



Perbandingan Kinerja Model GARCH Dan LSTM Dalam Memprediksi Volatilitas Harian IHSG

Gabriel Fernando Sitorus^{*1}, Yolanda Angel Lina Sitorus², Gracia Domini Simarmata³

Email: ¹gabrielfernandositorus@gmail.com, ²yolandasitorus1407@gmail.com, ³graciadms2604@gmail.com

^{1,2,3}Statistika, Fakultas Matematika Dan Ilmu Pengetahuan Alam, Universitas Negeri Medan.

Diterima: 13 Desember 2025 | Direvisi: - | Disetujui: 20 Desember 2025

©2020 Program Studi Teknik Informatika Fakultas Ilmu Komputer,
Universitas Muhammadiyah Riau, Indonesia

Abstrak

Penelitian ini membahas perbandingan kinerja model Generalized Autoregressive Conditional Heteroskedasticity (GARCH) dan Long Short-Term Memory (LSTM) dalam memprediksi volatilitas harian Indeks Harga Saham Gabungan (IHSG) pada periode 2016–2025. Volatilitas merupakan indikator penting dalam menilai risiko dan ketidakpastian pasar, sehingga metode prediksi yang akurat sangat dibutuhkan oleh investor, analis, dan pembuat kebijakan. Data harga penutupan IHSG diubah menjadi log return dan diproses melalui tahapan pembersihan, normalisasi, serta pembentukan sequence untuk kebutuhan pemodelan. Model GARCH(1,1) digunakan untuk menangkap sifat volatility clustering melalui pendekatan varian bersyarat, sedangkan LSTM dimanfaatkan untuk mempelajari pola non-linear dan hubungan jangka panjang pada deret waktu. Hasil penelitian menunjukkan bahwa GARCH(1,1) mampu menggambarkan pola volatilitas secara umum, namun kurang responsif terhadap perubahan volatilitas yang terjadi secara tiba-tiba. Sebaliknya, model LSTM memberikan performa prediksi yang lebih unggul dengan kesalahan prediksi yang rendah dan nilai koefisien determinasi yang tinggi. Temuan ini mengindikasikan bahwa pendekatan deep learning lebih efektif dalam memodelkan dinamika volatilitas IHSG dibandingkan metode ekonometrika tradisional, khususnya pada kondisi pasar yang fluktuatif.

Kata kunci: Volatilitas IHSG, GARCH, LSTM, Peramalan Deret waktu, Deep Learning

Comparison Of The Performance Of GARCH And LSTM Models In Predicting Daily Volatility Of The IHSG

Abstract

This study compares the performance of the Generalized Autoregressive Conditional Heteroskedasticity (GARCH) and Long Short-Term Memory (LSTM) models in predicting daily volatility of the Jakarta Composite Index (JCI) for the 2016–2025 period. Volatility is an important indicator in assessing market risk and uncertainty, so accurate prediction methods are needed by investors, analysts, and policymakers. The JCI closing price data is converted into log returns and processed through cleaning, normalization, and sequence formation stages for modeling purposes. The GARCH(1,1) model is used to capture the nature of volatility clustering through a conditional variance approach, while LSTM is utilized to study non-linear patterns and long-term relationships in time series. The results show that GARCH(1,1) is able to describe volatility patterns in general, but is less responsive to sudden changes in volatility. In contrast, the LSTM model provides superior prediction performance with low prediction errors and high coefficient of determination values. These findings indicate that the deep learning approach is more effective in modeling the volatility dynamics of the Jakarta Composite Index (JCI) than traditional econometric methods, especially under volatile market conditions.

Keywords: JCI Volatility, GARCH, LSTM, Time Series Forecasting, Deep Learning

1. PENDAHULUAN

Pasar saham merupakan indikator penting dalam mencerminkan kondisi perekonomian suatu negara, di mana fluktuasi harga saham sering dipengaruhi oleh faktor ekonomi global, kebijakan moneter, dan sentimen investor. Ketidakstabilan harga saham menimbulkan volatilitas yang menjadi ukuran utama risiko pasar, sehingga pemodelan dan prediksi volatilitas sangat diperlukan untuk mendukung pengambilan keputusan investasi dan manajemen risiko yang efektif [1],[2]. Pada konteks Indonesia, Indeks Harga Saham Gabungan (IHSG) menunjukkan dinamika yang sensitif terhadap guncangan global, termasuk perubahan kebijakan bank sentral internasional serta pergerakan indeks luar negeri. Kondisi ini menjadikan prediksi volatilitas IHSG sebagai aspek yang penting dalam memahami perilaku pasar modal domestik.

