan tingkat volatilitas harga dari masing-masing komoditas guna memperoleh gambaran dinamika pergerakan harga dalam jangka waktu tertentu. Selain itu, dilakukan pula pengujian stasioneritas menggunakan *Augmented Dickey-Fuller* (ADF) untuk mengidentifikasi keberadaan tren.

2.4.1. Uji Stasioneritas

Uji stasioneritas dilakukan untuk mengetahui apakah data memiliki tren atau pola musiman yang signifikan dalam jangka waktu pengamatan. Pengujian dilakukan menggunakan metode *Augmented Dickey-Fuller* (ADF) test. ADF test melakukan pengujian dengan membuktikan apakah hipotesis nol ditolak untuk mengetahui data bersifat stasioner atau tidak [26]. Rumus dasar dari ADF test ditunjukkan pada Persamaan (3).

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \sum_{i=1}^p \delta_i \Delta y_{t-i} + \varepsilon_t \dots\dots\dots(3)$$

Pada persamaan (3), y_t menunjukkan nilai variabel pada waktu ke- t , α merupakan nilai konstan, β merupakan koefisien tren, γ merupakan koefisien *lag* utama, δ merupakan koefisien *lag differenced*, dan ε_t merupakan *error term*.

2.4.2. Analisis Korelasi

Analisis korelasi dilakukan dalam memahami sebuah keterhubungan antara dua variabel. Metode korelasi *pearson* akan digunakan, yang akan menghasilkan nilai dari -1 sampai 1, yang mana semakin tinggi menunjukkan hubungan yang semakin sempurna, dan semakin rendah menunjukkan semakin tidak berhubungannya kedua variabel [27]. Dengan demikian, penggunaan metode ini diperlukan dalam penelitian ini sebagai alat dalam membantu memahami sejauh mana korelasi dari setiap harga komoditas pangan.

2.4.3. Analisis Volatilitas Harga

Analisis volatilitas harga dilakukan dengan menggunakan metode analisis data yang bernama *rolling statistic*. Metode ini melakukan perhitungan nilai statistik, seperti deviasi standar, dengan melakukan perhitungan nilai statistik tersebut dalam jendela waktu yang bergeser, yang bertujuan untuk memahami perubahan nilai statistik dari waktu ke waktu [28]. Tingkat fluktuasi harga didapatkan dari seberapa jauh perubahan harga. Oleh karena itu, volatilitas harga dapat dihitung dengan

menggunakan *rolling standard deviation* dengan panjang window yang digunakan selama 30 hari.

2.4.4. Dekomposisi Musiman

Dekomposisi musiman berfungsi untuk memecah data deret waktu menjadi tiga komponen utama, seperti tren, pola musiman, dan residu. Proses ini memberikan beberapa manfaat, salah satunya adalah untuk memahami waktu puncak dan estimasi efek dari liburan, hari kerja, dan akhir pekan sehingga dapat membantu untuk perencanaan [29]. Oleh karena itu penelitian ini akan melakukan identifikasi dan analisis terhadap komponen tren, pola musiman, dan residu guna memperoleh pemahaman yang lebih mendalam terhadap dinamika harga pangan komoditas dari waktu ke waktu.

2.5. Algoritma

2.5.1. Extreme Learning Machine (ELM)

Extreme Learning Machine atau ELM adalah model yang terkenal dikarenakan menggunakan satu lapisan sembunyi, dengan memiliki kelebihan seperti pembelajaran yang cepat dan kemampuan generalisasi yang baik [12]. ELM menggunakan pendekatan cara kerja yang serupa dengan bagaimana cara otak manusia bekerja, yang mana terdapat pengiriman informasi dari satu neuron ke neuron lain [30]. Demikian proses dari pembelajaran pada model ELM dapat dilihat pada persamaan berikut.

$$y_j = \sum_{i=1}^L \beta_i g(w_i x_j + b_i) \dots \dots \dots (4)$$

Pada persamaan (4), y_j merepresentasikan vektor target, β_i merupakan vektor bobot penghubung antara lapisan tersembunyi dan lapisan output, w_i adalah vektor bobot penghubung antara lapisan input dan lapisan tersembunyi. Selain itu, model ini menggunakan g sebagai fungsi aktivasi dan b_i sebagai bobot bias

2.5.2. Long Short-Term Memory (LSTM)

Long Short-Term Memory atau LSTM merupakan algoritma yang dikembangkan sebagai solusi dari permasalahan yang ditimbulkan *Recurrent Neural Networks* atau RNN mengenai *vanishing gradient*, dengan pembeda utama terhadap RNN adalah proses hidden state [31]. Dalam LSTM, terdapat 4 gate yang digunakan, yakni *forget gate*, *input gate*, *cell state*, dan *output gate*.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \dots \dots \dots (5)$$

Forget gate (f_t) merupakan mekanisme untuk menentukan data masukkan mana yang dibuang atau disimpan dalam *memory cell* [32]. Persamaan (5) menunjukkan proses forget gate, dengan fungsi aktivasi yang digunakan adalah *sigmoid* (σ), W_f merupakan bobot

pada target, h_{t-1} merupakan nilai *hidden state* sebelumnya, x_t adalah input, dan b_f adalah bias pada forget gate.

