

PERBANDINGAN KINERJA MODEL GARCH DAN LSTM DALAM MEMPREDIKSI VOLATILITAS HARIAN IHSG

Gabriel Fernando Sitorus

Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Medan, Medan, Indonesia, gabrielfernandositorus@gmail.com*

Yolanda Angelina Sitorus

Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Medan, Medan, Indonesia, yolandasitorus1407@gmail.com

Gracia Domini Simarmata

Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Medan, Medan, Indonesia, graciadms2604@gmail.com

Abstrak

Pasar saham merupakan instrumen keuangan yang rentan terhadap fluktuasi harga, yang dipengaruhi oleh faktor ekonomi, kebijakan pemerintah, dan sentimen investor. Volatilitas harga saham menjadi indikator penting untuk menilai risiko dan dinamika pasar, sehingga prediksi volatilitas harian memiliki peran strategis bagi investor dan pengambil kebijakan. Penelitian ini bertujuan untuk membandingkan kinerja model GARCH(1,1) dan Long Short-Term Memory (LSTM) dalam memprediksi volatilitas harian Indeks Harga Saham Gabungan (IHSG) pada periode 2016–2025. Data harga penutupan diolah menjadi log return dan melalui *preprocessing*, termasuk pembersihan, normalisasi, dan pembentukan *sequence* untuk kebutuhan pemodelan LSTM. Hasil penelitian menunjukkan bahwa GARCH(1,1) mampu menangkap pola volatilitas IHSG secara memadai, namun memiliki keterbatasan dalam menangani perubahan volatilitas yang cepat. Sebaliknya, LSTM menunjukkan performa prediksi yang lebih unggul dengan kesalahan prediksi rendah dan kemampuan penjelasan tinggi yang menunjukkan keunggulan dalam menangkap dinamika non-linear dan ketergantungan jangka panjang pada data volatilitas.

Kata Kunci: Volatilitas IHSG, GARCH (1,1), LSTM, Peramalan Deret Waktu, Deep Learning.

Abstract

The stock market is a financial instrument susceptible to price fluctuations, influenced by economic factors, government policies, and investor sentiment. Stock price volatility is an important indicator for assessing market risk and dynamics, thus predicting daily volatility plays a strategic role for investors and policymakers. This study aims to compare the performance of the GARCH(1,1) and Long Short-Term Memory (LSTM) models in predicting daily volatility of the Jakarta Composite Index (JCI) for the 2016–2025 period. Closing price data is processed into log returns and undergoes preprocessing, including cleaning, normalization, and sequence formation for LSTM modeling needs. The results show that GARCH(1,1) is able to adequately capture JCI volatility patterns, but has limitations in handling rapid volatility changes. In contrast, LSTM demonstrates superior predictive performance with low prediction errors and high explanatory power, indicating its superiority in capturing non-linear dynamics and long-term dependencies in volatility data.

Keywords: IHSG Volatility, GARCH (1,1), LSTM, Time Series Forecasting, DEEP Learning.

PENDAHULUAN

Prediksi volatilitas semakin krusial dalam pasar keuangan modern karena pergerakan harga dipengaruhi tidak hanya oleh kondisi ekonomi domestik, tetapi juga oleh dinamika global yang cepat. Faktor-faktor seperti ketidakstabilan ekonomi dunia, perubahan kebijakan suku

bunga di negara besar, serta sentimen investor yang mudah berubah menjadikan volatilitas pasar saham sebagai indikator penting untuk memahami arah ekonomi. Di Indonesia, IHSG sering mencerminkan respons pasar terhadap perubahan tersebut, sehingga pemahaman terhadap pola volatilitasnya memiliki nilai strategis bagi

investor maupun pembuat kebijakan (Sulistyowati & Rahmawati, 2020).

Dalam upaya memodelkan volatilitas, terdapat dua pendekatan utama yang umum digunakan, yakni model statistik klasik seperti GARCH dan metode berbasis kecerdasan buatan seperti LSTM. Model GARCH populer karena terbukti efektif dalam menangkap fenomena *volatility clustering*, yaitu kecenderungan volatilitas tinggi muncul secara berurutan dalam periode tertentu (Bakhtiar, 2020). Di sisi lain, LSTM menawarkan pendekatan modern yang mampu menangkap pola non-linear serta hubungan jangka panjang dalam data keuangan—hal yang sering sulit ditangani oleh model statistik tradisional. Kemampuan ini membuat LSTM semakin diminati sebagai metode prediksi pasar saham, termasuk untuk memperkirakan volatilitas IHSG (Wahyuni et al., 2022).

Namun, kajian literatur menunjukkan bahwa kinerja kedua pendekatan tersebut tidak selalu konsisten. Beberapa studi melaporkan bahwa model GARCH tetap mampu memberikan prediksi yang andal pada pasar dengan pola volatilitas yang relatif stabil, termasuk pada IHSG (Jange, 2023). Sebaliknya, penelitian lain menemukan bahwa GARCH kurang responsif ketika pasar mengalami perubahan cepat atau volatilitas dipengaruhi oleh faktor eksternal yang bersifat non-linear (Huang & Luo, 2024). Ketidakkonsistenan ini menimbulkan pertanyaan mengenai relevansi GARCH dalam memprediksi volatilitas pada pasar Indonesia yang kian kompleks.