Berbagai metode telah digunakan untuk memodelkan volatilitas, salah satunya adalah Generalized Autoregressive Conditional Heteroskedasticity (GARCH), yang telah terbukti efektif dalam menangkap fenomena volatility clustering serta perubahan varians bersyarat pada data keuangan [3], [4]. Model GARCH(1,1) merupakan salah satu model yang paling banyak digunakan dan memberikan performa yang baik dalam berbagai studi, termasuk pada pasar saham Indonesia [3]. Meskipun demikian, GARCH memiliki keterbatasan dalam memodelkan pola non-linear yang kompleks, terutama pada periode ketika pasar mengalami gejolak signifikan.

Seiring dengan berkembangnya teknologi kecerdasan buatan, metode berbasis deep learning seperti Long Short-Term Memory (LSTM) semakin banyak digunakan dalam prediksi deret waktu [5]. LSTM mampu menangkap hubungan non-linear serta dependensi jangka panjang yang sulit direpresentasikan oleh model statistik tradisional [6], [7]. Beberapa penelitian menunjukkan bahwa LSTM mampu memberikan akurasi prediksi volatilitas yang lebih tinggi dibandingkan model konvensional, baik pada pasar saham maupun aset keuangan lainnya [8], [9], [10].

Walaupun demikian, hasil-hasil penelitian sebelumnya masih menunjukkan inkonsistensi. Beberapa studi melaporkan bahwa GARCH unggul pada kondisi pasar yang relatif stabil, sedangkan penelitian lainnya menemukan bahwa LSTM lebih responsif terhadap perubahan volatilitas yang tiba-tiba [7], [11]. Selain itu, penelitian yang secara langsung membandingkan performa GARCH dan LSTM pada IHSG masih terbatas, khususnya yang menggunakan dataset periode panjang dan metrik evaluasi yang konsisten.

Berdasarkan kondisi tersebut, penelitian ini dilakukan untuk membandingkan kinerja model GARCH(1,1) dan LSTM dalam memprediksi volatilitas harian IHSG selama periode 2016–2025. Penelitian ini bertujuan memberikan pemahaman yang lebih komprehensif mengenai efektivitas kedua pendekatan tersebut dalam memodelkan volatilitas pasar Indonesia, serta memberikan kontribusi empiris bagi pengembangan strategi prediksi volatilitas yang lebih akurat dan adaptif.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode analisis deret waktu untuk memodelkan dan membandingkan volatilitas Indeks Harga Saham Gabungan (IHSG). Dua pendekatan utama digunakan, yaitu model ekonometrika GARCH dan model deep learning Long Short-Term Memory (LSTM). Pemilihan dua metode ini bertujuan untuk mengevaluasi kemampuan model tradisional dan model berbasis neural network dalam memprediksi volatilitas pasar. Penelitian dilakukan melalui beberapa tahapan sistematis, mulai dari pengumpulan data historis, preprocessing data, pengujian stasioneritas, pemodelan GARCH dan LSTM, hingga evaluasi performa menggunakan berbagai metrik kesalahan prediksi. Pendekatan ini memastikan bahwa hasil penelitian tidak hanya akurat secara statistik, tetapi juga relevan dalam konteks analisis volatilitas pasar keuangan.

2.1 Data dan Sumber Data

Data yang digunakan pada penelitian ini merupakan data harga penutupan (closing price) harian Indeks Harga Saham Gabungan (IHSG) untuk periode 2016–2025. Data diunduh menggunakan pustaka *yfinance* karena menyediakan data historis yang konsisten, lengkap, dan mudah diakses untuk analisis deret waktu [12]. Nilai harga penutupan kemudian diubah menjadi log return untuk menstabilkan varians serta memenuhi kebutuhan pemodelan volatilitas, sebagaimana umum digunakan dalam penelitian volatilitas pasar keuangan [2].

