

PERBANDINGAN PERFORMA ARIMAX-GARCH DAN LSTM PADA DATA HARGA PENUTUPAN SAHAM PT ANEKA TAMBANG TBK (ANTM.JK)

Dhiya Khalishah Tsany Suwarso¹, Akbar Rizki^{*2}, Salsabila Dwi Rahmi³, Hakim Zoelva Mahesa⁴, Windi Gunawan⁵, Zafira Ilma Fitri⁶, Yenni Anggraini⁷, Adelia Putri⁸, Muhammad Rizky Nurhambali⁹

^{1,2,3,4,5,6,7,8,9}Institut Pertanian Bogor, Bogor

Email: ¹dhiyakhalishah@apps.ipb.ac.id, ^{*2}akbar.rizki@apps.ipb.ac.id, ³salsabiladwi@apps.ipb.ac.id, ⁴hakimahesazoelva@apps.ipb.ac.id, ⁵29wndigunawan@apps.ipb.ac.id, ⁶fzafirailma@apps.ipb.ac.id, ⁷y_anggraini@apps.ipb.ac.id, ⁸adelia_pangestika@apps.ipb.ac.id, ⁹rizkynurhambali@apps.ipb.ac.id

^{*}Penulis Korespondensi

(Naskah masuk: 20 November 2024, diterima untuk diterbitkan: 28 Mei 2025)

Abstrak

Banyaknya data deret waktu dengan pola nonlinear dan memiliki volatilitas tinggi pada berbagai sektor membuat sulit untuk melakukan pemodelan klasik seperti *Autoregressive Integrated Moving Average* (ARIMA). Permasalahan ini dapat diatasi salah satunya dengan mengembangkan metode *Autoregressive Integrated Moving Average with Exogenous- Generalized Autoregressive Conditional Heteroskedasticity* (ARIMAX-GARCH) yang memanfaatkan kovariat eksternal, sehingga memberikan solusi lebih baik pada data yang tidak stasioner. Di sisi lain, metode deep learning seperti *Long Short-Term Memory* (LSTM) unggul dalam menangkap pola non-linear dan dependensi jangka panjang. Oleh karena itu, penelitian ini membandingkan performa ARIMAX-GARCH dan LSTM dalam memprediksi harga saham PT Aneka Tambang Tbk (ANTM.JK). Data mingguan penutupan harga saham ANTM.JK periode 1 Januari 2018 hingga 30 Oktober 2023 digunakan dalam penelitian ini. Pemodelan ARIMAX-GARCH dengan peubah kovariat berupa data harga nikel berjangka dunia digunakan karena terdapat pengaruh signifikan harga nikel terhadap harga penutupan saham ANTM.JK dan terdeteksi adanya heteroskedastisitas dalam model. Metode berbasis *machine learning*, LSTM digunakan karena metode ini dikenal memiliki akurasi prediksi yang baik. Pengolahan data dilakukan menggunakan bantuan *software* R-Studio dan Python. Hasil penelitian menunjukkan LSTM memiliki performa yang lebih baik dengan nilai MAPE sebesar 4,425%, nilai ini lebih kecil jika dibandingkan model terbaik ARIMAX(2,1,2)-GARCH(1,1) dengan MAPE 7,326%.

Kata kunci: ANTM.JK, ARIMAX, GARCH, LSTM, saham

COMPARISON OF ARIMAX-GARCH AND LSTM PERFORMANCE ON PT ANEKA TAMBANG TBK (ANTM.JK) STOCK CLOSING PRICE DATA

Abstract

The large number of time series data with nonlinear patterns and high volatility in various sectors makes it difficult to perform classical modeling such as *Autoregressive Integrated Moving Average* (ARIMA). This problem can be overcome by developing the ARIMA with *Exogenous- Generalized Autoregressive Conditional Heteroskedasticity* (ARIMAX-GARCH) that utilizes external covariates, thus providing a better solution to non-stationary data. On the other hand, deep learning methods such as *Long Short-Term Memory* (LSTM) excel in capturing non-linear patterns and long-term dependencies. Therefore, this study compares the performance of ARIMAX-GARCH and LSTM in predicting the stock price of PT Aneka Tambang Tbk (ANTM.JK). Weekly closing data of ANTM.JK stock price from January 1, 2018 to October 30, 2023 are used in this study. ARIMAX-GARCH modeling with covariate variables in the form of world nickel futures price data is used because there is a significant effect of nickel prices on the closing price of ANTM.JK shares and heteroscedasticity is detected in the model. Machine learning-based method, LSTM is used because this method is known to have good prediction accuracy. Data processing is done using R-Studio and Python software. The results show that LSTM has better performance with a MAPE value of 4.425%, this value is smaller than the best model ARIMAX(2,1,2)-GARCH(1,1) with a MAPE of 7.326%.

Keywords: ANTM.JK, ARIMAX, GARCH, LSTM, stock

1. PENDAHULUAN

Data deret waktu, merupakan sekumpulan amatan yang terkumpul secara kronologis. Dalam

aplikasinya, analisis data deret waktu digunakan untuk menghasilkan ramalan yang menjadi landasan dalam pengambilan keputusan terhadap kejadian yang akan datang (Montgomery, Jennings & Kulahci,

2015). Tidak hanya sekadar ramalan, analisis deret waktu digunakan pula untuk memahami perilaku data serta menjelaskan hubungan antaramatan dari waktu ke waktu (Juanda and Junaidi, 2012). Berbagai metode klasik tengah banyak berkembang untuk memodelkan data deret waktu, diantaranya adalah metode *Autoregressive Moving Average* (ARMA) yang dinilai mampu menjelaskan perilaku data deret waktu dengan baik dalam kondisi standar (kondisi data stasioner dan linear) (Cryer and Chan, 2008). Pada kondisi data yang tidak stasioner prosedur *differencing* dapat dilakukan, yang membawa metode ini berkembang pada metode *Autoregressive Integrated Moving Average* (ARIMA) (Prasetyo et al., 2024). Namun demikian, seringkali model ARIMA tidak mampu menjelaskan data dengan fluktuasi yang tinggi akibat adanya kondisi heteroskedastisitas, sehingga dikembangkan metode *Autoregressive Conditional Heteroskedasticity* (ARCH) dan *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) untuk mengatasi perubahan ragam pada jangka waktu tertentu (Jannah, 2021). Selain itu fluktuasi atau ketidakstabilan yang disebabkan karena adanya variabilitas yang berubah-ubah juga dapat ditangani dengan metode *Autoregressive Integrated Moving Average with Exogenous Variable* (ARIMAX). Metode ARIMAX dikembangkan dalam upaya menangani inklusi peubah-peubah kovariat yang dapat memengaruhi seri waktu yang tidak dapat ditangani oleh ARIMA (Hidayat and Hakim, 2021).

