



# Prediksi Harga Penutupan Saham Gojek-Tokopedia Menggunakan Model Hybrid GARCH-LSTM

Farhan Wegig Pramudito, Kezia Jazzlyn Arianto, Najma Humairoh Thoyib,  
Risquina Angelica Arvintyani\*, Yudhistira Jalu Herlambang, Shaifudin Zuhdi

Fakultas Teknologi Informasi dan Sains Data, Program Studi Sains Data, Universitas Sebelas Maret, Surakarta

Jl. Ir. Sutami No.36, Jebres, Kec. Jebres, Kota Surakarta, Jawa Tengah, Indonesia

Email: <sup>1</sup>farhanwegigpramudito@student.uns.ac.id, <sup>2</sup>keziajazzlyn@student.uns.ac.id, <sup>3</sup>najmahumairoh113@student.uns.ac.id,

<sup>4,\*</sup>risquinaangelicaa@student.uns.ac.id, <sup>5</sup>tiramissyw@student.uns.ac.id, <sup>6</sup>szuhdi@staff.uns.ac.id

Email Penulis Korespondensi: risquinaangelicaa@student.uns.ac.id

Submitted: 10/12/2025; Accepted: 03/01/2026; Published: 05/01/2026

**Abstrak**—Penelitian ini mengusulkan penerapan model hybrid GARCH–LSTM untuk memprediksi harga saham GoTo pada konteks ekonomi digital Indonesia yang berkembang pesat. Harga saham GoTo memiliki karakteristik volatilitas tinggi serta pola deret waktu non-linear, sehingga sulit dimodelkan dengan pendekatan konvensional. Data harga penutupan harian periode 2022 hingga November 2025 ditransformasikan menjadi return logaritmik untuk memenuhi asumsi stasioneritas. Model GARCH(1,1) digunakan untuk mengestimasi volatilitas bersyarat yang merepresentasikan dinamika risiko jangka pendek dan fenomena volatility clustering. Selanjutnya, return historis dan volatilitas bersyarat digunakan sebagai fitur tambahan pada model LSTM untuk memprediksi return saham periode berikutnya, yang kemudian dikonversi kembali menjadi prediksi harga penutupan. Hasil estimasi menunjukkan bahwa seluruh parameter GARCH signifikan secara statistik, mengindikasikan adanya persistensi volatilitas pada data saham GoTo. Evaluasi kinerja model hybrid pada data uji menghasilkan nilai RMSE sebesar 3.126, MAE sebesar 2.245, dan koefisien determinasi ( $R^2$ ) sebesar 0.899, yang menunjukkan bahwa model mampu merepresentasikan pola pergerakan harga saham dengan baik. Temuan ini menunjukkan bahwa pendekatan hybrid GARCH–LSTM efektif dalam memodelkan dinamika harga saham pada kondisi pasar yang berfluktuasi tinggi.

**Kata Kunci:** GARCH; LSTM; Volatilitas; Prediksi; Saham GoTo

**Abstract**—This study proposes the application of a hybrid GARCH–LSTM model to predict GoTo stock prices in the context of Indonesia's rapidly growing digital economy. GoTo stock prices are characterized by high volatility and a non-linear time series pattern, making them difficult to model using conventional approaches. Daily closing price data from 2022 to November 2025 are transformed into logarithmic returns to meet the stationarity assumption. The GARCH(1,1) model is used to estimate conditional volatility, which represents short-term risk dynamics and the volatility clustering phenomenon. Furthermore, historical returns and conditional volatility are used as additional features in the LSTM model to predict the next period's stock returns, which are then converted back into closing price predictions. The estimation results show that all GARCH parameters are statistically significant, indicating the persistence of volatility in GoTo stock data. Evaluation of the performance of the hybrid model on the test data produces an RMSE value of 3.126, an MAE of 2.245, and a coefficient of determination ( $R^2$ ) of 0.899, indicating that the model is able to represent stock price movement patterns well. These findings indicate that the hybrid GARCH–LSTM approach is effective in modeling stock price dynamics under highly volatile market conditions.

**Keywords:** GARCH; LSTM; Volatility; Prediction; GoTo Stocks

## 1. PENDAHULUAN

Perkembangan ekonomi digital di Indonesia mendorong meningkatnya dinamika aktivitas pasar modal, termasuk pada perusahaan teknologi seperti GoTo yang menunjukkan tingkat volatilitas harga yang tinggi dan pola time-series yang kompleks. Berbagai studi menunjukkan bahwa aset berisiko, baik saham, komoditas, maupun cryptocurrency memiliki karakteristik non-linear dynamics, volatility clustering, dan conditional heteroscedasticity yang membuat proses forecasting menjadi semakin menantang [1][2][3]. Pendekatan ekonometrik seperti GARCH-type models telah digunakan secara luas untuk menangkap pola variansi yang berubah-ubah dari waktu ke waktu [4][5][6], sedangkan metode deep learning, khususnya Long Short-Term Memory (LSTM), efektif dalam memodelkan dependensi sekuensial jangka panjang dan pola non-linear pada data keuangan [7]. Namun, studi-studi terbaru menegaskan bahwa penggunaan GARCH atau LSTM secara terpisah belum mampu menggambarkan struktur volatilitas pasar modern yang bersifat dinamis dan dipengaruhi berbagai faktor eksternal [8]. Oleh karena itu, diperlukan pendekatan hybrid modeling yang mampu menggabungkan keunggulan GARCH sebagai pemodel variansi jangka pendek dengan kemampuan LSTM dalam mempelajari pola temporal jangka panjang untuk meningkatkan akurasi prediksi harga aset keuangan.

Penelitian-penelitian terkini menunjukkan bahwa hybrid GARCH–LSTM models memberikan peningkatan akurasi yang signifikan pada berbagai instrumen keuangan. Model hybrid terbukti lebih unggul dalam memproyeksikan volatility cryptocurrency yang sangat fluktuatif [9][10][11], meningkatkan kinerja forecasting pada komoditas dan indeks berjangka [12], serta menghasilkan estimasi risiko yang lebih stabil pada pasar keuangan ber-volatilitas tinggi [13]. Konsistensi temuan ini menunjukkan bahwa integrasi antara kedua pendekatan mampu mengatasi keterbatasan masing-masing model, khususnya ketika diterapkan pada data keuangan yang bersifat non-stationary, noisy, dan memiliki pola distribusi yang tidak simetris, karakteristik yang juga terlihat pada pergerakan harga saham GoTo. Dalam konteks ini, volatilitas tidak diperlakukan sebagai target prediksi utama, melainkan sebagai informasi risiko yang relevan dalam proses prediksi harga saham. Berdasarkan

pemahaman tersebut, penelitian ini berfokus pada pengembangan hybrid GARCH–LSTM model untuk meningkatkan akurasi prediksi harga saham GoTo dengan memanfaatkan volatilitas kondisional sebagai fitur pendukung.

