

Penerapan Pemodelan Konvensional dan *Deep Learning* pada Data Saham dengan Pencilan

<http://dx.doi.org/10.28932/jutisi.v12i1.10587>

Riwayat Artikel

Received: 18 Desember 2024 | Final Revision: 20 Agustus 2025 | Accepted: 27 Agustus 2025

Creative Commons License 4.0 (CC BY – NC)



Muhammad Firlan Maulana^{#1}, Salsabila Fayiza^{#2}, Bulan Cahyani Suhaeri^{#3}, Ardelia Rahma Febyan^{#4}, Thariq Hambali^{#5}, Yenni Angraini^{#6}, Muhammad Rizky Nurhambali^{#7}

[#] Program Studi Statistika dan Sains Data, Sekolah Sains Data, Matematika, dan Informatika, IPB University
Jl. Meranti Wing 22, Kabupaten Bogor, 16680, Indonesia

¹firlan26muhammad@apps.ipb.ac.id

²fyzsalsabila@apps.ipb.ac.id

³bulancahyani@apps.ipb.ac.id

⁴ardeliarahma@apps.ipb.ac.id

⁵thariqhambalithariq@apps.ipb.ac.id

⁶y_angraini@apps.ipb.ac.id

⁷rizkynurhambali@apps.ipb.ac.id

✉ Corresponding author: y_angraini@apps.ipb.ac.id

Abstrak — Saham Apple Inc. (AAPL), salah satu perusahaan teknologi terkemuka, menjadi salah satu perhatian investor karena terus mengalami peningkatan jumlah pengguna setiap tahun. Oleh karena itu, peramalan harga saham Apple penting untuk membantu investor memitigasi risiko dan mengoptimalkan keputusan investasi. Peramalan ini dapat dilakukan menggunakan dua pendekatan utama, yaitu pendekatan konvensional seperti *autoregressive integrated moving average* (ARIMA) dan pendekatan berbasis *deep learning* seperti *long short-term memory network* (LSTM). Penelitian ini bertujuan untuk menemukan model terbaik menggunakan kedua metode tersebut, serta membandingkan akurasi model berdasarkan *dataset* dengan pencilan dan *dataset* pencilan tertangani. *Dataset* yang dianalisis dalam penelitian ini berasal dari data harga penutupan saham AAPL mingguan selama 500 periode, dari 26 Januari 2015 hingga 19 Agustus 2024 yang diperoleh dari Yahoo Finance. Penelitian ini memperoleh model ARIMA(1,1,1) sebagai model terbaik untuk kedua *dataset*, dengan *dataset* pencilan tertangani menghasilkan Mean Absolute Percentage Error (MAPE) uji lebih baik, sedangkan *dataset* dengan pencilan memiliki MAPE latih lebih baik. Metode LSTM menghasilkan nilai MAPE yang lebih kecil dibandingkan ARIMA, menunjukkan keunggulannya dalam menangkap pola fluktuatif data saham AAPL. Penanganan pencilan terbukti meningkatkan akurasi model, sebagaimana terlihat pada *dataset* pencilan tertangani. Penelitian ini memberikan wawasan mengenai efektivitas metode statistik dan *deep learning* dalam memodelkan harga saham, serta menekankan pentingnya penanganan pencilan dalam analisis data keuangan.

Kata kunci— ARIMA; LSTM; MAPE; Pencilan; Perbandingan Metode.

Application of Conventional Modeling and Deep Learning to Stock Data with Outliers

Abstract — Apple Inc. stock (AAPL), one of the leading technology companies, is one of the concerns of investors as it continues to see an increase in the number of users every year. Therefore, forecasting Apple's stock price is important to help investors mitigate risks and optimize investment decisions. This forecasting can be done using two main approaches, namely conventional approaches such as *Autoregressive Integrated Moving Average* (ARIMA) and deep learning-based approaches such as *Long Short-term Memory Network*

(LSTM). This study aims to find the best model using both methods, as well as compare the accuracy of the models based on datasets with outliers and datasets with handled outliers. The dataset analyzed in this study comes from weekly AAPL stock closing price data for 500 periods, from January 26, 2015 to August 19, 2024 obtained from Yahoo Finance. This study obtained the ARIMA(1,1,1) model as the best model for both datasets, with the outlier-handled dataset producing better test MAPE, while the dataset with outliers had better training MAPE. The LSTM method produced smaller MAPE values than ARIMA, demonstrating its superiority in capturing the fluctuating patterns of the AAPL stock data. Outlier handling was shown to improve model accuracy, as seen in the outlier-handled dataset. This research provides insight into the effectiveness of statistical and deep learning methods in modeling stock prices, and emphasizes the importance of outlier handling in financial data analysis.

Keywords— ARIMA; LSTM; MAPE, Method Comparison; Outliers.

I. PENDAHULUAN

Perkembangan ekonomi yang semakin pesat menurut membuat pasar modal menjadi salah satu wadah investasi banyak orang. Pasar modal sendiri menurut Rizki *et al.*, merupakan tempat bertemunya emiten dan investor sebagai pihak yang terlibat perdagangan dan/atau penawaran investasi modal [1]. Salah satu investasi di pasar modal adalah saham. Saham adalah suatu surat bukti kepemilikan atau tanda pemegang modal di perusahaan. Salah satu saham perusahaan yang banyak diperhatikan oleh banyak pihak karena menjadi produsen berbagai teknologi dengan pengguna terbanyak dan mengalami peningkatan setiap tahunnya adalah saham perusahaan Apple inc. dengan kode AAPL.

Peramalan memungkinkan untuk dilakukan pada data harga penutupan saham AAPL yang berupa data deret waktu. Salah satu metode yang paling sering digunakan yaitu metode *autoregressive integrated moving average* (ARIMA). Metode ARIMA adalah teknik peramalan deret waktu jarak pendek (dengan data masa lampau dan sekarang) yang akurat dengan sepenuhnya mengabaikan peubah independen dan digunakan untuk data yang menunjukkan pola tren atau yang tidak stasioner (non-stasioner) [1]. ARIMA menurut Sugianto *et al.* [2] merupakan metode peramalan deret waktu univariat yang memerlukan asumsi stasioneritas. Data yang tidak stasioner dapat disebabkan karena adanya pencilan. Metode ARIMA memang dapat memodelkan data dengan pencilan tetapi model yang didapat tidak maksimal. Pada penelitian ini, terdapat pencilan dalam data sehingga hal ini menjadi tantangan bagi peneliti. Seiring berkembangnya teknologi *deep learning*, muncul metode *long short-term memory* (LSTM). Tidak seperti metode statistik konvensional seperti ARIMA, LSTM tidak memerlukan data yang bersifat stasioner karena kemampuannya untuk mempelajari pola non-linear dalam data. Hal ini membuat LSTM menjadi pilihan populer untuk menganalisis data deret waktu yang kompleks dengan tren atau musiman yang tidak linier. Namun, LSTM menunjukkan stabilitas yang lebih lemah terhadap pencilan dibanding jenis *deep learning* lain seperti CNN [3]. Keberadaan pencilan dalam data pelatihan dapat memengaruhi kemampuan model untuk mempelajari pola yang sebenarnya karena LSTM cenderung meminimalkan kesalahan secara global tanpa menyaring pencilan secara khusus. Oleh karena itu, pra-proses data seperti deteksi dan penanganan pencilan sering diperlukan sebelum membangun model LSTM untuk meningkatkan akurasi prediksinya.

