

Prediksi Harga Saham NVIDIA Menggunakan Model LSTM dan GARCH

Fiqri Maulana Syach*¹, Taufik Baidawi¹, Jenie Sundari¹

¹Program Studi Rekayasa Perangkat Lunak, Universitas Bina Sarana Informatika, Indonesia

*e-mail: 10210062@bsi.ac.id

Abstrak

Prediksi harga saham merupakan tantangan kompleks dalam dunia keuangan karena tingginya volatilitas dan ketergantungan waktu pada data historis. Saham NVIDIA Corporation menjadi perhatian karena perannya dalam sektor teknologi mutakhir seperti AI dan GPU, yang membuat pergerakan harganya sangat fluktuatif. Untuk mengatasi tantangan tersebut, penelitian ini bertujuan mengembangkan model prediksi harga saham yang akurat dengan menggabungkan dua pendekatan: Long Short-Term Memory (LSTM) dan Generalized Autoregressive Conditional Heteroskedasticity (GARCH). GARCH digunakan untuk menghitung volatilitas harian sebagai fitur tambahan, sementara LSTM digunakan untuk memodelkan pola deret waktu harga saham. Penelitian dilakukan dengan pendekatan kuantitatif menggunakan data historis saham NVIDIA dari tahun 2015 hingga 2024 yang diambil dari Yahoo Finance. Hasil evaluasi model menunjukkan bahwa model hybrid GARCH-LSTM memiliki performa prediksi lebih baik dibandingkan model LSTM murni. Nilai Mean Absolute Error (MAE) yang diperoleh sebesar 1.72 dan Root Mean Squared Error (RMSE) sebesar 2.26, lebih rendah dibandingkan LSTM murni. Dengan demikian, integrasi GARCH dan LSTM terbukti efektif meningkatkan akurasi prediksi harga saham, serta dapat menjadi acuan dalam pengambilan keputusan investasi berbasis data.

Kata kunci: GARCH, LSTM, Machine Learning, NVIDIA, Saham.

Abstract

Stock price prediction is a complex challenge in the financial world due to its high volatility and time dependence on historical data. NVIDIA Corporation's stock is of interest due to its role in cutting-edge technology sectors such as AI and GPUs, which makes its price movements highly volatile. To address this challenge, this study aims to develop an accurate stock price prediction model by combining two approaches: Long Short-Term Memory (LSTM) and Generalized Autoregressive Conditional Heteroskedasticity (GARCH). GARCH is used to calculate daily volatility as an additional feature, while LSTM is used to model the time series pattern of stock prices. The study was conducted with a quantitative approach using historical NVIDIA stock data from 2015 to 2024 taken from Yahoo Finance. The model evaluation results show that the hybrid GARCH-LSTM model has better prediction performance than the pure LSTM model. The Mean Absolute Error (MAE) value obtained is 1.72 and the Root Mean Squared Error (RMSE) is 2.26, lower than the pure LSTM model. Thus, the integration of GARCH and LSTM has been proven to be effective in increasing the accuracy of stock price predictions and can be used as a reference in data-based investment decision making.

Keywords: GARCH, LSTM, Machine Learning, NVIDIA, Stock

1. PENDAHULUAN

Pasar saham menghadirkan tantangan tersendiri dalam memprediksi pergerakan harga, mengingat tingginya ketidakpastian dan respons harga yang sangat sensitif terhadap perubahan [1]. Kehadiran noise dalam data historis harga saham serta adanya ketergantungan waktu antara harga masa lalu dan harga saat ini menjadi tantangan dalam mengidentifikasi pola pergerakan harga [2]. Di tengah kondisi pasar yang terus berubah, akurasi model prediksi menjadi faktor krusial untuk mendukung pengambilan keputusan investasi yang lebih tepat. Salah satu model yang memiliki potensi kuat dalam melakukan prediksi harga saham adalah Recurrent Neural Network dengan arsitektur Long Short-Term Memory (RNN-LSTM) [3].

