



Prediksi Harga Saham Menggunakan ARIMA *Outlier* sebagai Pendekatan Awal Menuju Analisis AI Keuangan

Cindi Adam

Universitas Pembangunan Nasional “Veteran” Jawa Timur

Mohammad Idhom

Universitas Pembangunan Nasional “Veteran” Jawa Timur

Trimono

Universitas Pembangunan Nasional “Veteran” Jawa Timur

Alamat: Jl. Raya Rungkut Madya, Gunung Anyar, Kecamatan Gununganyar, Surabaya, Jawa Timur 60294.

Korespondensi penulis: idhom@upnjatim.ac.id

Abstract. *The development of artificial intelligence (AI) has driven innovation in financial analysis, including the prediction of volatile stock prices. This study aims to predict the stock price of PT Garudafood Putra Putri Jaya Tbk using an ARIMA model with Outlier handling as an initial approach towards a more adaptive prediction system. Daily closing price data from Yahoo Finance was analyzed through stationarity testing, ARIMA model identification, log-return-based Outlier detection, and performance evaluation using RMSE, MAE, and MAPE. The results show that ARIMA Outlier performs better than the basic ARIMA. The standard ARIMA produces a MAPE of 1.32% and an AIC of -899.46, while ARIMA with three dummy Outliers achieves a MAPE of 1.16% and an AIC of -900.37. The 14-day forecast shows a stable pattern in the range of Rp 370–371. In the test data, the basic ARIMA provided the best accuracy in mid-August, while ARIMA Outlier achieved the highest accuracy at the end of August with a prediction of Rp.370.2, which was very close to the actual price of Rp.370.4. These results show that handling Outliers improves the accuracy of the model, so that ARIMA Outlier can be used as a starting point for the development of an AI-based financial prediction system.*

Keywords: *ARIMA Outlier, Outlier Detection, Stock Price Prediction.*

Abstrak. Perkembangan kecerdasan buatan (AI) mendorong inovasi dalam analisis keuangan, termasuk prediksi harga saham yang fluktuatif. Penelitian ini bertujuan memprediksi harga saham PT Garudafood Putra Putri Jaya Tbk menggunakan model ARIMA dengan penanganan *Outlier* sebagai pendekatan awal menuju sistem prediksi yang lebih adaptif. Data harga penutupan harian dari Yahoo Finance dianalisis melalui uji stasioneritas, identifikasi model ARIMA, deteksi *Outlier* berbasis *log-return*, serta evaluasi performa menggunakan RMSE, MAE, dan MAPE. Hasil penelitian menunjukkan bahwa ARIMA *Outlier* memberikan performa lebih baik dibandingkan ARIMA dasar. ARIMA standar menghasilkan MAPE 1.32% dan AIC -899.46, sedangkan ARIMA dengan tiga *dummy Outlier* mencapai MAPE 1.16% dan AIC -900.37. Peramalan 14 hari ke depan menunjukkan pola yang stabil pada kisaran Rp 370–371. Pada data uji, ARIMA dasar memberikan akurasi terbaik pada pertengahan Agustus, sedangkan ARIMA *Outlier* mencapai akurasi tertinggi pada akhir Agustus dengan prediksi Rp 370.2 yang sangat dekat dengan harga aktual Rp 370.4. Hasil ini menunjukkan bahwa penanganan *Outlier* meningkatkan ketepatan model, sehingga ARIMA *Outlier* dapat digunakan sebagai fondasi awal menuju pengembangan sistem prediksi keuangan berbasis AI.

Kata kunci: ARIMA *Outlier*, Deteksi *Outlier*, Prediksi Harga Saham.

LATAR BELAKANG

Perkembangan teknologi informasi dan komunikasi memberikan pengaruh signifikan terhadap pertumbuhan ekonomi serta mendorong berbagai sektor untuk beradaptasi melalui digitalisasi (Negara & Febrianto, 2020; Suseno, Asyhari, & Saputra, 2025). Transformasi ini juga terjadi pada sektor keuangan, di mana analisis data digunakan untuk memahami dinamika pasar yang semakin kompleks. Salah satu tantangan utama pada pasar modal adalah fluktuasi harga saham yang rentan terhadap perubahan sentimen, kondisi makroekonomi, kebijakan pemerintah, maupun peristiwa internal perusahaan, sehingga memunculkan volatilitas tajam atau *Outlier*.

PT Garudafood Putra Putri Jaya Tbk (GOOD.JK) sebagai emiten sektor consumer goods juga mengalami dinamika serupa. Meskipun sektor ini cenderung defensif, harga saham Garudafood tetap menunjukkan volatilitas akibat tekanan biaya, persaingan pasar, serta kondisi ekonomi yang berubah-ubah. Berdasarkan laporan keuangan kuartal II tahun 2025, Garudafood mencatat pendapatan sebesar Rp 6.04 triliun dengan laba bersih Rp 257.7 miliar (PT Garudafood Putra Putri Jaya Tbk, 2025). Namun, harga saham GOOD sepanjang tahun 2025 tetap bergerak fluktuatif dalam kisaran Rp 330–400 per lembar (PT Garudafood Putra Putri Jaya Tbk, 2025). Perubahan harga yang tidak stabil ini tidak jarang menghasilkan nilai ekstrem atau *Outlier*, baik karena publikasi informasi perusahaan, aksi korporasi seperti dividen dan *stock split*, maupun faktor eksternal seperti kondisi global dan nilai tukar (Achmadi, 2023).

Karena harga saham rentan terhadap *Outlier*, diperlukan metode peramalan yang mampu menangani kondisi tersebut. Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan salah satu metode peramalan deret waktu yang paling umum digunakan dalam analisis keuangan. Model ARIMA dapat mengidentifikasi pola tren, pola musiman, serta fluktuasi acak yang terdapat pada data historis tanpa membutuhkan banyak variabel eksternal, sehingga sesuai diterapkan pada harga saham yang bersifat univariat (Kruba, Sofyan, Marshanda, & Syazana, 2025). Meskipun demikian, ARIMA sangat sensitif terhadap *Outlier*. Nilai ekstrem dapat mengganggu estimasi parameter dan memengaruhi akurasi model prediksi (Wanda, Mufarroha, Jauhari, & Anamisa, 2025). Untuk mengatasi kelemahan tersebut, pendekatan ARIMA dengan deteksi *Outlier*

(ARIMA *Outlier*) diadopsi sebagai versi yang lebih robust, karena mampu mendeteksi dan menyesuaikan pengaruh anomali tanpa mengabaikan pola historis.