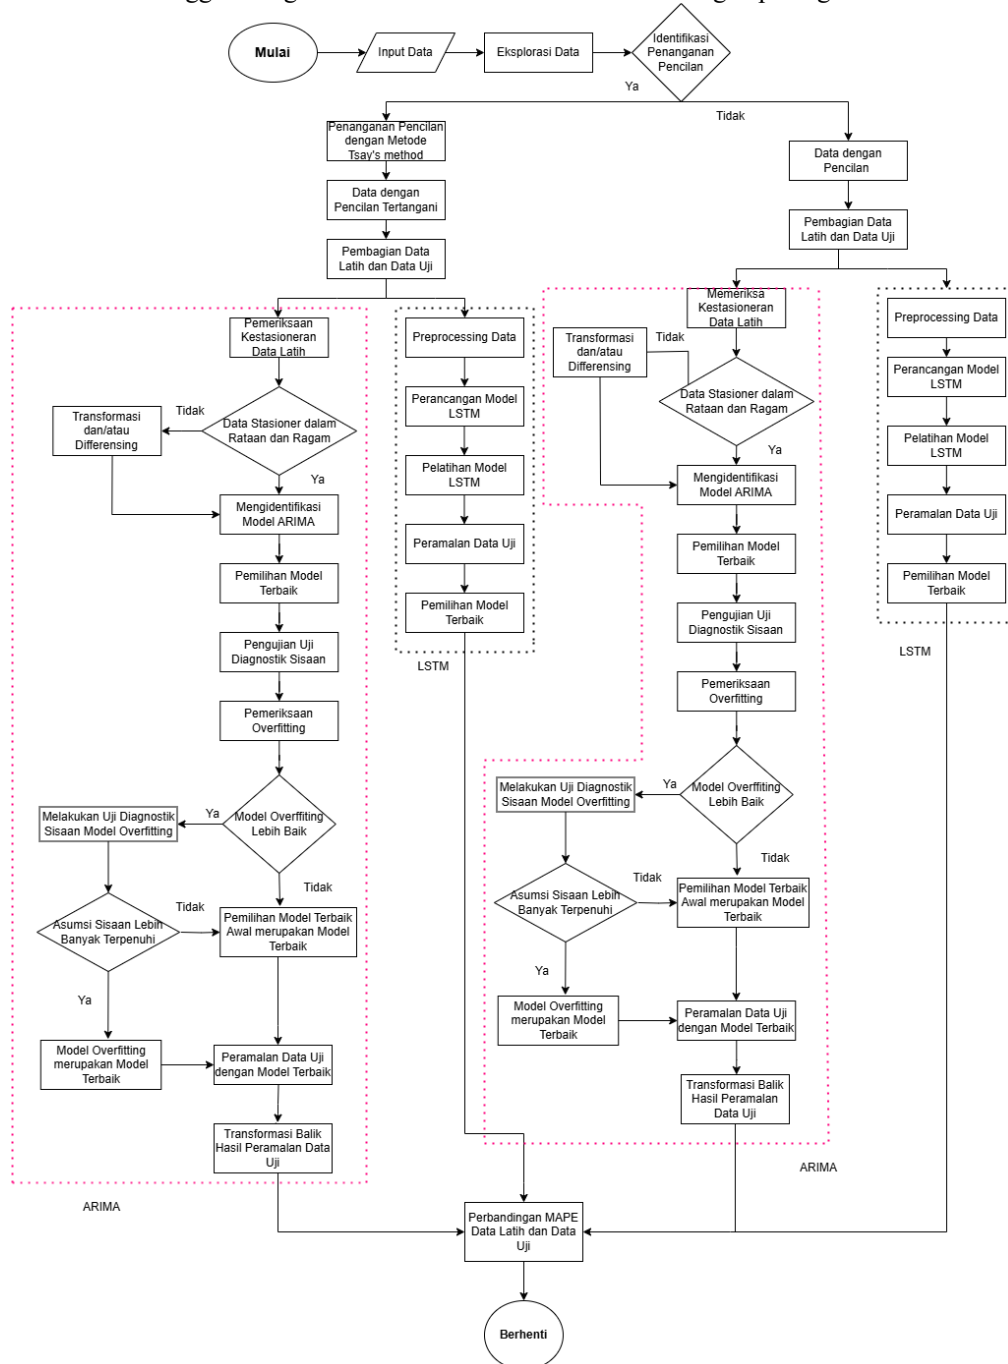
Beberapa penelitian sebelumnya yang berhubungan dengan penelitian ini, yaitu penelitian [4] tentang analisis teknis pasar saham Indonesia dengan *gated recurrent unit* (GRU) dan *temporal convolutional network* (TCN) yang mengidentifikasi 20 titik krisis JKSE selama periode 2002–2023. Hasil yang didapatkan menunjukkan metode GRU lebih akurat dan efisien sesuai dengan nilai *root mean square error* (RMSE) dan nilai *mean absolute error* (MAE) terkecil dibandingkan metode TCN. Selanjutnya, penelitian [5] tentang analisis perbandingan model ARIMA dan LSTM dalam peramalan harga penutupan saham menunjukkan nilai rata-rata RMSE, *mean absolute percentage error* (MAPE), dan waktu peramalan dari metode ARIMA lebih rendah dibandingkan dengan metode LSTM sehingga metode ARIMA disimpulkan lebih bagus performanya. Penelitian lain yang berkaitan yaitu penelitian [6] tentang peramalan metode ARIMA pada harga penutupan saham PT. Telekomunikasi Indonesia dari bulan Juni 2020 sampai Mei 2021 menghasilkan model ARIMA (0, 2, 1) sebagai model dengan nilai *mean square error* (MSE) terkecil. Kemudian, penelitian [7] menggunakan LSTM untuk prediksi lima emiten syariah, yaitu PT Aneka Tambang Tbk (ANTM), Erajaya Swasembada Tbk (ERAA), Kalbe Farma Tbk (KLBF), Semen Indonesia (Persero) Tbk (SMGR), dan Wijaya Karya (Persero) Tbk (WIKA). Hasil yang didapat yaitu nilai MAPE saham KLBF adalah yang terkecil dari keempat emiten lainnya, tetapi metode LSTM tetap efektif untuk membuat model optimal untuk kelima emiten.

Berdasarkan referensi dan rujukan penelitian sebelumnya, penelitian ini bertujuan membandingkan kinerja ARIMA sebagai pendekatan konvensional dengan LSTM sebagai pendekatan *deep learning* dalam data harga penutupan saham AAPL yang bersifat fluktuatif. Selain itu, perbandingan dilakukan dengan mempertimbangkan keberadaan pencilan dalam data. Penelitian ini juga bertujuan mengetahui apakah penanganan pencilan dapat menjadikan model yang terbentuk lebih baik.

Keunggulan dan kelemahan masing-masing metode dalam menghadapi pola data saham yang kompleks, nilai akurasi, serta pengaruh pencilan terhadap hasil prediksi diharapkan dapat tergambar melalui penelitian ini.

II. METODE PENELITIAN

Proses penelitian dilakukan mulai dari eksplorasi data, pembentukan dua *dataset* yang terdiri atas *dataset* dengan pencilan dan *dataset* dengan pencilan tertangani, penerapan metode ARIMA dan LSTM, hingga melakukan perbandingan nilai MAPE. Gambar 1 merupakan alur penelitian dari awal hingga akhir. Data pada penelitian ini merupakan data sekunder harga saham AAPL (Apple Inc.) yang bersumber dari laman Yahoo Finance. Data saham tersebut terdiri dari 500 periode mingguan, yang dimulai dari 26 Januari 2015 hingga 19 Agustus 2024. Proses analisis dibantu dengan perangkat lunak R dan Python.



Gambar 1. Diagram alur metode penelitian

A. Eksplorasi Data

- 1) *Plot Data Deret Waktu*: Data saham AAPL dieksplorasi menggunakan plot deret waktu untuk melihat pola serta kestasioneran data.
- 2) *Identifikasi dan Penanganan Pencilan*: Pencilan pada data diidentifikasi dan ditangani menggunakan *Tsay's Method*. *Tsay's Method* adalah sebuah pendekatan berbasis model ARIMA yang secara iteratif mendeteksi, mengklasifikasikan, dan mengoreksi pencilan pada data deret waktu sehingga didapatkan prediksi yang lebih akurat [8]. Kemudian, dibangun dua dataset, yaitu dataset dengan pencilan dan dataset dengan pencilan tertangani.
- 3) *Pembagian Data Latih dan Data Uji*: Data dibagi menjadi data latih sebanyak 360 periode, dimulai dari 26 Januari 2015 hingga 13 Desember 2021, dan data uji sebanyak 140 periode, dimulai dari 20 Desember 2021 hingga 19 Agustus 2024. Proporsi tersebut diterapkan karena pola fluktuasi pada periode tersebut stabil naik.