Saat ini, metode peramalan deret waktu semakin berkembang, tidak hanya mengandalkan metode klasik, tetapi juga memanfaatkan *deep learning*. Metode *deep learning* yang umum digunakan untuk peramalan adalah metode *Long Short-Term Memory* (LSTM). Metode LSTM sering diaplikasikan dalam metode peramalan data deret waktu karena dianggap lebih unggul dan handal dalam meramalkan periode jangka panjang dibandingkan dengan algoritma lain (Zahara, Sugianto and Ilmiddaviq, 2020). Sebagai pengembangan dari metode *Recurrent Neural Network* (RNN), arsitektur LSTM terdiri atas *memory cells* dan beberapa *gate* yang mencegah hilang atau berlebihan *error* dalam proses peramalan (Okut, 2021). Penelitian yang dilakukan Hochreiter and Schmidhuber (1997) pun menyatakan bahwa LSTM dapat secara efektif mempelajari pola dependensi data dalam jangka pendek dan panjang serta karakteristik nonlinear di dalamnya.

Maysoon (2023) menyatakan ARIMAX-GARCH telah mampu mengatasi masalah heteroskedastisitas pada peramalan Indeks Harga Saham Gabungan (IHSG) dan kurs dollar. Selain itu, Kartika & Karmilasari (2022), menunjukkan bahwa metode LSTM berhasil meminimalisir kesalahan pada data yang mengalami fluktuasi. Penelitian lain juga dilakukan oleh Budiprasetyo, Hani'ah & Aflah (2022) untuk melakukan peramalan menggunakan

data harga saham PT ANTM.JK, didapatkan bahwa model LSTM memberikan kinerja terbaik.

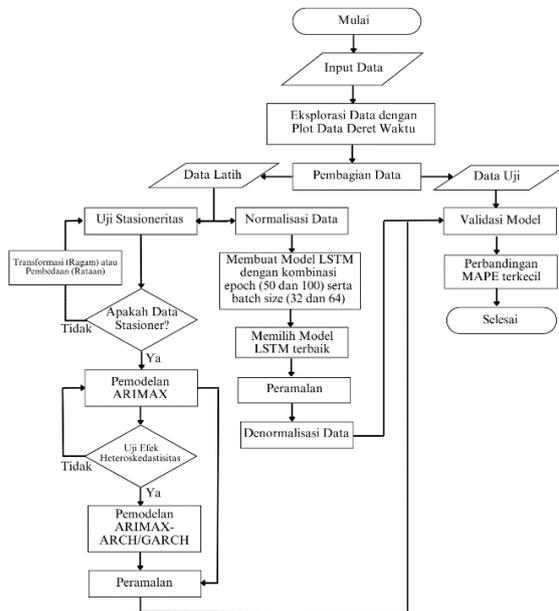
Telah terujinya metode ARIMAX-GARCH dan LSTM sebagai pendekatan yang efektif dalam meramalkan data deret waktu yang memiliki masalah heteroskedastisitas, mendasari peneliti untuk melakukan perbandingan performa metode klasik dengan metode berbasis *machine learning* pada data harga penutupan saham PT Aneka Tambang Tbk (ANTM.JK) sebagai salah data deret waktu di bidang ekonomi di Indonesia yang memiliki pola fluktuatif dan nonlinier. PT ANTM.JK merupakan salah satu perusahaan atau instansi Badan Usaha Milik Negara (BUMN) Indonesia yang berfokus pada sektor pertambangan (Ramdhani & Mubarok, 2019). Lingkup kegiatan perusahaan PT Aneka Tambang Tbk terdiri dari eksplorasi, proses penambangan, pengolahan atau produksi, dan pemasaran berbagai komoditas seperti emas, perak, feronikel, batubara, bauksit, dan bijih nikel (Kartika & Karmilasari, 2022). Pada tahun 2023, saham ANTM.JK terdaftar dalam "10 Daftar Saham *Blue Chip* yang Cocok untuk Investasi" karena beberapa sahamnya diprediksi akan mengalami tren positif sepanjang tahun tersebut. Hal ini membuat investor tertarik untuk memiliki saham di perusahaan ANTM.JK (Alfat et al., 2022). Peningkatan harga saham ANTM.JK yang cukup signifikan terjadi pada tahun 2020. Hal tersebut dipengaruhi oleh berita mengenai rencana Tesla untuk mendirikan pabrik baterai berbahan dasar nikel di Indonesia. Rencana ini memiliki dampak positif terhadap harga serta volume dari penjualan nikel di pasar domestik. Secara langsung rencana tersebut juga memengaruhi tren saham ANTM.JK. Hal ini disebabkan oleh fakta bahwa sekitar 30% pendapatan perusahaan ANTM.JK berasal dari feronikel dan bijih nikel (Fadli, 2021).

Penelitian sebelumnya mengenai harga saham PT Aneka Tambang Tbk (ANTM.JK) telah dilakukan oleh (Harsono and Galuh, 2021) dengan menerapkan model analisis regresi linier berganda didapatkan hasil bahwa harga nikel global memengaruhi perubahan harga saham ANTM.JK.

Hasil serupa juga diungkapkan oleh (Charissa and Eduardus, 2021) melalui metode regresi linier berganda pada data saham ANTM.JK mingguan dari Agustus 2016 hingga Agustus 2020. Hasil penelitian tersebut menunjukkan bahwa perubahan harga nikel dunia secara konsisten dapat memengaruhi return saham ANTM.JK. Puspitasari (2023) menggunakan metode ARIMA ARCH/GARCH dalam meramalkan harga penutupan saham ANTM.JK dengan model terbaik yang diperoleh ARIMA(1,1,0) ARCH(1).

Selain itu penggunaan metode berbasis *machine learning* juga telah dilakukan oleh Kartika & Karmilasari (2022), mengenai peramalan harga saham PT ANTM.JK pada periode 29 September 2005 sampai 13 April 2021 yang menunjukkan bahwa

metode LSTM berhasil meminimalisir kesalahan pada data yang mengalami fluktuasi.



Gambar 1. Diagram alir penelitian

Penelitian lain juga dilakukan oleh (Budiprasetyo, Hani'ah & Aflah, 2022) untuk melakukan peramalan menggunakan data harga saham PT ANTM.JK, didapatkan bahwa model LSTM memberikan kinerja terbaik dengan nilai MAPE yang dihasilkan sebesar 2,64. Oleh karena itu, penelitian ini membandingkan performa metode ARIMAX-GARCH (memanfaatkan peubah kovariat berupa harga nikel berjangka dunia) dan metode LSTM pada data harga penutupan saham PT Aneka Tambang Tbk (ANTM.JK)

2. METODE PENELITIAN

2.1. Data

Data deret waktu yang digunakan merupakan data harga penutupan saham PT Aneka Tambang Tbk (ANTM.JK) dalam satuan rupiah dengan periode mingguan mulai dari tanggal 1 Januari 2018 hingga 30 Oktober 2023. Data harga penutupan saham ANTM.JK merupakan data sekunder yang bersumber dari <https://finance.yahoo.com>. Pada penelitian ini digunakan peubah kovariat berupa harga nikel berjangka dunia (NICKEL) dalam satuan US Dollar yang bersumber dari id.investing.com. Peubah kovariat ini memiliki periode yang sama dengan data harga penutupan saham ANTM.JK.

