

Implementasi *Rolling Forecast* untuk Meningkatkan Akurasi Peramalan Arima pada Saham Unilever

Bandar Anzari¹, Alaika Luthfi², Qori Fadilah Widiastuti³, Embay Rohaeti^{4*}

^{1,2,3,4}Program Studi Matematika, Universitas Pakuan, Indonesia

e-mail: embay.rohaeti@unpak.ac.id

Abstrak

PT Unilever Indonesia Tbk (UNVR) menghadapi tantangan volatilitas harga saham yang tinggi akibat dinamika pasar dan faktor eksternal yang berfluktuasi, sehingga menurunkan akurasi model peramalan konvensional. Penelitian ini bertujuan untuk meningkatkan akurasi prediksi harga saham UNVR dengan menerapkan metode rolling forecast pada model ARIMA. Data yang digunakan merupakan data harga penutupan mingguan dari Januari 2015 hingga Januari 2025. Berdasarkan proses identifikasi Box-Jenkins dan pemilihan model menggunakan Akaike Information Criterion (AIC), model terbaik yang diperoleh adalah ARIMA(0,1,1). Hasil evaluasi menunjukkan bahwa penerapan rolling forecast secara signifikan meningkatkan kinerja model dengan penurunan MAPE dari 58,12% menjadi 3,44% dan MAE dari 1.481,51 menjadi 105,01, yang berarti peningkatan akurasi sebesar lebih dari 94%. Peningkatan ini menunjukkan bahwa pembaruan parameter model secara berkala efektif dalam menangkap perubahan tren harga terkini dan mengurangi bias prediksi. Secara praktis, hasil penelitian ini memberikan kontribusi bagi investor dan manajer portofolio dalam mengoptimalkan strategi pengambilan keputusan berbasis data dengan sistem peramalan yang lebih adaptif terhadap dinamika pasar saham.

Kata kunci—ARIMA, Harga Saham, Rolling Forecast, UNVR

1. PENDAHULUAN

PT Unilever Indonesia Tbk (UNVR) merupakan salah satu entitas utama di sektor barang konsumsi cepat habis (*Fast Moving Consumer Goods / FMCG*) yang sensitif terhadap perubahan kondisi ekonomi makro dan dinamika preferensi konsumen (Jota et al., 2025). Meskipun kinerja perusahaan ditopang oleh tata kelola dan profitabilitas yang stabil (Arifin, 2023), harga saham UNVR tetap menunjukkan volatilitas yang cukup tinggi akibat faktor eksternal seperti tekanan geopolitik, perubahan pola konsumsi, dan sentimen publik. Studi Kurniawan & Fahlevi (2025) menunjukkan bahwa fenomena boikot produk berpengaruh nyata terhadap peningkatan volatilitas saham UNVR, sedangkan indikator fundamental seperti *Earning Per Share (EPS)* dan *Return on Asset (ROA)* tetap berperan penting dalam menentukan tren jangka panjang (Jeynes & Budiman, 2024).

Pemilihan saham UNVR sebagai objek penelitian bukan tanpa alasan. Saham ini termasuk dalam kategori *blue-chip defensive stock* dengan kapitalisasi pasar besar di Bursa Efek Indonesia, namun menunjukkan tingkat fluktuasi mingguan yang lebih tinggi dibandingkan emiten sejenis pada periode 2020–2025 (Widyarti et al., 2021). Fenomena ini menjadikan UNVR contoh ideal untuk menguji efektivitas metode peramalan yang adaptif terhadap perubahan pola data, terutama ketika terjadi kejadian tak terduga di pasar. Dengan karakteristik tersebut, UNVR dipandang representatif dalam mengukur sejauh mana *rolling forecast* dapat meningkatkan ketepatan model ARIMA dalam menangkap dinamika harga saham yang bergerak cepat (Hartono & Widiantoro, 2024).

Dalam analisis data deret waktu (*time series*) periode 2015–2025, model ARIMA (*Autoregressive Integrated Moving Average*) dipilih sebagai pendekatan yang efektif untuk menangkap pola historis, tren, dan ketergantungan antarwaktu (Rusminto et al., 2024). Potensi akurasi model ini dalam prediksi data saham telah dibuktikan oleh Rusminto et al. (2024) dengan capaian nilai MAPE sebesar 1,31%. Namun, model ARIMA