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \dots \dots \dots (6)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \dots \dots \dots (7)$$

Input gate dengan menggunakan fungsi aktivasi sigmoid, akan berusaha untuk mencari tahu nilai yang akan diperbarui dan mencari kandidat untuk cell state baru dengan fungsi aktivasi *tanh*. Masing-masing kedua proses direpresentasikan melalui persamaan (6) dan (7) [32].

$$C_t = (i_t * \tilde{C}_t + f_t * C_{t-1}) \dots \dots \dots (8)$$

Cell state yang merupakan proses untuk menggantikan memory cell sebelumnya dengan melakukan proses perhitungan hasil dari forget, input, dan *candidate gate*, seperti pada persamaan (8) [32].

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \dots \dots \dots (9)$$

$$h_t = o_t * \tanh(C_t) \dots \dots \dots (10)$$

Output gate melakukan perhitungan dengan fungsi aktivasi sigmoid seperti pada persamaan (9) untuk menentukan nilai yang akan dikeluarkan, untuk menentukan hidden cell state yang baru yang akan dikalikan dengan cell state dengan menggunakan fungsi aktivasi tanh, seperti pada persamaan (10) [32].

2.5.3. LightGBM

LightGBM merupakan model berbasis gradient boosting yang menjadi hasil pengembangan yang dilakukan Microsoft pada tahun 2017, dengan kelebihan dapat mengatasi permasalahan komputasi yang tinggi dan konsumsi memori yang tinggi dan membuat proses komputasi yang lebih cepat dengan gradient boosting decision model yang lain [33]. Kecepatan dan efisiensi ini dicapai melalui empat teknik utama:

1. Histogram-based algorithm
Histogram-based algorithm merupakan pendekatan LightGBM dengan memasukkan setiap data ke dalam kelompok atau bin. Di setiap bin, nilai statistik seperti jumlah data atau nilai gradien dihitung dan dikumpulkan berdasarkan kelompok tersebut. Dari informasi ini, LightGBM mencari titik optimal untuk melakukan pemisahan pada *node decision tree* tanpa harus mengevaluasi data secara langsung [33], [34].
2. Gradient-based One-Side Sampling (GOSS)
Gradient-based One-Side Sampling merupakan pendekatan yang mengurangi jumlah data untuk dilatih dengan hanya berfokus pada data yang menghasilkan gradien besar dan melakukan *random sampling* terhadap data dengan gradien yang kecil [34].
3. Exclusive Feature Bundling (EFB)

Exclusive Feature Bundling merupakan pendekatan yang menambahkan efisiensi dari LightGBM dengan mengurangi fitur dengan menggabungkan fitur yang jarang muncul bersamaan dengan pendekatan aproksimasi yang membuat jumlah *bundle* minim meskipun terdapat sedikit konflik [34].

4. Leaf-wise strategy

Leaf-wise strategy adalah pendekatan dengan melakukan pemisahan pada *leaf node* yang memberikan keuntungan terbesar di setiap waktu [33], [34].

2.5.4. Gradient Boosting

Gradient Boosting merupakan teknik *ensemble learning* dengan mekanisme yang mengintegrasikan beberapa pohon regresi yang biasanya dikenal sebagai *weak learner*, yang dirancang sedemikian rupa untuk mengoreksi kesalahan yang dibuat oleh gabungan model-model sebelumnya [35].

$$F_n(x_t) = \sum_{i=1}^n f_i(x_t) \dots \dots \dots (11)$$

$$\operatorname{argmin} \sum_t L(y_t, F_n(x_t) + F_{n+1}(x_t)) \dots \dots \dots (12)$$

Persamaan (11) menunjukkan proses kombinasi aditif dari seluruh weak learner yang telah dilatih ($f_i(x_t)$) sehingga menghasilkan model final $F_n(x_t)$. Penambahan pohon baru $F_{n+1}(x_t)$, dioptimalkan untuk meminimalkan total kerugian seperti yang ditunjukkan pada persamaan (12).

2.5.5. Hyperparameter Tuning

Hyperparameter tuning dilakukan untuk memperoleh nilai yang ideal sebagai *hyperparameter* setiap mode, dan untuk nilai evaluasi setiap hasil *tuning* bisa dihasilkan dari *time-series cross validation*, yang merupakan pendekatan cross validation yang masih mempertahankan urutan temporal dari data ketika dibagi [36]. Kombinasi hyperparameter yang ditentukan terdapat pada Tabel 1.

Tabel 1 Kombinasi hyperparameter yang digunakan

Algoritma	Parameter	Nilai yang Diuji
Gradient Boosting	n_estimators	[100, 200, 300]
	learning_rate	[0.01, 0.1, 0.2]
	max_depth	[3, 4, 5]
LSTM	batch_size	[16, 32]
	lstm_units	[32, 64]
	dropout_rate	[0.1, 0.2, 0.3]
LightGBM	n_estimators	[100, 200]
	learning_rate	[0.01, 0.1]
	max_depth	[3, 5, 7]
ELM	num_leaves	[31, 64, 128]
	hidden_layer_size	[50, 100, 200]
	alpha	[1e-4, 1, 10]

	activation_func	['tanh', 'sigmoid', 'relu']
--	-----------------	-----------------------------

2.6. Evaluasi Kinerja Model

Kinerja model akan dievaluasi melalui dua pendekatan, yang pertama adalah dengan melakukan perhitungan performa, dan yang kedua adalah lama waktu komputasi. Dari segi performa, akan dilakukan pengujian dengan beberapa metrik perhitungan seperti MAE, RMSE, MAPE, dan R^2 .