2.2. Metode Penelitian

Data dianalisis menggunakan bantuan *software* R untuk eksplorasi data dan pemodelan ARIMAX ARCH/GARCH dan Python untuk pemodelan LSTM. Diagram alir penelitian disajikan pada Gambar 1.

Secara detail, berikut tahapan yang dilakukan pada penelitian ini.

1. Mengeksplorasi data menggunakan plot data deret waktu untuk melihat pola dan karakteristik data.
2. Membagi data berdasarkan kemiripan pola menjadi data latih dan data uji.
3. Memeriksa kestasioneran data dalam rata-rata dan ragam pada harga penutupan saham ANTM.JK. Plot Box-Cox digunakan dalam memeriksa kestasioneran data dalam ragam dan kestasioneran data dalam rata-rata diperiksa menggunakan plot *Autocorrelation Function* (ACF). Kestasioneran data dalam ragam dapat tercapai ketika nilai *rounded value* sama dengan satu atau nilai satu berada pada selang kepercayaan plot Box-Cox, sedangkan kestasioneran data dalam rata-rata dapat tercapai ketika plot ACF turun dengan cepat (Wahyuningsih et al., 2019). Selain melakukan eksplorasi dengan plot ACF, dilakukan uji formal lanjutan dengan menggunakan uji *Augmented Dickey Fuller* (ADF). Uji ADF mempunyai hipotesis H_0 : data tidak stasioner dalam rata-rata melawan H_1 : data stasioner dalam rata-rata (Desvina & Meijer, 2018). Keputusan hasil uji ADF merujuk pada *p-value* yang dihasilkan. Penanganan dilakukan dengan melakukan transformasi terlebih dahulu jika data tidak stasioner dalam ragam. Selanjutnya, jika data tidak stasioner dalam rata-rata, dilakukan pembedaan.
4. Melakukan pemodelan ARIMAX dengan menggunakan peubah kovariat data harga nikel berjangka dunia. Peubah kovariat ditambahkan untuk meningkatkan akurasi pada peramalan data (Chen et al., 2022). Adapun tahapan pemodelan ARIMAX sebagai berikut.
 - a. Melakukan pemodelan regresi data harga nikel berjangka dunia terhadap harga penutupan saham ANTM.JK. Data yang digunakan adalah data yang sudah stasioner dalam ragam.
 - b. Memeriksa kestasioneran data dalam rata-rata pada sisa hasil analisis regresi. Jika data belum stasioner dalam rata-rata, maka harus dilakukan pembedaan terlebih dahulu.
 - c. Mengidentifikasi model tentatif ARIMAX berdasarkan plot ACF, *Partial Autocorrelation Function* (PACF), dan *Extended Autocorrelation Function* (EACF).
 - d. Melakukan estimasi parameter model ARIMAX menggunakan metode kemungkinan maksimum.
 - e. Memilih calon model ARIMAX terbaik dari model tentatif dengan melihat keseluruhan parameter yang signifikan dan dari nilai *Akaike Information Criterion* (AIC) terkecil. AIC digunakan sebagai pertimbangan dalam pemilihan model dengan melihat dari banyaknya parameter suatu model. Adapun

rumus AIC adalah sebagai berikut (Montgomery, Jennings and Kulahci, 2015).

$$AIC = \ln \left(\frac{\sum_{t=1}^T e_t^2}{T} \right) + \frac{2p}{T} \quad (1)$$

Keterangan:

$\sum_{t=1}^T e_t^2$: jumlah kuadrat sisaan

T : banyak data

p : banyak parameter dalam model

- f. Melakukan *overfitting* pada calon model ARIMAX terbaik.
- g. Menentukan model ARIMAX terbaik dengan melihat keseluruhan parameter yang signifikan dan nilai AIC terkecil.
- h. Melakukan uji diagnostik sisaan pada model ARIMAX terbaik dengan menggunakan uji Kolmogorov-Smirnov untuk memeriksa asumsi normalitas, uji Ljung-Box untuk memeriksa asumsi ragam sisaan homogen dan kebebasan sisaan, dan asumsi nilai tengah sisaan sama dengan nol diperiksa dengan uji t. Formulasi model ARIMAX dituliskan pada persamaan berikut.

$$Y_t = \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{j=1}^q \theta_j e_{t-j} + \sum_{m=1}^n \beta_m X_{t-m} \quad (2)$$

Keterangan:

ϕ : parameter *autoregressive*

Y_{t-i} : data periode ke t-i

p : ordo *autoregressive*

θ : parameter *moving average*

e_{t-j} : *white noise* periode ke t-j

q : ordo *moving average*

β_m : parameter peubah kovariat ke-m

X_{t-m} : peubah kovariat ke t-m

n : jumlah peubah kovariat

5. Melakukan pengujian efek heteroskedastisitas pada sisaan model ARIMAX menggunakan uji ARCH-Lagrange Multiplier (ARCH-LM).
6. Melakukan pemodelan ARIMAX-ARCH/GARCH. Metode ARCH/GARCH digunakan dalam mengatasi masalah heterokedastisitas dengan memodelkan volatilitas dalam data deret waktu (Marvillia, 2013). Adapun pemodelan ARIMAX-ARCH/GARCH dilakukan dengan tahapan sebagai berikut.
 - a. Melakukan pendugaan parameter model ARIMAX-ARCH/GARCH(p,q).
 - b. Menentukan calon model ARIMAX-ARCH/GARCH terbaik dengan melihat keseluruhan parameter yang signifikan, hasil uji ARCH-LM yang tidak signifikan, dan nilai AIC terkecil.
 - c. Melakukan *overfitting* pada calon model ARIMAX-ARCH/GARCH terbaik.
 - d. Melakukan uji diagnostik sisaan pada model ARIMAX terbaik dengan menggunakan uji Kolmogorov-Smirnov untuk memeriksa asumsi normalitas, uji Ljung-Box untuk memeriksa asumsi ragam sisaan homogen

dan kebebasan sisaan, dan asumsi nilai tengah sisaan sama dengan nol diperiksa dengan uji t. Formulasi model GARCH dituliskan pada persamaan berikut.

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i e_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (3)$$

Keterangan

ω : konstanta

α : parameter ARCH

e_{t-i}^2 : kuadrat sisaan pada waktu t-i

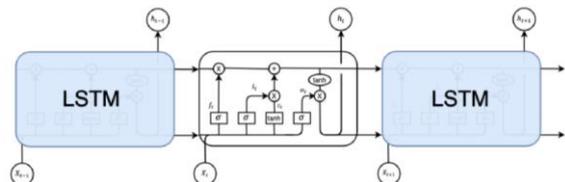
p : ordo ARCH

β : parameter GARCH

σ_{t-j}^2 : ragam sisaan pada waktu t-j

q : ordo GARCH

7. Melakukan pemodelan dengan LSTM menggunakan Python. LSTM adalah peningkatan dari *Recurrent Neural Network* (RNN) yang dilengkapi dengan *cell states* untuk mengingat dan melupakan data (Salam, 2021). *Cell state* akan melewati 3 mekanisme gerbang, yaitu *forget gate*, *input gate*, dan *output gate*. Adapun tahapan LSTM sebagai berikut.
 - a. Melakukan normalisasi data pada set data dengan teknik *min-max scaler* dari sklearn.
 - b. Melakukan *trial and error* agar didapatkan model LSTM terbaik dengan kombinasi *epoch* sebesar 50 dan 100 serta *batch size* sebesar 32 dan 64.
 - c. Membuat prediksi dengan model LSTM terbaik untuk data uji.
 - d. Melakukan denormalisasi data.
8. Melakukan validasi model pada model ARIMAX-ARCH/GARCH terbaik dan model LSTM terhadap data hasil ramalan dengan data aktual (data uji). Akurasi peramalan model berdasarkan nilai *Mean Absolute Percentage Error* (MAPE). Nilai MAPE didapatkan dari perhitungan antara persentase penyimpangan data aktual dengan data peramalan, perhitungan nilai MAPE dapat dilakukan dengan menggunakan persamaan (4).