Seiring berkembangnya teknologi kecerdasan buatan (AI), metode seperti ARIMA *Outlier* dapat menjadi langkah awal menuju integrasi dengan *machine learning* untuk prediksi harga saham yang lebih kompleks. Berdasarkan kondisi tersebut, penelitian ini dilakukan untuk memprediksi harga saham PT Garudafood Putra Putri Jaya Tbk menggunakan ARIMA *Outlier*. Penelitian bertujuan menganalisis pengaruh penyesuaian *Outlier* terhadap akurasi model serta menilai potensi metode ini sebagai pendekatan awal menuju sistem kecerdasan buatan dalam analisis keuangan. Hasil penelitian diharapkan berkontribusi pada pengembangan metode peramalan yang lebih robust dan relevan untuk pengambilan keputusan jangka pendek di pasar modal.

Meskipun berbagai penelitian menunjukkan bahwa penanganan *Outlier* pada model ARIMA mampu meningkatkan akurasi peramalan, sebagian besar studi masih berfokus pada data non-saham. Penelitian pada pasar modal, khususnya saham *consumer goods* yang memiliki karakter volatilitas tinggi, masih sangat terbatas. Selain itu, penggunaan pendekatan ARIMA dengan deteksi *Outlier* pada data saham yang mengalami fluktuasi tajam juga belum banyak dikaji. Berdasarkan hal tersebut, penelitian ini memprediksi harga saham harian Garudafood menggunakan model ARIMA *Outlier* serta menilai potensinya sebagai dasar pengembangan sistem kecerdasan buatan untuk analisis keuangan. Hasil penelitian diharapkan dapat memperkuat model prediksi yang lebih robust dan menjadi referensi bagi pengembangan metode berbasis AI di masa mendatang.

KAJIAN TEORITIS

Kajian teoritis ini bertujuan untuk menjelaskan teori-teori yang relevan dengan topik penelitian, khususnya terkait peramalan harga saham menggunakan model ARIMA *Outlier*. Bagian ini juga meninjau penelitian-penelitian sebelumnya yang menjadi acuan dan landasan bagi penelitian ini. Kajian dimulai dengan pembahasan konsep harga saham dan volatilitas, dilanjutkan dengan pemaparan mengenai model ARIMA serta pengembangan ARIMA *Outlier* untuk menangani *Outlier*. Selain itu, dibahas pula potensi integrasi dengan sistem kecerdasan buatan (AI) sebagai pijakan awal bagi pengembangan model prediksi yang lebih kompleks.

1. Model ARIMA

Model ARIMA adalah model deret waktu univariat yang mengintegrasikan komponen AR (*Autoregressive*) dan MA (*Moving Average*) untuk menganalisis data yang belum stasioner (Jamila, Siregar, & Yunis, 2021). Untuk data yang tidak stasioner, ARIMA memerlukan *differencing*, yang merupakan komponen I (*Integrated*), untuk menjadikan data stasioner sebelum penerapan AR dan MA, sehingga model dapat menghasilkan estimasi yang valid dan prediksi yang lebih akurat (Pradana, 2025).

Parameter model $ARIMA(p, d, q)$ ditentukan melalui analisis Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF). Plot ACF digunakan untuk mengidentifikasi kandidat nilai q pada komponen Moving Average, sedangkan plot PACF membantu menentukan nilai p pada komponen Autoregressive (Saputra & Febrianti, 2025). Secara umum, apabila ACF menunjukkan pola terputus (cut-off) pada lag tertentu sementara PACF mengalami penurunan bertahap, maka model yang lebih sesuai adalah MA. Sebaliknya, jika PACF terputus dan ACF menurun secara perlahan, maka model AR cenderung lebih tepat digunakan. Model ARIMA dasar ini berfungsi sebagai *baseline* untuk membandingkan kinerja model dengan dan tanpa penanganan *Outlier*. Secara umum, *model ARIMA(p, d, q)* dapat dituliskan sebagai berikut (Beeg, Paendong, & Mananohas, 2024):

$$X_t - X_{t-1} = \mu + \varphi_1(X_{t-1} - X_{t-2}) + \varphi_2(X_{t-2} - X_{t-3}) + \dots + \varphi_p(X_{t-p} - X_{t-p-1}) + \varepsilon_t - \theta_1\varepsilon_{t-1} - \dots - \theta_q\varepsilon_{t-q} \quad (1)$$

X_t : Nilai variabel dependen pada periode ke- t .

X_{t-p} : Nilai variabel dependen pada periode-periode sebelumnya.

φ_p : Koefisien *autoregressive*.

ε_t : Residual atau kesalahan acak pada periode ke- t .

μ : Rata-rata dari proses time series.

θ_q : Koefisien *Moving Average*.

Persamaan di atas menunjukkan bentuk umum $ARIMA(p, d, q)$, di mana differencing (d) menjadikan data stasioner. Model ini menjadi baseline sebelum

pengembangan ARIMA *Outlier* untuk menangani nilai ekstrem dan meningkatkan akurasi prediksi.