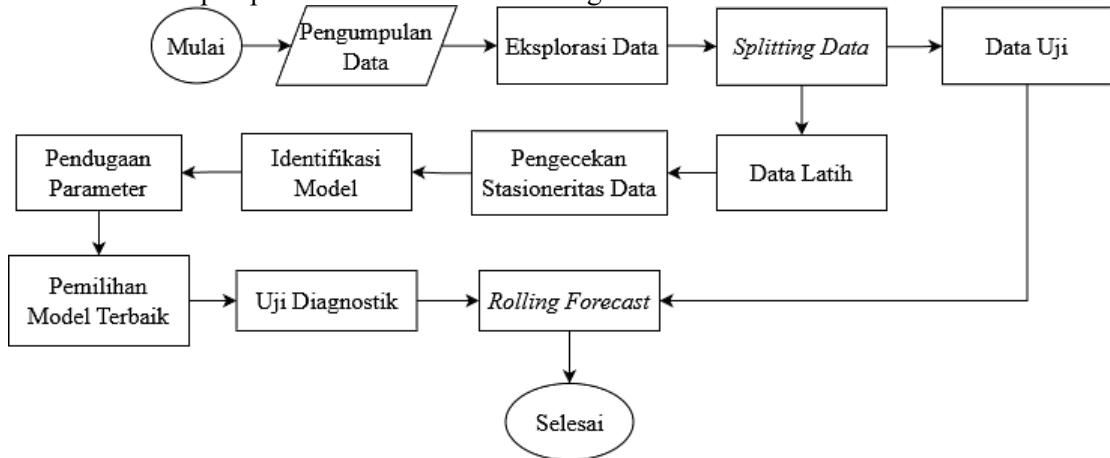
konvensional memiliki keterbatasan dalam menghadapi data dengan volatilitas tinggi karena parameter model bersifat statis dan tidak diperbarui seiring masuknya data baru (Karunia & Hidayati, 2025). Kondisi ini menyebabkan bias prediksi yang besar pada data yang mengalami fluktuasi tajam.

Keterbatasan tersebut menjadi dasar penerapan *rolling forecast* dalam penelitian ini. Pendekatan ini memberikan fleksibilitas adaptif dengan memperbarui model secara periodik sehingga mampu menangkap perubahan tren jangka pendek secara lebih efektif (Kovanen, 2024). Sejumlah penelitian sebelumnya (Yi et al., 2023; Liu & Lin, 2025) juga menunjukkan bahwa *rolling forecast* dapat memperbaiki *goodness of fit* model sekaligus mengurangi bias estimasi dalam data yang bersifat non-linier. Berdasarkan urgensi tersebut, penelitian ini difokuskan pada evaluasi peningkatan akurasi peramalan harga saham UNVR melalui penerapan *rolling forecast* pada model ARIMA.

2. METODE PENELITIAN

2.1 Tahapan Penelitian

Metode yang digunakan yaitu Autoregressive Integrated Moving Average dengan *rolling forecast* guna meramalkan. Tahapan penelitian ini dilakukan sebagaimana berikut:



Gambar 1 Diagram Tahapan Penelitian

2.2 Model ARIMA

ARIMA merupakan model statistik guna menelaah serta memprediksi data deret waktu. Dalam penerapannya, model ini berasal dari tiga metode utama yang dipadukan, yaitu AR, I, dan MA, yang bekerja secara bersama untuk menggambarkan pola data dari waktu ke waktu. Tiga metode yang membentuk ARIMA diuraikan sebagai berikut (Rusminto et al., 2024):

2.2.1 Komponen Autoregressive (AR)

Autoregressive menunjukkan keterkaitan antara data pada saat ini dengan data periode sebelumnya dalam suatu deret waktu. Persamaan AR(p) sebagai berikut (Rusminto et al., 2024):

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} \quad (1)$$

Keterangan:

Y_t = Nilai data pada suatu t waktu

ϕ_1, \dots, ϕ_p = Parameter AR

2.2.2 Integrated (I)

Integrated merupakan banyaknya proses *differencing* yang dibutuhkan agar data menjadi stasioner, yaitu data dengan nilai rata-rata dan variansi yang tetap. *Differencing* dituliskan sebagai berikut (Rusminto et al., 2024):

$$\begin{aligned}
 Y_t^l &= Y_t - Y_{t-1} \\
 Y_t^{ll} &= Y_t^l - Y_{t-1}^l \\
 &\dots \\
 Y_t^{(d)} &= Y_t^{(d)} - Y_{t-1}^{(d)}
 \end{aligned} \quad (2)$$

Keterangan:

$d = Differencing$

2.2.3 Moving Average (MA)

Moving average memperlihatkan keterkaitan data pada waktu tertentu dengan nilai kesalahan (*error term*) dari periode sebelumnya. Persamaan MA(q) dinyatakan sebagai berikut (Rusminto *et al.*, 2024):

$$Y_t = a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \cdots + \theta_q a_{t-q} \quad (3)$$

Keterangan:

a_t = Error pada waktu t

$\theta_1, \dots, \theta_q$ = Parameter moving average

2.3 Stasioneritas Data

Data dikategorikan stasioner apabila nilai rata-rata dan variansinya bersifat konstan. Sebaliknya, ketidakstasioneran terjadi apabila kedua nilai tersebut berubah seiring berjalanannya waktu. Dalam penelitian ini, kestasioneran data terhadap rata-rata diuji dengan metode *Augmented Dickey Fuller* (ADF). Rumusan hipotesis pada metode ADF adalah sebagai berikut:

$H_0: \gamma = 0$, menunjukkan bahwa data tidak bersifat stasioner

$H_1: \gamma \neq 0$, menunjukkan bahwa data bersifat stasioner

Kestasioneran data dapat dilihat dengan persamaan berikut:

$$\tau = \left| \frac{\hat{\gamma}}{SE(\hat{\gamma})} \right| \quad (4)$$

Keterangan:

τ = Nilai t hitung

$\hat{\gamma}$ = Nilai dugaan parameter

$SE(\hat{\gamma})$ = standar error dari $\hat{\gamma}$

Jika $\tau > t$ table atau $p\text{-value} < 0,05$ maka diambil Keputusan tolak H_0 (Muslihin & Ruchjana, 2023).