B. Pemodelan dengan ARIMA

- 1) *Identifikasi dan Penanganan Kestasioneran Data*: Secara eksploratif, kestasioneran data dapat dilihat melalui plot deret waktu [9]. Kemudian, kestasioneran dalam ragam diperiksa menggunakan plot Box-Cox, dengan selang kepercayaan yang mencakup nilai satu. Jika ragam tidak stasioner, maka dilakukan transformasi Box-Cox. Sementara itu, kestasioneran dalam rata-rata diperiksa menggunakan plot *autocorrelation function* (ACF) dan uji *Augmented Dickey-Fuller* (ADF). Identifikasi uji ADF menggunakan rumusan hipotesis H_0 jika rata-rata tidak stasioner dan H_1 jika rata-rata stasioner. Jika rata-rata tidak stasioner maka dilakukan *differencing* [10].
- 2) *Identifikasi Model Tentatif*: Model ARIMA diidentifikasi menggunakan plot ACF, *partial ACF* (PACF), dan *extended ACF* (EACF). Plot tersebut dapat membantu identifikasi orde dari model AR, MA, atau ARMA. Kemudian, model terbaik yang dipilih merupakan model yang signifikan pada setiap parameternya dan memiliki nilai *Akaike Information Criterion* (AIC) terendah.
- 3) *Diagnostik Model*: Uji diagnostik sisaan meliputi, uji *Kolmogorov-Smirnov* untuk memeriksa asumsi normalitas, uji *Ljung-Box* untuk memeriksa asumsi kebebasan sisaan dan kehomogenan sisaan, serta uji t untuk memeriksa asumsi nilai tengah sisaan sama dengan nol.
- 4) *Overfitting Model*: *Overfitting* diterapkan dengan menambah satu ordo pada AR dan/atau MA model tentatif terbaik, untuk melihat apakah terdapat model yang lebih baik di sekitar dugaan model tentatif [11]. Jika model baru yang diperoleh dari proses *overfitting* menunjukkan hasil yang lebih baik, maka uji diagnostik sisaan dilakukan kembali untuk memastikan bahwa asumsi model telah terpenuhi. Apabila model baru tidak memenuhi asumsi diagnostik, analisis dilanjutkan ke tahap selanjutnya.
- 5) *Peramalan Data Uji dan Transformasi Balik*: Berdasarkan model terbaik, dilakukan peramalan data uji sebanyak 140 periode ke depan. Kemudian, dilakukan transformasi balik terhadap proses *differencing* dan transformasi Box-Cox pada peramalan data uji.
- 6) *Pengukuran Keباikan Model*: Akurasi kebaikan model diukur menggunakan MAPE latih dan uji. Semakin rendah nilai MAPE mengindikasikan kualitas prediksi yang lebih baik [12]. Nilai MAPE latih dan uji dibandingkan antara model pada *dataset* dengan pencilan dan model pada *dataset* dengan pencilan tertangani.

C. Pemodelan LSTM

- 1) *Preprocessing Data*: Data latih dinormalisasi menggunakan *Min-Max Normalization* agar data berada dalam rentang 0–1 dengan menggunakan persamaan 1 [13].

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

Keterangan:

- x' = Skala data dalam rentang baru
- x = Nilai yang akan dinormalisasi
- x_{\min} = Nilai minimal dari data asli
- x_{\max} = Nilai maksimal dari data asli

- 2) *Perancangan Model*: Model LSTM dirancang dengan menentukan inisialisasi *hyperparameter* yang digunakan, seperti rasio perbandingan data latih dan uji, *learning rate*, *epoch*, *layers*, *units*, dan *dropout rate*. Tabel 1 menunjukkan pengaturan masing-masing parameter yang digunakan.

TABEL 1
KOMBINASI PARAMETER YANG DIGUNAKAN PADA LSTM

Parameter	Pengaturan
Rasio perbandingan data latih dan uji	72:28
<i>Learning rate</i>	[0,01; 0,001; 0,0001]
<i>Epoch</i>	100
<i>Layers</i>	2
<i>Units</i>	[128:64]
<i>Dropout rate</i>	0,2

- 3) *Pelatihan Model*: Model dilatih menggunakan *optimizer adaptive moment estimation* (ADAM), yang merupakan perkembangan dari algoritma *stochastic gradient decent* (SGD). *Optimizer* ADAM memperbarui bobot secara iteratif yang didasarkan pada data latih, diperkenalkan oleh Diederik Kingma [14].
- 4) *Peramalan Data Uji*: Model yang telah dilatih digunakan untuk memprediksi nilai pada data uji sebanyak 140 periode ke depan dan selanjutnya dilakukan denormalisasi data.
- 5) *Pemilihan Model Terbaik*: Tingkat akurasi model dievaluasi menggunakan nilai MAPE latih dan uji. Kemudian, dibandingkan nilai MAPE latih dan uji antara model pada *dataset* dengan pencilan dan model pada *dataset* dengan pencilan tertangani.

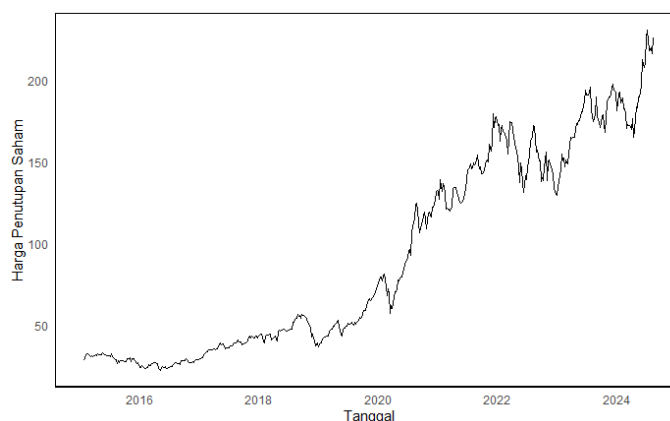
D. Membandingkan akurasi model ARIMA dan LSTM menggunakan nilai MAPE latih dan uji.

III. HASIL DAN PEMBAHASAN

A. Eksplorasi Data

1) Plot data deret waktu

Plot data deret waktu pada Gambar 2 menunjukkan pergerakan harga penutupan saham AAPL selama 500 periode dan merupakan plot dari keseluruhan data. Fluktuasi harga nilai penutupan saham AAPL dari waktu ke waktu menunjukkan adanya kecenderungan pola tren pada plot data deret waktu tersebut. Pola tren yang ditunjukkan merupakan pola tren naik (*uptrend*) dan peningkatan tertinggi terjadi di awal tahun 2020. Peningkatan tertinggi tersebut terjadi karena pada akhir tahun 2019 Apple Inc. merilis iPhone 11 yang memiliki desain baru dan harga lebih terjangkau dibanding seri sebelumnya. *Smartphone* iPhone 11 yang memiliki daya tarik tinggi pada konsumen menjadikannya *smartphone* buatan Apple Inc. terlaris di tahun 2020.



Gambar 2. Plot data deret waktu harga penutupan saham AAPL

2) Identifikasi dan penanganan pencilan

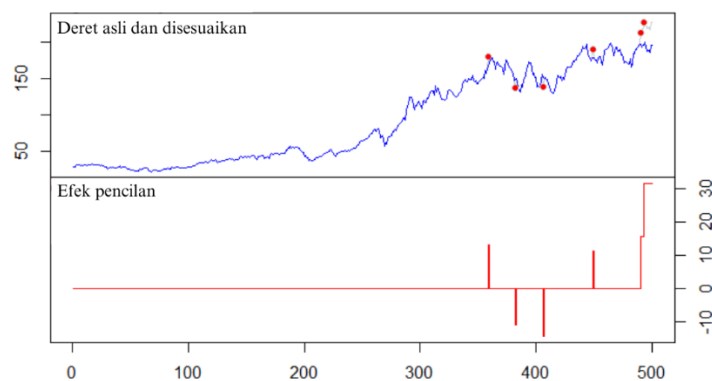
Penggunaan *package* “*tsoutliers*” di R dimanfaatkan untuk mendeteksi pencilan pada data saham AAPL. *Package* tersebut memanfaatkan Tsay’s Method mendeteksi adanya pencilan pada data deret waktu sekaligus melakukan penanganan terhadap pencilan yang terdeteksi. Pada data saham AAPL dengan 500 periode, terdapat enam pencilan yang terdeteksi. Pencilan merupakan pengamatan dengan nilai yang sangat berbeda dari ukuran pemusatan data, yang dapat memengaruhi hasil analisis pada beberapa metode tertentu.