2. Model ARIMA *Outlier*

ARIMA *Outlier* merupakan pengembangan dari model ARIMA yang dirancang untuk menangani nilai ekstrem pada data deret waktu, sehingga prediksi menjadi lebih akurat pada data yang mengandung fluktuasi tajam. Terdapat beberapa jenis *Outlier* yang umum digunakan, yaitu *Additive Outlier* yang merupakan suatu kejadian yang hanya memengaruhi nilai deret waktu pada satu periode tertentu; *Innovation Outliers* merupakan kejadian yang dampaknya mengikuti proses ARMA dan bergantung pada model serta estimasi parameter, dengan pengaruh yang dapat meningkat apabila kemunculannya berada lebih jauh di masa lalu; *Level Shift (LS)* merupakan kejadian yang menyebabkan perubahan mendadak dan permanen pada deret waktu; *Temporary Change (TC)* menghasilkan dampak awal yang kemudian berangsur-angsur melemah (Fadliani, Purnamasari, & Wasono, 2021). Secara umum, model ARIMA *Outlier* dapat dituliskan sebagai berikut (Utami, Sohibien, & Putra, 2021):

$$Z_t = c + \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \sum_{j=1}^m \alpha_j P_{j,t} + \varepsilon_t \quad (2)$$

Dengan:

m : Jumlah *Outlier dummy* yang dimasukkan.

α_j : Koefisien efek *Outlier* ke- j (magnitudo perubahan pada Z_t ketika $p_{j,t} = 1$).

$p_{j,t}$: Variabel dummy *Outlier* ke- j pada waktu t .

ε_t : *White noise*.

Persamaan di atas menunjukkan bentuk umum model ARIMA *Outlier*, di mana model ini menggabungkan komponen AR, MA, dan *differencing* (I) dengan penyesuaian terhadap *Outlier*. Penerapan ARIMA *Outlier* membuat model lebih robust terhadap nilai ekstrem pada data deret waktu, sehingga prediksi harga saham yang volatil menjadi lebih akurat dibandingkan ARIMA dasar. Pendekatan ini juga dapat dijadikan fondasi awal untuk pengembangan sistem prediksi berbasis kecerdasan buatan (AI) di penelitian selanjutnya.

3. *Artificial Intelligence* (AI) dalam Analisis Keuangan

Kecerdasan buatan (*Artificial Intelligence/AI*) merupakan salah satu kemajuan teknologi informasi dan komunikasi yang berkembang pesat dalam dekade terakhir (Ririh, Laili, Wicaksono, & Tsurayya, 2020). Kemajuan ini membawa perubahan besar dalam berbagai industri, termasuk sektor keuangan dan pasar modal, khususnya dalam analisis harga saham dan prediksi pergerakan pasar (Kusuma, 2024). AI mampu memproses data besar dan kompleks secara cepat, mengenali pola tersembunyi, serta menghasilkan prediksi yang lebih akurat dibandingkan metode tradisional. Dalam konteks tersebut, integrasi AI dengan model statistik seperti ARIMA *Outlier* dapat menjadi fondasi awal untuk meningkatkan ketepatan prediksi harga saham yang bersifat volatil dan sensitif terhadap anomali.

4. Penelitian Terdahulu

Beberapa penelitian sebelumnya menunjukkan bahwa penerapan ARIMA dengan penanganan *Outlier* mampu meningkatkan akurasi prediksi. (Trydini, Helmi, & Huda, 2023) menemukan bahwa ARIMA dengan *Innovational Outlier* (IO) meningkatkan akurasi prediksi harga saham PT Aneka Tambang Tbk dengan MAPE sebesar 7,30%. (Laome, Wibawa, Raya, & Asbahuna, 2021) membuktikan bahwa *Additive Outlier* (AO) pada model ARIMA menghasilkan prediksi yang lebih baik pada data kunjungan wisatawan. Studi lain oleh (Agustianto, Purnamasari, & Suyitno, 2020) menunjukkan bahwa pendekatan ARIMA dengan *Outlier* efektif digunakan dalam peramalan data lingkungan, dengan AIC sebagai indikator performa. Meskipun demikian, penelitian terkait penerapan ARIMA dengan deteksi *Outlier* pada saham sektor *consumer goods* masih terbatas, khususnya untuk data yang memiliki volatilitas tinggi.

METODE PENELITIAN

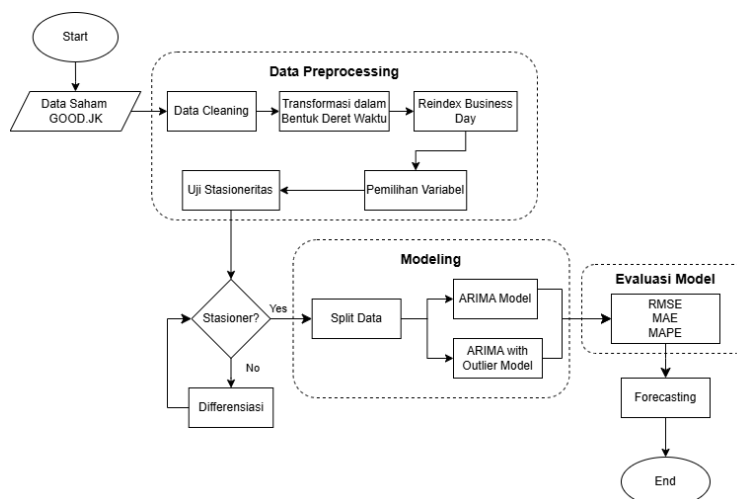
Penelitian ini merupakan penelitian kuantitatif dengan pendekatan analisis deret waktu yang digunakan untuk memodelkan dan memprediksi harga saham berbasis data historis. Metode utama yang digunakan adalah ARIMA yang dikombinasikan dengan deteksi *Outlier* agar model lebih robust terhadap anomali pasar dan menghasilkan prediksi jangka pendek yang akurat (Yusvida, Windarko, & Setiawardhana, 2025).

1. Sumber dan Jenis Data

Data yang digunakan merupakan data sekunder yang diperoleh dari platform Yahoo Finance yang menyediakan data historis saham secara terbuka. Variabel yang digunakan dalam penelitian ini adalah harga penutupan saham (*Close*) PT Garudafood Putra Putri Jaya Tbk (GOOD.JK). Harga penutupan dipilih karena model dapat mempelajari perubahan harga penutupan dari waktu ke waktu, mengidentifikasi pola historis, serta memberikan fokus pada pergerakan harga akhir yang dianggap sebagai indikator penting bagi investor (Silalahi & Muljono, 2024). Rentang waktu data yang digunakan adalah 1 Januari 2025 hingga 30 September 2025. Pemilihan periode ini dilakukan karena data tersebut merupakan data terbaru sehingga lebih relevan dan valid untuk menggambarkan kondisi pasar terkini.