MAE, RMSE, dan MAPE merupakan metrik evaluasi yang memiliki kesamaan dari melakukan perhitungan perbedaan antara nilai prediksi terhadap nilai aktual yang akan menghasilkan nilai eror, namun yang membedakan adalah MAE menghitung nilai eror menjadi nilai absolut, RMSE menghitung nilai akar kuadrat dari MAE, yang merupakan mengkuadratkan nilai eror, dan MAPE merupakan nilai persentase dari MAE berdasarkan nilai aktual [37]. Secara lengkap mengenai ketiga persamaan metrik di atas dijelaskan pada persamaan (13), (14), dan (15).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \dots \dots \dots (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \dots \dots \dots (14)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \dots \dots \dots (15)$$

Selain metrik MAE, RMSE, dan MAPE, metrik perhitungan evaluasi berikutnya yang digunakan adalah R^2 , yang merepresentasikan persentase keragaman pada variabel dependen yang mampu dijelaskan oleh variabel independen oleh model. Persamaan dari R^2 ditunjukkan melalui persamaan (16) [37].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \dots \dots \dots (16)$$

Sedangkan evaluasi dari segi lama waktu komputasi dilakukan dengan menentukan waktu pelatihan setiap model dimulai, sampai model selesai dilatih. Waktu diperhitungkan juga berdasarkan proses hyperparameter tuning dan cross validation yang dilakukan oleh masing-masing model.

3. Hasil Percobaan

3.1 Hasil Analisis Eksploratif

Bagian ini akan membahas hasil dari eksplorasi terhadap data harga komoditas pangan, dengan tujuan untuk memahami pola yang ada dalam data dan struktur data yang dianalisis sebelum lebih lanjut dilakukan pemodelan.

3.1.1 Uji Stasioneritas ADF

Untuk mengevaluasi apakah data deret waktu harga komoditas pangan bersifat stasioner atau tidak, dilakukan pengujian dengan menggunakan metode ADF. Hasil dari uji stasioneritas dapat dilihat pada Tabel 2.

Tabel 2 Hasil uji stasioneritas ADF


Komoditas	ADF Statistic	p-value	Kesimpulan
Beras	0.1996	0.9722	Tidak stasioner
Daging Ayam	-3.1731	0.0216	Stasioner
Telur Ayam	-4.2544	0.0005	Stasioner
Bawang Merah	-3.911	0.002	Stasioner
Bawang Putih	-3.0219	0.0329	Stasioner
Minyak Goreng	-1.0363	0.7398	Tidak stasioner

Berdasarkan hasil dari Tabel 2, dapat disimpulkan bahwa sebagian besar komoditas memiliki sifat stasioner. Hal ini ditunjukkan dari nilai p -value yang tidak melebihi 0.05, yang mengindikasikan penolakan terhadap hipotesis nol (bahwa data tidak stasioner). Komoditas yang memenuhi kriteria stasioneritas adalah daging ayam, telur ayam, bawang merah, dan bawang putih. Sebaliknya, dua komoditas lainnya, seperti beras ($p = 0.9722$) dan minyak goreng ($p = 0.7398$), menunjukkan nilai p -value yang tinggi, sehingga tidak dapat disimpulkan sebagai stasioner karena hipotesis nol diterima.

Hasil ini menunjukkan bahwa pola pergerakan harga untuk komoditas seperti beras dan minyak goreng cenderung memiliki tren jangka panjang atau fluktuasi yang tidak stabil secara statistik, berbeda dengan komoditas lain yang perubahannya cenderung stasioner. Meskipun tidak dilakukan proses transformasi terhadap data non-stasioner, informasi ini tetap relevan dalam interpretasi kinerja model.

3.1.2 Korelasi antar Komoditas

Untuk memahami korelasi dari satu komoditas dengan komoditas lainnya, maka perhitungan korelasi akan dilakukan guna memahami tidak hanya kenaikan dan penurunan dari satu komoditas secara independen, namun juga memahami hubungan dari satu komoditas dengan komoditas lainnya. Hasil visualisasi heatmap mengenai korelasi ditampilkan pada Gambar 2.




Gambar 2 Matriks korelasi antar komoditas pangan

Gambar 2 menunjukkan secara umum, sebagian besar komoditas memiliki tingkat korelasi sedang hingga tinggi, yang mengindikasikan terdapat kesamaan dari segi perilaku perubahan harga. Korelasi yang tinggi ditemukan antara telur ayam dan minyak goreng (0.64), telur ayam dan beras (0.54), serta telur ayam dan bawang merah (0.52), yang menunjukkan pola konsumsi yang saling berkaitan antara komoditas telur ayam dengan beberapa komoditas lainnya. Sebaliknya, bawang merah dan daging ayam (0.05) menunjukkan hubungan yang sangat lemah dari kedua komoditas dan pergerakan keduanya didasari oleh faktor yang berbeda.

3.1.3 Volatilitas Harga

Setelah memahami hubungan antar harga komoditas melalui korelasi, langkah selanjutnya adalah melihat dinamika perubahan harga dalam jangka waktu tertentu melalui analisis volatilitas. Gambar 3 menunjukkan volatilitas harga dalam bentuk nilai deviasi standar bergerak dalam kurun waktu 30 hari. Volatilitas tertinggi dihasilkan secara konsisten oleh komoditas bawang merah dan bawang putih, dengan lonjakan yang tinggi pada sekitar tahun 2019 – 2021. Di sisi lain, volatilitas dari komoditas daging ayam dan telur ayam menunjukkan pola volatilitas yang relatif rendah dan stabil, sedangkan komoditas beras dan minyak goreng yang sangat rendah, meskipun sempat ada lonjakan yang cukup besar pada 2019 menuju ke 2020 untuk minyak goreng dan pertengahan 2023 pada beras. Hal ini menunjukkan harga yang lebih terkendali meskipun pada komoditas beras dan minyak goreng, terdapat lonjakan yang besar pada waktu-waktu tertentu. Hal ini kemungkinan disebabkan oleh faktor kebijakan pemerintah dan krisis pasokan pada periode 2019 – 2020 serta pertengahan 2023.