Gambar 2. Skema kerja LSTM (Wiranda and Sadikin, 2019)

Keterangan:

A : jaringan syaraf

X_{t-1}, X_t : *input* pada waktu t-1 dan t

h_{t-1}, h_t : *output* pada waktu t-1 dan t

C_{t-1}, C_t : *cell state* pada waktu t-1 dan t

f_t : *forget gate*

i_t : *input gate*

C_t : vektor kandidat nilai baru

o_t : *output gate*

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{X_t - \hat{X}_t}{X_t} \right| \times 100\% \quad (4)$$

Keterangan:

- X_t : nilai pada waktu t
- \hat{X}_t : nilai ramalan pada waktu t
- n : jumlah periode peramalan

3. HASIL DAN PEMBAHASAN

3.1. Eksplorasi Data

Tahapan awal yang dilakukan adalah eksplorasi data menggunakan plot data deret waktu untuk melihat pola dan karakteristik data. Data dibagi menjadi data latih dan data uji yang digunakan untuk tahap validasi model selanjutnya. Data tersebut dibagi berdasarkan pola yang cenderung mirip. Gambar 2 menyajikan plot data deret waktu serta pembagian data harga penutupan saham ANTM.JK mingguan dengan data periode 1 Januari 2018 sampai 29 Agustus 2022 sebagai data latih dan data periode 5 September 2022 sampai 30 Oktober 2023 sebagai data uji.

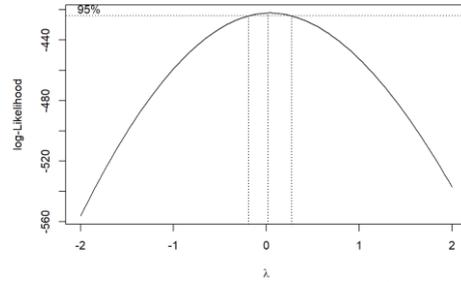
Secara eksploratif, Gambar 3 menunjukkan bahwa harga penutupan saham ANTM.JK cenderung fluktuatif sejak Januari 2018 dan naik secara signifikan mulai bulan Desember 2020. Hal ini dipengaruhi oleh berita mengenai rencana pembangunan pabrik baterai berbahan dasar nikel di Indonesia. Kemudian, harga penutupan saham ANTM.JK kembali fluktuatif hingga akhir Oktober 2023.

3.2. Kestasioneran Data

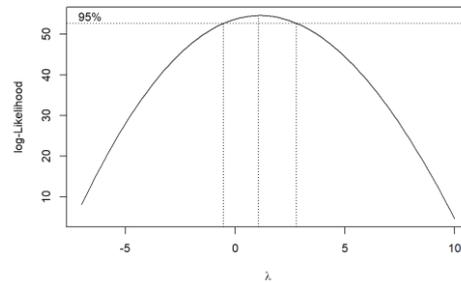
Langkah awal dalam pemodelan analisis data deret waktu adalah melakukan pemeriksaan pada kestasioneran data. Metode ARIMAX mensyaratkan data harus stasioner, baik dalam rata-rata maupun ragam (Rukini, 2014). Pengujian kestasioneran data dalam ragam dapat dilihat melalui plot Box-Cox.



Gambar 3. Plot harga penutupan saham ANTM.JK mingguan 2018-2023

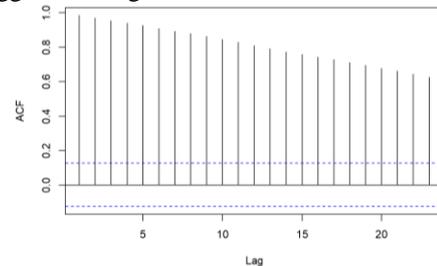


Gambar 4. Plot Box-Cox sebelum transformasi

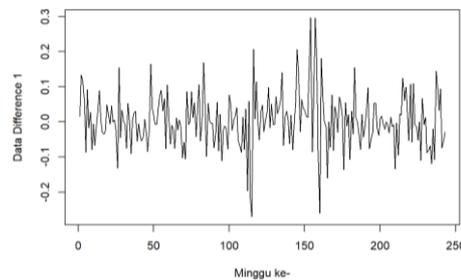


Gambar 5. Plot Box-Cox setelah transformasi logaritma natural

Gambar 4 menunjukkan plot Box-Cox dengan nilai optimum sebesar 0,020. Gambar tersebut juga menunjukkan bahwa selang kepercayaan 95% dari plot Box-Cox memiliki batas bawah -0,182 dan batas atas 0,263. Selang tersebut tidak memuat nilai satu, sehingga dapat dikatakan bahwa data tidak stasioner dalam ragam. Namun, pada selang kepercayaan 95% berdasarkan plot Box-Cox terdapat nilai 0. Oleh karena itu, dilakukan transformasi Box-Cox dengan menggunakan logaritma.



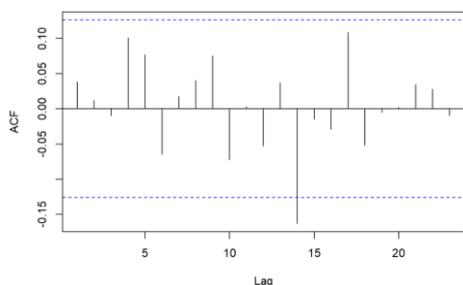
Gambar 6. Plot ACF sebelum pembedaan



Gambar 7. Plot harga penutupan harga saham ANTM.JK sesudah pembedaan pertama

Gambar 4 menunjukkan plot Box-Cox setelah dilakukan transformasi menggunakan logaritma. Dalam selang kepercayaan 95% terdapat nilai satu, sehingga kestasioneran data dalam ragam sudah tertangani.

Pengujian kestasioneran data dalam rata-rata dapat dilakukan secara eksploratif dan uji formal. Secara eksploratif, dapat dilihat dari plot data deret waktu dan plot ACF. Gambar 3 menunjukkan adanya pola yang cenderung fluktuatif pada plot data deret waktu harga penutupan saham ANTM.JK.