2. Langkah Analisis

Tahapan analisis dalam penelitian ini diuraikan secara sistematis, dimulai dari tahap pengumpulan data (*data collection*) hingga evaluasi kinerja model. Untuk memberikan gambaran yang lebih mudah dipahami, keseluruhan alur kerja ditampilkan dalam sebuah diagram alir (*flowchart*).



Gambar 1. *Workflow* Penelitian

Langkah-langkah penelitian dilakukan secara sistematis untuk mencapai tujuan, yaitu memodelkan dan memprediksi harga saham GOOD.JK menggunakan model ARIMA *Outlier*. Tahapan analisis dijelaskan secara lengkap berikut:

a) Praproses Data (*Data Preprocessing*)

Tahap praproses dilakukan untuk memastikan bahwa data harga penutupan berada dalam kondisi bersih dan siap digunakan untuk pemodelan ARIMA. Proses dimulai dengan mengurutkan data berdasarkan tanggal dan menjadikan kolom tanggal sebagai indeks deret waktu. Selanjutnya dilakukan penyesuaian kalender perdagangan dengan melakukan *reindex* terhadap seluruh hari kerja (*business days*). Proses ini memastikan bahwa tidak ada hari perdagangan yang terlewat akibat libur bursa atau ketidakteraturan penyedia data. Tanggal yang tidak memiliki nilai harga diisi menggunakan metode *forward fill* sehingga pergerakan harga tetap berkesinambungan.

Setelah data dipastikan lengkap dan berformat deret waktu, dilakukan transformasi log, yaitu mengubah nilai *Close* menjadi $\log(\text{Close})$. Transformasi log dilakukan untuk menstabilkan varians data, mengurangi sensitivitas terhadap fluktuasi ekstrem. Variabel $\log(\text{Close})$ inilah yang digunakan pada tahap analisis berikutnya. Tahap praproses ditutup dengan pengujian awal stasioneritas menggunakan uji *Augmented Dickey-Fuller* (ADF). Pengujian ini berfokus pada pendeteksian unit root, karena keberadaan unit root menandakan bahwa data tidak stasioner (Nurman & Nusrang, 2022). Secara matematis, persamaan uji ADF dapat dituliskan sebagai berikut (Melyani, Nurtsabita, Shafa, & Widodo, 2021).

$$\Delta Y_t = b_0 + \theta y_{t-1} + \sum_{i=2}^p \phi \Delta y_{t-1i} + \varepsilon_t \quad (3)$$

Apabila hasil uji menunjukkan $p - value \leq 0,05$, maka H_0 ditolak dan data dinyatakan stasioner. Sebaliknya, jika $p - value > 0,05$, data dianggap tidak stasioner sehingga perlu dilakukan proses *differencing*. Bentuk diferensiasi orde pertama, yang dirumuskan sebagai berikut (Nurman & Nusrang, 2022):

$$\Delta Y_t = Y_t - Y_{t-1} \quad (4)$$

b) Pembagian Data (*Train* dan *Test*)

Setelah data $\log(\text{Close})$ stasioner, dataset dibagi menjadi dua bagian, yaitu data train dan data test. Data train digunakan untuk membangun model ARIMA dan ARIMA *Outlier*, sedangkan data *test* digunakan untuk mengevaluasi kemampuan model dalam memprediksi harga saham pada periode terbaru. Pembagian dilakukan dengan proporsi 80% untuk data train dan 20% untuk data test. Dengan demikian, model dilatih menggunakan sebagian besar data historis untuk menangkap pola pergerakan harga, sementara data test mewakili periode terbaru untuk menilai kemampuan prediksi dalam kondisi pasar yang sebenarnya dan fluktuatif.

c) Pemodelan ARIMA

Pada tahap ini, model ARIMA dibangun menggunakan data train $\log(\text{Close})$ stasioner. Parameter model $ARIMA(p, d, q)$ ditentukan melalui analisis *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Plot ACF digunakan untuk mengidentifikasi kandidat nilai q pada komponen *Moving Average*, sedangkan plot PACF membantu menentukan nilai p pada komponen *Autoregressive*. Model ARIMA dasar ini berfungsi sebagai baseline untuk membandingkan kinerja model dengan dan tanpa penanganan *Outlier*.

d) Pemodelan ARIMA *Outlier*

Dalam penelitian ini, *Outlier* ditentukan berdasarkan *log return* harian saham dengan rumus (Fadhilah, Parmikanti, & Ruchjana, 2024):

$$r_t = \ln\left(\frac{X_t}{X_{t-1}}\right) \quad (5)$$

Titik-titik return yang berada di luar batas *interquartile range* dianggap sebagai kandidat *Outlier*. Titik-titik ini kemudian dipetakan ke tanggal harga *Close* dan diubah menjadi variabel *dummy*, dengan nilai 1 menandai tanggal *Outlier* dan 0 untuk tanggal normal. Model ARIMA kemudian di-fit secara iteratif dengan menambahkan satu per satu *Outlier* aktif.

e) Prediksi Harga Saham

Model ARIMA terbaik dengan *dummy Outlier* digunakan untuk memprediksi harga saham pada data test, kemudian hasil prediksi dikembalikan ke skala harga asli melalui transformasi eksponensial. Setelah itu, model yang sama digunakan untuk melakukan prediksi harga saham selama 14 hari ke depan. Hasil prediksi divisualisasikan sehingga memberikan gambaran lengkap kinerja model dan peramalan harga saham di masa depan.

f) Evaluasi Prediksi

Setelah model ARIMA di-fit pada data train, prediksi dilakukan pada data test untuk mengevaluasi performa awal. Evaluasi dilakukan menggunakan metrik kuantitatif seperti *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE). Model ARIMA dasar ini berfungsi sebagai *baseline* sebelum dilakukan penanganan *Outlier*. Dengan model *baseline*, peneliti dapat membandingkan perbaikan akurasi yang dihasilkan sebelum dan setelah memasukkan variabel *dummy Outlier* pada tahap pemodelan berikutnya.