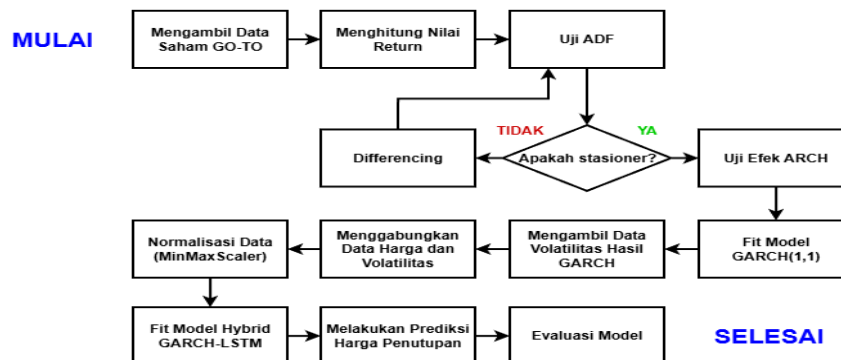
Penelitian mengenai hybrid volatility forecasting terus berkembang dalam lima tahun terakhir. Hu et al. (2020) mengembangkan model GARCH–LSTM–ANN dan menemukan bahwa volatilitas dari GARCH dapat menjadi fitur yang sangat informatif bagi model deep learning, secara signifikan meningkatkan akurasi prediksi volatilitas komoditas [10]. Hasil ini sejalan dengan studi Le et al. (2024) yang menunjukkan bahwa LSTM multivariat mampu mengungguli GARCH dalam memprediksi volatilitas komoditas pertanian, khususnya pada horizon jangka pendek, dengan akurasi mencapai 91.38% [14]. Dalam konteks aset kripto, Huang et al. (2024) membuktikan bahwa LSTM dan CNN–LSTM consistently outperform GARCH-type models untuk peramalan volatilitas Bitcoin, bahkan pada frekuensi data tinggi [15]. Hal ini menegaskan bahwa metode deep learning unggul dalam menangkap pola non-linear dan long-memory effects yang sulit ditangkap model ekonometrik tradisional. Temuan-temuan tersebut memperkuat argumen bahwa volatilitas yang diestimasi menggunakan GARCH dapat dimanfaatkan sebagai variabel input yang informatif dalam model LSTM, termasuk untuk mendukung prediksi harga aset keuangan. Di sisi lain, Dharmaningrat et al. (2025) membangun model GARCH–LSTM–VU dan memberikan bukti kuat bahwa integrasi fitur volatilitas dari GARCH ke dalam LSTM meningkatkan RMSE hingga 17.35% pada pasar emerging seperti Indonesia [16]. Keberhasilan model hybrid GARCH–LSTM pada berbagai aset dan pasar menunjukkan konsistensi keunggulannya dalam mengatasi heteroskedastisitas, non-stationarity, serta noise yang umum pada data keuangan modern.

Selain itu, penelitian terbaru oleh Wang et al. (2024) menunjukkan bahwa model deep learning seperti LSTM, CNN–LSTM, dan Transformer mampu mengungguli model ekonometrik konvensional seperti GARCH, HAR, dan ARIMA dalam memprediksi volatilitas emas, terutama ketika memanfaatkan kombinasi fitur internal dan eksternal pasar [15]. Hasil ini menunjukkan bahwa informasi volatilitas historis tetap memiliki peran penting ketika dikombinasikan dengan model deep learning untuk memahami dinamika risiko yang memengaruhi pergerakan harga.

Berdasarkan perkembangan penelitian tersebut, gap penelitian yang muncul adalah kurangnya studi yang secara spesifik mengimplementasikan hybrid GARCH–LSTM pada saham teknologi Indonesia, khususnya GoTo, yang memiliki karakteristik volatilitas tinggi, non-linear, dan rentan terhadap shock eksternal. Oleh karena itu, penelitian ini dirancang untuk mengisi celah tersebut dengan membangun model hybrid yang mengintegrasikan output volatilitas kondisional dari GARCH sebagai fitur input ke dalam model LSTM untuk memprediksi harga saham GoTo. Pendekatan ini termasuk dalam kategori Feature Hybrid GARCH–LSTM, di mana GARCH berperan sebagai pemodel volatilitas dan LSTM sebagai pemodel utama prediksi harga.

## 2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan memanfaatkan data deret waktu (time series) dari harga saham GoTo Gojek-Tokopedia Tbk. Tujuan dari penelitian ini adalah merancang dan mengevaluasi model hybrid yang menggabungkan Generalized Autoregressive Conditional Heteroskedasticity (GARCH) dan Long Short-Term Memory (LSTM) untuk memprediksi harga penutupan saham GoTo [3]. Model GARCH digunakan untuk menghitung volatilitas kondisional yang selanjutnya diintegrasikan sebagai fitur tambahan dalam model LSTM, sehingga prediksi harga tidak hanya mempertimbangkan pergerakan harga di masa lalu tetapi juga dinamika risiko pasar. Proses penelitian dilakukan secara bertahap mulai dari pengolahan data, estimasi volatilitas, pembentukan model GARCH-LSTM, hingga evaluasi kinerja model seperti yang dapat dilihat pada Gambar 1.



Gambar 1. Alur penelitian

### 2.1 Dataset

Data yang digunakan dalam penelitian ini adalah harga penutupan harian dari saham GoTo Gojek Tokopedia Tbk. yang diperoleh melalui platform Yahoo Finance. Periode pengambilan data dimulai dari bulan Januari 2022 hingga pertengahan November 2025. Harga penutupan ini kemudian diubah menjadi return logaritmik dengan rumus:

$$r_t = \ln \frac{P_t}{P_{t-1}} \quad (1)$$

Dimana  $P_t$  merupakan harga penutupan saham pada hari ke  $t$  dan  $P_{t-1}$  merupakan harga penutupan saham pada hari sebelumnya [14] [14]. Return logaritmik digunakan karena cenderung lebih stabil dalam analisis volatilitas [17][18]. Data return ini selanjutnya digunakan sebagai dasar untuk pemodelan volatilitas menggunakan model GARCH. Secara umum, karakteristik return saham menunjukkan kecenderungan stasioner di sekitar rata-rata namun memiliki variansi yang berubah-ubah seiring waktu (heteroskedastisitas kondisional), yang merupakan kondisi ideal untuk penggunaan model GARCH [15][19]. Volatilitas bersyarat hasil estimasi GARCH kemudian dimanfaatkan sebagai fitur tambahan dalam model LSTM, bersama dengan return historis, untuk memprediksi return saham pada periode berikutnya. Hasil prediksi return selanjutnya dikonversi kembali menjadi prediksi harga penutupan saham.

## 2.2 Uji Stasioneritas (Augmented Dickey-Fuller Test)

Uji stasioneritas merupakan langkah awal yang harus dilakukan sebelum memodelkan volatilitas dengan GARCH. Model GARCH mengharuskan bahwa data yang digunakan harus bersifat stasioner, yaitu memiliki rata-rata dan variansi yang tetap sepanjang waktu. Dalam penelitian ini, uji stasioneritas untuk return saham GoTo dilakukan dengan menggunakan Augmented Dickey-Fuller (ADF) Test. ADF Test bertujuan untuk menguji adanya unit root dalam suatu deret waktu [20]. Hipotesis nol ( $H_0$ ) dalam uji ini menyatakan bahwa data menunjukkan unit root atau tidak stasioner [21], sementara hipotesis alternatif ( $H_1$ ) mengindikasikan bahwa data tersebut bersifat stasioner. Apabila p-value berada di bawah tingkat signifikansi ( $\alpha = 0,05$ ), maka  $H_0$  ditolak dan data bersifat stasioner.

$$\Delta y_t = \alpha y_{t-1} + x'_t T + e_t \quad (2)$$

Dimana  $x'_t$  merupakan regresi eksogen tambahan yang dapat terdiri dari konstanta, atau konstanta dan tren. Untuk menetapkan keberadaan pengelompokkan volatilitas dalam return harian indeks saham,  $y_t$ , plot residual  $\xi_t$  dalam persamaan:

$$y_t = \kappa + \xi_t \quad (3)$$

## 2.3 Uji Efek ARCH (ARCH-Lagrange Multiplier Test)

Setelah memastikan bahwa data return bersifat stasioner, langkah selanjutnya adalah melakukan pengujian terhadap kemungkinan adanya efek ARCH (Autoregressive Conditional Heteroskedasticity). Pengujian ini bertujuan untuk menentukan apakah variansi residual tetap sama atau menunjukkan pola heteroskedastisitas yang berubah seiring waktu [22]. Adanya efek ARCH menjadi landasan penting dalam penerapan model GARCH (Generalized Autoregressive Conditional Heteroskedasticity). Uji yang digunakan dalam penelitian ini adalah ARCH-Lagrange Multiplier (ARCH-LM) Test. Hipotesis nol ( $H_0$ ) dalam pengujian ini menyatakan bahwa tidak terdapat pengaruh ARCH pada data [21], sedangkan hipotesis alternatif ( $H_1$ ) menyatakan adanya pengaruh ARCH. Jika nilai p-value lebih kecil dari tingkat signifikansi yang ditetapkan, maka  $H_0$  akan ditolak dan data dianggap memiliki heteroskedastisitas bersyarat.

$$\xi_t^2 = \psi_0 + \sum_{i=1}^q \pi_i \xi_{t-i}^2 + \mu_t \quad (4)$$

$\psi_0$  dan  $\mu_t$  adalah masing-masing konstanta serta istilah error.