Jenis pencilan pada data deret waktu yaitu *additive outlier* (AO), *innovational outlier* (IO), *level shift* (LS), dan *temporary change* (TC) [15]. Enam pencilan pada data saham AAPL yang digunakan dalam penelitian ini terdeteksi sebagai pencilan jenis AO dan LO. Berdasarkan hasil deteksi pencilan yang ditunjukkan oleh Tabel 2, terlihat bahwa seluruh pencilan terdapat pada index di atas 300. Pencilan dengan jenis AO memberikan efek atau dampak kepada satu titik amatan tanpa mempengaruhi titik waktu yang lain, sedangkan *Level Shift* merupakan jenis pencilan yang mengindikasikan adanya perubahan secara mendadak pada level rata-rata data dan berpotensi memberikan efek yang permanen pada data deret waktu [16].

TABEL 2
HASIL DETEKSI PENCILAN DENGAN PACKAGE “TSOUTLIERS”

No	Index	Tanggal	Jenis Pencilan
1	359	06/12/2021	Additive Outlier
2	382	16/05/2022	Additive Outlier
3	406	31/20/2022	Additive Outlier
4	449	28/08/2023	Additive Outlier
5	490	10/06/2024	Level Shift
6	493	01/07/2024	Level Shift

Garis biru pada Gambar 3 menunjukkan fluktuasi harga penutupan saham AAPL setelah dilakukan penanganan pada pencilan. Titik-titik merah pada plot tersebut menunjukkan letak pencilan pada data deret waktu. Garis samar-samar yang terletak di belakang garis biru menunjukkan fluktuasi harga penutupan saham AAPL yang asli sebelum dilakukan penanganan pada pencilan. Berdasarkan Gambar 3, dapat terlihat pula efek dari masing-masing pencilan yang terdapat pada plot *outlier effects* di bagian bawah dan digambarkan oleh garis merah. Terlihat bahwa pencilan pertama dan keempat memberikan efek berupa lonjakan tajam ke atas (positif) secara tiba-tiba. Lonjakan ini mengindikasikan adanya kenaikan harga penutupan saham AAPL yang terjadi secara tiba-tiba. Sebaliknya, terjadi efek berupa lonjakan ke bawah (negatif) pada pencilan kedua dan ketiga yang terjadi karena adanya penurunan harga penutupan saham AAPL. Terlihat pula pada pencilan pertama hingga pencilan keempat, lonjakan hanya terjadi pada titik tersebut dan kembali ke nol segera setelah melewati waktu amatan hanya memberikan gangguan sementara. Hal ini mengindikasikan bahwa pencilan-pencilan tersebut hanya memberikan gangguan sementara dan merupakan efek dari pencilan berjenis *Additive Outliers*.



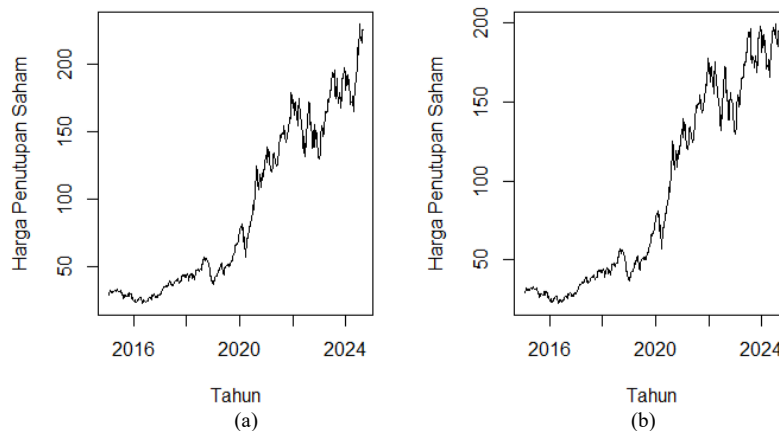
Gambar 3. Plot identifikasi letak dan efek pencilan

Plot efek pencilan juga menunjukkan adanya lonjakan pada pencilan kelima dan keenam yang tidak segera kembali ke nol setelah melewati waktu amatan. Lonjakan ini mengindikasikan bahwa pencilan memberikan efek yang permanen dan berkelanjutan pada rata-rata deret waktu. Terlihat bahwa terjadi lonjakan naik (positif) tanpa kembali ke nol pada efek dari pencilan kelima yang selanjutnya bertambah naik pada efek dari pencilan keenam. Lonjakan-lonjakan ini mengindikasikan bahwa pencilan kelima dan keenam merupakan pencilan dengan jenis *Level Shift*. Efek dari pencilan dengan jenis ini dapat memberikan dampak pada amatan berikutnya dan berpotensi menjadikan hasil prediksi dari model ARIMA tidak akurat.

TABEL 3
HASIL PENANGANAN PENCILAN OLEH PACKAGE “TSOUTLIERS”

No	Index	Koefisien/ Amplitudo	Harga Penutupan Saham Sebelum Penanganan	Harga Penutupan Saham Setelah Penanganan
1	359	12,9	179,4	166,5
2	382	-10,8	137,6	148,4
3	406	-14,3	138,4	152,7
4	449	11,1	189,5	178,4
5	490	15,6	212,5	196,9
6	493	15,7	226,3	195,0


Identifikasi pencilan yang dilakukan oleh *package* “tsoutliers”, dilanjutkan dengan melakukan penanganan. *Package* ini melakukan penanganan dengan cara menghapus efek yang sebelumnya telah diestimasi dengan memanfaatkan model ARIMA. Efek atau pengaruh pencilan terhadap data diukur terlebih dahulu dan menjadi bagian dari nilai koefisien (amplitudo). Tabel 3 menunjukkan hasil penanganan terhadap pencilan. Setelah keenam pencilan tertangani, dibentuk *dataset* baru untuk hasil penanganannya sehingga terbentuk dua *dataset* yaitu *dataset* dengan pencilan dan *dataset* dengan pencilan yang telah tertangani. Gambar 4(a) dan 4(b) menunjukkan perbedaan pola data deret waktu pada kedua *dataset*.




Gambar 4. (a) Plot data deret waktu *dataset* dengan pencilan dan (b) Plot data deret waktu *dataset* dengan pencilan tertangani

3) Pembagian data latih dan data uji

Berdasarkan Gambar 2, terlihat perubahan pola tren menjadi konstan yang terjadi pada tahun 2020 hingga 2022. Pada selang ini, dilakukan pembagian data penuh menjadi dua bagian, data latih dan data uji. Pembagian data didasarkan pada perubahan pola dan dilakukan pada indeks saat data tidak mengalami kenaikan dan penurunan secara signifikan. Pada indeks 360, tidak terjadi penurunan dan kenaikan harga penutupan saham AAPL sehingga selang indeks 1 hingga 360 dipilih menjadi bagian data latih dan selang indeks 361 hingga 500 dipilih menjadi bagian data uji. Proses pembagian data ini menjadikan data penuh terbagi dengan perbandingan 72:28 dengan 72% bagian awal dari data penuh menjadi data latih dan 28% bagian akhir menjadi data uji. Pendekatan ini diterapkan pada kedua *dataset*, yakni *dataset* dengan pencilan dan *dataset* dengan pencilan tertangani.



Gambar 5. (a). Plot deret waktu data latih; (b). Plot deret waktu data uji dari *dataset* dengan pencilan




Gambar 6. (a). Plot deret waktu data latih; (b). Plot deret waktu data uji dari *dataset* dengan pencilan tertangani

B. Pemodelan dengan Metode Konvensional ARIMA

1) Identifikasi dan penanganan kestasioneran data

ARIMA merupakan metode yang digunakan untuk menghasilkan prediksi berdasarkan pola data historis melalui proses sintesis [17]. Metode pemodelan ARIMA mengharuskan data latih bersifat stasioner baik dalam rata-rata maupun dalam ragam. Berdasarkan Gambar 5(a), terlihat bahwa terjadi volatilitas pada data latih. Plot tersebut menunjukkan harga penutupan saham AAPL menyebar dengan pola tren yang menandakan data latih tidak menyebar pada suatu nilai rata-rata tertentu. Selain itu, gejala volatilitas yang terjadi menunjukkan lebar pita yang tidak konsisten pada awal hingga akhir data latih. Bentuk sebaran data yang mengikuti pola tren dan lebar pita yang tidak konsisten mengindikasikan bahwa data latih harga penutupan saham AAPL dengan pencilan tidak stasioner baik dalam rata-rata maupun dalam ragam. Hal serupa juga terlihat pada Gambar 6(a) yang mengindikasikan data latih harga penutupan saham AAPL dengan pencilan tertangani juga tidak stasioner dalam rata-rata dan ragam. Gambar 5(b) dan 6(b) menunjukkan bahwa data uji pada kedua *dataset* tidak stasioner karena lebar pita yang tidak konsisten dan menyebar mengikuti pola gabungan. Data yang mengandung unsur tren berarti tidak stasioner dalam rata-rata maupun ragam [18].