Secara keseluruhan, tahapan analisis pada penelitian ini dilakukan secara runtut mulai dari pengumpulan data, praproses dan transformasi log, pengujian stasioneritas, pembagian data train dan test, pemodelan ARIMA dasar, hingga pengembangan model ARIMA *Outlier*.

HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil analisis data harga saham GOOD.JK dan pembahasan mendalam mengenai tahapan pemodelan ARIMA serta ARIMA dengan deteksi *Outlier*. Seluruh proses disusun mulai dari analisis deskriptif, transformasi data, uji stasioneritas, pemodelan ARIMA dasar, deteksi *Outlier*, hingga pemodelan lanjutan dengan variabel *dummy Outlier*.

1. Statistika Deskriptif dan Pola Harga Saham

Data historis harga penutupan (*Close*) saham GOOD.JK selama Januari hingga September 2025 dianalisis untuk memahami karakteristik awalnya. Berdasarkan hasil statistik deskriptif, harga saham memiliki nilai minimum

sekitar Rp 331.54 dan maksimum sekitar Rp 397.85, dengan nilai rata-rata Rp 369.95 dan standar deviasi 12,05. Rentang nilai ini menunjukkan bahwa fluktuasi harga saham GOOD.JK berada pada tingkat volatilitas sedang. Pada awal periode, harga bergerak relatif stabil di kisaran Rp 360-380. Memasuki bulan Maret hingga April 2025, terlihat penurunan tajam yang berlangsung cukup cepat. Kemudian harga kembali naik secara bertahap hingga mencapai titik puncak pada akhir Agustus 2025. Pola menunjukkan adanya volatilitas tidak beraturan, yang menandakan bahwa pergerakan harga dipengaruhi oleh dinamika pasar yang kuat, dan kemungkinan terdapat beberapa titik ekstrem yang dapat dikategorikan sebagai *Outlier*.

2. Transformasi *Log Return* dan Uji Stasioneritas

Karena data harga saham umumnya memiliki tren dan volatilitas yang tinggi, langkah awal yang dilakukan adalah mentransformasikan data menjadi *log return*. Transformasi ini tidak hanya menstabilkan varians, tetapi juga secara langsung menghasilkan deret waktu yang umumnya lebih stasioner dibandingkan harga asli. Setelah dilakukan transformasi *log return*, pola data menunjukkan fluktuasi yang acak tanpa tren yang jelas. Untuk memastikan karakteristik tersebut, dilakukan uji stasioneritas menggunakan *Augmented Dickey-Fuller* (ADF). Hasil uji ADF menunjukkan nilai ADF Statistic sebesar -12.3205 dengan $p - value$ 0.0000. Karena $p - value \leq 0.05$, maka dapat disimpulkan bahwa data log return bersifat stasioner. Dengan demikian, data log return sudah memenuhi syarat untuk digunakan secara langsung dalam pemodelan ARIMA tanpa perlu melakukan proses differencing tambahan.

3. Pemodelan ARIMA

Setelah data memenuhi asumsi stasioneritas, proses identifikasi model dilakukan menggunakan pola ACF dan PACF. Berbagai kombinasi parameter diuji, dan model dengan nilai AIC terendah dipilih sebagai model terbaik. Hasil pemilihan menunjukkan bahwa $ARIMA(2,0,0)$ merupakan model yang paling optimal dengan nilai AIC sebesar -899.46 . Model ini terdiri dari dua komponen autoregressive (AR) tanpa differencing ($d = 0$), sedangkan komponen moving average (MA) tidak diperlukan berdasarkan pola ACF.

Tabel 1. Summary Model ARIMA(2,0,0)

Komponen	Nilai
AR(1)	-0.2192
AR(2)	-0.1716
Ljung-Box (<i>p-value</i>)	0.00
ARCH Test / Heteroskedastisitas (<i>p-value</i>)	0.67
Jarque-Bera (statistik)	292.40

Sumber: Data diolah


Hasil estimasi menunjukkan bahwa komponen *autoregressive* pada model memberikan kontribusi penting, dengan koefisien *AR(1)* dan *AR(2)* signifikan pada tingkat $\alpha = 5\%$. Uji Ljung-Box menghasilkan *p-value* sebesar 0.00, yang mengindikasikan adanya autokorelasi pada residual sehingga residual belum sepenuhnya bersifat acak. Meskipun demikian, uji heteroskedastisitas menunjukkan *p-value* sebesar 0.67, menandakan bahwa varians residual stabil dan tidak terdapat heteroskedastisitas. Uji normalitas residual melalui Jarque-Bera memberikan nilai statistik JB sebesar 292.40 dengan $p < 0.05$, yang menunjukkan bahwa residual tidak berdistribusi normal. Ketidaknormalan ini umum terjadi pada data deret waktu, dan tidak secara langsung menggugurkan penggunaan model ARIMA.

4. Hasil Prediksi (*Forecasting*) ARIMA Standar

Berdasarkan model ARIMA terbaik yang diperoleh, peramalan pertama dilakukan pada data uji (*test data*). Pada awal periode prediksi, model memperkirakan adanya kenaikan tipis dari nilai awal sekitar Rp 376.56 menjadi \pm Rp 377.80, sebelum kemudian bergerak menurun secara bertahap hingga kisaran Rp 374.00 pada akhir periode pengujian. Jika dibandingkan dengan grafik aktual, terlihat bahwa garis prediksi tidak mengikuti pola volatil harga saham yang naik-turun tajam. Kondisi tersebut bukanlah kesalahan model, namun menggambarkan karakter ARIMA yang hanya menangkap pola autokorelasi yang signifikan, bukan fluktuasi acak (*noise*) yang terjadi pada pergerakan harian saham.

Setelah proses peramalan pada data uji, langkah berikutnya yaitu menghasilkan prediksi harga saham untuk 14 hari ke depan. Hasil *forecasting* menunjukkan bahwa harga saham diproyeksikan akan bergerak stabil dengan kecenderungan menurun perlahan dalam rentang Rp 371 – 372. Pada hari

pertama peramalan, nilai prediksi terlihat sedikit meningkat dari Rp 371.20 menjadi sekitar Rp 373.20, namun setelah itu konsisten bergerak turun bertahap hingga mendekati Rp 371.60 pada hari terakhir periode prediksi.