Risiko utama dalam investasi saham meliputi potensi penurunan harga (capital loss) serta kemungkinan perusahaan penerbit saham mengalami likuidasi [4]. Guna mengurangi resiko saat melakukan transaksi jual beli saham, investor perlu melakukan analisis terlebih dahulu, mengingat data harga saham termasuk dalam kategori deret waktu (time series) yang menunjukkan aktivitas pasar yang sangat dinamis [5]. Setiap saham tidak akan selalu mengalami kenaikan secara terus-menerus, begitu pula sebaliknya, tidak ada saham yang akan selamanya mengalami penurunan. Fluktuasi harga yang terjadi secara bergantian seiring berjalannya waktu akan membentuk pola-pola tertentu. Umumnya, pergerakan harga saham dalam kurun waktu tertentu memperlihatkan kecenderungan pola yang dapat diamati. Oleh karena itu, proses peramalan dianggap penting guna memaksimalkan keuntungan, yang menjadi tujuan utama para investor di pasar modal [6].

Salah satu saham yang banyak diminati oleh investor global adalah saham perusahaan NVIDIA Corporation [7]. NVIDIA dikenal sebagai perusahaan teknologi yang fokus pada pengembangan unit

pemrosesan grafis (GPU), kecerdasan buatan (AI), dan komputasi berkinerja tinggi. Sebagai perusahaan yang memiliki kapitalisasi pasar besar dan terlibat dalam berbagai bidang teknologi mutakhir seperti AI dan otomasi, saham NVIDIA menjadi salah satu yang paling banyak diperdagangkan dan dianalisis [8]. Namun demikian, tingginya volatilitas harga saham NVIDIA menjadi tantangan tersendiri dalam proses analisis dan prediksi harga di masa mendatang [9].


Teknik ini merupakan bagian dari kecerdasan buatan yang dirancang untuk meningkatkan pengetahuan atau performa suatu sistem berdasarkan pengalaman data sebelumnya [10]. Recurrent Neural Network (RNN) merupakan salah satu algoritma dalam machine learning yang dikenal memiliki tingkat akurasi tinggi dalam melakukan prediksi terhadap data berurutan atau time series [11]. Salah satu pengembangan dari algoritma RNN adalah Long Short-Term Memory (LSTM), yang dirancang untuk mengekstraksi informasi dari data berurutan jangka panjang [12]. LSTM memiliki keunggulan dalam mengatasi permasalahan vanishing gradient yaitu kondisi ketika nilai gradien mendekati nol dengan menggunakan mekanisme gerbang (gate) untuk mengontrol aliran informasi dalam jaringan [13]. Menurut penelitian Rahman Long Short-Term Memory (LSTM) dijelaskan sebagai metode Deep Learning yang memiliki beragam aplikasi dalam NLP, seperti speech recognition, text translation, dan sentiment analysis. LSTM merupakan versi lanjutan dari RNN yang dirancang untuk mengatasi isu vanishing gradient [14].

Berdasarkan penelitian yang dilakukan oleh Pipin (2023), model LSTM mampu melakukan prediksi terhadap harga pembukaan, harga terendah, dan harga tertinggi saham secara bersamaan dengan tingkat akurasi mencapai 95%. Kemampuan ini menunjukkan bahwa metode deep learning dapat mengekstraksi fitur dari data historis saham, mengenali pola temporal, mengidentifikasi hubungan non-linear, serta mengungkap tren yang mungkin tidak terdeteksi melalui pendekatan analisis konvensional [3]. Di sisi lain, fluktuasi harga saham sering kali dipengaruhi oleh volatilitas pasar yang bersifat heteroskedastik atau tidak konstan sepanjang waktu. Model Generalized Autoregressive Conditional Heteroskedasticity (GARCH) telah banyak digunakan untuk memodelkan dan memperkirakan volatilitas dalam data keuangan. Dengan demikian, informasi mengenai volatilitas dari model GARCH dapat menjadi fitur tambahan yang bagus dalam meningkatkan akurasi prediksi model LSTM [15].