Gambar 3 Fluktuasi perubahan harga komoditas pangan


3.1.4 Dekomposisi Musiman

Selain korelasi dan volatilitas, pola tren dan musiman juga dianalisis untuk memperoleh pemahaman komprehensif tentang dinamika harga jangka panjang. Gambar 4 menunjukkan hasil dekomposisi tren, *seasonal*, dan residu untuk masing-masing komoditas. Dapat diamati bahwa hampir semua komoditas menunjukkan

komponen seasonal yang teratur, yang menunjukkan pola musiman dan tahunan yang stabil. Pola ini paling stabil pada beras, daging ayam, dan telur ayam.

Komoditas beras dan minyak goreng terbukti non-stasioner, dikarenakan pergerakan arah tren yang cenderung naik dan tidak terkoreksi, sehingga perpindahan nilai rata-rata terjadi. Beras menunjukkan tren kenaikan yang konsisten dengan komponen musiman yang kuat dan berulang, sementara nilai residu yang relatif rendah, yang menandakan bahwa sebagian besar variasi harga dapat dijelaskan oleh faktor tren dan musiman. Sebaliknya, minyak goreng memiliki komponen musiman yang cenderung lemah dan nilai residu yang tinggi, yang diakibatkan dominasi guncangan harga yang terjadi pada tahun 2022.

Adapun bawang merah dan bawang putih, keduanya menunjukkan pola tren yang dinamis dan tidak linear, hal ini juga didukung dari hasil uji stasioner sebelumnya pada Tabel 2. Meskipun memiliki pola musiman yang jelas, kedua komoditas memiliki nilai residu yang sangat besar. Hal ini konsisten dengan temuan pada volatilitas harga di Gambar 3, yang menandakan adanya perubahan harga berdasarkan faktor-faktor tidak terduga di luar tren dan siklus musiman.



Gambar 4 Hasil dekomposisi tren, seasonal, dan residu

3.2 Hasil Pelatihan Model

3.2.1 Hasil Hyperparameter Tuning

Proses hyperparameter tuning dilakukan secara independen untuk masing-masing komoditas dari setiap

model dikarenakan karakteristik dari setiap komoditas yang berbeda-beda. Setiap dari proses hyperparameter tuning, maka akan dilakukan evaluasi dengan menggunakan time-series cross validation.

ELM memperoleh hasil kombinasi hyperparameter yang konsisten untuk setiap komoditas, sedangkan model seperti Gradient Boosting, LSTM, dan LightGBM menunjukkan beberapa variasi dari konfigurasi hyperparameter yang digunakan. Tabel 3 secara lengkap menunjukkan hasil hyperparameter terbaik untuk setiap model dalam setiap komoditas pangan.

Tabel 3 Hasil hyperparameter tuning

Komoditas	LightGBM	Gradient Boosting	LSTM	ELM
Beras	lr=0.1, depth=3, n_est=100, leaves=31	lr=0.2, depth=3, n_est=100	bs=16, units=64, dropout=0.1	act=tanh, alpha=0.0001, hidden=50
Daging Ayam	lr=0.1, depth=3, n_est=100, leaves=31	lr=0.1, depth=3, n_est=100	bs=16, units=64, dropout=0.1	act=tanh, alpha=0.0001, hidden=50
Telur Ayam	lr=0.01, depth=7, n_est=200, leaves=31	lr=0.1, depth=3, n_est=100	bs=16, units=64, dropout=0.2	act=tanh, alpha=0.0001, hidden=50
Bawang Merah	lr=0.1, depth=3, n_est=100, leaves=31	lr=0.1, depth=3, n_est=100	bs=16, units=32, dropout=0.2	act=tanh, alpha=0.0001, hidden=50
Bawang Putih	lr=0.01, depth=7, n_est=200, leaves=64	lr=0.01, depth=4, n_est=300	bs=16, units=64, dropout=0.1	act=tanh, alpha=0.0001, hidden=50
Minyak Goreng	lr=0.01, depth=3, n_est=200, leaves=31	lr=0.01, depth=3, n_est=200	bs=32, units=64, dropout=0.3	act=tanh, alpha=0.0001, hidden=50


3.2.2 Model LightGBM

Berdasarkan hasil pelatihan model LightGBM, didapatkan hasil prediksi seperti yang terdapat pada Gambar 5. Hasil menunjukkan bahwa LightGBM menunjukkan kinerja prediksi yang sangat baik pada komoditas seperti daging ayam, telur ayam, dan bawang merah dengan skor MAPE masing-masing 0.26%, 1.06%, 0.81%, dengan akurasi yang tinggi dan pola prediksi yang konsisten. Namun, kinerjanya cenderung menurun pada beras (MAPE = 9.84%) dan minyak goreng (MAPE = 1.70%), yang sebelumnya telah diidentifikasi sebagai komoditas dengan karakteristik non-stasioner. LightGBM

juga memberikan hasil yang kurang baik dalam memprediksi harga komoditas bawang putih dengan skor MAPE = 2.73%. Lebih lanjut hasil metrik LightGBM ditampilkan pada Tabel 4.