2.2 Preprocessing Data

Tahap preprocessing dilakukan untuk mempersiapkan data sebelum pemodelan. Tahapan yang dilakukan meliputi pemeriksaan nilai hilang, validasi tanggal transaksi, perhitungan log return, dan pembentukan data yang siap dianalisis. Normalisasi dilakukan menggunakan *MinMaxScaler* untuk memastikan skala data sesuai dengan karakteristik model LSTM yang sensitif terhadap perbedaan skala input.

Uji stasioneritas menggunakan Augmented Dickey–Fuller (ADF) diterapkan untuk memastikan bahwa deret log return memenuhi asumsi stasioneritas sebelum dimodelkan dengan GARCH [13]. Untuk keperluan LSTM, data diubah menjadi

sequence dengan jendela waktu 30 hari sehingga jaringan mampu mempelajari pola temporal jangka pendek maupun panjang. Selanjutnya, dataset dibagi menjadi data pelatihan (80%) dan data pengujian (20%) berdasarkan urutan waktu tanpa *shuffle* untuk menghindari *data leakage*.

2.3 Pemodelan GARCH

Model Generalized Autoregressive Conditional Heteroskedasticity (GARCH) digunakan sebagai pendekatan ekonometrika dasar dalam memodelkan volatilitas IHSG. GARCH(1,1) dipilih karena merupakan model yang paling umum digunakan dan mampu menangkap pola *volatility clustering* yang sering ditemui pada data keuangan [3], [14], [15].

Estimasi model dilakukan menggunakan persamaan mean sederhana tanpa komponen autoregresif yang kompleks, sementara persamaan varian mengikuti struktur standar GARCH(1,1) dengan parameter α dan β yang merepresentasikan pengaruh volatilitas jangka pendek dan jangka panjang. Model kemudian digunakan untuk menghasilkan prediksi volatilitas pada data pengujian secara *rolling forecast*.

2.4 Pemodelan LSTM

Long Short-Term Memory (LSTM) digunakan sebagai metode deep learning yang mampu menangkap hubungan non-linear serta ketergantungan jangka panjang pada deret waktu [6], [7]. Arsitektur model terdiri dari empat lapisan LSTM bertingkat dengan jumlah unit yang menurun secara bertahap, diikuti oleh *dense layer* sebagai pemetaan akhir.

Tabel 1. Parameter Proses Pelatihan LSTM

Parameter	Nilai
Epoch	Ditentukan menggunakan Early Stopping
Batch Size	32
Validation Split	10%
Loss Function	Mean Squared Error (MSE)
Optimizer	Adam
Learning Rate	0.001

Model dilatih menggunakan *optimizer Adam*, *loss function* Mean Squared Error, *batch size* 32, dan *Early Stopping* untuk mencegah *overfitting*. Input berupa sequence sepanjang 30 hari log return, sementara output adalah nilai volatilitas yang dihitung melalui *rolling standard deviation*. Proses pelatihan dilakukan menggunakan data pelatihan (80%) dan diuji pada 20% data sisanya. Arsitektur dan konfigurasi model mengacu pada penelitian terdahulu yang melaporkan performa tinggi LSTM dalam memodelkan volatilitas pasar [8], [9], [16].