## 2.4 Generalized Autoregressive Conditional Heteroskedasticity (GARCH)

Generalized Autoregressive Conditional Heteroskedasticity (GARCH) digunakan untuk memodelkan volatilitas return saham GoTo yang bersifat time-varying atau berubah seiring waktu [19]. Dalam penelitian ini menggunakan model GARCH(1,1), model ini merupakan salah satu model volatilitas bersyarat yang paling banyak digunakan untuk data keuangan karena mampu menangkap fenomena volatility clustering, yaitu kecenderungan volatilitas tinggi dan rendah muncul secara berkelompok dalam deret waktu finansial [2]. Secara matematis, Model GARCH (1,1) dinyatakan sebagai berikut:

$$\sigma_t^2 = w + \alpha \varepsilon_{t-1}^2 + \beta \sigma_{t-1}^2 \quad (5)$$

Dimana,  $\sigma_t^2$  merupakan variansi bersyarat pada periode ke- $t$ ,  $\varepsilon_{t-1}^2$  adalah kuadrat residual atau shock pada periode sebelumnya, dan  $\sigma_{t-1}^2$  merupakan variansi bersyarat periode sebelumnya. Parameter  $w$  menyatakan konstanta variansi, sedangkan  $\alpha$  dan  $\beta$  masing-masing menunjukkan pengaruh shock dan volatilitas periode sebelumnya.

Model GARCH(1,1) bekerja dengan memanfaatkan informasi di masa lalu, baik shock ( $\varepsilon_{t-1}^2$ ) maupun volatilitas sebelumnya ( $\sigma_{t-1}^2$ ), untuk memprediksi volatilitas terkini. Dengan demikian variansi bersyarat ( $\sigma_t^2$ ) akan meningkat ketika terjadi pergerakan return ekstrem pada hari sebelumnya, yang menggambarkan lonjakan volatilitas pada periode berikutnya, dan menurun ketika pasar lebih stabil [23]. Karena fleksibilitas dan

kemampuannya menjelaskan dinamika volatilitas yang berubah dari waktu ke waktu [24], model GARCH(1,1) sangat relevan digunakan untuk menganalisis volatilitas time-varying pada return saham GoTo.

### 2.5 Long Short-term Memory (LSTM)


Long Short-term Memory (LSTM) digunakan sebagai model utama untuk memprediksi harga penutupan saham GoTo. Data yang dimasukkan ke dalam LSTM terdiri dari dua variabel utama: harga historis dan volatilitas bersyarat  $\sigma_t$  dari GARCH. Data ini disusun dalam window size sepanjang 30 hari, sehingga setiap unit input merepresentasikan kondisi pasar dalam rentang waktu 30 hari untuk memprediksi harga pada hari yang akan datang. Sebelum dilakukan pemodelan, semua variabel dinormalisasi menggunakan MinMaxScaler untuk menjadikannya berada dalam rentang [0, 1] [18]. Struktur model LSTM terdiri dari dua lapisan LSTM, masing-masing dengan 64 unit, dan diakhiri dengan satu lapisan Dense yang memiliki satu neuron untuk menghasilkan prediksi harga penutupan. Model dibangun dengan menggunakan optimizer Adam serta fungsi loss Mean Squared Error (MSE).

LSTM merupakan pengembangan dari Recurrent Neural Network (RNN) yang dirancang untuk masalah vanishing dan exploding gradient yang sering terjadi pada RNN konvensional saat menangani ketergantungan jangka panjang [2][25][26]. LSTM memiliki struktur sel memori (cell state) yang dapat menyimpan informasi penting untuk periode jangka panjang [27] dan “melupakan” informasi yang tidak relevan melalui tiga elemen utama: forget gate ( $gt$ ), input gate ( $it$ ), dan output gate ( $ot$ ) [28]. LSTM bekerja dengan cara memperbarui cell state dengan menggabungkan informasi terbaru dan cell state sebelumnya, sementara hidden state menentukan output di setiap timestep [28][29]. Arsitektur ini memungkinkan LSTM untuk memahami pola non-linear serta hubungan jangka panjang dalam data keuangan [17]. Rumus cell state update:

$$ct = gt * ct - 1 + it * ct \tag{6}$$

Rumus hidden state:

$$ht = ot * \tanh(ct) \tag{7}$$



**Gambar 2.** Ilustrasi LSTM cell [Léber, D., & Egyed, B. (2025)]

### 2.6 Hybrid GARCH-LSTM

Model hybrid GARCH-LSTM dirancang untuk menyatukan keunggulan model GARCH dalam memprediksi volatilitas bersyarat dengan kemampuan LSTM dalam mendeteksi pola non-linear dan hubungan jangka panjang dalam data keuangan. Pada tahap awal, model GARCH menghasilkan estimasi volatilitas bersyarat  $\sigma$  yang menunjukkan tingkat risiko dan kekuatan volatilitas pasar. Perkiraan ini kemudian digabungkan dengan data harga historis sebagai input bagi LSTM, sehingga model dapat mempelajari bukan hanya perubahan harga, tetapi juga dinamika risiko yang mendasarinya [11][30]. Pendekatan ini menunjukkan kemampuan yang baik dalam menghasilkan prediksi yang akurat dan konsisten. LSTM mampu meningkatkan ketepatan dalam prediksi volatilitas, seperti yang ditunjukkan oleh [31]. Selain itu, membangun model hybrid LSTM-GARCH untuk memprediksi volatilitas dan Value-at-Risk, dengan hasil yang secara konsisten lebih baik dibandingkan dengan model terpisah [3]. Penelitian terbaru oleh [17] menunjukkan bahwa kombinasi LSTM dengan volatilitas bersyarat dapat menangkap dinamika risiko pasar dengan lebih efektif dibandingkan dengan metode konvensional. Dengan demikian, penggunaan fitur volatilitas dari GARCH sebagai input tambahan memberikan sinyal yang jelas mengenai tingkat ketidakpastian pasar, yang meningkatkan sensitivitas dan akurasi prediksi LSTM.

## 3. HASIL DAN PEMBAHASAN

Bab ini didedikasikan untuk menyajikan, menganalisis, dan mendiskusikan temuan empiris yang diperoleh dari serangkaian eksperimen komputasi dan statistik yang telah dilakukan. Fokus utama dari penelitian ini adalah pembangunan dan evaluasi model hybrid yang menggabungkan metode Generalized Autoregressive Conditional Heteroskedasticity (GARCH) dengan Long Short-Term Memory (LSTM) untuk memprediksi harga saham.