2.4 Kriteria Informasi Akaike (AIC)

Kriteria Informasi Akaike atau AIC digunakan untuk menilai tingkat ketepatan suatu model dalam menggambarkan data. Model yang baik dalam menggambarkan data secara akurat dan seimbang antara ketepatan serta kompleksitas model yaitu model dengan nilai AIC yang terkecil. Persamaan AIC sebagai berikut (Muslihin & Ruchjana, 2023):

$$AIC = n \ln \left(\frac{SSE}{n} \right) + 2f + n + n \ln(2\pi) \quad (5)$$

Keterangan:

SSE = Sum square error

f = Jumlah parameter pada model

n = Jumlah data

2.5 Rolling Forecast

Rolling forecast merupakan metode guna memprediksi secara berkelanjutan dengan memanfaatkan data terbaru. Proses ini dilakukan dengan menggeser jendela waktu secara bertahap sehingga model selalu diperbarui, menghasilkan prediksi dengan tingkat ketepatan yang tinggi dan kemampuan menyesuaikan diri terhadap perubahan tren serta fluktuasi data dari waktu ke waktu (Amiri & Wardati, 2025).

2.6 Evaluasi Model

Ukuran kesalahan peramalan digunakan sebagai indikator untuk menilai tingkat ketepatan model dalam memprediksi suatu data. Dalam penelitian ini, pengukuran tingkat kesalahan dilakukan menggunakan MAPE atau *Mean Absolute Percentage Error* dan MAE atau *Mean Absolute Error* (Amiri & Wardati, 2025).

$$MAPE = \left(\frac{1}{n} \sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{|Z_t|} \right) \times 100\% \quad (6)$$

$$MAE = \left(\frac{\sum_{t=1}^n |Z_t - \hat{Z}_t|}{n} \right) \quad (7)$$

3. HASIL DAN PEMBAHASAN

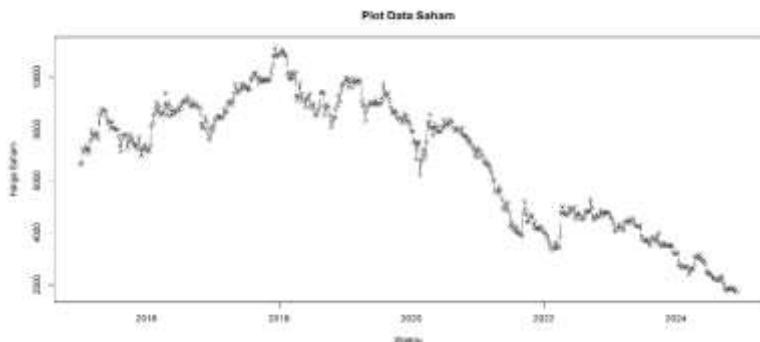
3.1 Data

Data sekunder yang mencakup harga saham historis PT Unilever Indonesia Tbk (UNVR) dengan interval mingguan selama periode 2015 hingga 2025. Sumber data ini berasal dari penyedia data pasar keuangan *Investing.com* melalui tautan <https://www.investing.com/equities/unilever-indon-historical-data>. Variabel yang dianalisis adalah harga penutupan (*closing price*) karena dianggap paling merepresentasikan nilai saham pada akhir sesi perdagangan dan menjadi standar dalam studi deret waktu keuangan.

Tabel 1 Data Saham UNVR

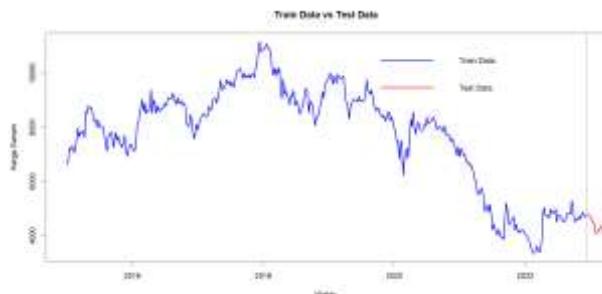
No	Date	Price
1	04/01/2015	6645
2	11/01/2015	6700
3	18/01/2015	7240
..
517	05/01/2025	1705

Tabel 1 menyajikan tampilan dari data harga penutupan saham UNVR, yang mencakup beberapa observasi mingguan antara tahun 2015 hingga 2025. Tampilan ini disajikan untuk memberikan kejelasan yang lebih baik mengenai struktur dan juga rentang data yang diaplikasikan dalam studi ini.



Gambar 2 Plot Data Saham

Pada Gambar 2 diperlihatkan plot awal data *time series* harga saham UNVR selama periode pengamatan. Secara visual, data menunjukkan pola fluktuasi yang cukup dinamis, dengan pergerakan naik dan turun yang tidak berulang secara teratur. Perubahan level harga yang cukup signifikan pada beberapa rentang waktu mengindikasikan adanya variasi tren serta pergeseran rata-rata seiring waktu. Berdasarkan tampilan grafik tersebut, dapat diamati bahwa data belum menunjukkan sifat stasioner, khususnya dalam hal rata-rata yang tampak tidak konstan sepanjang periode. Oleh karena itu, diperlukan proses *differencing* untuk mencapai kestasioneran sebelum dilakukan pemodelan lebih lanjut menggunakan metode ARIMA.