Pada jurnal Zhao dijelaskan bahwa Model GARCH adalah model statistik yang banyak digunakan untuk menangkap fenomena volatilitas klustering dan volatilitas yang berubah seiring waktu dalam data runtun waktu (time series) keuangan. GARCH(1,1) secara luas digunakan dalam praktik karena kesederhanaannya dan kinerjanya yang unggul. Setelah karya awal mengenai GARCH, banyak pengembangan lanjutan telah dilakukan. Salah satunya adalah GJR-GARCH yang dirancang untuk menangkap asimetri dalam respons volatilitas, di mana guncangan negatif memiliki dampak yang lebih kuat dibandingkan guncangan positif [16]. Kondisi ini menuntut metode prediksi yang mampu menangkap pola temporal kompleks dan dinamika volatilitas. LSTM unggul dalam mempelajari pola data runtun waktu, sementara GARCH mampu memodelkan perubahan volatilitas harga. Kombinasi keduanya diharapkan menghasilkan prediksi yang lebih akurat dan informatif, sehingga mendukung pengambilan keputusan investasi yang lebih tepat.

2. METODE

Penelitian ini dilaksanakan melalui beberapa tahapan sistematis agar dapat mencapai tujuan secara terarah dan dapat dipertanggungjawabkan secara ilmiah. Setiap tahapan memiliki peran penting dalam membentuk keseluruhan proses, mulai dari tahap awal pengumpulan hingga tahap evaluasi model seperti pada Gambar 1.



Gambar 1. Metode Penelitian

1. Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diambil dari situs Yahoo Finance. Data ini dipilih karena tersedia secara bebas, terstandarisasi, dan mencakup informasi penting seperti harga pembukaan (Open), penutupan (Close), tertinggi (High), terendah (Low), volume transaksi (Volume), serta tanggal. File data disimpan dalam format CSV dan dibaca menggunakan pustaka pandas

Data sekunder merupakan jenis data yang tidak dikumpulkan secara langsung oleh peneliti, melainkan diperoleh dari sumber pihak ketiga. Data ini berasal dari referensi eksternal, seperti artikel, jurnal ilmiah, dan berbagai sumber lainnya yang telah tersedia sebelumnya [17]. Dalam konteks penelitian ini, data yang digunakan berasal dari situs Yahoo Finance, yang menyediakan data historis saham perusahaan secara terbuka dan dapat diakses publik. Data tersebut mencakup informasi harga saham perusahaan Nvidia (kode saham: NVDA) mulai dari tahun 2015 - 2024.

Tabel 1. Preview Dataset Saham NVIDIA

Date	Close_NVDA	High_NVDA	Low_NVDA	Open_NVDA	Volume_NVDA
1/5/2015	0.474939	0.484539	0.47278	0.483099	197952000
1/6/2015	0.46054	0.476139	0.46006	0.475659	197764000
1/7/2015	0.45934	0.46798	0.4579	0.4639	321808000
1/8/2015	0.476619	0.479499	0.46438	0.46462	283780000
1/9/2015	0.478539	0.482139	0.47182	0.478299	209540000
.....
1/26/2024	61.00809	61.75981	60.55027	60.93712	390309000
1/29/2024	62.44155	62.46554	60.88414	61.20901	348733000
1/30/2024	62.75043	63.46917	62.23663	62.87639	410735000
1/31/2024	61.50391	62.24563	60.67722	61.41694	453795000
2/1/2024	63.00334	63.16728	61.62686	62.07668	369146000

2. Transformasi Data

Untuk memastikan data yang digunakan tidak mengandung nilai kosong (missing value) yang dapat memengaruhi hasil model, dilakukan pembersihan data dengan metode dropna (). Untuk menghitung volatilitas yang akan digunakan sebagai input dalam model GARCH, dilakukan transformasi data dengan menambahkan kolom baru bernama LogReturn. Kolom ini dihitung menggunakan persamaan:

$$LogReturn = \ln \left(\frac{(Harga Penutupan Hari Ini)}{(Harga Penutupan Hari Sebelumnya)} \right) \quad (1)$$