Tabel 4 Hasil metrik evaluasi LightGBM

Komoditas	MAE	MAPE	RMSE	R ²
Beras	1.70	9.84%	1.86	-4.99
Daging Ayam	0.11	0.26%	0.25	0.969
Telur Ayam	0.38	1.06%	0.45	0.78
Bawang Merah	0.44	0.81%	0.82	0.98
Bawang Putih	1.42	2.73%	1.52	0.64
Minyak Goreng	0.42	1.70%	0.44	-4.22



Gambar 5 Hasil prediksi harga komoditas pangan dengan LightGBM


3.2.3 Model LSTM

Berikutnya merupakan implementasi model LSTM dalam memprediksi harga komoditas pangan, yang terdapat pada Gambar 6. Berdasarkan hasil yang telah didapat, LSTM memperoleh hasil prediksi yang baik terhadap komoditas daging ayam, telur ayam, bawang merah, dan bawang putih terhadap nilai aktual, dengan nilai metrik eror yang didapat dengan MAPE masing-masing secara berurutan untuk setiap komoditas adalah 0.34%, 0.34%, 1.16%, 0.36%, dan 0.48%. Namun terkhusus bawang putih, meskipun nilai eror yang dihasilkan rendah, namun model LSTM kurang bisa menghasilkan hasil prediksi harga yang mendekati nilai harga aktual, meskipun secara tren makro dengan mudah ditangkap oleh model LSTM. Sebaliknya untuk beras, sama halnya dengan LightGBM, model LSTM kurang mampu untuk memprediksi komoditas tersebut, yang juga didukung oleh nilai eror yang besar, yakni nilai MAPE = 4.94%. Untuk metrik evaluasi yang dihasilkan LSTM, lebih lanjut dapat dilihat pada Tabel 5.

Tabel 5 Hasil metrik evaluasi LSTM

Komoditas	MAE	MAPE	RMSE	R ²
-----------	-----	------	------	----------------

Beras	0.85	4.94%	0.92	-0.47
Daging Ayam	0.14	0.34%	0.26	0.96
Telur Ayam	0.12	0.34%	0.25	0.93
Bawang Merah	0.63	1.16%	0.94	0.97
Bawang Putih	0.19	0.36%	0.36	0.98
Minyak Goreng	0.12	0.48%	0.13	0.56




Gambar 6 Hasil prediksi harga komoditas pangan dengan LSTM

3.2.4 Model ELM


Setelah LightGBM dan LSTM, kemudian didapatkan hasil dari model ELM yang direpresentasikan dalam Gambar 7. Berdasarkan hasil yang didapatkan, model ELM dapat memprediksi dengan baik untuk hampir semua harga dari komoditas pangan, seperti daging ayam, telur ayam, bawang merah, bawang putih, dan minyak goreng, dengan masing-masing skor MAPE sebesar 0.22%, 0.20%, 0.62%, 0.36%, dan 0.07%, hal ini menunjukkan bahwa ELM dapat dengan mudah memperoleh akurasi yang tinggi dari segi prediksi untuk setiap harga pangan yang memiliki volatilitas. Sebaliknya, pada komoditas beras, ELM kurang mampu melakukan prediksi harga, yang menunjukkan bahwa ELM kurang mampu dalam melakukan prediksi terhadap pergerakan harga yang cenderung stabil dan minim lonjakan harga, meskipun sesekali harga beras mengalaminya. Tabel 6 lebih lanjut menjelaskan metrik dari ELM untuk setiap komoditas pangan.

Tabel 6 Hasil metrik evaluasi ELM

Komoditas	MAE	MAPE	RMSE	R ²
Beras	0.53	3.06%	0.58	0.43
Daging Ayam	0.09	0.22%	0.24	0.96
Telur Ayam	0.07	0.20%	0.22	0.95
Bawang Merah	0.33	0.62%	0.75	0.98
Bawang Putih	0.19	0.36%	0.35	0.98
Minyak Goreng	0.02	0.07%	0.05	0.94



Gambar 7 Hasil prediksi harga komoditas pangan dengan ELM



Gambar 8 Hasil prediksi harga komoditas pangan dengan GB

3.2.5 Model Gradient Boosting

Model terakhir yang dilakukan pengujian adalah Gradient Boosting atau GB, yang mana hasil dari prediksi terhadap harga komoditas pangan ditunjukkan pada Gambar 8. Sama halnya dengan LightGBM, GB memperoleh hasil yang sangat baik untuk komoditas daging ayam, telur ayam, dan bawang merah dengan skor MAPE masing-masing sebesar 0.27%, 0.29%, dan 0.76%. Namun untuk komoditas bawang putih, GB lebih baik dalam memprediksi harga bila dibandingkan LightGBM, meskipun skor yang dihasilkan terbilang masih rendah, dengan skor MAPE = 1.10%. Tetapi, untuk komoditas beras dan minyak goreng, keduanya sama-sama masih menghasilkan prediksi yang kurang baik, dengan skor MAPE masing-masing adalah 9.82% dan 1.72%. Hal ini menunjukkan bahwa secara garis besar, kedua model memiliki hasil yang kurang lebih mirip, dikarenakan keduanya merupakan algoritma berbasis *boosting decision trees*, meskipun GB lebih baik dari sisi memprediksi harga komoditas bawang putih. Tabel 7 menunjukkan hasil evaluasi berdasarkan nilai metrik yang dihasilkan oleh GB.