Gambar 3 Plot Data Saham pembagian data train dan data test

Ilustrasi pada Gambar 3, yang menunjukkan pembagian set data, mengindikasikan bahwa data harga saham UNVR untuk studi ini dipecah menjadi dua kelompok. 80 persen dialokasikan sebagai data untuk pelatihan, sementara 20 persen sisanya digunakan untuk pengujian.

3.2 Uji Kestasioneran

Uji kestasioneran adalah prasyarat fundamental dalam melakukan analisis deret waktu. Hal ini penting sebab model ARIMA hanya dapat berfungsi secara maksimal jika data yang digunakan bebas dari tren yang dominan atau varians yang berubah seiring waktu. Oleh karena itu, uji *Augmented Dickey-Fuller* (ADF) diterapkan pada data pelatihan (training data) untuk memverifikasi kondisi kestasioneran data pada level rata-rata.

Tabel 2 Ringkasan Uji Kestasioneran (ADF Test) Sebelum Data Ditransformasi Melalui *Differencing*

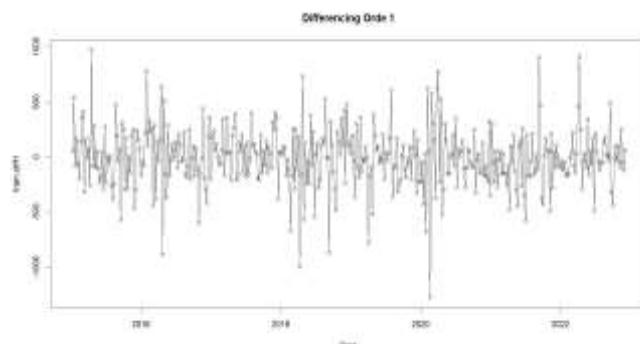
Uji Kestasioneran	Statistik ADF	P-value	Keputusan	Keterangan
Sebelum Differencing	-22.787	0.4597	Gagal tolak H0	Data tidak stasioner

Berdasarkan hasil uji ADF pada Tabel 2, diperlukan proses transformasi lebih lanjut, seperti *differencing* orde pertama, untuk menghasilkan data yang memenuhi asumsi kestasioneran sebelum pemodelan ARIMA dapat dilakukan secara optimal.

Tabel 3 Ringkasan Uji Kestasioneran (ADF Test) Setelah Data Ditransformasi Melalui *Differencing*

Uji Kestasioneran	Statistik ADF	P-value	Keputusan	Keterangan
Setelah Differencing	-69.056	0.01	Tolak H0	Data stasioner

Data, setelah melewati prosedur *differencing*, terbukti memenuhi asumsi esensial yang dibutuhkan untuk proses pemodelan ARIMA, sebagaimana ditunjukkan oleh hasil uji ADF yang tercantum dalam Tabel 3. Karena data kini berada dalam kondisi stasioner, langkah-langkah selanjutnya—yaitu identifikasi, estimasi, dan penentuan model ARIMA—dapat dieksekusi dengan tingkat akurasi yang lebih tinggi

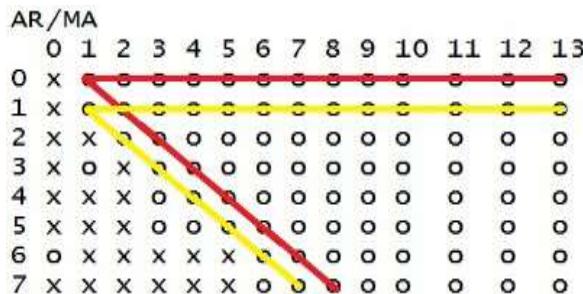


Gambar 4 Plot Visualisasi Data Saham Pasca-Transformasi *Differencing* Orde Pertama

Gambar 4 menunjukkan bahwa data telah berfluktuasi secara acak di sekitar rataan nol, tanpa pola tren yang jelas seperti pada data asli. Visualisasi ini dapat diamati bahwa amplitudo fluktuasi cenderung konsisten sepanjang periode pengamatan, menandakan bahwa varians data relatif stabil setelah dilakukan *differencing*. Hal ini menunjukkan bahwa proses transformasi tidak hanya menghilangkan tren jangka panjang, tetapi juga membantu mengendalikan volatilitas yang berlebihan. Dengan demikian, Gambar 4 memberikan bukti visual yang kuat bahwa tahap pra-pemrosesan telah menghasilkan data yang memenuhi asumsi stasioneritas, sehingga layak digunakan dalam pemodelan ARIMA selanjutnya.

3.3 Pemodelan ARIMA

Pemilihan model dilakukan melalui eksplorasi pola *Extended Autocorrelation Function* (EACF) untuk mengidentifikasi kombinasi orde AR, I, dan MA yang paling sesuai dengan karakteristik data. Berikut hasil pola EACF yang disajikan dalam ilustrasi di bawah ini:



Gambar 5 Visualisasi Pola EACF Pasca-Transformasi *Differencing* Orde Pertama

Indikator utama yang digunakan untuk menyeleksi kandidat model potensial adalah pola segitiga kosong (*empty triangle*) yang terlihat pada Gambar 5. Pola segitiga kosong ini memberikan indikasi awal mengenai kestabilan dan kemampuan adaptif model terhadap dinamika data aktual. Dengan memperhatikan area di mana pola tersebut muncul, dapat diinterpretasikan bahwa model yang berada dalam zona segitiga kosong memiliki keseimbangan optimal antara kompleksitas dan kemampuan prediksi. Interpretasi ini penting karena membantu memahami sejauh mana model mampu menyesuaikan diri terhadap fluktuasi data, terutama ketika terjadi perubahan tren yang signifikan. Dengan demikian, visualisasi pada Gambar 5 tidak hanya berfungsi sebagai alat seleksi model, tetapi juga sebagai representasi visual dari performa dan ketahanan model dalam menghadapi variasi data pada tahap peramalan. Rincian kandidat model terpilih, termasuk estimasi parameter serta nilai *Akaike Information Criterion* (AIC) dan *Bayesian Information Criterion* (BIC), dirangkum dalam tabel berikut.