3. Pembangunan Model GARCH

Model GARCH (Generalized Autoregressive Conditional Heteroskedasticity) digunakan dalam penelitian ini untuk mengukur volatilitas atau tingkat ketidakpastian dalam pergerakan harga saham NVIDIA. Volatilitas yang dimaksud adalah variasi return harian saham yang menunjukkan risiko pasar, di mana nilai volatilitas yang tinggi mengindikasikan ketidakstabilan harga yang lebih besar. Fenomena volatility clustering yang umum terjadi pada pasar saham di mana periode dengan volatilitas tinggi cenderung diikuti oleh periode tinggi lainnya, dan sebaliknya dapat ditangkap dengan model ini.

Tabel 2. Summary Model GARCH

Parameter	Koefisien	Standar Error	Z-Statistic	P-Value	Signifikansi
omega	9E-05	2.1E-05	4.2333	0	Signifikan
alpha[1]	0.1	0.02	5	0	Signifikan
beta[1]	0.8	0.05	16	0	Signifikan

Koefisien (Coefficient): Menunjukkan nilai estimasi dari parameter model.
Standar Error: Ukuran ketidakpastian dari koefisien estimasi.
Z-Statistic: Nilai statistik uji Z untuk menguji signifikansi parameter.
P-Value: Menunjukkan apakah parameter signifikan secara statistik (biasanya signifikan jika $p < 0.05$).
Signifikansi: Menandakan bahwa parameter berpengaruh secara statistik terhadap model.

Penelitian ini menggunakan model GARCH(1,1) dari pustaka arch di Python. Notasi (1,1) berarti model memanfaatkan satu lag error kuadrat (ARCH) dan satu lag varians sebelumnya (GARCH). Hasil estimasi menunjukkan parameter $\omega = 9.013e-05$, $\alpha[1] = 0.1000$, dan $\beta[1] = 0.8000$, semuanya signifikan ($p\text{-value} < 0.05$), sehingga valid untuk menggambarkan volatilitas. $\alpha[1]$ menunjukkan seberapa cepat volatilitas merespons shock baru, sedangkan $\beta[1]$ yang tinggi (0.8000) menandakan bahwa volatilitas bersifat persisten dan dapat bertahan dalam beberapa hari. Nilai volatilitas hasil GARCH kemudian disimpan dalam file CSV dan digabungkan dengan data historis saham (open, close, high, low, volume) sebagai input tambahan untuk model LSTM. Tujuannya agar LSTM tidak hanya mempelajari pergerakan harga, tetapi juga memahami risiko dan tingkat ketidakstabilan pasar.

Tabel 3. Dataset setelah ditambahkan kolom volatilitas

Date	Close_NVDA	High_NVDA	Low_NVDA	Open_NVDA	Volume_NVDA	LogReturn	GARCH_Volatility
1/5/2015	0.474939	0.484539	0.47278	0.483099	197952000	-0.01703	0.021094845
1/6/2015	0.46054	0.476139	0.46006	0.475659	197764000	-0.03079	0.022052169
1/7/2015	0.45934	0.46798	0.4579	0.4639	321808000	-0.00261	0.024359568
1/8/2015	0.476619	0.479499	0.46438	0.46462	283780000	0.036927	0.023832738
1/9/2015	0.478539	0.482139	0.47182	0.478299	209540000	0.00402	0.025682297
.....
1/26/2024	61.00809	61.75981	60.55027	60.93712	390309000	-0.00956	0.024704336
1/29/2024	62.44155	62.46554	60.88414	61.20901	348733000	0.023224	0.024375453
1/30/2024	62.75043	63.46917	62.23663	62.87639	410735000	0.004935	0.024623807
1/31/2024	61.50391	62.24563	60.67722	61.41694	453795000	-0.02006	0.023991031
2/1/2024	63.00334	63.16728	61.62686	62.07668	369146000	0.024087	0.024572884