Tabel 7 Hasil metrik evaluasi GB

Komoditas	MAE	MAPE	RMSE	R ²
Beras	1.70	9.82%	1.86	-4.96
Daging Ayam	0.11	0.27%	0.26	0.96
Telur Ayam	0.10	0.29%	0.23	0.94
Bawang Merah	0.41	0.76%	0.79	0.98
Bawang Putih	0.57	1.10%	0.68	0.93
Minyak Goreng	0.43	1.72%	0.44	-4.23

3.3 Perbandingan Performa Model

Tabel 8 dan Gambar 9 menunjukkan hasil evaluasi rata-rata setiap model dari semua komoditas. Berdasarkan hasil yang telah didapat, dari segi kinerja untuk melakukan prediksi, model ELM menunjukkan nilai rata-rata performa prediksi terbaik secara konsisten pada metrik MAE (0.21), MAPE (0.76%), RMSE (0.36), dan R² (0.87). Kemudian disusul oleh model LSTM dengan MAE 0.34, MAPE 1.27%, RMSE 0.48, dan R² 0.65. Gradient Boosting menempati posisi ketiga dengan nilai MAE 0.55, MAPE 2.33%, RMSE 0.71, dan R² -0.90.


Dengan demikian, LightGBM merupakan model dengan performa prediksi terburuk, yang memiliki nilai MAE 0.75, MAPE 2.73%, RMSE 0.89, dan R² -0.98. Model Gradient Boosting dan LightGBM memiliki nilai R² negatif, yang menunjukkan bahwa kedua model kurang efektif dalam memprediksi bila dibandingkan prediksi dengan nilai rata-rata.

Dari segi waktu pelatihan, LightGBM menjadi yang tercepat dengan waktu pelatihan rata-rata 3.93 detik. Berikutnya disusul oleh model ELM dengan lama waktu 4.65 detik, Gradient Boosting dengan 15.60 detik, dan LSTM memperoleh waktu terlama, dengan total waktu 720.89 detik.

Meskipun ELM bukan merupakan algoritma tercepat dalam pelatihan, namun bila dibandingkan dengan LightGBM yang merupakan model tercepat, perbedaan yang dihasilkan tidak begitu jauh (hanya berbeda 0.72 detik). Dengan demikian, secara keseluruhan, model ELM dapat dianggap sebagai model terbaik, dikarenakan dapat berhasil menggabungkan akurasi prediksi yang tinggi dan efisiensi komputasi. LSTM sebagai model terbaik kedua bisa dijadikan pilihan, meskipun tantangan yang dihadapi adalah dari segi waktu pelatihan.

Tabel 8 Hasil metrik evaluasi rata-rata dari setiap model

Model	MAE	MAPE	RMSE	R ²	Waktu Pelatihan (detik)
ELM	0.21	0.76%	0.36	0.87	4.65
Gradient Boosting	0.55	2.33%	0.71	-0.90	15.60
LSTM	0.34	1.27%	0.48	0.65	720.89
LightGBM	0.75	2.73%	0.89	-0.98	3.93



Gambar 9 Grafik batang dari hasil metrik evaluasi rata-rata dari setiap model

4. Kesimpulan

Berdasarkan hasil evaluasi terhadap keempat model prediksi harga komoditas pangan di Jayapura, diperoleh bahwa Extreme Learning Machine (ELM) merupakan model dengan performa terbaik secara keseluruhan, baik dari sisi akurasi prediksi maupun efisiensi waktu pelatihan. Model ini memperoleh nilai metrik yang unggul, yaitu MAE 0.21, MAPE 0.76%, RMSE 0.36, R² 0.87, dan lama waktu pelatihan 4.65 detik. Dengan demikian, model ELM menjadi kandidat yang ideal dan menjadi rekomendasi utama untuk sistem prediksi berbasis waktu nyata, khususnya untuk dipergunakan dalam konteks pengambilan kebijakan pangan di wilayah Jayapura. Keunggulan yang dimiliki model ini dapat menjadikannya sangat relevan dalam mendukung respons cepat terhadap dinamika pergerakan harga pangan di Jayapura. Sebagai arah penelitian selanjutnya, dapat dilakukan *feature engineering* untuk memperkaya konteks data, menambahkan variabel eksternal dengan pendekatan multivariat, memperluas cakupan komoditas yang dianalisis, dan penggunaan algoritma yang belum dipergunakan dalam penelitian ini.

REFERENSI

- [1] A. R. Salasa, "Paradigma dan Dimensi Strategi Ketahanan Pangan Indonesia," *Jejaring Administrasi Publik*, vol. 13, no. 1, pp. 35–48, Sep. 2021, doi: 10.20473/jap.v13i1.29357.