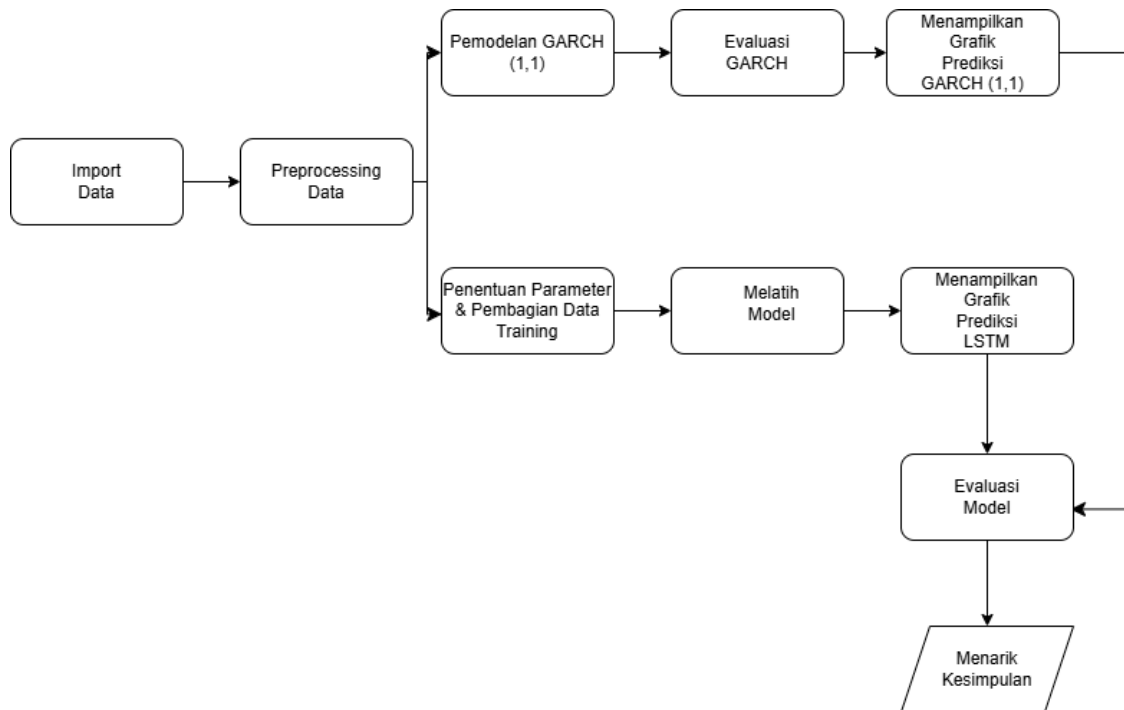
2.5 Evaluasi Model

Evaluasi model dilakukan untuk membandingkan performa GARCH(1,1) dan LSTM dengan menggunakan beberapa metrik kesalahan prediksi, yaitu Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), serta koefisien determinasi R^2 [17].

Semua evaluasi dilakukan pada data pengujian yang tidak digunakan dalam proses pelatihan model untuk mengukur kemampuan generalisasi. Perbandingan dilakukan dengan memastikan bahwa prediksi kedua model disejajarkan dengan nilai aktual agar evaluasi berlangsung adil dan konsisten.

2.6 Diagram Alur Penelitian

Alur penelitian mengikuti tahapan: pengambilan data, preprocessing, pemodelan GARCH, pemodelan LSTM, visualisasi prediksi, dan evaluasi model. Diagram ini menggambarkan aliran proses mulai dari input data hingga penarikan kesimpulan.



Gambar 1. Alur Penelitian

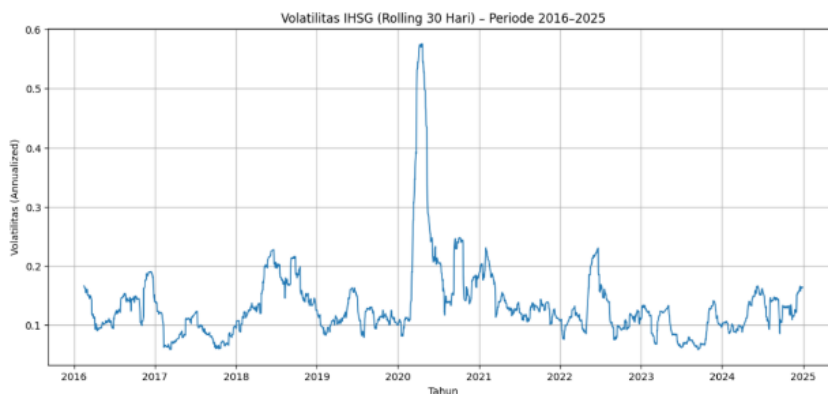
3. HASIL DAN PEMBAHASAN

Hasil penelitian diawali dengan proses preprocessing yang menghasilkan 2.180 observasi log return IHSG. Data telah dibersihkan dan dibagi menjadi 80% data pelatihan dan 20% data pengujian. Hasil preprocessing diringkas pada tabel berikut.