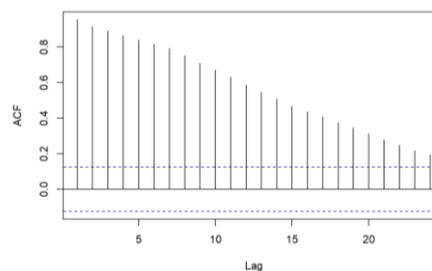
Gambar 8. Plot ACF sesudah pembedaan satu kali

Selain itu, terdapat kenaikan yang signifikan di beberapa periode sehingga tidak dapat disebut stasioner dalam rata-rata. Hal ini didukung dengan plot ACF pada Gambar 6 yang menunjukkan adanya indikasi *tails off slowly* (menurun secara eksponensial), sehingga data tersebut dapat dikatakan tidak stasioner dalam rata-rata. Uji formal ADF juga memperkuat kesimpulan tersebut dengan hasil *p-value* sebesar 0,5475 yang lebih besar dari taraf nyata 5%. Hasil pengujian ini menyatakan bahwa data tidak stasioner dalam rata-rata.

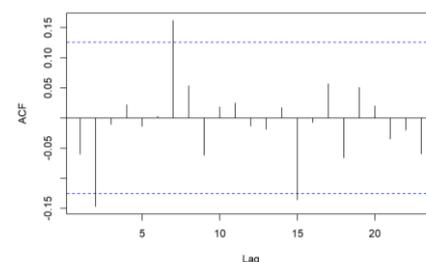
Ketidastasioneran data dalam rata-rata ditangani dengan melakukan pembedaan sebanyak satu kali. Gambar 7 menunjukkan bahwa plot data deret waktu sudah cenderung bergerak pada nilai tengah tertentu. Oleh karena itu, data dapat dikatakan sudah stasioner dalam rata-rata. Hasil ini didukung oleh plot ACF pada Gambar 8 yang terpotong setelah lag ke-14. Uji formal ADF juga memperkuat kesimpulan tersebut karena memiliki *p-value* sebesar 0,01 yang lebih kecil dari taraf nyata 5%, dengan kata lain data telah stasioner pada rata-rata.

3.3. Pemodelan ARIMAX

Pemodelan ARIMAX diawali dengan melakukan pemodelan regresi pada harga nikel berjangka dunia terhadap harga penutupan saham ANTM.JK. Pemeriksaan kestasioneran data dalam rata-rata pada sisaan hasil regresi dilakukan menggunakan plot ACF dan uji formal ADF. Plot ACF pada Gambar 9, memberikan informasi adanya indikasi *tails off slowly* (menurun secara eksponensial), sehingga data tersebut dapat dikatakan tidak stasioner dalam rata-rata. Uji formal ADF juga memperkuat kesimpulan tersebut dengan hasil *p-value* sebesar 0,6481 yang lebih besar dari taraf nyata 5%.



Gambar 9. Plot ACF sisaan sebelum pembedaan

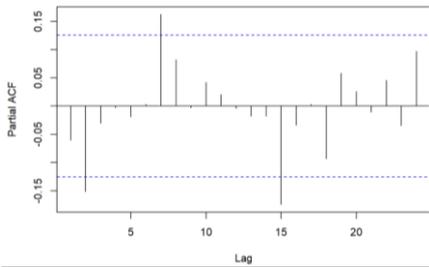


Gambar 10. Plot ACF sisaan sesudah pembedaan satu kali

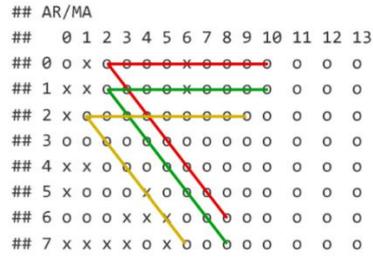
Setelah menangani kestasioneran rata-rata pada data sisaan melalui pembedaan sebanyak satu kali, terlihat bahwa data tersebut sudah stasioner dalam rata-rata yang ditandai dengan plot ACF yang terpotong setelah lag ke-2. Hal ini ditunjukkan oleh plot ACF yang disajikan pada Gambar 10. Uji formal ADF juga memperkuat kesimpulan tersebut karena memiliki *p-value* sebesar 0,01 yang lebih kecil dari taraf nyata 5%.

Identifikasi model tentatif ARIMAX dilakukan pada data sisaan hasil regresi yang sudah stasioner dengan melihat plot ACF, PACF, dan EACF. Gambar 10 menunjukkan bahwa plot ACF cenderung *cuts off* pada lag ke-2, sehingga jika plot PACF dianggap *tails off*, maka model tentatifnya adalah ARIMAX(0,1,2). Sebaliknya, pada plot PACF yang ditunjukkan pada Gambar 11, model tentatif yang terbentuk adalah ARIMAX(2,1,0). Jika plot ACF maupun plot PACF keduanya dianggap *tails off*, maka model yang terbentuk adalah ARIMAX(2,1,2).

Cryer & Chan (2008) menyatakan bahwa model ARMA(p,q) secara teoritis memiliki pola segitiga-nol (*triangle of zeroes*), dan nilai yang ditandai dengan simbol "o" di pojok kiri atas pada plot EACF sesuai dengan ordo ARMA. Setelah dilakukan pembedaan sebanyak satu kali pada data, didapatkan model tentatif pada plot EACF seperti yang ditunjukkan pada Gambar 12, yaitu, ARIMAX(0,1,2), ARIMAX(1,1,2), dan ARIMAX(2,1,1). Estimasi parameter model tentatif ARIMAX terlihat pada Tabel 1. Model ARIMAX(2,1,2) merupakan model dengan keseluruhan parameter yang signifikan dan nilai AIC terkecil. Model ini dipilih sebagai kandidat model ARIMAX terbaik yang akan dilakukan *overfitting*.



Gambar 11. Plot PACF sisaan sesudah pembedaan

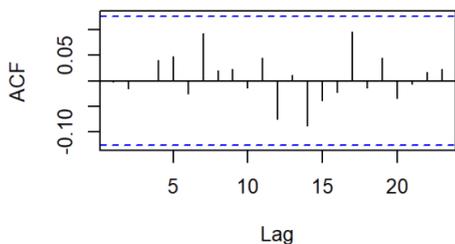


Gambar 12. Plot EACF sesudah pembedaan

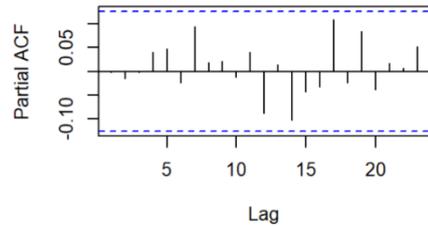
Tabel 1. Estimasi parameter model ARIMAX