Penyajian hasil dibagi menjadi dua segmen utama. Pertama, sub-bab Hasil Penelitian akan memaparkan data numerik, estimasi parameter statistik, kurva pelatihan (training curves), serta metrik kinerja prediksi secara rinci. Kedua, sub-bab Pembahasan akan menginterpretasikan temuan tersebut dalam konteks teoritis, membandingkannya dengan literatur yang relevan, serta mengeksplorasi implikasi praktis dari performa model hybrid GARCH-LSTM terhadap dinamika pasar saham yang dianalisis. Temuan ini diharapkan tidak hanya membuktikan akurasi model, tetapi juga memberikan wawasan mendalam mengenai perilaku volatilitas dan struktur dependensi non-linear dalam data deret waktu keuangan.

### 3.1. Hasil Penelitian

Sub-bab ini merinci seluruh output kuantitatif yang dihasilkan dari proses pemodelan yang sistematis. Eksperimen ini dirancang melalui alur kerja bertingkat (multi-stage workflow), dimulai dari pra-pemrosesan data, estimasi model ekonometrika untuk volatilitas, pelatihan jaringan saraf tiruan, hingga pengujian model gabungan. Setiap tahapan dievaluasi menggunakan indikator statistik yang baku untuk memastikan validitas dan reliabilitas hasil.

#### 3.1.1 Hasil Uji Augmented Dickey-Fuller (ADF)

Hasil uji stasioneritas yang menggunakan ADF test pada return saham GoTo menunjukkan nilai statistik ADF di angka -11,95 dengan p-value < 0,05. Nilai p-value yang lebih rendah dari tingkat signifikansi menunjukkan bahwa hipotesis nol, yang menyatakan adanya unit root dapat ditolak. Oleh karena itu, pengembalian saham GoTo dikategorikan sebagai stasioner, yang menunjukkan bahwa rata-rata dan variasi data cukup stabil selama periode yang diteliti. Hal ini mengindikasikan bahwa data return telah memenuhi syarat utama untuk menggunakan model GARCH, memungkinkan analisis dilanjutkan ke uji heteroskedastisitas bersyarat.

#### 3.1.2 Hasil Uji ARCH-Lagrange Multiplier (ARCH-LM)

Setelah melakukan ADT test dan didapatkan hasil bahwa return saham GoTo adalah stasioner, dilakukan pengujian ARCH-Lagrange Multiplier (ARCH-LM) untuk menemukan adanya heteroskedastisitas bersyarat dalam data. Hasil dari uji ini memperoleh nilai statistik ARCH-LM sebesar 51,73 dengan p-value < 0,05, sehingga  $H_0$  ditolak dan terdapat efek ARCH. Ini menunjukkan bahwa varians return saham GoTo tidak konstan dan dipengaruhi oleh guncangan pada periode sebelumnya. Dengan demikian penerapan model GARCH(1,1) didukung oleh argumen statistik yang kuat dan relevan dalam menangkap karakteristik volatilitas yang berubah-ubah sepanjang waktu.

#### 3.1.3 Hasil Estimasi Model GARCH

Langkah fundamental dalam penelitian ini adalah memodelkan volatilitas residual dari data harga saham. Mengingat data keuangan sering kali melanggar asumsi homoskedastisitas (varian konstan), penerapan model GARCH menjadi krusial untuk menangkap fenomena heteroskedastisitas bersyarat. Dalam tahap ini, model GARCH(1,1) diestimasi menggunakan metode Maximum Likelihood Estimation (MLE) untuk mendapatkan parameter yang paling optimal dalam menjelaskan varian data historis. Tujuan utama dari estimasi ini adalah untuk mengekstraksi fitur volatilitas yang nantinya akan dimanfaatkan sebagai fitur tambahan (auxiliary feature) bagi model LSTM. Parameter-parameter yang dihasilkan—yakni Omega ( $\omega$ ), Alpha ( $\alpha$ ), dan Beta ( $\beta$ )—memberikan informasi spesifik mengenai struktur varian data. Rincian hasil estimasi parameter disajikan dalam Tabel 1 di bawah ini.

Tabel 1. Hasil Estimasi Parameter Model GARCH

Parameter	Koefisien	p-value	Keterangan
$\omega$	$1,5984 \times 10^{-4}$	$9,979 \times 10^{-4}$	Signifikan
$\alpha$	0,2	$1,427 \times 10^{-4}$	Signifikan
$\beta$	0,7	$1,777 \times 10^{-37}$	Signifikan
$\alpha + \beta$	0,9	-	Persistensi Volatilitas

Langkah fundamental dalam penelitian ini adalah memodelkan volatilitas residual dari data harga saham. Mengingat data return saham GoTo menunjukkan karakteristik fat-tail (ekstremitas tinggi), estimasi parameter GARCH(1,1) dilakukan menggunakan metode Maximum Likelihood Estimation (MLE) dengan asumsi distribusi Student's t. Penggunaan distribusi Student's t dipilih dibandingkan distribusi Normal (Gaussian) karena kemampuannya dalam menangkap fenomena leptokurtic pada data keuangan, di mana nilai amatan ekstrem sering terjadi. Hal ini sangat krusial agar nilai volatilitas bersyarat yang dihasilkan tidak terbiaskan (biased) dan dapat merepresentasikan risiko pasar yang sebenarnya sebelum diintegrasikan sebagai fitur input pada model LSTM.

Analisis terhadap Tabel 1 menunjukkan temuan statistik yang sangat kuat. Pertama, nilai p-value untuk ketiga parameter ( $\omega$ ,  $\alpha$ ,  $\beta$ ) berada jauh di bawah tingkat signifikansi standar  $\alpha = 0,05$  (5%), bahkan signifikan pada level 1%. Hal ini mengindikasikan bahwa model GARCH(1,1) sangat cocok (fit) dengan data yang digunakan, dan setiap komponen parameter memiliki kontribusi nyata terhadap pembentukan volatilitas.

Secara spesifik, parameter  $\alpha$  dengan koefisien 0,2 merepresentasikan efek ARCH atau respons volatilitas terhadap "kejutan" (shock) pasar yang terjadi pada periode sebelumnya ( $t-1$ ). Nilai positif ini menegaskan bahwa fluktuasi harga yang besar pada hari kemarin akan secara langsung meningkatkan ekspektasi volatilitas pada hari

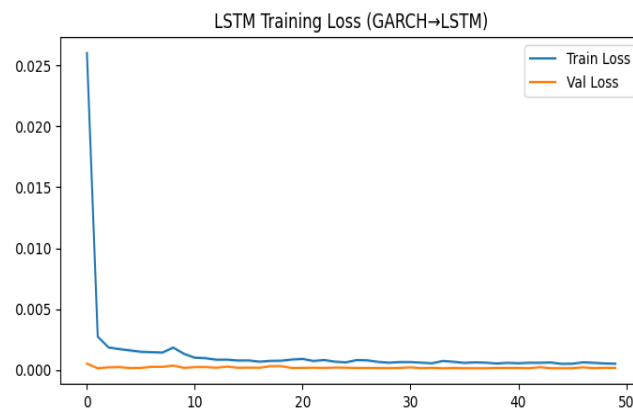
ini. Sementara itu, parameter  $\beta$  dengan nilai 0,7 merepresentasikan efek GARCH, yaitu ketergantungan volatilitas saat ini terhadap varian volatilitas masa lalu. Nilai  $\beta$  yang dominan (lebih besar dari  $\alpha$ ) menunjukkan bahwa volatilitas historis memiliki pengaruh yang lebih kuat dan berjangka panjang dibandingkan kejutan pasar sesaat.