Gambar 7. (a). Plot ACF *dataset* dengan pencilan; (b). Plot ACF *dataset* dengan pencilan tertangani

Pemeriksaan kestasioneran data latih dari kedua *dataset* dilanjutkan dengan eksplorasi plot ACF. Gambar 7(a) dan 7(b) menunjukkan plot ACF yang turun secara lambat (*tails-off slowly*). Hal ini mengindikasikan data latih pada kedua *dataset* tidak stasioner dalam rata-rata. Selain melalui eksplorasi plot data latih dan plot ACF, pemeriksaan kestasioneran data juga dilakukan melalui uji formal, yakni uji ADF. Tabel 4 menunjukkan hasil uji ADF yang dilakukan pada kedua *dataset* menghasilkan *p-value* yang melebihi taraf nyata 5%. Hal ini mengindikasikan tak cukup bukti untuk menolak hipotesis nol yakni data tidak stasioner dalam rata-rata. Hasil uji formal selaras dengan eksplorasi plot deret waktu dan plot ACF. Berdasarkan Tabel 4, uji formal *Box-Cox* sebelum transformasi pada kedua *dataset* menghasilkan selang nilai lambda yang tidak memuat nilai $\lambda=1$. Hal ini mengindikasikan kedua *dataset* tidak stasioner dalam ragam.

TABEL 4
HASIL PENGUJIAN STASIONERITAS RATAAN DAN RAGAM

	Sebelum differencing	Setelah differencing	Sebelum Transformasi Box-cox			Setelah Transformasi Box-Cox	
	<i>p-value ADF</i>	<i>p-value ADF</i>	Batas bawah λ	Batas atas λ	λ optimum	Batas bawah λ	Batas atas λ
Dataset dengan pencilan	0,9836	< 0,01	-0,7878	-0,5454	-0,667	0,7878	1,0909
Dataset dengan pencilan tertangani	0,9838	< 0,01	-0,7474	-0,5454	-0,667	0,7878	1,0909

Penanganan atas ketidakstasioneran data latih dilakukan dengan melakukan transformasi dan differencing. Ketidakstasioneran kedua dataset dalam ragam ditangani dengan melakukan transformasi Box-Cox pada masing-masing dataset. Transformasi Box-Cox dilakukan dengan cara memangkatkan amatan pada data latih dengan nilai lambda optimum. Tabel 4 menunjukkan hasil Transformasi Box-Cox pada data latih yang menunjukkan selang lambda telah memuat nilai $\lambda=1$. Hal ini mengindikasikan bahwa data latih dari kedua dataset telah stasioner dalam ragam.

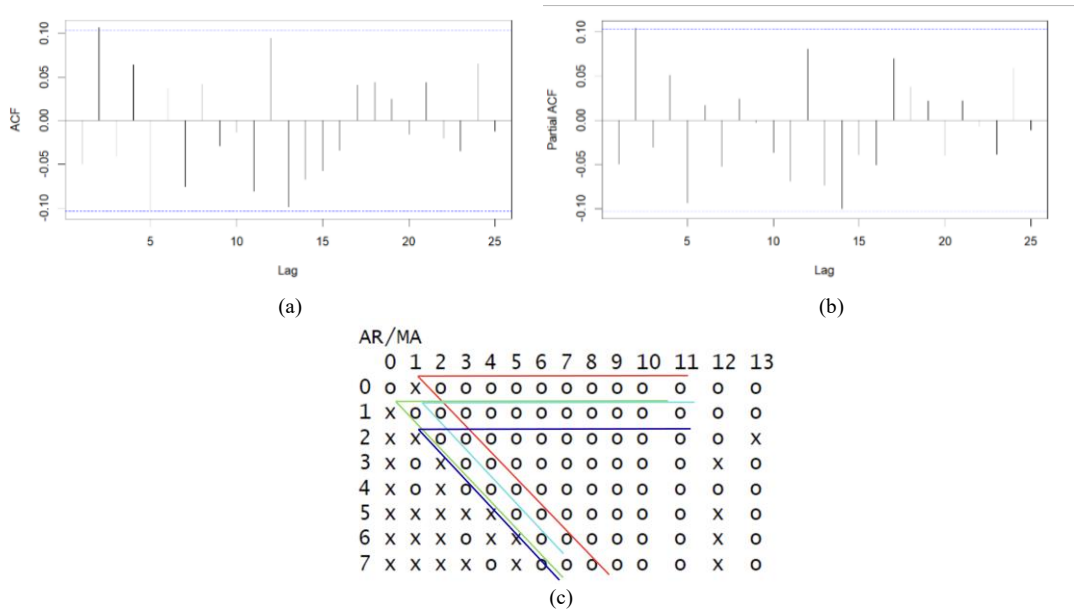


Gambar 8. (a). Plot deret waktu dataset dengan pencilan setelah differencing; (b). Plot deret waktu dataset dengan pencilan tertangani setelah differencing

Penanganan terhadap ketidakstasioneran data latih dari kedua dataset dalam rataa dilakukan dengan melakukan differencing sebanyak satu kali. Gambar 8(a) dan (b) menunjukkan amatan dari kedua dataset telah menyebar pada nilai tengah tertentu yang mengindikasikan kedua dataset telah stasioner dalam ragam. Berdasarkan Tabel 4, uji formal ADF setelah dilakukan differencing juga menunjukkan *p-value* yang kurang dari taraf nyata 5%. Hal ini mengindikasikan cukup bukti untuk menolak hipotesis nol yang berarti data stasioner dalam ragam.

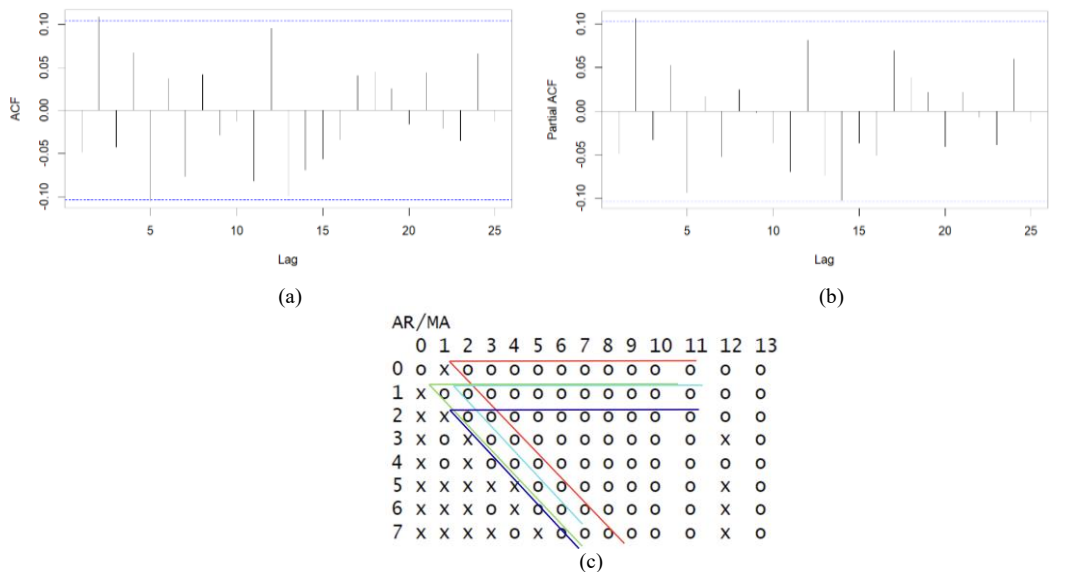
2) Identifikasi model

Penentuan model tentatif dilakukan dengan eksplorasi plot autocorrelation function (ACF), partial autocorrelation function (PACF), dan extended autocorrelation function (EACF). Eksplorasi yang dilakukan terhadap plot-plot tersebut akan memberikan informasi mengenai ordo pada model AR(*p*) dan MA(*q*). Berdasarkan Gambar 9(a) dan 9(b), pada dataset dengan pencilan didapati plot ACF dan PACF keduanya mengalami tails-off. Gambar 9(c) menunjukkan bahwa segitiga bulat yang dapat terbentuk pada plot EACF menghasilkan model tentatif yang beberapa di antaranya adalah ARIMA(0,1,2), ARIMA(1,1,1), ARIMA(1,1,2), dan ARIMA(2,1,2).