Tabel 4 Komparasi Kinerja Berbagai Kandidat Model ARIMA

Model	Estimasi	AIC	BIC
ARIMA(0,1,1)	-0.1532	5792.76	5800.80
ARIMA(1,1,1)	0.2102	5794.07	5813.06
	-0.3581		
ARIMA(2,1,2)	-0.8279	5792.95	5805.88
	0.1275		
	0.7001		
	-0.2999		
ARIMA(0,1,2)	-0.1442	5793.82	5806.13
	-0.0468		

Merujuk pada data dalam tabel, Penilaian model dilakukan terutama menggunakan *Akaike Information Criterion* (AIC) karena kriteria ini lebih menekankan kemampuan prediktif model, sesuai dengan tujuan penelitian yang berfokus pada peramalan. Sebagai pembanding, *Bayesian Information Criterion* (BIC) juga digunakan untuk memberikan penalti yang lebih ketat terhadap kompleksitas model. Hasil komparasi pada

Tabel 4 menunjukkan bahwa ARIMA(0,1,1) memiliki nilai AIC dan BIC terendah dibandingkan model kandidat lainnya.

Meskipun beberapa model lain memiliki nilai AIC yang relatif mendekati, perbedaan tersebut tidak signifikan secara statistik ($\Delta AIC < 2$). Dengan mempertimbangkan prinsip parsimoni, signifikansi dan kestabilan parameter, serta hasil uji diagnostik residual yang memenuhi asumsi *white noise*, model ARIMA(0,1,1) dipilih sebagai model paling efisien dan layak digunakan dalam peramalan dengan pendekatan *rolling forecast*. ARIMA(0,1,1) teridentifikasi sebagai model yang paling optimal dengan nilai AIC dan BIC terendah, yakni sebesar 5792.76 serta 58000.80. Dengan terpilihnya model optimal ini, tahapan berikutnya melibatkan estimasi parameter melalui metode *Maximum Likelihood Estimation* (MLE) untuk merumuskan persamaan matematisnya. Mengacu pada hasil estimasi ini, notasi matematis model ARIMA(0,1,1) menggunakan operator *backshift* dapat dinyatakan sebagai:

$$Y_t = Y_{\{t-1\}} + e_t - \theta e_{\{t-1\}} \quad (8)$$

Dengan hasil estimasi parameter MA:

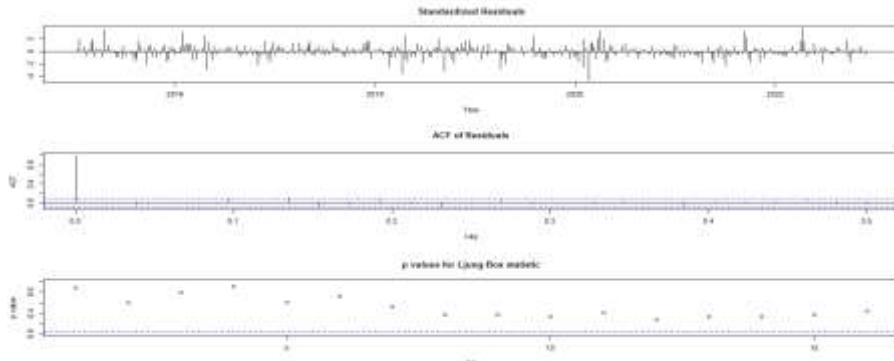
$$\theta_1 = -0.1532 \quad (9)$$

Dengan demikian, formulasi akhir untuk model ARIMA(0,1,1) adalah:

$$Y_t = Y_{\{t-1\}} + e_t + 0.1532 e_{\{t-1\}} \quad (10)$$

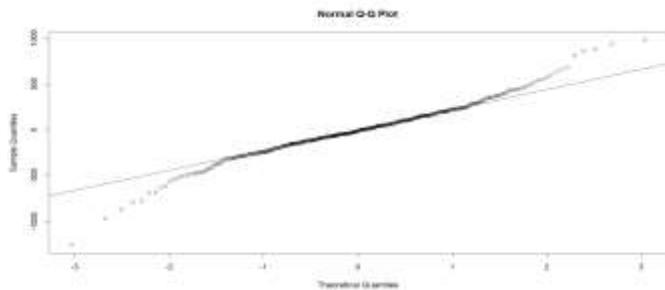
3.4 Uji Diagnostik Model ARIMA

Proses verifikasi dijalankan dengan menganalisis residual. Metode yang digunakan mencakup pemeriksaan *Standardized Residuals Plot*, *ACF Residual Plot*, *Uji Ljung-Box*, dan *Normal Q-Q Plot*, di mana hasil-hasil ini ditunjukkan secara visual pada Gambar 6 dan Gambar 7.