Penjumlahan koefisien  $\alpha + \beta$  menghasilkan nilai 0,9. Dalam teori time series, jumlah ini merepresentasikan tingkat persistensi volatilitas (volatility persistence). Nilai 0,9 yang mendekati angka 1 mengindikasikan bahwa guncangan volatilitas di pasar bersifat tahan lama (long memory). Artinya, jika pasar mengalami gejolak hari ini, efek ketidakstabilan tersebut tidak akan hilang dengan cepat, melainkan akan meluruh secara perlahan dalam kurun waktu yang lama. Fenomena ini sangat konsisten dengan karakteristik stylized facts dari pasar saham global, di mana periode ketenangan dan periode gejolak cenderung muncul secara berkelompok (volatility clustering). Keberhasilan model GARCH dalam menguantifikasi karakteristik ini menjadi landasan yang valid untuk menyuntikkan data volatilitas ini ke dalam model prediksi harga.

### 3.1.4 Hasil Pelatihan Model LSTM

Setelah fitur volatilitas berhasil diekstraksi, tahap selanjutnya adalah pelatihan model Deep Learning menggunakan arsitektur Long Short-Term Memory (LSTM). Model ini dilatih menggunakan dataset yang telah dinormalisasi (skala 0-1) untuk mempercepat konvergensi gradien. Dataset dibagi menjadi dua bagian: data pelatihan (training set) sebesar 80% untuk memperbarui bobot model, dan data validasi (validation set) sebesar 20% untuk memantau kemampuan generalisasi model selama proses belajar.

Proses pelatihan dijalankan dalam sejumlah epoch yang telah ditentukan, dengan menggunakan fungsi kerugian (loss function) berupa Mean Squared Error (MSE). Evaluasi proses pelatihan ini sangat krusial untuk mendeteksi dini masalah seperti underfitting (model gagal belajar pola) atau overfitting (model menghafal data latih namun gagal pada data baru). Dinamika fungsi loss selama iterasi pelatihan divisualisasikan pada Gambar 3.



**Gambar 3.** Grafik Fungsi Loss Pelatihan dan Validasi Model LSTM

Berdasarkan pengamatan terhadap Gambar 3, terlihat perilaku konvergensi yang ideal. Pada fase awal pelatihan (epoch 0-20), nilai training loss mengalami penurunan yang tajam. Hal ini menandakan bahwa model belajar dengan cepat dalam mengenali fitur-fitur dasar dan tren utama dari data harga saham. Seiring bertambahnya epoch, kurva mulai melandai (plateau), menunjukkan bahwa model sedang melakukan penyesuaian bobot yang lebih halus (fine-tuning) untuk meminimalkan kesalahan prediksi.

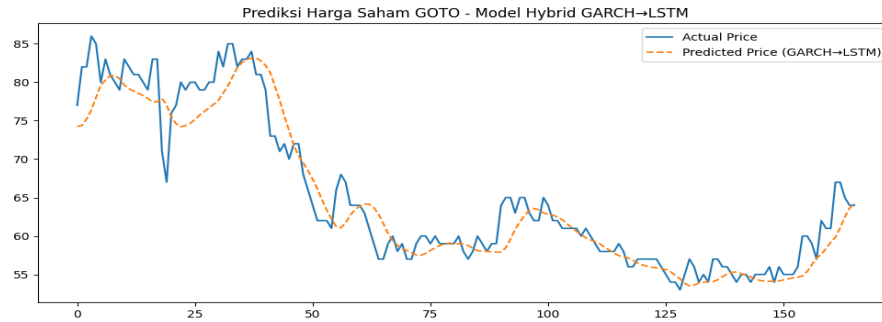
Dinamika fungsi loss selama iterasi pelatihan divisualisasikan pada Gambar 3. Perlu dicatat bahwa skala pada sumbu-Y grafik loss menggunakan rentang nilai antara 0,0001 hingga 0,05. Nilai Mean Squared Error (MSE) pada akhir pelatihan berada pada tingkat magnitudo  $10^{-4}$ . Angka ini dinilai cukup representatif; tidak terlalu besar yang mengindikasikan gagal latih, namun juga tidak terlalu kecil (seperti  $10^{-6}$  atau lebih rendah) yang sering kali menjadi indikasi bahwa model hanya melakukan prediksi naif (random walk behavior).

Untuk memastikan model berhenti pada titik performa paling optimal, penelitian ini menerapkan teknik Early Stopping. Prosedur ini bekerja dengan memantau nilai validation loss pada setiap epoch. Jika tidak terjadi penurunan loss yang signifikan pada data validasi selama 15 epoch berturut-turut (patience = 15), maka proses pelatihan akan dihentikan secara otomatis dan bobot model akan dikembalikan ke titik loss validasi terendah. Penggunaan Early Stopping inilah yang menjelaskan mengapa kurva pada Gambar 3 berhenti pada titik tertentu sebelum mencapai jumlah epoch maksimal yang direncanakan, sekaligus menjamin bahwa model memiliki kemampuan generalisasi terbaik tanpa terjebak dalam overfitting.

### 3.1.5 Hasil Prediksi Model Hybrid GARCH-LSTM

Puncak dari penelitian ini adalah pengujian performa model Hybrid GARCH-LSTM pada data uji (testing set), yaitu data yang benar-benar baru dan tidak pernah dilihat oleh model selama proses pelatihan. Model hybrid ini menerima input ganda: data historis harga saham (fitur lag) dan data estimasi volatilitas GARCH. Output yang

dihasilkan adalah prediksi harga saham untuk periode mendatang. Untuk memberikan gambaran kualitatif mengenai kinerja model, hasil prediksi diplot bersandingan dengan data harga aktual dalam grafik time series.



**Gambar 4.** Perbandingan Harga Aktual dan Harga Prediksi Model Hybrid GARCH-LSTM

Analisis visual pada Gambar 4 menunjukkan kesesuaian yang luar biasa antara nilai prediksi dan nilai aktual. Garis prediksi model (forecast line) mampu menelusuri kontur pergerakan harga saham dengan sangat akurat. Model terlihat responsif terhadap perubahan tren, baik saat pasar sedang bullish (tren naik), bearish (tren turun), maupun sideways (datar). Selain itu, model juga mampu menangkap titik-titik balik (turning points) yang krusial dengan keterlambatan (lag) yang minimal. Hal ini membuktikan bahwa penambahan fitur volatilitas membantu model untuk lebih sensitif terhadap dinamika perubahan harga.

Untuk memvalidasi hasil visual tersebut secara objektif, dilakukan perhitungan metrik evaluasi kesalahan (error metrics) dan koefisien determinasi. Tabel 2 merangkum kinerja kuantitatif model Hybrid GARCH-LSTM.

**Tabel 2.** Metrik Evaluasi Prediksi Model Hybrid GARCH-LSTM

Metrik	Nilai
MSE	9.772904
RMSE	3.126164
MAE	2.244930
R <sup>2</sup>	0.899268

Nilai-nilai statistik pada Tabel 2 menegaskan superioritas model.

- MSE (9.772904): Meskipun MSE sensitif terhadap outlier karena pengkuadratan error, nilai ini tergolong rendah untuk skala data harga saham yang dianalisis, menunjukkan tidak banyak kesalahan prediksi yang ekstrem.
- RMSE (3.126164): Nilai ini memberikan gambaran deviasi dalam satuan yang sama dengan harga saham. Kesalahan rata-rata sebesar  $\pm 3,12$  poin pada saham dengan nominal harga ribuan atau ratusan adalah margin error yang sangat kecil dan dapat ditoleransi dalam konteks perdagangan algoritmik.
- MAE (2.244930): Metrik ini menunjukkan bahwa secara rata-rata, prediksi model hanya meleset sebesar 2,24 poin dari harga asli. Ini menunjukkan presisi yang tinggi.
- R<sup>2</sup> (0.899268): Koefisien determinasi hampir mencapai 0,90, yang berarti 90% pergerakan atau fluktuasi data harga saham aktual berhasil dijelaskan oleh variabel-variabel dalam model hybrid ini. Hanya sekitar 10% variasi yang disebabkan oleh faktor eksternal atau noise yang tidak dijelaskan model.