Gambar 9 (a). Plot ACF ; (b). Plot PACF; (c). Plot EACF *dataset* dengan pencilan setelah *differencing*

Berdasarkan Gambar 10(a) dan 10(b), pada *dataset* dengan pencilan tertangani didapati plot ACF dan PACF keduanya mengalami *tails-off*. Plot ACF dan PACF dari *dataset* ini sekilas mirip dengan plot ACF dan PACF *dataset* dengan pencilan. Plot EACF pada Gambar 10(c) juga hanya menunjukkan sedikit perbedaan dengan plot EACF *dataset* dengan pencilan. Gambar 10(c) menunjukkan bahwa model tentatif yang dapat terbentuk dari plot EACF adalah ARIMA(0,1,2), ARIMA(1,1,1), ARIMA(1,1,2), dan ARIMA(2,1,2).



Gambar 10.(a). Plot ACF ; (b). Plot PACF; (c). Plot EACF *dataset* dengan pencilan tertangani setelah *differencing*

Berdasarkan Tabel 5, didapati model terbaik bagi *dataset* dengan pencilan adalah ARIMA(1,1,1). Model ARIMA terbaik diperoleh dengan cara melihat signifikansi dari parameter-parameter yang dimiliki model dan nilai AIC terkecil. ARIMA(1,1,1) memiliki nilai AIC paling kecil jika dibandingkan dengan nilai AIC model tentatif lainnya. Selain itu, ARIMA(1,1,1) juga memiliki parameter yang semuanya signifikan pada taraf nyata 5%. Pendekatan serupa juga dilakukan untuk mengevaluasi model tentatif dari *dataset* dengan pencilan tertangani. Tabel 5 menunjukkan bahwa ARIMA(1,1,1) merupakan model terbaik karena memiliki nilai AIC terkecil dan parameter-parameter yang signifikan pada taraf nyata 5%. Berdasarkan hal ini, didapati ARIMA(1,1,1) merupakan model terbaik sementara bagi *dataset* dengan pencilan dan *dataset* dengan pencilan tertangani.

TABEL 5
HASIL ESTIMASI PARAMETER DAN UJI SIGNIFIKANSI MODEL TENTATIF PADA KEDUA DATASET

	Model	Parameter	Pr(> z)	Signifikansi (Taraf Nyata 5%)	AIC	
Dataset dengan pencilan	ARIMA(0,1,2)	MA(1)	0,53726	Tidak signifikan	-3432,79	
		MA(2)	0,03983	Signifikan		
	ARIMA(1,1,1)	AR(1)	$< 2,2 \times 10^{-16}$	Signifikan	-3436,08	
		MA(1)	$< 2,2 \times 10^{-16}$	Signifikan		
	ARIMA(1,1,2)	AR(1)	$< 2,2 \times 10^{-16}$	Signifikan	-3435	
		MA(1)	$< 2,2 \times 10^{-16}$	Signifikan		
	ARIMA(2,1,2)	AR(1)	MA(2)	0,3334	Tidak signifikan	-3433,65
			AR(1)	0,3810	Tidak signifikan	
			AR(2)	0,1344	Tidak signifikan	
			MA(1)	0,4223	Tidak signifikan	
	Dataset dengan pencilan tertangani	ARIMA(0,1,2)	MA(1)	0,55579	Tidak signifikan	-3434,15
			MA(2)	0,03767	Signifikan	
ARIMA(1,1,1)		AR(1)	$< 2,2 \times 10^{-16}$	Signifikan	-3437,56	
		MA(1)	$< 2,2 \times 10^{-16}$	Signifikan		
ARIMA(1,1,2)		AR(1)	$< 2,2 \times 10^{-16}$	Signifikan	-3436,58	
		MA(1)	$< 2,2 \times 10^{-16}$	Signifikan		
ARIMA(2,1,2)		AR(1)	MA(2)	0,30200	Tidak signifikan	-3436,52
			AR(1)	0,36504	Tidak signifikan	
			AR(2)	0,32007	Tidak signifikan	
			MA(1)	0,40362	Tidak signifikan	
			MA(2)	0,40200	Tidak signifikan	

3) Diagnostik model

Diagnostik model selanjutnya dilakukan pada model terbaik sementara yang telah diperoleh. Analisis sisaan untuk memeriksa kebebasan dan kenormalan sisaan menjadi dasar pada diagnostik model [19]. Analisis sisaan juga dilakukan untuk memeriksa heteroskedastisitas sisaan dan nilai tengah sisaan sama dengan nol. Berdasarkan Tabel 6, model terbaik sementara ARIMA(1,1,1) pada kedua *dataset* memiliki hasil diagnostik yang sama. Uji Kolmogorov-Smirnov yang dilakukan untuk menguji normalitas sisaan menghasilkan kesimpulan tak-tolak hipotesis nol pada kedua *dataset* dan mengindikasikan bahwa sisaan tidak menyebar normal. Uji Box-Ljung yang dilakukan untuk menguji sisaan saling bebas dan heteroskedastisitas sisaan menghasilkan kesimpulan tak-tolak hipotesis nol pada kedua *dataset* dan mengindikasikan tidak terdapat autokorelasi pada sisaan dan sisaan menyebar homogen pada kedua model. *T-test* yang dilakukan untuk menguji nilai tengah sisaan sama dengan nol juga menghasilkan hasil kesimpulan tak-tolak hipotesis nol dan mengindikasikan bahwa nilai tengah sisaan sama dengan nol.

TABEL 6
HASIL UJI FORMAL TIAP ASUMSI SISAAN

Model terbaik sementara	Asumsi sisaan			
	Sisaan menyebar normal	Sisaan saling bebas	Sisaan menyebar homogen	Nilai tengah sisaan sama dengan nol
	<i>P-value</i> Uji Kolmogorov-Smirnov	<i>P-value</i> Uji Box-Ljung	<i>P-value</i> Uji Box-Ljung	<i>P-value</i> T-test
ARIMA(1,1,1) dataset dengan pencilan	$< 2,2 \times 10^{-16} *$	0,5296	0,2493	0,9987
ARIMA(1,1,1) dataset dengan pencilan tertangani	$< 2,2 \times 10^{-16} *$	0,5005	0,2434	0,9986

*Signifikan pada taraf nyata 5% (tolak hipotesis nol)

Hasil diagnostik model berdasarkan analisis sisaan menunjukkan asumsi-asumsi yang terpenuhi antara lain asumsi sisaan saling bebas, sisaan menyebar homogen, dan nilai tengah sisaan sama dengan nol. Tabel 6 menunjukkan bahwa terdapat satu asumsi yang tidak terpenuhi yaitu asumsi sisaan menyebar normal. Berdasarkan teorema limit pusat, asumsi kenormalan dalam penelitian ini dapat dianggap terpenuhi karena banyaknya data yang diamati cukup besar [20]. Model ARIMA(1,1,1) memenuhi tiga dari empat asumsi sisaan dan satu sisaan yang tidak terpenuhi dapat dianggap terpenuhi berdasarkan teorema limit pusat. Hal ini memastikan bahwa model ARIMA(1,1,1) merupakan model terbaik bagi dataset dengan pencilan dan dataset dengan pencilan tertangani.