Gambar 6 Plot Residual Terstandarisasi, Autocorrelation Function (ACF) Residual, dan uji Ljung-Box

Pengecekan diagnostik pada Gambar 6 menunjukkan bahwa model ARIMA(0,1,1) memenuhi asumsi residual secara memadai, sehingga layak digunakan untuk tujuan peramalan. Plot residual terstandarisasi memperlihatkan pola yang berfluktuasi secara acak di sekitar nilai nol tanpa indikasi tren atau varians yang tidak konstan, yang menandakan bahwa residual bersifat stabil sepanjang waktu dan tidak menunjukkan pola sistematis yang belum tertangkap oleh model. Plot ACF residual menunjukkan seluruh nilai autokorelasi berada dalam batas kepercayaan, sehingga tidak terdapat autokorelasi yang signifikan antar residual. Hal ini diperkuat oleh hasil uji Ljung-Box yang menghasilkan nilai *p-value* di atas 0,05 pada sebagian besar *lag*, sehingga hipotesis nol (H_0) bahwa residual bersifat *white noise* tidak dapat ditolak. Dengan demikian, model ARIMA(0,1,1) dapat dianggap valid secara statistik dan cukup andal untuk digunakan dalam proses peramalan data pada periode selanjutnya.



Gambar 7 Plot Kuantil-Kuantil Normal (*Normal Q-Q Plot*)

Analisis Normal Q-Q Plot pada Gambar 7 menunjukkan bahwa residual model ARIMA(0,1,1) memiliki tingkat kedekatan yang tinggi terhadap garis diagonal, khususnya pada bagian tengah distribusi, yang mengindikasikan bahwa sebagian besar residual berdistribusi mendekati normal. Kondisi ini menandakan bahwa model mampu menangkap pola utama data dengan baik, sehingga kesalahan prediksi bersifat acak dan tidak sistematis pada mayoritas observasi. Meskipun demikian, penyimpangan pada bagian ekor distribusi (*tail*) masih dapat diamati, baik di sisi kiri maupun kanan, yang mengindikasikan adanya *outlier* atau karakteristik *heavy-tailed*. Fenomena ini umumnya berkaitan dengan volatilitas harga saham yang tinggi atau shock pasar pada periode tertentu, sehingga residual pada titik ekstrem menjadi sulit dimodelkan secara sempurna. Walaupun asumsi normalitas tidak sepenuhnya terpenuhi pada nilai ekstrem, secara keseluruhan residual masih cukup memenuhi asumsi normalitas, sehingga model ARIMA(0,1,1) tetap layak digunakan untuk keperluan peramalan dan analisis tren.

3.5 Rolling Forecast

Mengacu pada tahap sebelumnya, model terbaik yang teridentifikasi berdasarkan nilai AIC dan BIC adalah ARIMA(0,1,1). Model ini selanjutnya diaplikasikan untuk proses peramalan harga saham PT Unilever Indonesia Tbk (UNVR) menggunakan dua pendekatan, yaitu *static forecast* dan *rolling forecast*, dengan tahapan awal yang sama, untuk selanjutnya dibandingkan kinerja akurasi prediksinya.

1. Forecast Biasa (*Static Forecast*)

Pada pendekatan *static forecast*, model ARIMA diestimasi satu kali menggunakan seluruh data pelatihan (*training data*) dan kemudian digunakan untuk menghasilkan prediksi pada periode pengujian tanpa pembaruan parameter di setiap langkah. Pendekatan ini mengasumsikan bahwa pola data bersifat relatif stabil sepanjang periode peramalan.

2. Rolling Forecast (*One-Step-Ahead*)

Pendekatan *rolling forecast*, digunakan skema *one-step-ahead forecasting* dengan *expanding window*. Secara teknis, model ARIMA dilatih ulang setiap kali satu observasi baru tersedia, dengan menambahkan data aktual terbaru ke dalam *training set*. Dengan frekuensi data mingguan, pembaruan model dilakukan setiap minggu, dan pada setiap iterasi dihasilkan prediksi satu periode ke depan. Pendekatan ini memungkinkan model untuk selalu memanfaatkan informasi terbaru dan menyesuaikan diri terhadap perubahan pola serta volatilitas harga saham.

Kedua pendekatan tersebut dievaluasi menggunakan metrik yang sama, yaitu Mean Absolute Error (MAE) dan Mean Absolute Percentage Error (MAPE), berdasarkan data pengujian (*test data*). Hasil perbandingan akurasi ditunjukkan pada Tabel 5.

Tabel 5 Perbandingan *Rolling Forecast* dan *Forecast Biasa*

Metode Peramalan	MAE	MAPE
Forecast Biasa	1481.51	58.12%
Rolling Forecast	105.01	3.44%

Berdasarkan hasil komparasi akurasi dalam Tabel 5 diperhatikan, metode *rolling forecast* menunjukkan superioritas signifikan dibandingkan metode peramalan statis (*forecast biasa*). Indikasi ini terlihat dari nilai MAE (105.01) dan MAPE (3.44%) yang jauh lebih minimal, yang mengonfirmasi bahwa

model menghasilkan prediksi dengan kesalahan yang sangat terbatas dan memiliki akurasi yang optimal. Sebaliknya, peramalan statis menunjukkan kinerja yang jauh di bawah standar, dengan MAE 1481.51 dan MAPE 58.12%, yang menyiratkan bahwa hasil prediksinya sangat jauh dari nilai aktual.