Model	Parameter	Koefisien	p-value	AIC
ARIMAX (0,1,2)	MA(1)	0,011	0,866	-593,226
	MA(2)	-0,04	0,462	
	Xreg	0,626	0,000*	
ARIMAX (2,1,0)	AR(1)	0,012	0,857	-593,313
	AR(2)	-0,052	0,426	
	Xreg	0,627	0,000*	
ARIMAX (2,1,2)	AR(1)	0,075	0,000*	-595,133
	AR(2)	-0,999	0,000*	
	MA(1)	-0,064	0,000*	
	MA(2)	1,000	0,000*	
	Xreg	0,621	0,000*	
ARIMAX (1,1,2)	AR(1)	0,047	0,945	-591,231
	MA(1)	-0,035	0,958	
	Xreg	0,626	0,000*	
ARIMAX (2,1,1)	AR(1)	0,066	0,912	-591,322
	AR(2)	-0,053	0,419	
	MA(1)	-0,055	0,927	
	Xreg	0,627	0,000*	

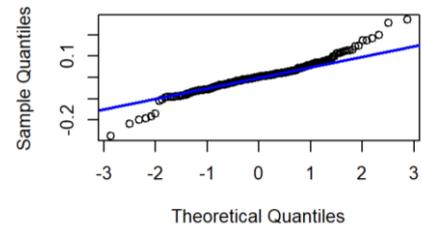
*Parameter signifikan pada taraf nyata 5%



Gambar 13. Plot ACF sisaan model ARIMAX(2,1,2)



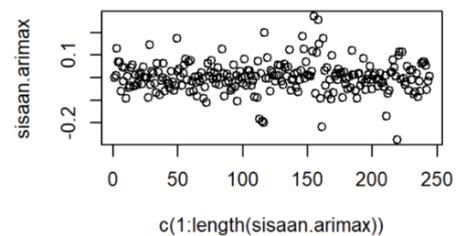
Gambar 14. Plot PACF sisaan model ARIMAX(2,1,2)



Gambar 15. Plot kuantil-kuantil sisaan model ARIMAX(2,1,2)

Pada hasil *overfitting*, model ARIMAX(3,1,2) memiliki nilai AIC sebesar -593,133 dan tidak seluruh parameternya signifikan dan model ARIMAX(2,1,3) dengan nilai AIC sebesar -593,132 dan tidak seluruh parameternya signifikan. Sehingga, model ARIMAX(2,1,2) merupakan model ARIMAX terbaik.

Uji diagnostik dilakukan terhadap sisaan model ARIMAX(2,1,2). Secara eksploratif, pada Gambar 13 merupakan plot ACF sisaan dan plot PACF sisaan pada Gambar 14 tidak signifikan hingga 20 lag pertama sehingga sisaan saling bebas. Hasil ini juga didukung oleh uji formal menggunakan uji Ljung-Box dari sisaan dengan p-value sebesar 0,978 yang lebih besar dari taraf nyata 5%. Selanjutnya, uji normalitas sisaan secara eksploratif dapat dilihat melalui plot kuantil-kuantil. Berdasarkan plot kuantil-kuantil pada Gambar 15, terlihat bahwa titik pada plot cenderung tidak mengikuti garis kenormalan. Hal ini mengidentifikasi adanya pelanggaran asumsi normalitas sisaan pada model ARIMAX(2,1,2). Hasil tersebut diperkuat dengan uji Kolmogorov-Smirnov yang mendapatkan p-value sebesar 0,000 yang kurang dari taraf 5%.



Gambar 16. Plot sisaan nilai tengah ARIMAX(2,1,2)

Selanjutnya dilakukan uji keheterogenan ragam secara eksploratif dilihat melalui plot sisaan ARIMAX(2,1,2). Plot sisaan yang tertera pada Gambar 16, memperlihatkan bahwa ragam sisaan ARIMAX(2,1,2) cenderung tidak homogen. Hal ini didukung dengan uji formal Ljung-Box dari sisaan

kuadrat dengan *p-value* sebesar 0,000 yang lebih kecil dari pada taraf nyata sebesar 5%. Selanjutnya, dilakukan uji t untuk memeriksa asumsi nilai tengah sisaan bernilai nol dan didapatkan *p-value* sebesar 0,474 yang lebih besar dari taraf nyata 5%. Hal tersebut menandakan nilai tengah sisaan bernilai nol.

3.4. Pengujian Efek Heteroskedastisitas

Pada model ARIMAX(2,1,2) terindikasi bahwa sisaannya tidak memenuhi asumsi homoskedastisitas. Uji *Lagrange Multiplier* (LM) dilakukan untuk mengidentifikasi adanya efek ARCH pada sisaan model. Pada Tabel 2, terlihat bahwa *p-value* uji ARCH-LM signifikan hingga lag ke-20. *P-value* yang lebih kecil dari taraf nyata 5% menunjukkan adanya efek heteroskedastisitas pada sisaan model ARIMAX(2,1,2). Model GARCH akan lebih cocok digunakan jika nilai *p-value* signifikan lebih dari lag 12 (Desvina & Rahmah, 2016). Maka dari itu, pendugaan model menggunakan GARCH akan dilakukan.

Tabel 2. Hasil uji ARCH-LM

Lag	P-value
4	0,000*
8	0,000*
12	0,000*
16	0,002*
20	0,006*

*Parameter signifikan pada taraf nyata 5%

3.5. Pemodelan ARCH-GARCH

Model GARCH terbaik, diperoleh dengan melakukan *trial and error*. Model terbaik GARCH dilihat berdasarkan signifikansi parameter, nilai AIC, dan *p-value* uji ARCH-LM. Berdasarkan hasil *trial and error*, didapatkan bahwa model ARIMAX(2,1,2)-GARCH(1,1) merupakan model terbaik dengan keseluruhan parameter yang signifikan, nilai AIC yang kecil, dan *p-value* uji ARCH-LM yang tidak signifikan yaitu sebesar 0,270 artinya efek ARCH sudah teratasi. Hasil estimasi parameter model ARIMAX(2,1,2)-GARCH(1,1) selanjutnya tercantum pada Tabel 3.

Tabel 3. Estimasi parameter model ARIMAX-GARCH

Model	Parameter	Koefisien	p-value	AIC
ARIMAX (2,1,2) -	AR(1)	1,784	0,000*	-2,575
	AR(2)	-0,951	0,000*	
GARCH (1,1)	MA(1)	-1,837	0,000*	
	MA(2)	1,003	0,000*	
	Xreg	0,632	0,000*	
	ω	0,001	0,004*	
	α	0,256	0,005*	
	β	0,457	0,000*	

*Parameter signifikan pada taraf nyata 5%

Pada hasil *overfitting*, model ARIMAX(2,1,2)-GARCH(2,1) memiliki nilai AIC sebesar -2,559 dan tidak seluruh parameternya signifikan serta model ARIMAX(2,1,2)-GARCH(1,2) memiliki nilai AIC sebesar -5,567 dan tidak seluruh parameternya signifikan. Oleh karena itu, model ARIMAX(2,1,2)-

GARCH(1,1) merupakan model ARIMAX-ARCH/GARCH terbaik.