Di sisi lain, model LSTM juga menghadapi sejumlah tantangan. Meskipun mampu menangkap pola yang kompleks, kinerjanya sangat bergantung pada kualitas data, panjang *sequence*, dan pengaturan *hyperparameter*. Beberapa studi menunjukkan peningkatan akurasi yang signifikan saat LSTM diterapkan, terutama pada data deret waktu dengan pola non-linear yang kuat (García & Aguayo, 2024). Namun, terdapat pula penelitian yang menemukan bahwa LSTM tidak selalu lebih unggul dibandingkan model statistik tradisional, terutama pada pasar yang relatif stabil atau ketika data kurang bervariasi. Ketidakkonsistenan hasil ini menciptakan *research gap*, karena belum ada kesimpulan yang jelas mengenai model mana yang lebih efektif, khususnya untuk prediksi volatilitas harian IHSG. Berdasarkan kondisi tersebut, penelitian ini menjadi penting untuk dilakukan. Dengan membandingkan kinerja GARCH dan LSTM menggunakan data IHSG yang sama serta metode evaluasi yang konsisten, penelitian ini diharapkan dapat memberikan gambaran yang lebih objektif mengenai kelebihan dan keterbatasan masing-masing pendekatan. Selain itu, relevansi penelitian ini meningkat mengingat pasar modal Indonesia kini bergerak dalam lingkungan yang semakin kompleks dan dipengaruhi oleh faktor eksternal yang sulit diprediksi. Penelitian ini bertujuan untuk menentukan model prediksi volatilitas yang paling akurat dan adaptif, sehingga hasilnya dapat memberikan kontribusi praktis bagi investor, analis, dan pembuat kebijakan dalam mengelola risiko pasar (Dharmaningrat et al., 2025).

Kajian Teori

Pemodelan volatilitas pasar saham berangkat dari dua pendekatan besar: model ekonometrika tradisional dan model *deep learning*. Di antara pendekatan klasik, GARCH menjadi model yang paling banyak digunakan karena kemampuannya menangkap fenomena *volatility clustering*, yakni pola ketika periode volatilitas tinggi dan rendah terjadi secara berkelompok (Bakhtiar, 2020; Fitriyani et al., 2025). Dengan struktur parameter yang sederhana, GARCH mampu menggambarkan persistensi guncangan volatilitas dari waktu ke waktu dan menjadi dasar bagi banyak model turunan. Namun, di era komputasi modern, LSTM (Long Short-Term Memory) menawarkan alternatif yang lebih fleksibel. LSTM dirancang untuk mengenali pola urutan dan dependensi jangka panjang pada data deret waktu, yang membuatnya efektif dalam mempelajari hubungan non-linear yang sering kali muncul pada pergerakan indeks saham (Jiang, 2021; Wahyuni et al., 2022). Kedua pendekatan ini kemudian menjadi pusat perhatian banyak penelitian, terutama ketika pasar bergerak semakin cepat dan kompleks sehingga menuntut model prediksi yang lebih adaptif.

Sejumlah penelitian yang membandingkan performa GARCH dan LSTM menunjukkan hasil yang tidak konsisten. Pada satu sisi, GARCH terbukti masih mampu memberikan estimasi volatilitas yang stabil ketika pasar menunjukkan struktur risiko yang relatif teratur, sebagaimana terlihat pada berbagai kajian terhadap IHSG yang menegaskan bahwa GARCH(1,1) dapat menangkap heteroskedastisitas secara memadai (Jange, 2023; Hutapea, 2025). Selain itu, model TGARCH yang diterapkan pada IHSG memperlihatkan bahwa variasi GARCH yang menangkap efek asimetris mampu meningkatkan akurasi ketika pasar menunjukkan respons lebih kuat terhadap berita negatif dibandingkan berita positif (Tanjung et al., 2025). Studi internasional bahkan menunjukkan bahwa model GARCH dengan komponen memori panjang, pergantian rezim, dan distribusi heavy-tail dapat memberikan hasil yang lebih baik dalam kondisi pasar tertentu, menunjukkan fleksibilitas teori GARCH ketika dimodifikasi secara struktural (Huang & Luo, 2024). Pada konteks volatilitas IHSG sendiri, keterkaitan lintas pasar juga terbukti memengaruhi pergerakan volatilitas, menambah tantangan bagi model prediksi tradisional karena pasar domestik tidak bergerak dalam isolasi (Lesmana, 2022; Stevanus & Sukamulja, 2020). Hasil-hasil tersebut memperlihatkan bahwa meskipun GARCH memiliki fondasi teoritis yang kuat, efektivitasnya sangat bergantung pada dinamika pasar yang sedang berlangsung.

Di sisi lain, penelitian berbasis LSTM memperlihatkan potensi keunggulan dalam menangkap ketergantungan pola yang lebih rumit dan non-linear. Dalam konteks IHSG, model LSTM menunjukkan kemampuan membaca pola volatilitas yang tidak dapat ditangkap oleh model linier sederhana dan cenderung lebih akurat dalam periode pasar yang bergejolak (Wahyuni et al., 2022). Temuan ini sejalan dengan tren global di mana *deep learning* semakin dikenal sebagai pendekatan yang unggul dalam lingkungan data yang kompleks (Jiang, 2021). Namun, performa LSTM tidak selalu stabil; kualitas prediksi sangat dipengaruhi oleh pemilihan struktur jaringan, panjang *sequence*, serta konfigurasi *hyperparameter*. Ketika parameter tidak dirancang dengan tepat atau data pelatihan tidak cukup panjang, LSTM dapat menghasilkan prediksi yang kurang reliabel atau mengalami *overfitting*. Penggunaan LSTM pada pasar lain seperti kripto menunjukkan bahwa, meskipun model ini dapat memberikan peningkatan akurasi, hasilnya sangat bergantung pada komposisi data dan horizon waktu yang diuji (García-Medina & Aguayo-Moreno, 2024). Pendekatan hibrida seperti integrasi LSTM-GARCH juga telah menunjukkan performa yang lebih stabil, meskipun peningkatannya tidak selalu signifikan (Koo & Kim, 2022). Temuan-temuan ini menegaskan bahwa LSTM dapat menjadi alternatif kuat ketika pasar menunjukkan residu non-linear, tetapi tidak menjamin performa yang konsisten pada semua kondisi pasar.