Tabel 2. Ringkasan Dataset Setelah Preprocessing

Keterangan	Nilai
Jumlah Data Total	2180
Jumlah Data Train	1744
Jumlah Data Test	436
Dimensi X_train	(1714, 30, 1)
Dimensi X_test	(406, 30, 1)

Proses tersebut memastikan bahwa data memiliki struktur yang sesuai untuk pemodelan GARCH dan pembentukan sequence sepanjang 30 hari untuk model LSTM. Pola volatilitas umum IHSG selama periode penelitian divisualisasikan berikut.



Gambar 2. Grafik Volatilitas IHSG Tahun 2016–2025

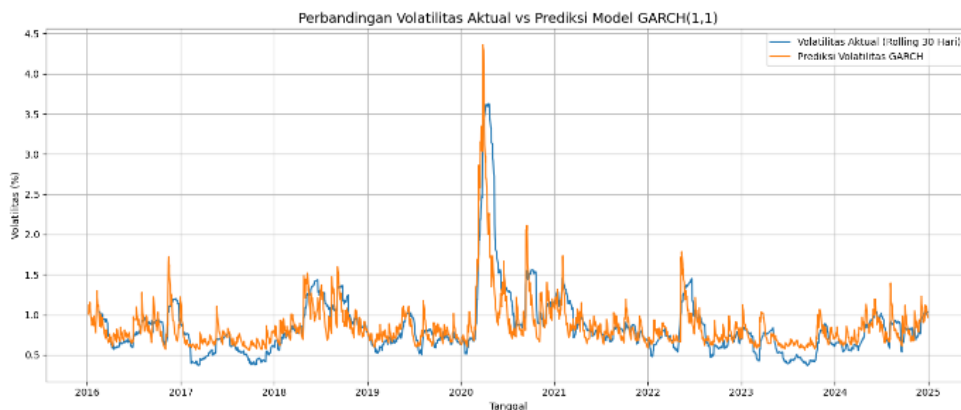
Visualisasi memperlihatkan periode volatilitas tinggi dan rendah yang muncul secara berkelompok, menunjukkan adanya volatility clustering yang menjadi dasar penggunaan GARCH(1,1) sebagai model baseline.

Pemodelan pertama dilakukan menggunakan GARCH(1,1). Estimasi parameter menunjukkan bahwa seluruh parameter utama signifikan secara statistik, dengan nilai β yang tinggi yang menandakan adanya persistensi volatilitas jangka panjang. Ringkasan parameter ditunjukkan pada tabel berikut.

Tabel 3. Estimasi Parameter Model GARCH(1,1)

Parameter	Koefisien	Std. Error	t-Statistik	p-value
Mean Model				
Const	0.0311	0.01637	1.903	0.05699
AR(1)	-0.0223	0.02384	-0.937	0.349
Volatility Model (GARCH)				
ω (omega)	0.0516	0.02629	1.963	0.04960
α_1 (alpha)	0.1238	0.04098	3.022	0.00251
β_1 (beta)	0.8105	0.06817	11.889	1.35e-32
$\alpha + \beta$	0.9343	–	–	–


Hasil estimasi tersebut mengindikasikan bahwa pergerakan volatilitas IHSG sangat dipengaruhi oleh informasi masa lalu dan cenderung bertahan dalam jangka waktu panjang. Prediksi volatilitas yang dihasilkan oleh model dibandingkan dengan nilai aktual pada gambar berikut.



Gambar 3. Perbandingan Volatilitas Aktual dan Prediksi GARCH(1,1)

Model GARCH terlihat mampu mengikuti pola utama volatilitas, namun responsnya cenderung lebih lambat saat terjadi lonjakan volatilitas secara tiba-tiba, yang merupakan salah satu keterbatasan model yang bersifat linear dan bergantung pada varians historis.

Pemodelan selanjutnya menggunakan LSTM yang dilatih menggunakan arsitektur empat lapis dengan jumlah unit yang menurun secara bertahap. Model ini mampu mempelajari pola non-linear dan ketergantungan jangka panjang secara lebih fleksibel. Hasil prediksi ditunjukkan pada gambar berikut.