Keunggulan *rolling forecast* dibandingkan teknik peramalan dinamis lainnya terletak pada sifatnya yang adaptif namun relatif sederhana. Berbeda dengan metode yang memerlukan pemodelan tambahan terhadap varians atau struktur *nonlinier*, *rolling forecast* memungkinkan peningkatan akurasi hanya melalui pembaruan parameter model berdasarkan data terbaru. Hal ini menjadikannya sesuai untuk peramalan harga saham yang bersifat fluktuatif dan berubah secara dinamis.

Peramalan model dilakukan menggunakan metode *rolling forecast* terhadap data pendugaan yang diperoleh pada data *train* peramalan ARIMA tanpa *rolling forecast*. Selanjutnya, Gambar 8 menyajikan ilustrasi visual yang membandingkan antara keluaran hasil prediksi dengan data aktual yang sesungguhnya.



Gambar 8 Perbandingan Hasil Prediksi dan Data Aktual

Secara visual, Gambar 8 menunjukkan adanya komparasi antara data harga aktual (ditandai garis merah) dan hasil peramalan (ditandai garis biru) pada set data pengujian. Hasil visualisasi menunjukkan bahwa model mampu mengikuti pola dan arah pergerakan harga secara konsisten, dengan kedekatan yang cukup baik terhadap data aktual. Pada kondisi fluktuasi moderat, garis prediksi tampak selaras dengan pergerakan harga, menandakan kemampuan model dalam menangkap dinamika historis data. Ketika terjadi perubahan tren yang signifikan, khususnya penurunan tajam harga saham pada periode 2023 hingga 2025, model tetap berhasil merepresentasikan arah tren dengan baik meskipun terdapat deviasi pada beberapa titik ekstrem. Hal ini menunjukkan efektivitas penerapan *rolling forecast* dalam menjaga responsivitas model terhadap perubahan struktur tren, sehingga model tetap adaptif terhadap dinamika pasar yang cepat berubah.

3.6 Hasil Peramalan dengan Rolling Forecast

Prediksi harga selanjutnya dilakukan menggunakan model ARIMA(0,1,1) yang teridentifikasi sebagai model paling unggul pada fase pemilihan model. Model tersebut kemudian dipakai untuk memproyeksikan harga saham di periode mendatang. Karena data memiliki frekuensi mingguan, periode peramalan ditetapkan mulai dari 12 Januari 2026 sampai dengan 16 Februari 2026. Hasil peramalan tidak hanya mencakup nilai prediksi tunggal, tetapi juga batas atas dan batas bawah untuk interval kepercayaan 95%, yang menyajikan estimasi mengenai rentang kemungkinan nilai harga pada setiap periode waktu.

Tabel 6 Hasil Ramalan

Tanggal	Prediksi	Lower 95%	Upper 95%
12-Jan-25	4748.18	4213.66	5282.71
19-Jan-25	4743.55	4043.33	5443.77
26-Jan-25	4738.91	3905.30	5572.52
02-Feb-25	4734.27	3785.86	5682.69
09-Feb-25	4729.64	3678.88	5780.39
16-Feb-25	4725.00	3581.03	5868.98

Hasil peramalan pada Tabel 6 menunjukkan bahwa harga yang diprediksi oleh model ARIMA(0,1,1) mengalami penurunan bertahap sepanjang periode peramalan, yaitu dari 4748,18 pada 12 Januari 2025 menjadi 4725,00 pada 16 Februari 2025. Walaupun demikian, interval kepercayaan 95% cukup lebar, menggambarkan adanya tingkat ketidakpastian dalam pergerakan harga di masa depan. Meskipun nilai prediksi menunjukkan kecenderungan stabil dan sedikit menurun, rentang batas bawah dan batas atas tetap memberikan ruang fluktuasi yang cukup besar. Secara keseluruhan, model mampu menggambarkan pola pergerakan harga dengan baik dan dapat digunakan sebagai dasar pertimbangan untuk analisis selanjutnya.

4. KESIMPULAN DAN SARAN

Berdasarkan hasil analisis penerapan *rolling forecast* pada model ARIMA untuk prediksi pergerakan harga saham UNVR, dapat disimpulkan beberapa poin utama:

1. Model Terbaik: Proses identifikasi menunjukkan bahwa ARIMA(0,1,1) adalah model paling optimal. Model ini dibentuk setelah data mengalami proses *differencing* satu kali ($d = 1$) untuk memenuhi syarat kestasioneran, dengan persamaan $Y_t = Y_{t-1} + e_t + 0.1532, e_{t-1}$
2. Peningkatan Akurasi: Penerapan metode *rolling forecast* terbukti sangat efektif dalam mereduksi tingkat kesalahan peramalan. Metode ini menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 3,44% dan *Mean Absolute Error* (MAE) sebesar 105,01. Hasil ini jauh lebih unggul dibandingkan metode peramalan biasa (statis) yang menghasilkan error sangat besar dengan MAPE 58,12% dan MAE 1481,51.
3. Kelebihan dan Kekurangan:
 - Kelebihan: Model *rolling forecast* memiliki daya adaptasi yang tinggi terhadap perubahan tren harga saham terkini, menjadikannya responsif terhadap fluktuasi pasar dan menghasilkan error prediksi yang minimal.
 - Kekurangan: Meskipun akurat, analisis residual menunjukkan sedikit penyimpangan dari normalitas (terutama pada bagian *tail*), mengindikasikan bahwa model masih sensitif terhadap *outlier* ekstrem. Selain itu, interval kepercayaan hasil peramalan ke depan cenderung lebar, merefleksikan adanya ketidakpastian pasar yang tinggi.
4. Saran
 - Untuk penelitian mendatang, disarankan untuk menguji metode peramalan hibrida (misalnya ARIMA-GARCH atau kombinasi ARIMA dengan *Machine Learning*) guna menangani masalah volatilitas dan *outlier* yang lebih kompleks.
 - Penambahan variabel eksogen (*regressor*) seperti indeks harga saham gabungan atau indikator ekonomi makro ke dalam model dapat dipertimbangkan untuk mempersempit interval ketidakpastian prediksi dan meningkatkan daya prediktif.

DAFTAR PUSTAKA

Amiri, Y. I. A., & Wardati, N. K. 2025. Peramalan Permintaan Produk Menggunakan ARIMA Berbasis Data Mining. *Jurnal Informatika: Jurnal Pengembangan IT*, 10(3), 821–831. <https://doi.org/10.30591/jpit.v10i3.8665>

Arifin, A. H. 2023. Firm Value Volatility in View of Profit Performance and Practices Good Corporate Governance. *SEIKO: Journal of Management & Business*, 6(1), 296–310. <https://doi.org/10.37531/sejaman.v6i2.4503>

Hartono, P. C., & Widiantoro, A. D. 2024. Analisis Prediksi Harga Saham Unilever Menggunakan Regresi Linier dengan RapidMiner. *Journal of Computer and Information Systems Ampera*, 5(3), 174–190.

Jeynes, Z., & Budiman, A. 2024. PENGARUH RETURN ON ASSET, RETURN ON EQUITY, CURRENT RATIO, EARNING PER SHARE DAN DEBT TO EQUITY RATIO TERHADAP HARGA SAHAM PT. UNILEVER INDONESIA (PERSERO) TBK PERIODE 2016-2022. *JIMEA: Jurnal Ilmiah MEA (Manajemen, Ekonomi, Dan AKuntansi)*, 8(1), 56–78. <https://doi.org/10.31955/mea.v8i1.3627>

Jota, A. L., Sumirat, E. A., & Sukarno, S. 2025. Stock Valuation of PT Unilever Indonesia Tbk : Assessing Financial Impact of Economic and Industry Pressures in the FMCG Sector. *JII : Journal of Indonesian Impressions*, 4(6), 2252–2266. <https://doi.org/10.58344/jii.v4i6.6793>

Karunia, R. D., & Hidayati, N. 2025. Implementasi Model ARIMA untuk Analisa Prediksi Harga Penutupan Saham Historis Harian Perusahaan BP Minyak dan Gas Multinasional. *Justin: Jurnal Sistem dan Teknologi Informasi*, 13(3), 346–353.

Kurniawan, F., & Fahlevi, M. R. 2025. PENGARUH BOIKOT PRODUK TERHADAP VOLATILITAS RETURN EMITEN UNILEVER INDONESIA TBK Fernando. *JURNAL EKONOMI DAN BISNIS*, 27(1), 2023–2026. <https://repository.metrouniv.ac.id/id/eprint/11148/>

Kovanen, S., 2024, Machine learning in rolling forecasting - case Rainmaker, *Tesis*, Industrial Engineering and Management, Lappeenranta-Lahti University of Technology LUT, Finlandia.

Liu, H., & Lin, Z. 2025. Galerkin-ARIMA: A Two-Stage Polynomial Regression Framework for Fast Rolling One-Step-Ahead Forecasting. *arXiv preprint arXiv:2507.07469*.

Muslihin, K. R. A., & Ruchjana, B. N. 2023. Model Autoregressive Moving Average (ARMA) untuk Peramalan Tingkat Inflasi di Indonesia. *Limits : Journal of Mathematics and Its Application*, 20(2), 209–218. <https://doi.org/10.12962/limits.v20i2.15098>

Rusminto, M. Z., Wibowo, S. A., & Wahyuni, F. S. 2024. PERAMALAN HARGA SAHAM MENGGUNAKAN METODE ARIMA (AUTOREGRESSIVE INTEGRATED MOVING AVERAGE) TIME SERIES. *JATI: Jurnal Mahasiswa Teknik Informatika*, 8(2), 1263–1270. <https://doi.org/10.36040/jati.v8i2.9089>

Widyarti, E.T., Maruddani, D.A., Trimono, T., & Hersugondo, H. 2021. Blue chip stocks valuation and risk prediction on the indonesia stock exchange. *Academy of Accounting and Financial Studies Journal*, 25(6), 1–14.

Yi, Z., Yao, Y., Liu, W., & Gao, Y. 2023. Analysis and Prediction of the Real Economic Health of the Country based on ARIMA Model. *International Core Journal of Engineering*, 9(5), 476-483.