4. Pembangunan Model LSTM

Tabel 4. Arsitektur model LSTM

Layer (type)	Output Shape	Param
lstm_6 (LSTM)	(None, 60, 100)	41,600
batch_normalization_2 (BatchNormalization)	(None, 60, 100)	400
dropout_4 (Dropout)	(None, 60, 100)	0
lstm_7 (LSTM)	(None, 50)	30,200
dense_3 (Dense)	(None, 1)	51

Total params: 72,251 (282.23 KB)
 Trainable params: 72,051 (281.45 KB)
 Non-trainable params: 200 (800.00 B)

Model dalam penelitian ini menggunakan arsitektur Long Short-Term Memory (LSTM) yang dirancang khusus untuk memproses data deret waktu. Lapisan pertama terdiri dari 100 unit LSTM yang menerima input sepanjang 60 timesteps dan mengembalikan seluruh urutan output untuk menangkap pola

temporal. Setelah itu, diterapkan Batch Normalization untuk menstabilkan pelatihan dan Dropout sebagai regularisasi guna mencegah overfitting. Output kemudian diteruskan ke lapisan LSTM kedua dengan 50 unit yang merangkum seluruh informasi menjadi satu vektor representasi. Vektor ini menjadi input bagi lapisan Dense dengan satu neuron sebagai output akhir prediksi harga saham. Model dilatih selama 50 epoch, dengan total 72.051 parameter yang dioptimasi menggunakan backpropagation untuk meminimalkan selisih antara prediksi dan harga aktual. Struktur lengkap model dijelaskan pada Tabel 4 berikut.


5. Evaluasi Model

Pada penelitian ini menggunakan MAE dan RMSE untuk mengevaluasi model LSTM yang dibangun. MAE adalah metrik yang berguna untuk mengevaluasi dan membandingkan performa beberapa model regresi yang berbeda, Karena MAE tidak memperhitungkan arah kesalahan [18], metrik ini memberikan pandangan yang jelas dan langsung tentang kesalahan prediksi rata-rata tanpa terpengaruh oleh kesalahan besar yang mungkin ada di dalam dataset [19]. Root Mean Square Error (RMSE) adalah metrik yang berguna untuk mengevaluasi dan membandingkan performa beberapa model regresi yang berbeda. Karena RMSE memiliki satuan yang sama dengan variabel yang diprediksi, metrik ini memberikan interpretasi yang langsung dan mudah dipahami tentang seberapa jauh prediksi model dari nilai sebenarnya [20].

3. HASIL PENELITIAN

3.1 Evaluasi Model

Evaluasi performa model LSTM dilakukan dengan memantau nilai loss (Mean Squared Error/MSE) selama proses pelatihan terhadap data latih (training) dan data (validasi). Gambar 2 menyajikan grafik nilai training loss dan validation loss terhadap jumlah epoch yang dilakukan selama masa training model LSTM.