Uji diagnostik model dilakukan pada sisaan model terbaik ARIMAX(2,1,2)-GARCH(1,1) menggunakan uji Kolmogorov-Smirnov, uji Ljung-Box, dan uji t. Berdasarkan uji Ljung-box, diperoleh bahwa sisaan saling bebas karena didapatkan *p-value* sebesar 0,540 yang lebih besar dari taraf nyata 5%. Selanjutnya, uji kenormalan sisaan dengan uji Kolmogorov-Smirnov memberi kesimpulan bahwa sisaan tidak mengikuti sebaran normal karena didapatkan *p-value* sebesar 0,000 yang kurang dari taraf nyata 5%. Uji t dilakukan untuk memeriksa asumsi nilai tengah sisaan sama dengan nol dan didapatkan *p-value* sebesar 0,498 yang lebih besar dari taraf nyata 5%. Hal tersebut menandakan bahwa asumsi terpenuhi. Pengujian kehomogenan ragam dilakukan menggunakan uji Ljung-Box dari sisaan kuadrat. Uji ini menyimpulkan bahwa ragam sisaan telah homogen karena didapatkan *p-value* pada lag pertama sebesar 0,890 yang lebih besar dari taraf nyata 5%. Dengan demikian, model GARCH berhasil mengatasi pelanggaran asumsi kehomogenan ragam pada model ARIMAX. Model rata-rata yang terbentuk dari ARIMAX(2,1,2)-GARCH(1,1) disajikan pada persamaan (5).

$$Y_t = 1,8Y_{t-1} - 0,9Y_{t-2} + e_t - 1,8e_{t-1} + 1,0e_{t-2} + 0,6X_t \quad (5)$$

Adapun model ragam yang terbentuk dari ARIMAX(2,1,2)-GARCH(1,1) disajikan pada persamaan (6).

$$\sigma_t^2 = 0,001 + 0,256e_{t-1}^2 + 0,457\sigma_{t-1}^2 \quad (6)$$

3.6. Pemodelan Menggunakan LSTM

Tahapan awal dalam pemodelan menggunakan LSTM adalah melakukan normalisasi data. Proses normalisasi data dilakukan menggunakan metode *Min-Max scaler*. Pada metode *Min-Max*, proses yang dilakukan adalah membagi hasil pengurangan data ke-i dengan data terkecil menggunakan hasil pengurangan data terbesar dan data terkecil (Cahyani, Mujahidin & Fiqar, 2023). Proporsi pembagian data sebesar 80% data latih dan 20% data uji, sama seperti pemodelan pada ARIMAX-ARCH/GARCH. Pada Tabel 4, terlihat bahwa model LSTM terbaik berasal dari *epoch* 100 dan *batch size* 32 karena memiliki nilai MAPE yang terkecil. Selanjutnya, dibuat prediksi untuk validasi model dengan model LSTM terbaik yang terbentuk dan hasilnya dinormalisasi. Denormalisasi adalah proses untuk mengembalikan data menjadi skala awal (Cahyani, Mujahidin & Fiqar, 2023).

Tabel 4. MAPE pada setiap kombinasi *epoch* dan *batch size*

Epoch	Batch Size	MAPE
50	32	4,582%
50	64	7,780%
100	32	4,337%
100	64	4,492%

3.7. Validasi Model

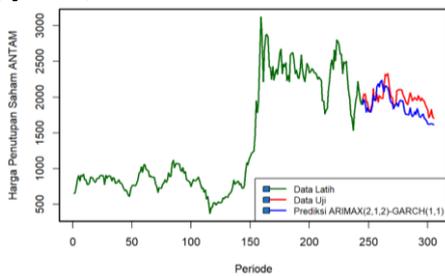
Perbandingan model antara ARIMAX(2,1,2)-GARCH(1,1) dan model LSTM dilakukan dengan melihat nilai ukuran akurasi model, yaitu MAPE yang lebih kecil. Perhitungan nilai MAPE didasarkan pada persamaan (3). Perbandingan nilai MAPE dilakukan pada data uji. Pada Gambar 17 terlihat peramalan dari model ARIMAX(2,1,2)-GARCH(1,1) yang fluktuatif hingga akhir periode dan didapatkan nilai MAPE sebesar 7,326%. Sedangkan, pada Gambar 18 terlihat model LSTM cenderung fluktuatif dan lebih mengikuti pola data uji hingga akhir periode dan didapatkan nilai MAPE sebesar 4,425%. Hal ini menunjukkan bahwa metode LSTM lebih baik digunakan untuk memprediksi harga saham penutupan ANTM.JK.

4. KESIMPULAN DAN SARAN

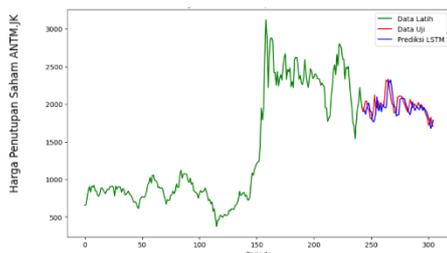
Hasil penelitian menunjukkan model ARIMAX- ARCH/GARCH terbaik adalah ARIMAX(2,1,2)-GARCH(1,1). Model tersebut berhasil mengatasi masalah heteroskedastisitas dan memiliki parameter yang seluruhnya signifikan. Model ini menghasilkan akurasi yang sangat baik, yaitu nilai MAPE sebesar 7,326%.

Penambahan peubah kovariat data harga nikel berjangka dunia ke dalam model ini menunjukkan pengaruh yang signifikan terhadap fluktuasi harga saham ANTM.JK. Model GARCH juga berhasil mengatasi pelanggaran asumsi kehomogenan ragam sisaan pada model ARIMAX.

Namun demikian, metode berbasis *machine learning*, LSTM, menghasilkan nilai prediksi harga saham ANTM.JK lebih baik dibandingkan model ARIMAX-GARCH. Hal ini ditunjukkan dengan hasil prediksinya yang dekat dengan data aktual dan juga diperkuat dengan besaran nilai MAPE yang lebih kecil, yaitu 4,425%.



Gambar 17. Validasi model ARIMAX(2,1,2)-GARCH(1,1) pada data uji



Gambar 18. Validasi model LSTM pada data uji

Kedua metode yang digunakan pada penelitian ini telah mampu memprediksi harga saham PT. ANTM.JK dengan baik. Namun demikian, pengembangan pada penelitian selanjutnya metode lain yang lebih *advance* dapat digunakan, seperti model GARCH asimetris untuk penanganan heteroskedastisitas. Metode *deep learning Multivariate LSTM* juga dapat dilakukan dengan menambahkan peubah lainnya agar didapatkan hasil pemodelan yang lebih baik.