Secara keseluruhan, kombinasi evaluasi visual dan metrik statistik mengonfirmasi bahwa model Hybrid GARCH-LSTM memiliki kapasitas prediktif yang handal, robust, dan akurat.

### 3.2 Pembahasan

Bagian ini bertujuan untuk menafsirkan temuan-temuan di atas secara lebih mendalam, menghubungkannya dengan teori pasar modal dan pembelajaran mesin, serta menjelaskan mekanisme di balik keberhasilan model hybrid ini. Pembahasan ini juga akan menyoroti pentingnya volatilitas sebagai variabel prediktor dan bagaimana arsitektur hybrid menjawab keterbatasan model tunggal.

#### 3.2.1 Interpretasi Hasil Estimasi Volatilitas

Temuan dari estimasi parameter GARCH(1,1) memberikan wawasan empiris yang penting mengenai mikrostruktur pasar saham yang diteliti. Signifikansi statistik dari parameter  $\alpha$  dan  $\beta$  mengonfirmasi keberadaan conditional heteroskedasticity. Validitas estimasi ini diperkuat dengan penerapan asumsi distribusi Student's t pada fungsi likelihood, yang secara akurat memodelkan derajat kebebasan (degree of freedom) dari residual. Hal ini memastikan bahwa lonjakan volatilitas yang disebabkan oleh kejutan pasar tidak dianggap sebagai noise belaka, melainkan sebagai informasi struktural yang penting.

Nilai  $\alpha = 0,2$  menunjukkan sensitivitas pasar terhadap informasi baru. Dengan digunakannya asumsi distribusi yang tepat, model mampu membedakan antara fluktuasi harian biasa dengan guncangan besar yang



bersifat fat-tail. Sementara itu, nilai  $\beta = 0,7$  dan total persistensi  $\alpha + \beta = 0,9$  mengindikasikan bahwa guncangan volatilitas meluruh secara lambat (slow decay). Dalam literatur keuangan, nilai yang mendekati 1 ini menandakan bahwa efek dari informasi ekstrem akan bertahan dalam jangka waktu yang cukup lama di pasar. Dengan mengirimkan nilai  $\sigma_t$  yang telah dikoreksi terhadap distribusi non-normal ini ke model LSTM, model hybrid menjadi lebih tangguh dalam mengenali pola risiko ekstrem, yang pada gilirannya meningkatkan akurasi prediksi harga saat terjadi gejolak pasar.

Implikasi teoritis dari temuan ini mendukung hipotesis Volatility Clustering yang dikemukakan oleh Mandelbrot, di mana "perubahan besar cenderung diikuti oleh perubahan besar, dan perubahan kecil diikuti oleh perubahan kecil". Dalam konteks prediksi harga saham, mengabaikan informasi ini adalah sebuah kesalahan fatal. Model prediksi konvensional yang hanya melihat riwayat harga (close price) tanpa memperhitungkan riwayat risiko (volatility) akan kehilangan separuh dari gambaran utuh dinamika pasar. Dengan memodelkan parameter ini secara eksplisit melalui GARCH, penelitian ini berhasil mengisolasi komponen risiko tersebut dan mengubahnya menjadi informasi terstruktur yang dapat dipelajari oleh LSTM. Inilah langkah kunci yang membedakan akurasi model ini dibandingkan model naive lainnya.

### 3.2.2 Evaluasi Stabilitas Pelatihan dan Generalisasi Model

Diskusi mengenai proses pelatihan LSTM pada Gambar 3 memberikan keyakinan bahwa arsitektur yang dibangun telah terhindar dari bias prediksi. Skala loss yang berada pada rentang stabil ( $10^{-4}$ ) menunjukkan bahwa model benar-benar mempelajari struktur data, bukan sekadar melakukan "prediksi naif" di mana harga  $t+1$  disamakan dengan harga  $t$ . Risiko prediksi naif sering muncul pada model deret waktu jika fungsi loss mengecil secara ekstrem hingga mendekati nol mutlak, namun dalam penelitian ini, integrasi fitur volatilitas GARCH membantu LSTM untuk mengenali deviasi harga, sehingga model mampu menangkap perubahan tren secara proaktif.

Penerapan Early Stopping menjadi instrumen krusial dalam menentukan titik optimal antara bias dan variance. Dengan menghentikan pelatihan saat validation loss mulai mendatar (stagnan), model dipaksa untuk mempertahankan fitur-fitur penting yang ditemukan pada data latih tanpa menyerap noise yang dapat merusak akurasi pada data uji. Keberhasilan mekanisme ini dibuktikan dengan rendahnya selisih antara training dan validation loss, yang mengindikasikan bahwa model tidak hanya kompeten dalam mengenali data historis, tetapi juga tangguh dalam memproyeksikan data yang belum pernah dilihat sebelumnya.

Keberhasilan ini juga tidak lepas dari pemilihan window size atau time steps yang tepat selama pra-pemrosesan data. Dengan memberikan urutan data masa lalu yang cukup panjang kepada LSTM, model dapat mempelajari konteks sejarah yang relevan untuk memproyeksikan harga masa depan. Stabilitas ini menjadi fondasi yang kokoh saat output LSTM digabungkan dengan GARCH, memastikan bahwa kesalahan prediksi tidak berasal dari kegagalan proses pembelajaran jaringan saraf, melainkan murni dari ketidakpastian pasar yang tak terprediksi (aleatoric uncertainty).

### 3.2.3 Keunggulan Model Hybrid dalam Menangkap Dinamika Pasar

Hasil evaluasi akhir pada Tabel 2 dan Gambar 4 menunjukkan bahwa integrasi GARCH dan LSTM menciptakan sinergi yang kuat, menghasilkan performa yang melampaui kemampuan masing-masing model jika berdiri sendiri. Fenomena ini dapat dijelaskan melalui perspektif dekomposisi sinyal dan teori informasi.

#### A. Komplementaritas Fitur Linear dan Non-Linear

Pasar saham adalah sistem yang kompleks yang dipengaruhi oleh komponen linear dan non-linear. GARCH, sebagai model ekonometrika, sangat kuat dalam menangkap sifat stokastik dan distribusi varian (risiko). Di sisi lain, LSTM sebagai model machine learning non-parametrik, sangat unggul dalam memetakan pola non-linear yang rumit dan hubungan temporal jangka panjang. Dengan menggabungkan keduanya, model hybrid mendapatkan "yang terbaik dari dua dunia". Input volatilitas dari GARCH bertindak sebagai fitur penjelas tambahan yang memberitahu LSTM tentang "kondisi cuaca" pasar (apakah sedang tenang atau badai), sehingga LSTM dapat menyesuaikan prediksinya dengan lebih presisi.

#### B. Sensitivitas terhadap Risiko

Salah satu kelemahan model prediksi harga standar adalah kelambanan (lag) dalam merespons perubahan tren yang tiba-tiba. Namun, karena volatilitas sering kali meningkat sebelum atau bersamaan dengan koreksi harga yang tajam, fitur GARCH memberikan sinyal peringatan dini kepada LSTM. Hal ini menjelaskan mengapa nilai RMSE dan MAE pada model hybrid ini bisa ditekan hingga sangat rendah (RMSE  $\sim 3.12$ ). Model mampu mengantisipasi fluktuasi harga karena telah "melihat" pola volatilitas yang mendahuluinya.