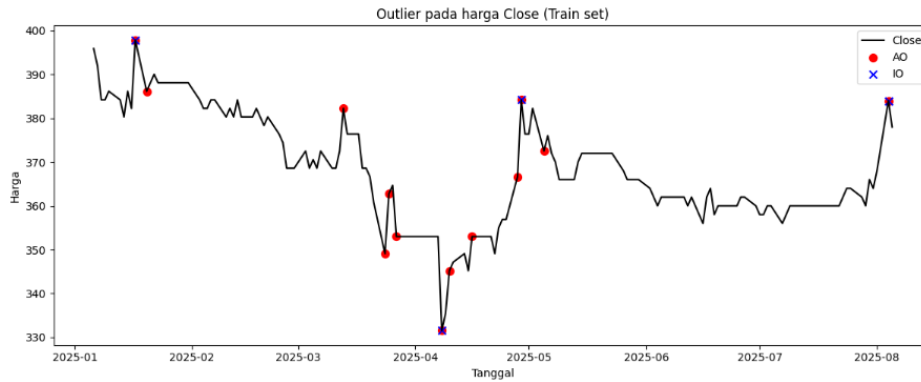


Gambar 2. Hasil Prediksi (*Forecasting*) ARIMA(2,0,0)

Dengan karakter prediksi seperti ini, model ARIMA dapat dikatakan berhasil dalam menangkap dinamika utama pasar tanpa terpengaruh fluktuasi jangka pendek. Hal ini sesuai dengan prinsip ARIMA bahwa ketika tidak terdapat pola autokorelasi yang kuat di masa mendatang, hasil prediksi akan bersifat konvergen menuju nilai stabil, sehingga menghasilkan estimasi yang lebih dapat diandalkan untuk pengambilan keputusan jangka pendek.

5. Deteksi *Outlier* Berdasarkan *Log Return*

Pada tahap ini dilakukan proses deteksi *Outlier* menggunakan metode *Interquartile Range* (IQR) pada nilai *log return* harga saham. Berdasarkan hasil perhitungan, ditemukan 13 titik *Outlier* pada data train. Pada grafik, *Outlier* direpresentasikan dalam dua kategori, yaitu *Additive Outlier* (AO) yang ditandai dengan titik merah dan *Innovational Outlier* (IO) yang ditandai dengan simbol silang biru. AO menggambarkan kejutan harga yang hanya terjadi pada satu periode, sedangkan IO menunjukkan gangguan yang berdampak terhadap periode-periode berikutnya.



Gambar 3. Grafik Log Return dengan Penandaan Outlier

Keberadaan nilai ekstrem tersebut berpotensi menyebabkan model ARIMA membaca pola data secara tidak tepat karena parameter dapat terdorong mengikuti fluktuasi harga yang bersifat sesaat. Oleh karena itu, identifikasi jenis *Outlier* menjadi langkah penting untuk memastikan proses pemodelan tidak terdistraksi oleh pergerakan ekstrem yang tidak mencerminkan pola harga yang sebenarnya.

6. Pemodelan ARIMA *Outlier*

Setelah proses deteksi *Outlier* dilakukan menggunakan metode IQR pada nilai *log-return*, setiap titik yang teridentifikasi sebagai *extreme shock* diberi variabel *dummy* dengan nilai 1, sedangkan titik lainnya diberi nilai 0. Variabel *dummy* ini kemudian digunakan sebagai *exogenous variable* (X) dalam pemodelan ARIMA.

Tabel 2. Iterasi Model ARIMA *Outlier*

Iterasi	<i>Outlier Aktif</i>	Model ARIMA	AIC	RMSE	MAE	MAPE
1	2025-04-08	ARIMA(2,0,0) + 1 <i>dummy Outlier</i>	-920.69	7.55	6.75	1.81
2	2025-04-29	ARIMA(2,0,0) + 2 <i>dummy Outlier</i>	-897.60	5.82	5.14	1.37
3	2025-08-04	ARIMA(2,0,0) + 3 <i>dummy Outlier</i>	-900.37	5.34	4.42	1.16
4	2025-01-17	ARIMA(2,0,0) + 4 <i>dummy Outlier</i>	-906.48	5.62	4.44	1.17
5	2025-03-25	ARIMA(2,0,0) + 5 <i>dummy Outlier</i>	-910.94	6.23	4.95	1.31
6	2025-03-24	ARIMA(2,0,0) + 6 <i>dummy Outlier</i>	-902.56	5.63	4.48	1.18
7	2025-03-27	ARIMA(2,0,0) + 7 <i>dummy Outlier</i>	-899.11	5.45	4.46	1.18

Iterasi	Outlier Aktif	Model ARIMA	AIC	RMSE	MAE	MAPE
8	2025-01-20	ARIMA(2,0,0) + 8 <i>dummy Outlier</i>	-897.85	5.48	4.55	1.21
9	2025-04-10	ARIMA(2,0,0) + 9 <i>dummy Outlier</i>	-899.00	5.45	4.45	1.18
10	2025-04-28	ARIMA(2,0,0) + 10 <i>dummy Outlier</i>	-901.96	5.85	4.59	1.21
11	2025-05-05	ARIMA(2,0,0) + 11 <i>dummy Outlier</i>	-899.81	5.59	4.48	1.18
12	2025-03-13	ARIMA(2,0,0) + 12 <i>dummy Outlier</i>	-901.88	6.06	4.76	1.25
13	2025-04-16	ARIMA(2,0,0) + 13 <i>dummy Outlier</i>	-903.93	6.72	5.45	1.44

Sumber: Data diolah

Proses pemodelan dilakukan secara iteratif dengan menambahkan *Outlier* secara bertahap. Iterasi pertama hanya mengaktifkan satu *Outlier*, kemudian iterasi berikutnya menambahkan satu *Outlier* tambahan, hingga seluruh 13 *Outlier* dicoba untuk dimasukkan. Pada setiap iterasi, kualitas model dievaluasi menggunakan nilai AIC, RMSE, MAE, dan MAPE. Hasil iterasi menunjukkan bahwa performa terbaik diperoleh pada Iterasi ke-3, yaitu ketika tiga titik *Outlier* dimasukkan ke dalam model.