4) Overfitting model

Model ARIMA(1,1,1) yang sudah dipastikan sebagai model terbaik bagi dataset dengan pencilan dan dataset dengan pencilan tertangani selanjutnya dilakukan *overfitting*. *Overfitting* dilakukan dengan menambahkan ordo p dan q secara bergantian dari model terbaik awal untuk mencari model yang lebih baik dibandingkan model terbaik awal yang telah teridentifikasi [21]. Tabel 7 menunjukkan bahwa hasil *overfitting* model ARIMA(1,1,1) pada kedua dataset terdapat parameter yang tidak signifikan pada taraf nyata 5% di masing-masing model yang terbentuk. Berdasarkan hal ini, model hasil *overfitting* tidak lebih baik dibandingkan model terbaik awal sehingga ARIMA(1,1,1) masih menjadi model terbaik bagi dataset dengan pencilan dan dataset dengan pencilan tertangani.

TABEL 7
HASIL ESTIMASI PARAMETER DAN UJI SIGNIFIKANSI MODEL OVERFITTING KEDUA DATASET

Dataset	Model	Parameter	<i>P-value</i>	Signifikansi (Taraf Nyata 5%)	AIC
Dataset dengan pencilan	ARIMA(2,1,1)	AR(1)	$1,472 \times 10^{-11}$	Signifikan	-3436,6
		AR(2)	0,41939	Tidak signifikan	
		MA(1)	$1,090 \times 10^{-12}$	Signifikan	
	ARIMA(1,1,2)	AR(1)	$< 2 \times 10^{-16}$	Signifikan	
		MA(1)	$< 2 \times 10^{-16}$	Signifikan	
		MA(2)	0,43357	Tidak signifikan	
Dataset dengan pencilan tertangani	ARIMA(2,1,1)	AR(1)	$9,405 \times 10^{-12}$	Signifikan	-3438,24
		AR(2)	0,38384	Tidak signifikan	
		MA(1)	$5,062 \times 10^{-13}$	Signifikan	
	ARIMA(1,1,2)	AR(1)	$< 2 \times 10^{-16}$	Signifikan	
		MA(1)	$< 2 \times 10^{-16}$	Signifikan	
		MA(2)	0,40340	Tidak signifikan	

5) Pengukuran kebaikan model

Kebajikan model ARIMA(1,1,1) diukur melalui nilai MAPE. MAPE merupakan metode yang digunakan untuk menghitung akurasi. Metode ini disebut lebih akurat dan lebih sederhana untuk dipelajari jika dibandingkan dengan metode lainnya. Semakin baik kemampuan suatu model dalam melakukan peramalan ditandai dengan semakin kecilnya nilai MAPE [22]. Penelitian ini mengukur kebaikan model berdasarkan dua nilai MAPE yaitu MAPE latih dan MAPE uji.

MAPE latih didapatkan dengan menghitung *fitted value* data latih dan membandingkannya dengan nilai aktual data latih. MAPE uji didapatkan dengan meramalkan 140 nilai data uji menggunakan model terbaik dan mentransformasi balik kemudian membandingkan hasilnya dengan nilai aktual data uji yang juga sebanyak 140 amatan. Nilai MAPE latih dan MAPE uji dari metode ARIMA disajikan pada Tabel 8. Pengukuran kebaikan model ARIMA(1,1,1) dalam memperoleh nilai *fitted value* data latih dan peramalan data uji pada kedua *dataset* menghasilkan nilai MAPE yang seluruhnya di bawah 10%. Suatu model dengan nilai MAPE di bawah 10% dapat dikategorikan model yang sangat baik dalam melakukan peramalan.

TABEL 8
MAPE DATA LATIH DAN DATA UJI METODE ARIMA DARI KEDUA *DATASET*

<i>Dataset</i>	Latih	Uji
<i>Dataset</i> dengan pencilan	1,806	10,379
<i>Dataset</i> dengan pencilan tertangani	1,839	9,337

C. Penerapan Metode Deep Learning LSTM

LSTM merupakan salah satu teknik dalam pengembangan jaringan saraf tipe *Recurrent Neural Network* (RNN) yang diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997 [23]. Metode LSTM membutuhkan beberapa parameter yang harus didefinisikan terlebih dahulu. Penentuan parameter yang digunakan pada metode LSTM tidak memiliki aturan baku untuk diterapkan pada sistem [24].

TABEL 9
MAPE DATA LATIH DAN DATA UJI METODE LSTM DARI KEDUA *DATASET*

<i>Dataset</i>	<i>Learning rate</i>	Latih	Uji
<i>Dataset</i> dengan pencilan	0,01	5,83	9,25
	0,001	4,43	4,46
	0,0001	5,68	5,44
<i>Dataset</i> dengan pencilan tertangani	0,01	7,95	4,74
	0,001	6,83	4,28
	0,0001	5,18	5,53

Kombinasi parameter yang dipilih untuk melakukan metode LSTM seperti yang ditunjukkan oleh Tabel 1 diterapkan pada *dataset* dengan pencilan dan *dataset* dengan pencilan tertangani. Pembagian data latih dan data uji pada metode LSTM ini dilakukan serupa seperti pada metode ARIMA. Jenis LSTM yang digunakan *Stacked LSTM* dengan menggunakan dua *layers*. Kebaikan dari metode LSTM ditunjukkan oleh MAPE pada Tabel 9. Nilai learning rate 0,001 dipilih sebagai nilai terbaik bagi *dataset* dengan pencilan tertangani karena memiliki nilai MAPE uji terkecil.

D. Perbandingan MAPE Pemodelan ARIMA dan LSTM

Berdasarkan Tabel 10, didapati terdapat selisih yang cukup besar pada MAPE data latih dan data uji yang dihasilkan oleh metode ARIMA baik pada *dataset* dengan pencilan maupun pada *dataset* dengan pencilan tertangani. Berbeda dengan metode ARIMA, selisih MAPE data latih dan data uji yang dihasilkan oleh metode LSTM sangat kecil. Selisih MAPE data latih dan data uji yang terlampaui jauh pada metode ARIMA dapat terjadi karena adanya *overfitting* model pada pola data latih dan terdapat perbedaan pola pada data latih dan data uji. Pola data saham AAPL yang tidak stabil dan adanya pencilan menjadikan metode ARIMA menghasilkan model yang kurang tergeneralisasi. *Overfitting* ini dapat disebabkan oleh dua faktor utama yakni keterbatasan ARIMA dalam menangani data non-stasioner dan berpola tidak menentu seperti data saham, dan sensitivitas ARIMA terhadap pencilan sehingga dapat terjadi distorsi estimasi parameter dan struktur model. Model ARIMA yang kurang tergeneralisasi ditandai dengan ketidakmampuan untuk menangkap pola jangka panjang dengan baik, sehingga didapati penurunan MAPE uji yang cukup drastis.

Berbeda dengan ARIMA, model LSTM menunjukkan performa yang jauh lebih stabil dengan selisih MAPE latih dan MAPE uji yang sangat kecil. Tabel 10 menunjukkan bahwa model LSTM menghasilkan nilai MAPE yang lebih baik. LSTM cenderung bekerja lebih baik pada data yang fluktuatif dengan komponen yang tidak stabil [25]. Hal ini mengindikasikan bahwa model LSTM berhasil mempelajari pola umum dalam data tanpa terjebak pada *noise* atau fluktuasi jangka pendek. Kemampuan LSTM untuk menangani ketergantungan jangka panjang dan menyimpan informasi penting dalam sel memori internalnya memungkinkan model ini untuk lebih adaptif terhadap perubahan pola yang bersifat dinamis dan tidak linear.