Kompleksitas hubungan antar pasar juga menjadi faktor sensitif yang memengaruhi keberhasilan kedua model tersebut. IHSG, misalnya, memiliki keterkaitan yang erat dengan pergerakan indeks global seperti DJIA, SSEC, dan Nikkei, sehingga guncangan pada pasar luar negeri dapat dengan cepat memengaruhi dinamika volatilitas domestik (Lesmana, 2022). Keterkaitan lintas pasar tersebut menunjukkan bahwa prediksi volatilitas tidak hanya bergantung pada karakteristik internal IHSG tetapi juga pada kondisi eksternal yang sering kali tidak dapat ditangkap secara langsung oleh model tradisional. Pada skala sistemik, volatilitas bahkan dapat menjadi saluran transmisi risiko yang dapat berkontribusi pada instabilitas keuangan, sehingga kesalahan estimasi model dapat berimplikasi lebih besar dari sekadar ketidaktepatan prediksi statistik (Mieg, 2022). Selain itu, kualitas prediksi juga sangat dipengaruhi oleh horizon waktu, frekuensi data, dan pemilihan variabel, di mana GARCH maupun LSTM dapat menunjukkan performa yang berbeda pada kondisi pasar yang berbeda pula (Bakhtiar, 2020). Dengan demikian, sensitivitas terhadap konteks pasar, kualitas data, dan konfigurasi teknis menjadi salah satu alasan

utama mengapa tidak ada model tunggal yang secara tegas dapat dinyatakan unggul dalam memprediksi volatilitas IHSG.

Berdasarkan analisis literatur yang tersedia, dapat disimpulkan bahwa baik GARCH maupun LSTM memiliki keunggulan dan kelemahan masing-masing, dan bukti empiris sejauh ini belum menunjukkan konsensus yang jelas mengenai model mana yang paling unggul. Model GARCH kuat pada pasar dengan struktur volatilitas yang stabil dan dapat diinterpretasikan dengan jelas, sedangkan LSTM unggul dalam pasar dengan pola non-linear yang kuat. Namun, sebagian besar penelitian di Indonesia masih menggunakan salah satu pendekatan secara terpisah. Penelitian hibrida mulai dilakukan tetapi lebih berfokus pada integrasi model, bukan pada perbandingan sistematis antara GARCH dan LSTM sebagai dua pendekatan independen (Dharmaningrat et al., 2025). Dengan kata lain, terdapat kesenjangan penelitian yang jelas, yaitu belum adanya kajian yang secara langsung dan terstandar membandingkan performa kedua model dalam memprediksi volatilitas harian IHSG menggunakan dataset, horizon waktu, dan metrik evaluasi yang konsisten. Kesenjangan inilah yang menjadi dasar penelitian Anda untuk memberikan pemahaman yang lebih komprehensif mengenai efektivitas masing-masing model dalam konteks pasar modal Indonesia.

METODE

Data yang digunakan dalam penelitian ini merupakan data harga penutupan (closing price) harian Indeks Harga Saham Gabungan (IHSG) selama periode 1 Januari 2016 hingga 31 Desember 2025. Pemilihan periode sepuluh tahun dilakukan untuk memastikan tersedianya deret waktu yang cukup panjang dan representatif, sehingga karakteristik volatilitas dapat ditangkap secara lebih stabil dan akurat oleh kedua model yang dibandingkan, baik GARCH maupun LSTM. Data diperoleh melalui pustaka Python *yfinance*, yaitu modul yang menyediakan akses langsung ke data pasar yang bersumber dari Yahoo Finance. Pemilihan *yfinance* dilakukan karena data yang disediakan bersifat real-time, historis, dan konsisten, memiliki kelengkapan frekuensi data harian, dan dapat diakses secara langsung melalui kode Python tanpa proses pengunduhan manual, sehingga meminimalkan risiko kesalahan input data.

Variabel utama yang digunakan adalah harga penutupan IHSG, yang selanjutnya diubah menjadi log return untuk memperoleh deret waktu

yang stasioner. Log return dihitung menggunakan formula:

$$r_t = \ln \frac{p_t}{p_{t-1}}$$

di mana P_t adalah harga penutupan IHSG pada hari ke- t . Penggunaan log return dipilih karena mampu menstabilkan varians, menghindari nilai negatif yang tidak realistis pada rasio harga, serta merupakan standar umum dalam analisis volatilitas keuangan.

Seluruh data yang diperoleh kemudian dibagi menjadi dua bagian, yaitu 80% sebagai data pelatihan (training set) dan 20% sebagai data pengujian (testing set). Pembagian ini mengikuti praktik umum dalam machine learning dan pemodelan deret waktu, sehingga model dapat mempelajari pola historis secara cukup mendalam tanpa kehilangan kemampuan generalisasi pada periode yang belum pernah dilihat sebelumnya.

Preprocessing dilakukan untuk memastikan bahwa data yang digunakan dalam pemodelan memiliki kualitas yang baik, memenuhi asumsi struktural dari masing-masing metode, serta siap diproses oleh algoritma machine learning maupun model statistik. Tahapan preprocessing yang dilakukan adalah sebagai berikut:

Tahap pertama adalah memeriksa keberadaan nilai hilang (missing value), anomali harga, atau duplikasi tanggal transaksi. Karena data pasar keuangan umumnya telah terstandarisasi, kemungkinan missing value relatif kecil; namun tetap dilakukan pengecekan sistematis. Nilai hilang yang muncul akibat hari libur bursa tidak diimputasi, melainkan dibiarkan sebagai skip alami, karena harga penutupan hanya tersedia pada hari perdagangan.

Setelah data harga penutupan dinyatakan valid, data ditransformasi menjadi log return menggunakan :

$$r_t = \ln \frac{p_t}{p_{t-1}}$$

Transformasi ini dilakukan supaya log return lebih stabil secara statistik, log return membuat proses lebih dekat dengan asumsi stasioneritas, model GARCH dan LSTM tetap membutuhkan return sebagai basis pembentukan volatilitas.

Nilai return pada observasi pertama akan hilang secara otomatis karena formula relatif terhadap $P_t - 1$.

Sebelum membangun model GARCH, dilakukan pemeriksaan stasioneritas deret return menggunakan Augmented Dickey-Fuller (ADF). Return pada umumnya sudah stasioner, tetapi uji tetap diperlukan untuk memastikan validitas model. Jika ditemukan ketidakstasioneran, dilakukan differencing tambahan, namun hal ini jarang terjadi pada log return IHSG.