7. Perbandingan Kinerja Model ARIMA Dasar dan ARIMA *Outlier*

Setelah dilakukan pemodelan ARIMA dasar dan dibandingkan dengan ARIMA yang dilengkapi variabel *dummy Outlier*, terlihat bahwa penanganan *Outlier* memberikan pengaruh positif terhadap performa model.

Tabel 3. Perbandingan Kinerja Model ARIMA(2,0,0) dan ARIMA(2,0,0) + 3 *dummy Outlier*

Model	AIC	RMSE	MAE	MAPE
ARIMA(2,0,0)	-899.46	5.70	4.96	1.32%
ARIMA(2,0,0) + 3 <i>dummy Outlier</i>	-900.37	5.34	4.42	1.16%


Sumber: Data diolah

Model ARIMA standar memberikan performa yang cukup baik, ditunjukkan oleh nilai MAPE sebesar 1.32%. Namun, setelah memasukkan tiga *dummy Outlier* sebagai variabel eksogen, model menunjukkan peningkatan

performa yang konsisten. Nilai MAPE menurun menjadi 1.16%, dan nilai RMSE serta MAE ikut membaik. Penurunan MAPE ini menunjukkan bahwa keberadaan *Outlier* memang memengaruhi dinamika pergerakan harga, dan penyesuaiannya dalam model membuat proses pemodelan menjadi lebih robust. Oleh karena itu, *ARIMA Outlier* dapat dinilai memberikan performa prediksi yang lebih optimal dibandingkan model *ARIMA* tanpa penanganan *Outlier*.

8. Hasil Prediksi Harga Saham 14 Hari ke Depan Model *ARIMA Outlier*

Pada tahap akhir analisis, dilakukan proses peramalan menggunakan model *ARIMA Outlier* yang telah teridentifikasi sebagai model terbaik. Peramalan dilakukan selama 14 hari kerja ke depan berdasarkan pola historis yang telah dipelajari model.



Gambar 4. Hasil Prediksi Harga Saham Model *ARIMA Outlier*

Pada periode pengujian, model *ARIMA(2,0,0) + 3 dummy Outlier* menghasilkan pola prediksi yang lebih halus dibandingkan data aktual. Prediksi dimulai dari sekitar Rp 378 dan bergerak turun secara bertahap menuju Rp 371 pada akhir periode uji. Meskipun grafik aktual menunjukkan fluktuasi yang lebih tajam dengan harga sempat berada di kisaran Rp 385, turun ke sekitar Rp 366, lalu naik kembali menuju Rp 372 perbedaan tersebut merupakan hal yang wajar mengingat volatilitas harga saham harian yang tidak sepenuhnya dapat ditangkap oleh model linier.

Untuk peramalan 14 hari ke depan, model memproyeksikan penurunan yang lebih moderat dan stabil. Nilai ramalan bergerak dari sekitar Rp 371 pada hari pertama menjadi sekitar Rp 370, lalu turun perlahan hingga mendekati Rp 369 pada hari terakhir prediksi. Pola ini menunjukkan bahwa model mampu mengidentifikasi kecenderungan tren pelemahan meskipun tidak mengikuti

fluktuasi jangka pendek secara presisi. Dengan demikian, model tetap memberikan gambaran arah pergerakan harga yang informatif, terutama dalam konteks identifikasi tren jangka pendek, sementara deviasi terhadap data aktual mencerminkan karakter volatil dari pasar saham itu sendiri, bukan kesalahan model.

KESIMPULAN DAN SARAN

Berdasarkan analisis dan hasil penelitian pada harga saham PT Garudafood Putra Putri Jaya Tbk, dapat ditarik beberapa kesimpulan. Pertama, model ARIMA terbukti efektif dalam memprediksi harga saham jangka pendek dengan memanfaatkan pola historis dan autokorelasi data univariat. Dengan menerapkan model ARIMA *Outlier*, penelitian ini berhasil menangani pengaruh *Outlier* melalui penggunaan variabel *dummy* sebagai eksogen, sehingga model menjadi lebih robust. Hasil *forecast* 14 hari ke depan menunjukkan harga saham yang relatif stabil, mencerminkan kemampuan model dalam menangkap tren jangka pendek meskipun prediksi tidak mengikuti fluktuasi harian secara persis. Tingkat akurasi model juga baik, ditunjukkan oleh nilai MAPE sebesar 1,16% pada model ARIMA(2,0,0) dengan tiga *dummy Outlier*, yang menandakan kesalahan prediksi berada pada kategori sangat baik.

Secara keseluruhan, penelitian ini menunjukkan bahwa model ARIMA *Outlier* dapat dijadikan pendekatan awal yang efektif dalam membangun sistem prediksi harga saham yang lebih adaptif. Hasil ARIMA *Outlier* dapat dimanfaatkan sebagai dasar bagi sistem kecerdasan buatan (AI) untuk menganalisis tren harga saham secara lebih kompleks, sehingga mendukung pengambilan keputusan investasi yang lebih tepat dan adaptif di pasar keuangan.

Sebagai saran, penelitian selanjutnya dapat mempertimbangkan penggunaan data frekuensi lebih tinggi, pengujian pada periode yang lebih panjang, atau penggabungan ARIMA *Outlier* dengan teknik AI lainnya untuk meningkatkan akurasi prediksi. Selain itu, analisis multivariat dengan memasukkan indikator fundamental dan teknikal juga dapat dilakukan untuk memperoleh model prediksi harga saham yang lebih komprehensif dan akurat.