Gambar 4. Perbandingan Volatilitas Aktual dan Prediksi LSTM

Garis prediksi LSTM terlihat sangat dekat dengan nilai aktual, termasuk pada periode terjadinya lonjakan volatilitas. Hal ini menunjukkan bahwa model mampu menangkap perubahan dinamika pasar yang tidak linear, sehingga menghasilkan prediksi yang lebih akurat dibandingkan GARCH.

Evaluasi kinerja kedua model dilakukan menggunakan RMSE, MAE, MAPE, dan R². Ringkasan hasil evaluasi ditunjukkan pada tabel berikut.

Tabel 4. Hasil Evaluasi Model GARCH dan LSTM

Metrik	GARCH	LSTM
RMSE (Root Mean Square Error)	0.241354	0.006726
MAE (Mean Absolute Error)	0.156754	0.004570
MAPE (Mean Absolute Percentage Error)	18.858612%	4.791961%
SR ² (Koefisien Determinasi)	0.649921	0.949340

Hasil evaluasi menunjukkan bahwa LSTM memiliki performa yang jauh lebih baik dibandingkan GARCH. Nilai kesalahan prediksi pada LSTM sangat rendah, sementara nilai R² mendekati 1, menandakan kemampuan model dalam menjelaskan hampir seluruh variasi volatilitas aktual. Sebaliknya, GARCH memiliki tingkat kesalahan lebih tinggi dan hanya mampu menjelaskan sekitar dua pertiga dari variasi volatilitas.

Perbandingan menyeluruh mengindikasikan bahwa LSTM lebih unggul dalam memprediksi volatilitas IHSIG, terutama pada periode dengan fluktuasi tajam. Namun demikian, GARCH tetap memberikan gambaran yang informatif sebagai model baseline yang sederhana dan interpretatif.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa model GARCH(1,1) mampu menggambarkan pola volatilitas IHSIG secara umum, terutama pada periode ketika volatilitas bergerak secara bertahap dan membentuk pola *volatility clustering*. Namun, model ini kurang responsif dalam menangkap perubahan volatilitas yang terjadi secara mendadak sehingga tingkat akurasi masih terbatas. Sebaliknya, model LSTM memberikan performa prediksi yang jauh lebih baik dengan nilai kesalahan yang rendah dan kemampuan penjelasan yang sangat tinggi. Model ini mampu mengikuti dinamika volatilitas yang bersifat non-linear dan fluktuatif sehingga menghasilkan prediksi yang lebih mendekati nilai aktual.

Berdasarkan hasil tersebut, dapat disimpulkan bahwa LSTM merupakan model yang lebih efektif dalam memprediksi volatilitas harian IHSIG dibandingkan GARCH(1,1). Meskipun demikian, GARCH tetap memiliki nilai sebagai model dasar yang sederhana dan interpretatif dalam analisis volatilitas. Hasil penelitian ini diharapkan dapat menjadi rujukan dalam pemilihan metode prediksi volatilitas pada pasar modal Indonesia serta mendorong pengembangan model prediksi yang lebih adaptif terhadap perubahan kondisi pasar.