Karena LSTM akan memprediksi volatilitas langsung, bukan return, maka target nilai volatilitas disusun dengan pendekatan rolling standard deviation jangka pendek:

$$\sigma_t^2 = \sqrt{\frac{1}{n} \sum_{i=1}^n (r_{t-i} - \bar{r})^2}$$

Setelah dihitung, volatilitas akan dinormalisasi (misalnya menggunakan MinMaxScaler atau StandardScaler) agar kompatibel dengan jaringan LSTM yang sensitif terhadap skala data.

Dataset hasil preprocessing kemudian dibagi menjadi: 80% untuk training dan 20% untuk testing. Pembagian dilakukan setelah preprocessing dengan tujuan menghindari data leakage, sequence supaya LSTM tidak terpotong secara arbitrer sebelum dibentuk menjadi window, memastikan model diuji menggunakan urutan waktu yang sebenarnya (no-shuffle). Karena LSTM memiliki sifat menghasilkan prediksi yang mulai bergeser (*lagging*) karena proses sequence input. Ini menyebabkan perbedaan panjang antara: data actual dan data prediksi. Untuk mencegah error pada evaluasi (RMSE, MAE, MAPE, R^2), dilakukan penyesuaian: Prediksi LSTM dimulai pada titik ke (*window size+1*). Sehingga jumlah prediksi selalu identik dengan jumlah data aktual yang digunakan untuk testing. Dengan demikian, perbandingan performa antar model konsisten dan tidak memunculkan bias teknis akibat perbedaan panjang vektor.

Setelah melalui tahap *preprocessing*, di lanjutkan ke tahap selanjutnya, yaitu tahap pemodelan. Pada tahap pemodelan, penelitian ini membandingkan dua pendekatan pemodelan volatilitas, yaitu model statistik tradisional GARCH(1,1) dan model berbasis *deep learning* Long Short-Term Memory (LSTM). Model Generalized Autoregressive Conditional Heteroskedasticity (GARCH) digunakan untuk memodelkan volatilitas

return IHSG berdasarkan sifat heteroskedastik dan volatilitas yang berubah-ubah (volatility clustering) pada pasar keuangan. Dalam penelitian ini digunakan model GARCH(1,1) karena merupakan model yang paling umum, stabil, dan terbukti efektif untuk memprediksi volatilitas jangka pendek pada indeks saham. Model GARCH (1,1) terdiri dari dua komponen yaitu : Persamaan Mean dan Persamaan Varian. Karena fokus penelitian adalah volatilitas, persamaan mean ditetapkan sebagai model sederhana tanpa komponen autoregressive:

$$r_t = \mu + \epsilon_t, \epsilon_t = \sigma_t z_t$$

di mana:

- r_t = log return IHSG pada waktu t,
- μ = mean return,
- ϵ_t = residual,
- z_t = white noise berdistribusi Student-t atau Gaussian (akan dibandingkan saat estimasi).

Model GARCH(1,1) mendefinisikan varians bersyarat sebagai:

$$\sigma_t^2 = \omega + \alpha \epsilon_{t-1}^2 + \beta \sigma_{t-1}^2$$

dengan:

- $\omega > 0$: konstanta,
- $\alpha \geq 0$: efek volatilitas jangka pendek (ARCH effect),
- $\beta \geq 0$: efek volatilitas jangka panjang (GARCH effect).

Kondisi kestabilan model:

$$\alpha + \beta < 1$$

Jika syarat ini terpenuhi, volatilitas bersifat stasioner secara varians.

Model GARCH yang telah diestimasi digunakan untuk melakukan prediksi volatilitas pada horizon satu langkah ke depan (one-step-ahead forecast) untuk seluruh periode testing (20% data terakhir). Peramalan dilakukan secara rolling untuk memastikan model tidak menggunakan informasi masa depan.

Hasil prediksi berupa:

$$\hat{\sigma}_t = \sqrt{\sigma_t^2}$$

yang kemudian akan dibandingkan dengan volatilitas aktual (rolling volatility), dan prediksi dari model LSTM. Model Long Short-Term Memory (LSTM) digunakan sebagai pendekatan berbasis deep learning untuk memprediksi volatilitas harian IHSG. LSTM dipilih karena mampu menangkap hubungan non-linear, pola jangka panjang, serta dinamika kompleks pada deret waktu keuangan yang tidak dapat dimodelkan secara optimal oleh model linear seperti GARCH.

Pada penelitian ini digunakan deep LSTM dengan empat lapisan (4-layer), karena arsitektur yang terlalu dalam seperti 20 layer berpotensi menyebabkan overfitting, exploding gradient, dan ketidakstabilan model. Empat layer merupakan kedalaman yang secara empiris optimal dan seimbang antara stabilitas, kapasitas belajar, dan akurasi prediksi.

Arsitektur LSTM yang digunakan adalah sebagai berikut:

1. Input layer: menerima sequence log return sepanjang 30 hari (window = 30).
2. LSTM Layer 1 : 64 unit, return_sequences = True.
3. LSTM Layer 2 : 64 unit, return_sequences = True.
4. LSTM Layer 3 : 32 unit, return_sequences = True.
5. LSTM Layer 4 : 16 unit, return_sequences = False.
6. Dense Layer : 1 unit output untuk menghasilkan prediksi volatilitas.

Aktivasi yang digunakan adalah tanh, sedangkan metode regularisasi dropout diterapkan untuk menghindari overfitting.

Pelatihan dilakukan menggunakan konfigurasi berikut:

Tabel 1. Parameter Proses Pelatihan Model LSTM

| Parameter | Nilai |
|------------------|---------------------------------------|
| Epoch | Ditentukan menggunakan Early Stopping |
| Batch Size | 32 |
| Validation Split | 10% |

| Parameter | Nilai |
|---------------|--------------------------|
| Loss Function | Mean Squared Error (MSE) |
| Optimizer | Adam |
| Learning Rate | 0.001 |

Model dilatih menggunakan dataset hasil preprocessing yang terdiri dari input (X) berbentuk sequence dan target (Y) berupa volatilitas aktual (rolling volatility). Pembagian data dilakukan berdasarkan urutan waktu tanpa melakukan shuffle, karena data deret waktu harus mempertahankan hubungan temporal.