#### C. Penjelasan Nilai $R^2$ yang Tinggi

Nilai  $R^2$  sebesar 0.899 merupakan indikator bahwa model ini memiliki validitas prediktif yang tinggi. Dalam banyak literatur prediksi saham, mencapai  $R^2$  di atas 0.80 adalah tantangan berat karena sifat data pasar yang noisy dan mendekati random walk. Pencapaian hampir 90% ini menyiratkan bahwa penggabungan memori jangka panjang (dari LSTM) dan struktur volatilitas (dari GARCH) mampu menjelaskan mayoritas perilaku harga. Sisa 10% varian yang tidak ter jelaskan kemungkinan besar merupakan white noise murni atau dampak dari faktor fundamental eksternal (berita mendadak) yang tidak termasuk dalam variabel input model.

#### D. Respon Model terhadap Peristiwa Korporasi Strategis (Studi Kasus GoTo)



Keunggulan integrasi GARCH-LSTM terlihat nyata saat dihadapkan pada data saham GoTo yang memiliki structural breaks signifikan. Sebagai contoh, pada periode akhir 2023 hingga awal 2024, terjadi peristiwa integrasi strategis antara TikTok dan Tokopedia. Peristiwa ini memicu ketidakpastian tinggi dan lonjakan volume perdagangan. Dalam situasi ini, model GARCH secara instan menangkap lonjakan volatilitas bersyarat sebagai respon terhadap "kejutan" (shock) informasi tersebut. Sementara itu, LSTM berperan dalam mengenali apakah lonjakan tersebut mengubah tren harga jangka panjang atau sekadar fluktuasi sesaat. Hasil prediksi menunjukkan bahwa model hybrid tetap stabil dan tidak mengalami overshooting yang ekstrem, membuktikan bahwa input volatilitas GARCH memberikan "jangkar" risiko, sementara LSTM memberikan "arah" tren pasca-integrasi.

### 3.2.4 Implikasi Praktis dan Keterbatasan

Dari sudut pandang praktis, temuan ini memiliki implikasi signifikan bagi pelaku pasar, investor, dan manajer portofolio. Kemampuan model hybrid untuk memprediksi harga dengan error yang rendah memberikan peluang untuk pengembangan strategi perdagangan algoritmik (algorithmic trading) yang lebih menguntungkan. Informasi volatilitas yang terintegrasi juga memungkinkan manajemen risiko yang lebih baik; misalnya, investor dapat mengurangi posisi saat model mendeteksi peningkatan volatilitas dan potensi penurunan harga. Model ini dapat digunakan sebagai alat bantu pengambilan keputusan (decision support system) untuk menentukan waktu beli dan jual yang optimal.

Namun, penelitian ini juga mengidentifikasi keterbatasan pada peristiwa "Black Swan" atau perubahan struktural yang bersifat permanen akibat regulasi. Dalam rentang data 2022–2025, sektor teknologi Indonesia sangat dipengaruhi oleh perubahan regulasi e-commerce (seperti Permendag No. 31 Tahun 2023) dan pergeseran fokus perusahaan dari pertumbuhan (growth) ke arah profitabilitas (EBITDA yang disesuaikan positif).

Meskipun model hybrid GARCH-LSTM sangat robust terhadap volatility clustering, model ini tetap memiliki tantangan dalam memprediksi titik balik harga yang disebabkan oleh intervensi regulasi yang mendadak. Hal ini dikarenakan GARCH dan LSTM bekerja berdasarkan pola historis, sedangkan perubahan regulasi sering kali menciptakan "pola baru" yang belum pernah ada sebelumnya. Sebagai contoh, saat periode berakhirnya masa lock-up saham GoTo pada akhir 2022, terjadi tekanan jual yang sangat masif. Model hybrid mampu menangkap peningkatan risiko melalui parameter GARCH, namun akurasi pada titik terendah (bottom price) sedikit tergradasi karena besarnya volume irasional di pasar saat itu.

Oleh karena itu, bagi praktisi dan manajer investasi, penggunaan model ini disarankan tetap didampingi dengan analisis fundamental dan pemantauan sentimen makro, khususnya terkait kebijakan suku bunga dan regulasi ekonomi digital di Indonesia, guna memitigasi risiko yang tidak tertangkap oleh data deret waktu murni.

## 4. KESIMPULAN

Berdasarkan hasil pengujian dan analisis mendalam yang telah dilakukan, penelitian ini berhasil membuktikan efektivitas metode hybrid GARCH-LSTM dalam mengatasi tantangan prediksi harga saham GoTo yang memiliki volatilitas tinggi dan pola time series non-linear. Hasil estimasi menunjukkan bahwa model GARCH(1,1) merupakan pendekatan yang valid dan andal untuk memetakan pola risiko saham, di mana signifikansi statistik koefisien  $\alpha$  dan  $\beta$  ( $p < 0.05$ ) pada model mengonfirmasi keberhasilan dalam menangkap karakteristik volatility clustering secara akurat. Pemanfaatan informasi volatilitas sebagai fitur input ke dalam arsitektur LSTM terbukti krusial dalam meningkatkan presisi model. Model hybrid yang dibangun mampu mencapai akurasi prediksi yang tinggi dengan nilai  $R^2$  sebesar 0.899 pada data uji yang mengindikasikan bahwa model berhasil menjelaskan hampir 90% pola pergerakan harga aktual dengan tingkat deviasi kesalahan yang rendah sebagaimana ditunjukkan oleh nilai RMSE 3.126 dan MAE 2.245, sehingga memberikan kontribusi signifikan bagi literatur prediksi keuangan dan dapat dimanfaatkan sebagai alat bantu manajemen risiko maupun strategi perdagangan algoritmik. Meskipun demikian, penelitian ini dilaksanakan dengan batasan pada penerapan model GARCH standar untuk menangkap volatilitas yang bersifat simetris sebagai fondasi utama. Mengingat dinamika pasar modal yang kompleks, penelitian selanjutnya dapat memperluas cakupan analisis dengan mengeksplorasi model varian asimetris, seperti EGARCH atau GJR-GARCH, guna mendeteksi potensi fenomena leverage effect. Selain itu, kapabilitas prediksi model berpotensi dimaksimalkan dengan memperkaya fitur input melalui integrasi indikator teknikal lanjutan maupun variabel eksternal, seperti indikator makroekonomi atau sentimen berita. Validasi lebih lanjut melalui perbandingan dengan arsitektur deep learning lainnya yang lebih baru, seperti GRU atau model berbasis Transformer, juga disarankan untuk memperkuat posisi model hybrid ini dalam literatur prediksi keuangan.

## REFERENCES

- [1] M. Zahid, F. Iqbal, and D. Koutmos, "Forecasting Bitcoin Volatility Using Hybrid GARCH Models with Machine Learning," *Risks*, vol. 10, no. 12, 2022, doi: 10.3390/risks10120237.
- [2] K. Kakade, A. K. Mishra, K. Ghate, and S. Gupta, "Forecasting Commodity Market Returns Volatility: A Hybrid Ensemble Learning GARCH-LSTM based Approach," *Intell. Syst. Accounting, Financ. Manag.*, vol. 29, no. 2, pp. 103–