- [2] E. Indrayani *et al.*, "PEMBERDAYAAN MASYARAKAT PESISIR MELALUI BUDIKDAMBER (BUDIDAYA IKAN DALAM EMBER) UNTUK KETAHANAN PANGAN DI KAMPUNG HOLTEKAMP, DISTRIK MUARA TAMI, KOTA JAYAPURA," *BALOB: Jurnal Pengabdian Masyarakat*, vol. 2, no. 2, pp. 29–38, Nov. 2023.
- [3] Sudiro, Tommi, and R. K. Samosir, "Optimalisasi Fungsi Lahan Perkampungan Sebagai Sumber Ketahanan Pangan Nasional di Kampung Mosso, Jayapura," *Journal Scientific of Mandalika (jsm)*, vol. 6, no. 4, pp. 1088–1095, 2025.
- [4] A. W. Murti, J. A. Mollet, and H. Hutajulu, "Analisis Pengembangan Kawasan Berbasis Komoditas Palawija pada Kota Jayapura," *Indo-Fintech Intellectuals: Journal of Economics and Business*, vol. 3, no. 2, pp. 154–170, Aug. 2023, doi: 10.54373/ifijeb.v3i2.152.
- [5] I. Marina, D. Sukmawati, E. Juliana, and Z. N. Safa, "Dinamika Pasar Komoditas Pangan Strategis: Analisis Fluktuasi Harga Dan Produksi," *Paspalum: Jurnal Ilmiah Pertanian*, vol. 12, no. 1, p. 160, Apr. 2024, doi: 10.35138/paspalum.v12i1.700.
- [6] R. P. Masini, M. C. Medeiros, and E. F. Mendes, "Machine learning advances for time series forecasting," *J Econ Surv*, vol. 37, no. 1, pp. 76–111, Feb. 2023, doi: 10.1111/joes.12429.
- [7] M. Rahman, F. Rashid, S. K. Roy, and Md. A. Habib, "Application of extreme learning machine (ELM) forecasting model on CO2 emission dataset of a natural gas-fired power plant in Dhaka, Bangladesh," *Data Brief*, vol. 54, p. 110491, Jun. 2024, doi: 10.1016/j.dib.2024.110491.
- [8] A. C. Purba, T. Handhayani, and J. Hendryli, "Comparison of Support Vector Regression (SVR) and Long Short-Term Memory (LSTM) Methods for Meteorological Data Prediction in Nusa Tenggara," in *2025 International Conference on Computer Sciences, Engineering, and Technology Innovation (ICoCSETI)*, IEEE, Jan. 2025, pp. 675–680. doi: 10.1109/ICoCSETI63724.2025.11020432.
- [9] T. Handhayani, I. Lewenusa, D. E. Herwindiati, and J. Hendryli, "A Comparison of LSTM and BiLSTM for Forecasting the Air Pollution Index and Meteorological Conditions in Jakarta," in *2022 5th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, IEEE, Dec. 2022, pp. 334–339. doi: 10.1109/ISRITI56927.2022.10053078.
- [10] A. D. Hartanto, Y. Nur Kholik, and Y. Pristyanto, "Stock Price Time Series Data Forecasting Using the Light Gradient Boosting Machine (LightGBM) Model," *JOIV: International Journal on Informatics Visualization*, vol. 7, no.