Setelah pelatihan selesai, model melakukan prediksi volatilitas pada 20% data testing. Proses prediksi mengikuti aturan:

$$\hat{\sigma}_t = f(X_t)$$

di mana:

- X_t adalah sequence 30 hari sebelumnya,
- $f(\cdot)$ adalah fungsi pemetaan yang dipelajari oleh jaringan LSTM.

Output prediksi kemudian di inverse transform untuk mengembalikannya ke satuan volatilitas asli.

Karena model LSTM menggunakan *window size* 30, maka prediksi pertama baru dapat dihasilkan pada titik observasi ke-31. Dengan demikian, prediksi dan nilai aktual harus disejajarkan terlebih dahulu agar evaluasi model (RMSE, MAE, MAPE, R^2) tidak memberikan error dimensi. Solusi ini diterapkan adalah memotong 30 titik pertama dari nilai aktual yang ada pada data Test Sehingga evaluasi metrik dapat dilakukan dengan konsisten dan tanpa error.

Setelah model selesai dilatih lalu di lanjutkan dengan evaluasi model, evaluasi model dilakukan untuk mengukur kinerja prediksi volatilitas harian IHSG oleh kedua model, yaitu GARCH(1,1) dan LSTM. Evaluasi dilakukan menggunakan beberapa metrik statistik yang umum digunakan dalam pemodelan deret waktu dan peramalan volatilitas keuangan. Seluruh evaluasi

dilakukan pada 20% data testing, yang tidak digunakan pada proses pelatihan model. Agar evaluasi dapat dilakukan secara konsisten, model LSTM telah disesuaikan untuk menghilangkan efek lag akibat penggunaan window size, sehingga jumlah observasi antara prediksi LSTM dan nilai aktual identik. Untuk model GARCH, prediksi dilakukan secara rolling sehingga perbedaan dimensi data tidak terjadi. Beberapa uji yang di gunakan dalam evaluasi model pada penelitian ini adalah: Mean Square Error (MSE), Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE).

MSE mengukur rata-rata kesalahan kuadrat antara nilai aktual dan prediksi. MSE memberikan penalti yang besar terhadap kesalahan besar sehingga sensitif terhadap outlier.

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2$$

Metrik ini memberikan penalti lebih besar pada error yang ekstrem, sehingga cocok dalam data volatilitas yang sensitif terhadap lonjakan.

RMSE merupakan akar dari MSE dan memberikan interpretasi kesalahan dalam satuan yang sama dengan variabel volatilitas.

$$RMSE = \sqrt{MSE}$$

Memudahkan interpretasi karena memiliki satuan yang sama dengan data asli.

MAE mengukur rata-rata kesalahan absolut antara prediksi dan nilai aktual. MAE lebih robust terhadap outlier dibanding MSE.

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|$$

MAE Lebih stabil terhadap outlier dan memberikan gambaran rata-rata kesalahan absolut.

MAPE mengukur tingkat kesalahan secara persentase. MAPE berguna untuk memberikan interpretasi mengenai seberapa besar kesalahan prediksi dalam bentuk persen.

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|$$

Hasil Dan Pembahasan

Preprocessing

Hasil dari *preprocessing* yang sudah dilakukan adalah :

Tabel 2. Ringkasan Informasi Dataset

| 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 preprocessing menghasilkan total 2.180 observasi log return IHSG untuk periode 2016–2025. Setelah penghapusan nilai hilang akibat perhitungan log return, data dibagi menjadi dua bagian, yaitu data pelatihan (80%) sebanyak 1.714 observasi dan data pengujian (20%) sebanyak 406 observasi. Pembagian ini dilakukan secara berurutan sesuai karakteristik data deret waktu agar struktur temporal tetap terjaga.

Selanjutnya, data log return dinormalisasi menggunakan MinMaxScaler untuk keperluan pemodelan LSTM, dan dilakukan pembentukan sequence dengan jendela waktu sepanjang 30 hari. Proses ini menghasilkan 1.714 sequence untuk data training dan 406 sequence untuk data testing, masing-masing dengan bentuk tiga dimensi (samples,time steps,features) yaitu (1714,30,1)(1714, 30, 1). Struktur ini sesuai dengan kebutuhan arsitektur LSTM karena setiap instance input terdiri dari 30 nilai log return berturut-turut yang digunakan untuk memprediksi log return hari berikutnya atau volatilitas. Untuk gambaran isi datanya, dapat dilihat pada tabel di bawah.

Tabel 3. Lima Baris Pertama Dataset

| Tanggal | Close | Log Return |
|------------|-------------|------------|
| 2016-01-05 | 4557.644531 | 0.007024 |
| 2016-01-06 | 4608.802246 | 0.011162 |


| Tanggal | Close | Log Return |
|------------|-------------|------------|
| 2016-01-07 | 4530.271484 | -0.017186 |
| 2016-01-08 | 4546.111328 | 0.003490 |
| 2016-01-11 | 4465.309082 | -0.017934 |

Tabel 4. Lima Baris Terakhir Dataset

| Tanggal | Close | Log Return |
|------------|-------------|------------|
| 2024-12-20 | 6983.865234 | 0.000949 |
| 2024-12-23 | 7096.444824 | 0.015991 |
| 2024-12-24 | 7065.746094 | -0.004335 |
| 2024-12-27 | 7036.570801 | -0.004138 |
| 2024-12-30 | 7079.904785 | 0.006140 |

Tinjauan terhadap lima data awal menunjukkan bahwa log return pada awal periode bervariasi antara positif dan negatif, misalnya pada 5 Januari 2016 log return bernilai 0,0070, sedangkan pada 7 Januari 2016 bernilai -0,0172, mencerminkan fluktuasi pasar saham yang wajar. Pada akhir periode 2024, pola serupa juga muncul dengan log return kecil positif maupun negatif yang menandakan volatilitas pasar tetap hadir pada akhir rentang data. Secara keseluruhan, preprocessing berjalan dengan baik dan menghasilkan dataset yang bersih, terstruktur, serta siap digunakan untuk proses pemodelan GARCH maupun LSTM.