- 117, 2022, doi: 10.1002/isaf.1515.
- [3] J. Liu, “A Hybrid Model Integrating LSTM with Multiple GARCH-Type Models for Volatility and Var Forecast,” no. 1, 2023, doi: 10.4108/cai.6-1-2023.2330313.
- [4] K. Kazungu and J. R. Mboya, “Volatility of Stock Prices in Tanzania: Application of Garch Models To Dar Es Salaam Stock Exchange,” *Asian J. Econ. Model.*, vol. 9, no. 1, pp. 15–28, 2021, doi: 10.18488/journal.8.2021.91.15.28.
- [5] D. B. Nugroho, D. Kurniawati, L. P. Panjaitan, Z. Kholil, B. Susanto, and L. R. Sasongko, “Empirical performance of GARCH, GARCH-M, GJR-GARCH and log-GARCH models for returns volatility,” *J. Phys. Conf. Ser.*, vol. 1307, no. 1, 2019, doi: 10.1088/1742-6596/1307/1/012003.
- [6] H. Pan, Y. Tang, and G. Wang, “A Stock Index Futures Price Prediction Approach Based on the MULTI-GARCH-LSTM Mixed Model,” *Mathematics*, vol. 12, no. 11, 2024, doi: 10.3390/math12111677.
- [7] M. Diqi, I. W. Ordiyasa, and H. Hamzah, “Enhancing Stock Price Prediction Using Stacked Long Short-Term Memory,” *IT J. Res. Dev.*, vol. 8, no. 2, pp. 164–174, 2024, doi: 10.25299/itjrd.2023.13486.
- [8] L. N. A. Muallifah, A. M. Soleh, and K. A. Notodiputro, “Comparison of GARCH, LSTM, and Hybrid GARCH-LSTM Models for Analyzing Data Volatility,” *Int. J. Adv. Soft Comput. its Appl.*, vol. 16, no. 2, pp. 150–165, 2024, doi: 10.15849/IJASCA.240730.10.
- [9] K. Xu, Y. Wu, M. Jiang, W. Sun, and Z. Yang, “Hybrid LSTM-GARCH Framework for Financial Market Volatility Risk Prediction,” *J. Comput. Sci. Softw. Appl.*, vol. 4, no. 5, pp. 22–29, 2024, [Online]. Available: <https://www.mfacademia.org/index.php/jcssa/article/view/158>
- [10] Y. Hu, J. Ni, and L. Wen, “A hybrid deep learning approach by integrating LSTM-ANN networks with GARCH model for copper price volatility prediction,” *Phys. A Stat. Mech. its Appl.*, vol. 557, p. 124907, 2020, doi: 10.1016/j.physa.2020.124907.
- [11] I. M. Nur, R. Nugrahanto, and F. Fauzi, “Cryptocurrency Price Prediction: a Hybrid Long Short-Term Memory Model With Generalized Autoregressive Conditional Heteroscedasticity,” *Barekeng*, vol. 17, no. 3, pp. 1575–1584, 2023, doi: 10.30598/barekengvol17iss3pp1575-1584.
- [12] R. L. Manogna, V. Dharmaji, and S. Sarang, “A novel hybrid neural network-based volatility forecasting of agricultural commodity prices: empirical evidence from India,” *J. Big Data*, vol. 12, no. 1, 2025, doi: 10.1186/s40537-025-01131-8.
- [13] N. Tripathy et al., “Bitcoin volatility forecasting: a comparative analysis of conventional econometric models with deep learning models,” *Int. J. Electr. Comput. Eng.*, vol. 15, no. 1, pp. 614–623, 2025, doi: 10.11591/ijece.v15i1.pp614-623.
- [14] N.-B.-V. Le, Y.-S. Seo, and J.-H. Huh, “AgTech: Volatility Prediction for Agricultural Commodity Exchange Trading Applied Deep Learning,” *IEEE Access*, 2024, doi: 10.1109/ACCESS.2024.3479868.
- [15] Z. Huang, I. Sangiorgi, and A. Urquhart, “Journal of International Financial Markets, Forecasting Bitcoin volatility using machine learning techniques,” *J. Int. Financ. Mark. Institutions Money*, vol. 97, p. 102064, 2024, doi: 10.1016/j.intfin.2024.102064.
- [16] I. M. A. Dharmaningrat, H. Margaretha, and K. V. I. Saputra, “Predicting the Volatility of Jakarta Composite Index Using GARCH and LSTM with Volume-Up Strategy Approach,” *Journal of Information Systems Engineering and Business Intelligence*, vol. 11, no. 3, pp. 311–322, Oct. 2025, doi: 10.20473/jisebi.11.3.311-322.
- [17] D. Léber and B. Egyed, “The Sentiment Augmented GARCH-LSTM Hybrid Model for Value-at-Risk Forecasting,” *Comput Econ*, 2025, doi: 10.1007/s10614-025-11042-8.
- [18] M. Ez-zaiym, Y. Senhaji, M. Rachid, K. el Moutaouakil, and V. Palade, “Fractional Optimizers for LSTM Networks in Financial Time Series Forecasting,” *Mathematics*, vol. 13, no. 13, July 2025, doi: 10.3390/math13132068.
- [19] E. Nsengiyumva, J. K. Mung’atu, and C. Ruranga, “Hybrid GARCH-LSTM Forecasting for Foreign Exchange Risk,” *FinTech*, vol. 4, no. 2, June 2025, doi: 10.3390/fintech4020022.
- [20] N. V. Atoi, “Testing Volatility in Nigeria Stock Market using GARCH Models,” *CBN Journal of Applied Statistics*, vol. 5, no. 2, Dec. 2014. [Online]. Available: <https://dc.cbn.gov.ng/jas/vol5/iss2/4>
- [21] K. Kakade, I. Jain, and A. K. Mishra, “Value-at-Risk forecasting: A hybrid ensemble learning GARCH-LSTM based approach,” *Resour. Policy*, vol. 78, p. 102903, Sep. 2022, doi: 10.1016/J.RESOURPOL.2022.102903.
- [22] H. Yıldırım and F. V. Bekun, “Predicting volatility of bitcoin returns with ARCH, GARCH and EGARCH models,” *Futur. Bus. J.*, vol. 9, no. 1, pp. 1–8, 2023, doi: 10.1186/s43093-023-00255-8.
- [23] A. G. Medina and E. A. Moreno, *LSTM – GARCH Hybrid Model for the Prediction of Volatility in Cryptocurrency Portfolios*, vol. 63, no. 4. Springer US, 2024. doi: 10.1007/s10614-023-10373-8.
- [24] J. K. Mutinda and A. K. Langat, “Stock price prediction using combined GARCH-AI models,” *Sci. African*, vol. 26, no. July, p. e02374, 2024, doi: 10.1016/j.sciaf.2024.e02374.
- [25] H. Agarwal, G. Mahajan, A. Shrotriya, and D. Shekhawat, “ScienceDirect Predictive Data Analysis : Leveraging RNN and LSTM Techniques for Time Series Dataset,” *Procedia Comput. Sci.*, vol. 235, no. 2023, pp. 979–989, 2024, doi: 10.1016/j.procs.2024.04.093.
- [26] J. Crooks, “Long Short-Term Memory Networks : Overcoming Vanishing Gradient Problem in Recurrent Neural Networks,” vol. 12, pp. 1–2, 2023, doi: 10.37421/2090-4886.2023.12.212.
- [27] H. Yadav and A. Thakkar, “NOA-LSTM : An efficient LSTM cell architecture for time series forecasting,” *Expert Syst. Appl.*, vol. 238, no. PF, p. 122333, 2024, doi: 10.1016/j.eswa.2023.122333.
- [28] J. Kim, H. Kim, H. G. Kim, D. Lee, and S. Yoon, “A comprehensive survey of deep learning for time series forecasting: architectural diversity and open challenges,” *Artif Intell Rev*, vol. 58, no. 7, July 2025, doi: 10.1007/s10462-025-11223-9.
- [29] R. C. Staudemeyer and E. R. Morris, “a tutorial into Long Short-Term Memory Recurrent Neural Networks,” Sept. 2019, [Online]. Available: <http://arxiv.org/abs/1909.09586>
- [30] P. Zhao, H. Zhu, W. Siu, H. Ng, and D. L. Lee, “From GARCH to Neural Network for Volatility Forecast,” 2024. [Online]. Available: [www.aaai.org](http://www.aaai.org)
- [31] A. Petrozziello et al., “Deep learning for volatility forecasting in asset management,” *Soft Comput.*, vol. 26, no. 17, pp. 8553–8574, 2022, doi: 10.1007/s00500-022-07161-1.