DAFTAR PUSTAKA

- [1] D. Khalishah *et al.*, “PERBANDINGAN PERFORMA ARIMAX-GARCH DAN LSTM PADA DATA HARGA PENUTUPAN SAHAM PT ANEKA TAMBANG TBK (ANTM . JK) COMPARISON OF ARIMAX-GARCH AND LSTM PERFORMANCE ON PT ANEKA TAMBANG TBK (ANTM . JK) STOCK CLOSING PRICE DATA,” vol. 12, no. 3, pp. 695–704, 2025.
- [2] M. R. Bahtiar, “Volatility Forecasts Jakarta Composite Index (JCI) and Index Stock Volatility Sector with Estimated Time Series Volatility Forecasts Jakarta Composite Index (JCI) and Index Stock Volatility Sector with Estimated Time Series,” vol. 12, no. 1, 2020, doi: 10.21002/icmr.v12i1.12049.
- [3] T. Hutapea, “Analysis of Volatility of the Return of Composite Stock Price Index Using ARCH / GARCH Model , January 2015 - September 2024 Analisis Volatilitas Return Indeks Harga Saham Gabungan (ISHG) Memakai Model ARCH / GARCH , Januari 2015 – september 2024,” vol. 7, no. 1, 2025, doi: 10.59806/jkamtb.v7i1.498.
- [4] A. A. Tanjung and D. P. Sari, “Analisis Dinamika Volatilitas Indeks Harga Saham Gabungan (IHSG) : Aplikasi Model Threshold GARCH,” vol. 5, no. 4, pp. 441–447, 2025, doi: 10.47065/jtear.v5i4.2096.
- [5] D. A. Adha, A. Ramadhan, H. Maulana, P. P. H. Harahap, and E. Ismanto, “Jurnal Computer Science and Information Technology (CoSciTech) Peramalan Harga Emas Berbasis Time Series Menggunakan Arsitektur LSTM Deep Learning Gold Price Forecasting Based on Time Series Using the LSTM Deep Learning Architecture,” vol. 6, no. 2, pp. 329–336, 2025.
- [6] W. Jiang, “Applications of deep learning in stock market prediction: recent progress,” pp. 1–97.
- [7] L. Wahyuni, S. Abusini, and M. Kumiawaty, “Prediction of Jakarta Composite Index Volatility Using Long Short Term Memory,” no. 04, pp. 32–40, 2022.
- [8] A. G. Medina and E. A. Moreno, *LSTM – GARCH Hybrid Model for the Prediction of Volatility in Cryptocurrency Portfolios*, no. 0123456789. Springer US, 2023. doi: 10.1007/s10614-023-10373-8.
- [9] E. Koo and G. Kim, “A Hybrid Prediction Model Integrating GARCH Models With a Distribution Manipulation Strategy Based on LSTM Networks for Stock Market Volatility,” *IEEE Access*, vol. 10, pp. 34743–34754, 2022, doi: 10.1109/ACCESS.2022.3163723.
- [10] K. Kasus, H. Covid-, P. Saham, P. Vaksin, M. Long, and S. M. Lstm, “Jurnal Computer Science and Information Technology (CoSciTech),” vol. 6, no. 2, pp. 181–188, 2025.
- [11] I. M. A. Dharmaningrat and K. V. I. Saputra, “Predicting the Volatility of Jakarta Composite Index Using GARCH and LSTM with Volume-Up Strategy Approach,” vol. 11, no. 3, pp. 311–322, 2025.
- [12] W. Budiharto, “Data science approach to stock prices forecasting in Indonesia during Covid - 19 using Long Short - Term Memory (LSTM),” *J. Big Data*, 2021, doi: 10.1186/s40537-021-00430-0.
- [13] S. P. Bhardwaj, R. K. Paul, D. R. Singh, and K. N. Singh, “An Empirical Investigation of Arima and Garch Models in Agricultural Price Forecasting,” vol. 59, no. 3, pp. 415–428, 2014, doi: 10.5958/0976-4666.2014.00009.6.
- [14] E. Rafulta, F. Yanuar, D. Devianto, and I. Artikel, “Pemodelan dan Peramalan Volatilitas Memori Panjang pada Return Saham ANTM Studi Komparatif Model GARCH dan,” vol. 5, no. 1, pp. 75–89, 2025.
- [15] B. Jange, “Prediksi Volatilitas Indeks Harga Saham Gabungan Menggunakan GARCH,” vol. 4, no. 1, pp. 1–6, 2023, doi: 10.47065/arbitrase.v4i1.1122.
- [16] J. Kumiansyah, S. K. Gusti, F. Yanto, and M. Affandes, “Implementasi Model Long Short Term Memory (LSTM) dalam Prediksi Harga Saham,” vol. 6, no. 2, pp. 79–86, 2025, doi: 10.47065/bit.v5i2.1783.
- [17] D. M. Legawa, M. R. Rizqullah, A. P. Sari, S. P. Prediction, D. Learning, and T. Series, “Penerapan algoritma lstm untuk prediksi harga saham byd”.