Sedangkan Visualisasi dari Volatilitas harga IHSG dapat dilihat pada gambar di bawah.



Gambar 1. Volatilitas IHSG 2016-2025

Grafik menunjukkan pergerakan volatilitas harian IHSG yang dihitung menggunakan rolling window 30 hari, diubah menjadi annualized volatility. Secara umum, volatilitas berada pada kisaran 0,06 hingga 0,58, dengan fluktuasi yang jelas sepanjang periode 2016–2025.


Setelah melalui tahap *preprocessing*, selanjutnya dilakukan modeling untuk kedua model yang di gunakan untuk memprediksi volatilitas IHSG. Hasil model yang di dapat adalah :

Tabel 6. 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 | - | - | - |

Berdasarkan hasil estimasi model AR-GARCH (1,1), diperoleh bahwa komponen mean return IHSG tidak menunjukkan pengaruh yang signifikan secara statistik. Hal ini terlihat dari koefisien AR(1) sebesar -0.0223 dengan nilai p sebesar 0.349 , yang mengindikasikan bahwa return hari sebelumnya tidak berpengaruh signifikan terhadap return hari ini. Koefisien konstanta pada mean model bernilai 0.0311 dan hanya signifikan pada tingkat kepercayaan 10% , sehingga dapat disimpulkan bahwa pergerakan return IHSG cenderung bersifat acak (*random walk*) dan tidak memiliki pola autokorelasi yang kuat. Sementara itu, pada bagian volatilitas, seluruh parameter GARCH(1,1) menunjukkan signifikansi pada tingkat kepercayaan 5% . Koefisien alpha (α) sebesar 0.1238 dengan *p-value* 0.0025 mengindikasikan bahwa adanya shock atau perubahan harga besar pada periode sebelumnya akan meningkatkan volatilitas pada periode berikutnya. Koefisien beta (β) sebesar 0.8105 dengan *p-value* mendekati nol menunjukkan bahwa volatilitas IHSG bersifat sangat persisten, di mana efek volatilitas cenderung bertahan dalam jangka waktu yang cukup lama. Nilai $\alpha + \beta$ sebesar 0.9343 , yang mendekati satu, semakin menegaskan adanya *volatility clustering*, yaitu kondisi di mana periode volatilitas tinggi cenderung diikuti oleh periode volatilitas tinggi berikutnya. Secara keseluruhan, hasil ini menunjukkan bahwa model


AR-GARCH(1,1) mampu menangkap dinamika volatilitas IHSG dengan baik selama periode pengamatan, sementara dinamika return lebih bersifat acak dan kurang dipengaruhi oleh informasi historis jangka pendek.



Gambar 2. Prediksi Volatilitas vs Aktual (GARCH)

Pada grafik volatilitas yang dihasilkan oleh model GARCH(1,1), terlihat bahwa pola prediksi model cenderung mengikuti pergerakan volatilitas aktual sepanjang periode pengamatan. Estimasi volatilitas yang dihasilkan tampak mampu menangkap kecenderungan terjadinya *volatility clustering*, yaitu periode ketika volatilitas meningkat atau menurun secara bertahap. Meskipun demikian, pola prediksi tersebut belum sepenuhnya responsif terhadap perubahan volatilitas yang terjadi secara tiba-tiba, sehingga pada beberapa bagian terlihat deviasi antara nilai prediksi dan nilai aktual. Hal ini mencerminkan keterbatasan pendekatan GARCH yang hanya mengandalkan informasi varians masa lalu dan bersifat linear, sehingga kurang mampu merepresentasikan dinamika volatilitas yang kompleks pada pasar saham. Secara keseluruhan, grafik ini memperlihatkan bahwa GARCH tetap memberikan gambaran yang relevan mengenai struktur volatilitas jangka pendek, meskipun akurasi tidak sepenuhnya optimal pada kondisi pasar yang sangat fluktuatif. Untuk Model LSTM, Model LSTM yang dibangun pada penelitian ini merupakan jaringan saraf dalam (*deep learning*) yang terdiri dari beberapa layer berurutan untuk menangkap dinamika volatilitas IHSG yang bersifat non-linear dan bergantung pada pola historis jangka pendek maupun panjang. Arsitektur yang ditunjukkan pada gambar terdiri dari satu *Stacked LSTM layer* dengan 20 unit memori, diikuti oleh beberapa *Dense layer* sebagai lapisan pemetaan non-linear, serta satu *output layer* dengan satu neuron untuk menghasilkan estimasi volatilitas harian. Model ini dirancang untuk menerima input berupa *sequence window* sepanjang 30 hari log return, sehingga jaringan dapat mempelajari pola ketergantungan jangka panjang (*long-term dependencies*) pada data keuangan yang bersifat volatil dan tidak stasioner. Aktivasi non-linear pada

lapisan Dense memungkinkan jaringan menangkap hubungan kompleks antara input dan volatilitas yang diprediksi. Selain itu, arsitektur model menggunakan mekanisme *memory cell* dan *gated operations* khas LSTM, sehingga mampu mengatasi permasalahan *vanishing gradient* dan kesulitan pemodelan data time series yang berfluktuasi seperti IHSG. Secara keseluruhan, model ini merepresentasikan pendekatan deep learning yang lebih fleksibel dibandingkan GARCH karena tidak terbatas oleh asumsi distribusi tertentu dan mampu mempelajari struktur non-linear dalam data. Hasil Prediksi yang di dapat dari model LSTM adalah :



Gambar 3. Prediksi Volatilitas vs Aktual (LSTM)