DAFTAR REFERENSI

- Achmadi, N. (2023). Analisis Pengaruh Inflasi, Suku Bunga, Nilai Tukar Terhadap Harga Saham Sektor Perbankan Di Bursa Efek Indonesia Tahun 2021-2022. *Jurnal Riset Akuntansi Mercu Buana*, 9(2).
- Agustianto, R., Purnamasari, I., & Suyitno, S. (2020). Analisis Data Ketinggian Permukaan Air Sungai Mahakam Daerah Kutai Kartanegara Tahun 2010-2016 Menggunakan Model Autoregressive Integrated Moving Average (ARIMA) Dengan Efek *Outlier*: Studi Kasus: Data Rata-rata Ketinggian Tiap Bulan Permukaan Air Sungai Mahakam, Tenggarong, Kalimantan Timur. *Eksponensial*, 11(1), 39–46.
- Beeg, F. A. F., Paendong, M. S., & Mananohas, M. L. (2024). Penerapan Model ARIMA-GARCH untuk Peramalan Harga Emas Dunia. *D\Cartesian: Jurnal Matematika Dan Aplikasi*, 13(2), 73–79.
- Fadhilah, D. N., Parmikanti, K., & Ruchjana, B. N. (2024). Peramalan Return Saham Subsektor Perbankan Menggunakan Model ARIMA-GARCH. *Jurnal Fourier*, 13(1), 1–19.
- Fadliani, I., Purnamasari, I., & Wasono, W. (2021). Peramalan dengan metode sarima pada data inflasi dan identifikasi tipe *Outlier* (Studi Kasus: Data Inflasi Indonesia Tahun 2008-2014). *Jurnal Statistika Universitas Muhammadiyah Semarang*, 9(2), 109–116.
- Jamila, A. U., Siregar, B. M., & Yunis, R. (2021). Analisis Runtun Waktu Untuk Memprediksi Jumlah Mahasiswa Baru Dengan Model Arima. *Paradigma*, 23(1), 85.
- Kruba, R., Sofyan, H., Marshanda, D., & Syazana, N. (2025). Peramalan Saham Indofood di Indonesia Menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA). *Jurnal Manajemen Dan Keuangan*, 14(1), 102–117.
- Kusuma, N. P. N. (2024). Prediksi Harga Saham Blue Chip Pada Indeks Idx30 Menggunakan Algoritma Recurrent Neural Network (RNN). *Ekonomi & Bisnis*, 23(1), 90–97.
- Laome, L., Wibawa, G. N. A., Raya, R., & Asbahuna, A. R. (2021). Forecasting time series data containing *Outliers* with the ARIMA additive *Outlier* method. *Journal of Physics: Conference Series*, 1899(1), 012106. IOP Publishing.
- Melyani, C. A., Nurtsabita, A., Shafa, G. Z., & Widodo, E. (2021). Peramalan inflasi di Indonesia menggunakan metode autoregressive moving average (ARMA). *Journal of Mathematics Education and Science*, 4(2), 67–74.
- Negara, A. K., & Febrianto, H. G. (2020). Pengaruh Kemajuan Teknologi Informasi Dan Pengetahuan Investasi Terhadap Minat Investasi Generasi Milenial Di Pasar Modal. *Business Management Journal*, 16(2), 81–95.
- Nurman, S., & Nusrang, M. (2022). Analysis of rice production forecast in maros district using the box-jenkins method with the arima model. *ARRUS Journal of Mathematics and Applied Science*, 2(1), 36–48.
- Pradana, B. L. (2025). Time Series Forecasting of LQ45 Stock Index Using ARIMA: Insights and Implications. *Journal of Management, Accounting and Business Research*, 1(1), 27–40.

- PT Garudafood Putra Putri Jaya Tbk. (2025). *Laporan Keuangan Konsolidasian Interim untuk Periode Enam Bulan yang Berakhir pada 30 Juni 2025*.
- Ririh, K. R., Laili, N., Wicaksono, A., & Tsurayya, S. (2020). Studi komparasi dan analisis swot pada implementasi kecerdasan buatan (Artificial Intelligence) di Indonesia. *J@ Ti Undip: Jurnal Teknik Industri*, 15(2), 122–133.
- Saputra, J. E., & Febrianti, W. (2025). Application of Autoregressive Integrated Moving Average (ARIMA) for Forecasting Inflation Rate in Indonesia. *Jurnal Matematika, Statistika Dan Komputasi*, 21(2), 382–396.
- Silalahi, R. N., & Muljono, M. (2024). Perbandingan Kinerja Metode Linear Regression, LSTM dan GRU Untuk Prediksi Harga Penutupan Saham Coco-Cola. *Komputika: Jurnal Sistem Komputer*, 13(2), 201–211.
- Suseno, J., Asyhari, H., & Saputra, M. A. (2025). DAMPAK DIGITALISASI TERHADAP PERTUMBUHAN EKONOMI DI INDONESIA. *Jurnal Dinamika Sosial Dan Sains*, 2(1), 432–438.
- Trydini, T. R., Helmi, H., & Huda, N. M. (2023). PREDIKSI HARGA SAHAM MENGGUNAKAN MODEL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE DENGAN INNOVATIONAL *OUTLIER*. *BIMASTER: Buletin Ilmiah Matematika, Statistika Dan Terapannya*, 12(1).
- Utami, S. P., Sohibien, D., & Putra, G. (2021). Model ARIMA Musiman dengan *Outlier* untuk Peramalan Penumpang Pesawat Tujuan Domestik dari Bandara Soekarno Hatta di Masa Pandemi Covid-19. *Warta Ardhia*, 47(1), 17–26.
- Wanda, I. S., Mufarroha, F. A., Jauhari, A., & Anamisa, D. R. (2025). Peramalan Produksi Padi Menggunakan Extreme Learning Machine (ELM) Dengan Deteksi *Outlier*. *JUSIFOR: Jurnal Sistem Informasi Dan Informatika*, 4(1), 51–58.
- Yusvida, R., Windarko, N. A., & Setiawardhana, S. (2025). EVALUASI KINERJA MODEL ARIMA DALAM PERAMALAN KONSUMSI ENERGI GEDUNG BERTINGKAT. *Briliant: Jurnal Riset Dan Konseptual*, 10(3), 697–706.