- 4, p. 2270, Dec. 2023, doi: 10.62527/joiv.7.4.1740.
- [11] K. Oikonomou and D. Damigos, "Short term forecasting of base metals prices using a LightGBM and a LightGBM - ARIMA ensemble," *Mineral Economics*, vol. 38, no. 1, pp. 37–49, Mar. 2025, doi: 10.1007/s13563-024-00437-y.
- [12] A. Winata, M. D. Lauro, and T. Handhayani, "SISTEMASI: Jurnal Sistem Informasi Analysis and Prediction of Foodstuffs Prices in Tasikmalaya Using ELM and LSTM," 2023. [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [13] M. Oni, M. D. Lauro, A. Winata, and T. Handhayani, "Analysis And Forecasting of Foodstuffs Prices in Bandung Using Gated Recurrent Unit," *Jurnal Esensi Infokom : Jurnal Esensi Sistem Informasi dan Sistem Komputer*, vol. 7, no. 2, pp. 15–21, Oct. 2023, doi: 10.55886/infokom.v7i2.651.
- [14] Y. Zhang, C. Zhu, and Q. Wang, "LightGBM-based model for metro passenger volume forecasting," *IET Intelligent Transport Systems*, vol. 14, no. 13, pp. 1815–1823, Dec. 2020, doi: 10.1049/iet-its.2020.0396.
- [15] "Berdasarkan Daerah - PIHPS." Accessed: Jun. 14, 2025. [Online]. Available: <https://www.bi.go.id/hargapangan/TabelHarga/PasarTradisionalDaerah>
- [16] S. Albahra *et al.*, "Artificial intelligence and machine learning overview in pathology & laboratory medicine: A general review of data preprocessing and basic supervised concepts," *Semin Diagn Pathol*, vol. 40, no. 2, pp. 71–87, Mar. 2023, doi: 10.1053/j.semdp.2023.02.002.
- [17] A. H. Adineh, Z. Narimani, and S. C. Satapathy, "Importance of data preprocessing in time series prediction using SARIMA: A case study," *International Journal of Knowledge-based and Intelligent Engineering Systems*, vol. 24, no. 4, pp. 331–342, Jan. 2021, doi: 10.3233/KES-200065.
- [18] T. Emmanuel, T. Maupong, D. Mpoeleng, T. Semong, B. Mphago, and O. Tabona, "A survey on missing data in machine learning," *J Big Data*, vol. 8, no. 1, p. 140, Oct. 2021, doi: 10.1186/s40537-021-00516-9.
- [19] B. Deepa and K. Ramesh, "Epileptic seizure detection using deep learning through min max scaler normalization," *Int J Health Sci (Qassim)*, pp. 10981–10996, May 2022, doi: 10.53730/ijhs.v6nS1.7801.
- [20] A. Pranolo *et al.*, "Enhanced Multivariate Time Series Analysis Using LSTM: A Comparative Study of Min-Max and Z-Score Normalization Techniques," *ILKOM Jurnal Ilmiah*, vol. 16, no. 2, pp. 210–220, Aug. 2024, doi: 10.33096/ilkom.v16i2.2333.210-220.
- [21] A. Prasetya Wibawa, W. Lestar, A. Bella Putra Utama, I. Tri Saputra, and Z. Nabila Izdiyar, "Multilayer Perceptron untuk Prediksi Sessions pada Sebuah Website Journal Elektronik," *Indonesian Journal of Data and Science*, vol. 1, no. 3, Dec. 2020, doi: 10.33096/ijodas.v1i3.15.
- [22] R. E. Wahyuni, "OPTIMASI PREDIKSI INFLASI DENGAN NEURAL NETWORK PADA TAHAP WINDOWING ADAKAH PENGARUH PERBEDAAN WINDOW SIZE," *Technologia: Jurnal Ilmiah*, vol. 12, no. 3, p. 176, Jul. 2021, doi: 10.31602/tji.v12i3.5181.
- [23] Y. Yang, "TCN-QV: an attention-based deep learning method for long sequence time-series forecasting of gold prices," *PLoS One*, vol. 20, no. 5, p. e0319776, May 2025, doi: 10.1371/journal.pone.0319776.
- [24] V. Cerqueira, L. Torgo, and I. Mozetič, "Evaluating time series forecasting models: an empirical study on performance estimation methods," *Mach Learn*, vol. 109, no. 11, pp. 1997–2028, Nov. 2020, doi: 10.1007/s10994-020-05910-7.
- [25] D. F. Rahman and A. Q. Munir, "Pendekatan Eksploratif dalam Analisis Data Harga Pangan Nasional dengan Tableau," *ILKOMNIKA: Journal of Computer Science and Applied Informatics*, vol. 6, no. 2, pp. 53–63, Aug. 2024, doi: 10.28926/ilkomnika.v6i2.659.
- [26] Ajewole KP, Adejuwon SO, and Jemilohun VG, "Test for Stationarity on Inflation Rates in Nigeria using Augmented Dickey Fuller Test and Phillips-Persons Test," *IOSR Journal of Mathematics*, vol. 16, no. 3, pp. 11–14, 2020, doi: 10.9790/5728-1603031114.
- [27] M. K. Alim and D. B. Arianto, "ANALISIS KORELASI ANTARA FAKTOR EKONOMI DAN DISTRIBUSI PENDUDUK DI JAWA TIMUR TAHUN 2020 MENGGUNAKAN METODE KORELASI PEARSON," *Kohesi: Jurnal Multidisiplin Saintek*, vol. 1, no. 4, pp. 20–30, 2023.
- [28] M. Heru Widiyanto, R. Mayasari, and G. Garno, "IMPLEMENTASI TIME SERIES PADA DATA PENJUALAN DI GAIKINDO MENGGUNAKAN ALGORITMA SEASONAL ARIMA," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 3, pp. 1501–1506, Oct. 2023, doi: 10.36040/jati.v7i3.6879.
- [29] A. Dokumentov and R. J. Hyndman, "STR: Seasonal-Trend Decomposition Using Regression," *INFORMS Journal on Data Science*, vol. 1, no. 1, pp. 50–62, Apr. 2022, doi: 10.1287/ijds.2021.0004.
- [30] K. Kireyna Cindy Pradhisa and R. Yotenka, "Penerapan Metode Extreme Learning Machine (ELM) untuk Meramalkan Produksi Air Minum dan Air yang Dijual di Kota Yogyakarta Tahun 2023," *Emerging Statistics and Data Science*

- Journal*, vol. 2, no. 2, pp. 258–263, Jun. 2024, doi: 10.20885/esds.vol2.iss.2.art19.
- [31] J. Cahyani, S. Mujahidin, and T. P. Fiqar, “Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional,” *Jurnal Sistem dan Teknologi Informasi (JustIN)*, vol. 11, no. 2, p. 346, Jul. 2023, doi: 10.26418/justin.v11i2.57395.
 - [32] N. Selle, N. Yudistira, and C. Dewi, “Perbandingan Prediksi Penggunaan Listrik dengan Menggunakan Metode Long Short Term Memory (LSTM) dan Recurrent Neural Network (RNN),” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 9, no. 1, pp. 155–162, Feb. 2022, doi: 10.25126/jtiik.2022915585.
 - [33] Y. Wang *et al.*, “Short-Term Load Forecasting for Industrial Customers Based on TCN-LightGBM,” *IEEE Transactions on Power Systems*, vol. 36, no. 3, pp. 1984–1997, May 2021, doi: 10.1109/TPWRS.2020.3028133.
 - [34] Y. Wang and T. Wang, “Application of Improved LightGBM Model in Blood Glucose Prediction,” *Applied Sciences*, vol. 10, no. 9, p. 3227, May 2020, doi: 10.3390/app10093227.
 - [35] U. Singh, M. Rizwan, M. Alaraj, and I. Alsaidan, “A Machine Learning-Based Gradient Boosting Regression Approach for Wind Power Production Forecasting: A Step towards Smart Grid Environments,” *Energies (Basel)*, vol. 14, no. 16, p. 5196, Aug. 2021, doi: 10.3390/en14165196.
 - [36] M. B. - and Dr. B. B. -, “A Comprehensive Review of Cross-Validation Techniques in Machine Learning,” *International Journal on Science and Technology*, vol. 16, no. 1, Jan. 2025, doi: 10.71097/IJSAT.v16.i1.1305.
 - [37] K. Albeladi, B. Zafar, and A. Mueen, “Time Series Forecasting using LSTM and ARIMA,” *International Journal of Advanced Computer Science and Applications*, vol. 14, no. 1, 2023, doi: 10.14569/IJACSA.2023.0140133.