Dari grafik perbandingan antara volatilitas aktual dan hasil prediksi model LSTM, diketahui bahwa garis prediksi berada sangat dekat dengan pergerakan volatilitas yang sesungguhnya hampir di seluruh periode observasi. Model LSTM mampu mengikuti perubahan volatilitas, baik saat meningkat maupun menurun, dengan tingkat kedekatan yang lebih tinggi dibandingkan model GARCH. Pola prediksi yang dihasilkan terlihat lebih halus namun tetap akurat, mencerminkan kemampuan jaringan LSTM dalam mempelajari hubungan non-linear serta dependensi jangka panjang pada data volatilitas. Respons model terhadap perubahan yang terjadi dalam waktu singkat juga lebih baik, sehingga tidak terjadi keterlambatan prediksi ketika volatilitas mengalami lonjakan tiba-tiba. Visualisasi ini memperlihatkan secara jelas bahwa LSTM memiliki kemampuan prediktif yang lebih kuat dan lebih adaptif dalam menggambarkan dinamika volatilitas IHSG. Setelah model selesai di bangun, selanjutnya model akan di uji menggunakan keempat model pengujian, hasil yang di dapat adalah sebagai berikut :

Tabel 7. Hasil Evaluasi GARCH

| Metrik | Nilai |
|--------|------------|
| RMSE | 0.241354 |
| MAE | 0.156754 |
| MAPE | 18.858612% |

| Metrik | Nilai |
|----------------|----------|
| R ² | 0.649921 |

Berdasarkan hasil evaluasi, model GARCH(1,1) menunjukkan performa prediksi yang cukup baik. Nilai RMSE sebesar 0.241354 dan MAE sebesar 0.156754 mengindikasikan bahwa rata-rata kesalahan prediksi model relatif kecil, sehingga estimasi volatilitas yang dihasilkan cukup mendekati nilai aktual. MAPE yang berada pada angka 18.86% menunjukkan tingkat kesalahan persentase yang masih berada dalam kategori baik, karena nilai MAPE di bawah 20% umumnya menandakan bahwa model mampu mengikuti pola volatilitas dengan cukup akurat. Selain itu, nilai R² sebesar 0.649921 berarti bahwa sekitar 65% variasi volatilitas aktual dapat dijelaskan oleh model, menandakan bahwa GARCH(1,1) memiliki kemampuan penjelasan yang cukup kuat dalam memodelkan dinamika volatilitas. Secara keseluruhan, hasil evaluasi ini menunjukkan bahwa model GARCH(1,1) layak digunakan sebagai alat analisis volatilitas dan mampu memberikan prediksi yang informatif bagi studi empiris di pasar modal.

Tabel 6. Hasil Evaluasi Model LSTM

| Metrik | Nilai |
|----------------|-----------|
| RMSE | 0.006726 |
| MAE | 0.004570 |
| MAPE | 4.791961% |
| R ² | 0.949340 |

Hasil evaluasi model LSTM menunjukkan performa prediksi yang sangat baik dalam memodelkan volatilitas saham. Nilai RMSE sebesar 0.006726 dan MAE sebesar 0.004570 mengindikasikan bahwa kesalahan rata-rata model dalam memprediksi volatilitas berada pada tingkat yang sangat rendah. Selain itu, nilai MAPE sebesar 4.79% memperlihatkan bahwa kesalahan persentase relatif model tetap di bawah 5%, yang secara umum dikategorikan sebagai tingkat akurasi yang sangat tinggi dalam konteks peramalan deret waktu. Nilai R² sebesar 0.9493 juga memperkuat temuan ini, karena menunjukkan bahwa model mampu menjelaskan sekitar 94,93% variasi volatilitas aktual. Dengan demikian, LSTM terbukti memiliki kemampuan prediksi yang sangat kuat dan lebih responsif terhadap pola non-linear volatilitas dibandingkan metode tradisional seperti GARCH, sehingga menjadi model yang efektif untuk analisis volatilitas jangka pendek dan menengah.

Hasil evaluasi menunjukkan bahwa model GARCH(1,1) mampu menangkap pola volatilitas IHSG dengan cukup baik, tetapi akurasi masih terbatas. Sebaliknya, model LSTM memberikan performa prediksi yang jauh lebih tinggi dengan error yang lebih rendah dan nilai R^2 yang mendekati 1. Dengan demikian, LSTM terbukti lebih efektif dan akurat dalam memprediksi volatilitas IHSG dibandingkan model GARCH.

PENUTUP

SIMPULAN

Berdasarkan hasil penelitian mengenai perbandingan performa model GARCH(1,1) dan model LSTM dalam memprediksi volatilitas Indeks Harga Saham Gabungan (IHSG) periode 2016–2025, diperoleh beberapa kesimpulan penting. Pertama, model GARCH(1,1) mampu menangkap karakteristik volatilitas pasar saham yang bersifat *volatility clustering*, namun tingkat akurasi relatif terbatas dengan nilai RMSE, MAE, dan MAPE yang lebih tinggi serta R^2 yang lebih rendah. Hal ini menunjukkan bahwa GARCH hanya efektif untuk menangkap dinamika volatilitas berbasis varians kondisional, tetapi kurang optimal untuk pola volatilitas yang lebih kompleks.

Sebaliknya, model LSTM menunjukkan kinerja prediksi yang jauh lebih baik. Nilai RMSE dan MAE yang sangat rendah serta R^2 mendekati 1 menandakan bahwa LSTM mampu mempelajari pola volatilitas jangka panjang maupun hubungan non-linear dalam data. Dengan demikian, secara keseluruhan, model LSTM lebih unggul dan direkomendasikan sebagai model prediksi volatilitas IHSG dibandingkan GARCH(1,1).

SARAN

Berdasarkan temuan penelitian ini, terdapat beberapa saran yang dapat dijadikan masukan bagi peneliti selanjutnya, praktisi pasar modal, maupun pengembangan metode prediksi volatilitas di masa depan:

1. Penelitian selanjutnya disarankan untuk menambahkan variabel eksternal seperti indeks global (DJIA, SSEC, Nikkei), suku bunga, nilai tukar, atau sentimen pasar. Penambahan variabel dapat meningkatkan kemampuan model, terutama LSTM, dalam membaca kondisi pasar yang dipengaruhi faktor internasional.