TABEL 10
PERBANDINGAN MAPE DATA LATIH DAN DATA UJI PADA METODE ARIMA DAN LSTM DARI KEDUA *DATASET*

<i>Dataset</i>	Metode	Latih	Uji
Dataset dengan pencilan	ARIMA	1,81	10,38
	LSTM	4,43	4,46
Dataset dengan pencilan tertangani	ARIMA	1,84	9,34
	LSTM	6,83	4,28

IV. SIMPULAN

Data harga saham AAPL menunjukkan tren naik selama 26 Januari 2015 hingga 19 Agustus 2024 dengan enam pencilan terdeteksi melalui metode Tsay. Model ARIMA terbaik untuk data dengan pencilan maupun pencilan tertangani adalah model ARIMA (1,1,1). Model tersebut menghasilkan performa lebih baik dengan pencilan tertangani. Namun, jika dibandingkan dengan LSTM, LSTM menjadi model yang lebih baik. Hal ini ditunjukkan dengan nilai MAPE yang lebih kecil, terutama pada data pencilan tertangani. Hal ini disebabkan oleh arsitektur LSTM yang dirancang untuk mengenali pola kompleks dan menangkap hubungan jangka panjang pada data deret waktu, seperti volatilitas harga saham. ARIMA yang mengandalkan asumsi linearitas dan ketergantungan jangka pendek memiliki keterbatasan dalam memodelkan fluktuasi dinamis pada data saham. Penanganan pencilan lebih lanjut meningkatkan performa LSTM karena pencilan yang dibiarkan dapat mendistorsi pola data, menyebabkan ketidaktepatan prediksi, terutama pada metode berbasis statistik seperti ARIMA. Hasil ini menegaskan bahwa metode LSTM lebih unggul dalam mengatasi data saham yang kompleks dan tidak stasioner. Penelitian ini masih memiliki ruang untuk dikembangkan lebih lanjut. Saran yang dapat diberikan adalah penggunaan model *deep learning* lain yang lebih kompleks seperti GRU (*Gated Recurrent Unit*), *Bidirectional LSTM*, dan lain sebagainya dalam memodelkan data saham AAPL.

DAFTAR PUSTAKA

- [1] M. I. Rizki, T. Ammar, F. Fitriyani, and S. Fasya, "Peramalan Indeks Harga Saham PT Verena Multi Finance Tbk Dengan Metode Pemodelan ARIMA Dan ARCH-GARCH," *J Statistika: Jurnal Ilmiah Teori dan Aplikasi Statistika*, vol. 14, no. 1, pp. 11–23, 2021.
- [2] W. D. Sugianto, A. M. Soleh, and F. M. Afendi, "Forecasting Simulation with ARIMA and Combination of Stevenson-Porter-Cheng Fuzzy Time Series," *International Journal of Computer Science and Network*, vol. 6, no. 6, pp. 806–811, 2017.
- [3] Y. A. Nugroho and H. A. Hutahaean, "Pengembangan Model Deep Learning LSTM dan CNN untuk Peramalan Penjualan Sepeda Motor di Indonesia," *Jupiter: Publikasi Ilmu Keteknikan Industri, Teknik Elektro dan Informatika*, vol. 3, no. 2, pp. 94–104, 2025.
- [4] S. Aisyah, Y. Angraini, K. Sadik, B. Sartono, and G. A. Dito, "Technical Analysis of the Indonesian Stock Market with Gated Recurrent Unit and Temporal Convolutional Network," *JUITA: Jurnal Informatika*, pp. 187–196, 2024.
- [5] A. D. Milniadi and N. O. Adiwijaya, "ANALISIS PERBANDINGAN MODEL ARIMA DAN LSTM DALAM PERAMALAN HARGA PENUTUPAN SAHAM (STUDI KASUS : 6 KRITERIA KATEGORI SAHAM MENURUT PETER LYNCH)," *SIBATIK JOURNAL: Jurnal Ilmiah Bidang Sosial, Ekonomi, Budaya, Teknologi, dan Pendidikan*, vol. 2, no. 6, pp. 1683–1692, 2023.
- [6] D. A. Rezaldi and S. Sugiman, "Peramalan metode ARIMA data saham PT. Telekomunikasi Indonesia," *PRISMA: Prosiding Seminar Nasional Matematika*, vol. 4, pp. 611–620, 2021.
- [7] G. Budiprasetyo, M. Hani'ah, and D. Z. Aflah, "Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM)," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 8, no. 3, pp. 164–172, 2022.
- [8] R. S. Tsay, "Time Series Model Specification in the Presence of Outliers," *J. Am. Stat. Assoc.*, vol. 81, no. 393, pp. 132–141, 1986.
- [9] R. Arianti, S. Sahrman, and L. P. Talanko, "Model ARIMA dengan Variabel Eksogen dan GARCH pada Data Kurs Rupiah," *ESTIMASI: Journal of Statistics and Its Application*, vol. 3, no. 1, pp. 41–48, 2022.
- [10] S. Aktivani, "Uji Stasioneritas Data Inflasi Kota Padang Periode 2014-2019," *Jurnal Statistika Industri dan Komputasi*, vol. 6, no. 1, pp. 26–33, 2021.
- [11] M. Ulinnuha, F. M. Afendi, and I. M. Sumertajaya, "Study of Clustering Time Series Forecasting Model for Provincial Grouping in Indonesia Based on Rice Price," *Indonesian Journal of Statistics and Its Applications (IJSIA)*, vol. 6, no. 1, pp. 50–62, 2022.
- [12] A. F. Syalsabilla, S. Astutik, and A. F. Rozy, "Optimalisasi Prediksi Harga Ihsng Menggunakan Hybrid Weighted Fuzzy Time Series Hidden Markov Model Dengan Algoritma Evolusi Differensial," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 4, pp. 837–844, 2024.

- [13] A. Hanafiah, Y. Arta, H. O. Nasution, and Y. D. Lestari, "Penerapan Metode Recurrent Neural Network dengan Pendekatan Long Short-Term Memory (LSTM) Untuk Prediksi Harga Saham," *Bulletin of Computer Science Research*, vol. 4, no. 1, pp. 27–33, 2023.
- [14] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," in *3rd International Conference on Learning Representations (ICLR)*, Y. Bengio and Y. LeCun, Eds., San Diego, CA, 2015.
- [15] G. K. Vishwakarma, C. Paul, and A. M. Elsayah, "An algorithm for outlier detection in a time series model using backpropagation neural network," *J. King Saud Univ. Sci.*, vol. 32, no. 8, pp. 3328–3336, 2020.
- [16] C. Chen and L.-M. Liu, "Joint Estimation of Model Parameters and Outlier Effects in Time Series," *J. Am. Stat. Assoc.*, vol. 88, no. 421, pp. 284–297, 1993.
- [17] N. Kalchbrenner, I. Danihelka, and A. Graves, "Grid Long Short-Term Memory," 2016, *arXiv*. Accessed: Sep. 16, 2025. [Online]. Available: <https://arxiv.org/abs/1507.01526v3>
- [18] M. Al Haris, N. Intan, and P. R. Arum, "Peramalan Tingkat Inflasi di Indonesia dengan Metode ARIMA-GARCH Berdasarkan Optimasi Kalman Filter," in *PROSIDING SEMINAR NASIONAL SAINS DATA*, 2024, pp. 568–580.
- [19] R. Mulyani, Y. P. Sari, and Sumantriyadi, "Forecasting Produksi Perikanan Budidaya Di Kota Palembang Dengan Metode Autoregressive Integrated Moving Average (ARIMA)," *Sainmatika: Jurnal Ilmiah Matematika dan Ilmu Pengetahuan Alam*, vol. 19, no. 2, pp. 163–174, 2022.
- [20] N. S. Maharani *et al.*, "Aplikasi Model Arima Garch Dalam Peramalan Data Nilai Tukar Rupiah Terhadap Dolar Tahun 2017-2022," *Jurnal Matematika Sains dan Teknologi*, vol. 24, no. 1, pp. 37–50, 2023.
- [21] A. Iswari, Y. Angraini, and M. Masjkur, "Comparison of The SARIMA Model and Intervention in Forecasting The Number of Domestic Passengers at Soekarno-Hatta International Airport," *Indonesian Journal of Statistics and Its Applications (IJSIA)*, vol. 6, no. 1, pp. 132–146, 2022.
- [22] T. Prasetyo, R. A. Putri, D. Ramadhani, Y. Angraini, and K. A. Notodiputro, "Perbandingan Kinerja Metode Arima, Multi-Layer Perceptron, dan Random Forest dalam Peramalan Harga Logam Mulia Berjangka yang Mengandung Pencilan," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 2, pp. 265–274, 2024.
- [23] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [24] A. Rahmadeyan and Mustakim, "Long Short-Term Memory and Gated Recurrent Unit for Stock Price Prediction," *Procedia Comput. Sci.*, vol. 234, pp. 204–212, 2024.
- [25] R. Zhang, H. Song, Q. Chen, Y. Wang, S. Wang, and Y. Li, "Comparison of ARIMA and LSTM for prediction of hemorrhagic fever at different time scales in China," *PLoS One*, vol. 17, no. 1, p. e0262009, 2022.