DAFTAR PUSTAKA

- ALFAT, L., HERMAWAN, H., RUSTANDIPUTRI, A., INZHAGI, R. & TANDJILAL, R., 2022. Prediksi Saham PT. Aneka Tambang Tbk. dengan K-Nearest Neighbors. *JSAI (Journal Scientific and Applied Informatics)*, 5(3), pp.236–243. <https://doi.org/10.36085/jsai.v5i3.3975>.
- BUDIPRASETYO, G., HANI'AH, M. & AFLAH, D.Z., 2022. Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM). *Jurnal Nasional Teknologi dan Sistem Informasi*, 8(3), pp.164–172. <https://doi.org/10.25077/TEKNOSI.v8i3.2022.164-172>.
- CAHYANI, J., MUJAHIDIN, S. & FIQAR, T.P., 2023. Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional. *Jurnal Sistem dan Teknologi Informasi (JustIN)*, 11(2), p.346. <https://doi.org/10.26418/justin.v11i2.57395>.
- CHARISSA, E.A. & EDUARDUS, T., 2021. Pengaruh Perubahan Harga Emas Dan Nikel Terhadap Return Saham PT Aneka Tambang Tbk. [online] Universitas Gajah Mada. Available at: <<https://etd.repository.ugm.ac.id/penelitian/detail/196871>>.
- CHEN, Y.-P., LIU, L.-F., CHE, Y., HUANG, J., LI, G.-X., SANG, G.-X., XUAN, Z.-Q. & HE, T.-F., 2022. Modeling and Predicting Pulmonary Tuberculosis Incidence and Its Association with Air Pollution and Meteorological Factors Using an ARIMAX Model: An Ecological Study in Ningbo of China. *International Journal of Environmental Research and Public Health*, 19(9), p.5385. <https://doi.org/10.3390/ijerph19095385>.
- CRYER, J.D. & CHAN, K.-S., 2008. *Time series analysis: with applications in R*. 2. ed., corr. print ed. Springer texts in statistics. New York, NY: Springer.
- DESVINA, A.P. & MEIJER, I.O., 2018. Penerapan Model ARCH/GARCH untuk Peramalan Nilai Tukar Petani. *Jurnal Sains Matematika dan Statistika*, 4(1), pp.43–54.

- DESVINA, A.P. & RAHMAH, N., 2016. Penerapan Metode ARCH/GARCH Dalam Peramalan Indeks Harga Saham Sektor. *Jurnal Sains Matematika dan Statistika*, 2(1).
- FADLI, F., 2021. Hubungan Pola Penyebaran dan Ketebalan Zona Bijih Endapan Nikel Laterit dengan Topografi Permukaan Pada PT Aneka Tambang Tbk. *Indonesian Journal of Earth Sciences*, 1(1), pp.10–16. <https://doi.org/10.52562/injoes.v1i1.18>.
- HARSONO, N.D. & GALUH, A.K., 2021. *Analisis pengaruh debt to equity ratio, earning per share, price to book value, dan harga nikel dunia terhadap harga saham PT. Aneka Tambang Tbk.* [online] Universitas Brawijaya. Available at: <<https://repository.ub.ac.id/id/eprint/191294/>>.
- HIDAYAT, S. & HAKIM, N., 2021. Peramalan Ekspor Luar Negeri Banten Menggunakan Model Arimax. *Jurnal Lebesgue: Jurnal Ilmiah Pendidikan Matematika, Matematika dan Statistika*, 2(2), pp.204–213. <https://doi.org/10.46306/lb.v2i2.75>.
- HOCHREITER, S. & SCHMIDHUBER, J., 1997. Long Short-Term Memory. *Neural Computation*, 9(8), pp.1735–1780.
- JANNAH, M., 2021. *Kajian Metode Hybrid ARIMA-GARCH dan LSTM untuk Pendekatan Pemodelan Harga Beberapa Bahan Pokok.* [Master Theses] IPB University. Available at: <<https://repository.ipb.ac.id/handle/123456789/107035>>.
- JUANDA, B. & JUNAI, J., 2012. *Ekonometrika deret waktu: Teori dan Aplikasi.* Bogor: IPB Press.
- KARTIKA, S.D. & KARMILASARI, K., 2022. Implementasi Long Short-Term Memory Pada Prediksi Harga Saham PT Aneka Tambang Tbk. *Jurnal Ilmiah Komputasi*, [online] 21(1). <https://doi.org/10.32409/jikstik.21.1.2815>.
- MARVILLIA, B.L., 2013. Pemodelan dan Peramalan Penutupan Harga Saham PT. Telkom dengan Metode Arch - Garch. *MATHunesa*, 2(1).
- MAYSOON, K., 2023. *Penerapan Metode Arimax-Garch Dalam Meramalkan Indeks Harga Saham Gabungan (IHSG).* Universitas Lampung.
- MONTGOMERY, D.C., JENNINGS, C.L. & KULAHCI, M., 2015. *Introduction to Time Series Analysis and Forecasting.* 2nd Edition ed. Wiley series in probability and statistics. Hoboken, NJ: Wiley-Interscience.
- OKUT, H., 2021. Deep Learning for Subtyping and Prediction of Diseases: Long-Short Term Memory. In: P. Luigi Mazzeo and P. Spagnolo, eds. *Deep Learning Applications.* [online] IntechOpen. <https://doi.org/10.5772/intechopen.96180>.
- PRASETYO, T.A., SILITONGA, J.P., ALFREDO, M., SIAHAAN, R.S., SARAGIH, R., HANDAYANI, D. & CHANDRA, R., 2024. Evaluating the efficacy of univariate LSTM approach for COVID-19 data prediction in Indonesia. *Indonesian Journal of Electrical Engineering and Computer Science*, 34(2), p.1353. <https://doi.org/10.11591/ijeecs.v34.i2.pp1353-1366>.
- PUSPITASARI, I.A., 2023. *Analisis Model ARCH dan GARCH pada Saham PT. X.* [Undergraduate Thesis] Institut Teknologi Sepuluh Nopember. Available at: <<http://repository.its.ac.id/id/eprint/97343>>.
- RAMDHANI, Y. & MUBAROK, A., 2019. Analisis Time Series Prediksi Penutupan Harga Saham Antm.Jk Dengan Algoritma SVM Model Regresi. *JURNAL RESPONSIF*, 1(1), pp.77–82.
- RUKINI, R., 2014. Model ARIMAX Dan Deteksi GARCH Untuk Peramalan Inflasi Kota Denpasar Tahun 2014. *Jurnal Ekonomi Kuantitatif Terapan*, 7(2), pp.168–182.
- SALAM, N.F., 2021. *Klasifikasi teks sentimen review e-commerce menggunakan algoritma Long Short-Term Memory (LSTM).* Universitas Hasanuddin.
- WAHYUNINGSIH, S., GOEJANTORO, R., SIRINGORINGO, M., SAPUTRA, A.R. & AMINAH, S., 2019. Application Seasonal Autoregressive Integrated Moving Average to Forecast the Number of East Kalimantan Hotspots. *Journal of Physics: Conference Series*, 1351(1), p.012085. <https://doi.org/10.1088/1742-6596/1351/1/012085>.
- WIRANDA, L. & SADIKIN, M., 2019. Penerapan Long Short Term Memory pada Data Time Series untuk Memprediksi Penjualan Produk PT. Metiska Farma. *Jurnal Nasional Pendidikan Teknik Informatika*, 8(3), pp.184–196.
- ZAHARA, S., SUGIANTO & ILMIDDAVIQ, M.B., 2020. Consumer price index prediction using Long Short Term Memory (LSTM) based cloud computing. *Journal of Physics: Conference Series*, 1456(1), p.012022. <https://doi.org/10.1088/1742-6596/1456/1/012022>.