2. Penggunaan model GARCH dapat dikembangkan dengan varian yang lebih kompleks, seperti EGARCH, TGARCH, GJR-GARCH, atau GARCH dengan distributed-lag yang lebih panjang. Model-model ini lebih sensitif terhadap asymmetry effect dan heavy-tail distribution sehingga berpotensi memberikan hasil prediksi yang lebih baik dibandingkan GARCH(1,1).
3. Arsitektur LSTM dapat diperluas atau digabungkan dengan metode lain, misalnya GRU, Bi-LSTM, CNN-LSTM, atau model hybrid seperti LSTM-GARCH. Kombinasi model memungkinkan penanganan pola volatilitas yang lebih kompleks serta mengurangi risiko overfitting.
4. Frekuensi data dapat dipertimbangkan untuk diperluas, misalnya menggunakan data intraday (hourly atau minute-level) untuk melihat dinamika volatilitas jangka pendek secara lebih detail. Hal ini sangat relevan mengingat pasar finansial modern bergerak semakin cepat.
5. Peneliti disarankan untuk mengeksplorasi teknik optimasi hyperparameter, seperti Grid Search, Random Search, atau Bayesian Optimization, agar model LSTM dapat mencapai performa prediksi yang lebih optimal dan stabil pada berbagai kondisi pasar.
6. Agar hasil penelitian semakin aplikatif, pihak industri seperti investor, manajer risiko, dan analis pasar modal dapat menggunakan model LSTM sebagai alat bantu prediksi volatilitas, terutama dalam strategi manajemen risiko, penentuan portofolio, serta pengambilan keputusan terkait timing investasi.

DAFTAR PUSTAKA

- Bakhtiar, M. R. (2020). *Volatility forecasts Jakarta Composite Index (JCI) and index stock volatility sector with estimated time series*. Indonesian Capital Market Review, 12(1), 12–27. <https://doi.org/10.21002/icmr.v12i1.12049>
- Dharmaningrat, I. M. A., Margaretha, H., & Saputra, K. V. I. (2025). *Predicting the volatility of Jakarta Composite Index using GARCH and LSTM with Volume-Up strategy approach*. Journal of Information Systems Engineering and Business Intelligence, 11(3), 311–322. <https://doi.org/10.20473/jisebi.11.3.311-322>

- Fitriyani, F., Hernita, H., & Firdaus, F. (2025). *Analisis volatilitas return IHSG periode 2020–2023 menggunakan model GARCH(1,1)*. JMSA: Jurnal Matematika, Statistika dan Aktuaria, 1(1).
<https://ejournal.umkota.ac.id/index.php/JMSA/article/view/42>
- García-Medina, A., & Aguayo-Moreno, E. (2024). *LSTM–GARCH hybrid model for the prediction of volatility in cryptocurrency portfolios*. Computational Economics, 63, 1511–1542.
<https://doi.org/10.1007/s10614-023-10373-8>
- Huang, Y., & Luo, Y. (2024). *Forecasting conditional volatility based on hybrid GARCH-type models with long memory, regime switching, leverage effect and heavy-tail*. The North American Journal of Economics and Finance, 72, 102148.
<https://doi.org/10.1016/j.najef.2024.102148>
- Hutapea, T. (2025). *Analysis of volatility of the return of Composite Stock Price Index using ARCH/GARCH model, January 2015–September 2024*. JKAMTB: Jurnal Kewirausahaan, Akuntansi dan Manajemen Tri Bisnis, 7(1), 81–99.
<https://doi.org/10.59806/jkamtb.v7i1.498>
- Jange, B. (2023). *Prediksi volatilitas IHSG menggunakan model GARCH (1,1)*. Arbitrase: Jurnal Ekonomi dan Akuntansi, 5(2), 157–170.
<https://journal.ikopin.ac.id/index.php/arbitrase/article/view/1795>
- Jiang, W. (2021). *Applications of deep learning in stock market prediction: Recent progress*. Expert Systems with Applications, 184, 115537.
<https://doi.org/10.1016/j.eswa.2021.115537>
- Koo, E., & Kim, G. (2022). *A hybrid prediction model integrating GARCH models with a distribution manipulation strategy based on LSTM networks for stock market volatility*. IEEE Access, 10, 34743–34754.
<https://doi.org/10.1109/ACCESS.2022.3163723>
- Lesmana, A. (2022). *The effect of the world exchange indexes (DJIA, SSEC and Nikkei 225) on the Indonesia Stock Exchange Index (IDX)*. Journal of Asian Multicultural Research for Economy and Management Study, 3(1), 1–9.
<https://doi.org/10.47616/jamrems.v3i1.230>
- Mieg, H. A. (2022). *Volatility as a transmitter of systemic risk: Is there a structural risk in finance?* Risk Analysis, 42(9), 1952–1964.
<https://doi.org/10.1111/risa.13564>
- Stevanius, S., & Sukamulja, S. (2020). *Co-integration and co-movement between Asian stock price index and Jakarta Composite Index*. Indonesian Capital Market Review, 12(1), 55–68.
<https://doi.org/10.21002/icmr.v12i1.12175>
- Sulistiyowati, S., & Rahmawati, M. F. (2020). *Analisis pengaruh pasar saham terhadap pertumbuhan ekonomi di negara berkembang*. Research Fair Unisri, 4(1), 107–114.
<https://doi.org/10.33061/rsfu.v4i1.3392>
- Tanjung, A. A., Mulyani, M., & Sari, D. P. (2025). *Analisis dinamika volatilitas Indeks Harga Saham Gabungan (IHSG): Aplikasi model Threshold GARCH*. Journal of Trends Economics and Accounting Research, 5(4).
<https://doi.org/10.47065/jtear.v5i4.2096>
- Wahyuni, L., Abusini, S., & Kurniawaty, M. (2022). *Prediction of Jakarta Composite Index volatility using Long Short Term Memory*. American Journal of Engineering Research, 11(4), 32–40. <http://www.ajer.org/papers/Vol-11-issue-4/E11043240.pdf>