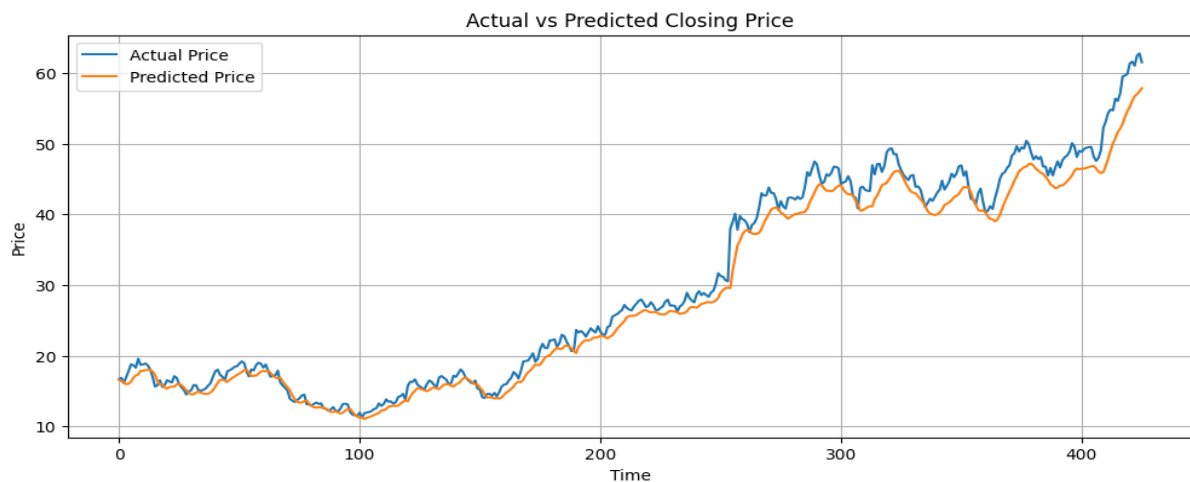


Gambar 2. Grafik Model Loss Per Epoch

Pada Gambar 2, kurva biru menggambarkan training loss, sementara kurva oranye menunjukkan validation loss. Keduanya mengalami penurunan signifikan dalam 10 hingga 20 epoch pertama, yang menunjukkan bahwa model dengan cepat belajar pola dari data. Pada awal pelatihan (epoch 0–10), terlihat penurunan tajam pada kedua kurva. Hal ini menunjukkan bahwa model berhasil mempelajari representasi dasar dari data dengan cukup cepat, dan proses optimisasi berjalan efektif sejak awal. Memasuki pertengahan pelatihan (epoch 10–30), laju penurunan mulai melambat. Training loss turun lebih cepat dan mendekati nol, sedangkan validation loss juga menurun namun tetap berada di atas training loss. Kondisi ini menunjukkan bahwa model tetap mampu belajar namun mulai menghadapi tantangan dalam melakukan generalisasi terhadap data yang tidak terlihat. Pada akhir pelatihan (epoch >30), kedua kurva mencapai nilai yang sangat rendah dan cenderung stabil. Ini menunjukkan bahwa model tidak hanya menghafal data latih, tetapi juga mampu memprediksi data validasi dengan akurasi tinggi. Tidak tampak adanya peningkatan validation loss secara signifikan, yang biasanya menandakan overfitting.

3.2 Kinerja Prediksi Model

Kemampuan model dalam memprediksi harga penutupan saham NVIDIA pada data uji divisualisasikan dengan membandingkan harga aktual dengan harga hasil prediksi model. Grafik perbandingan ini disajikan pada Gambar 3.



Gambar 3. Grafik Perbandingan harga aktual vs prediksi pada data uji coba

Gambar 3 menunjukkan kemampuan model LSTM dalam memprediksi harga penutupan saham NVIDIA selama periode pengujian, dengan garis biru sebagai harga aktual dan garis oranye sebagai hasil prediksi. Grafik berisi lebih dari 400-time steps, sehingga mencerminkan performa model pada rentang waktu yang cukup panjang. Secara visual, model berhasil mengikuti pola pergerakan harga, baik saat tren naik maupun turun. Contohnya, pada titik ke-100 hingga ke-250 terjadi kenaikan harga dari sekitar \$12 ke lebih dari \$25, dan model mampu mengikuti pola ini dengan baik. Pada lonjakan tajam titik ke-250 hingga ke-300, prediksi sedikit terlambat namun tetap akurat dalam arah pergerakan. Di akhir pengujian (titik ke-400 hingga ke-440), saat harga mendekati \$63, model memprediksi sekitar \$58–\$60, dengan selisih \$3–\$5 yang masih dapat diterima mengingat volatilitas pasar. Konsistensi prediksi ini menunjukkan bahwa LSTM mampu menangkap pola temporal jangka pendek dan panjang, dan memiliki potensi kuat sebagai alat prediksi harga saham berbasis data historis.

3.3 Evaluasi Kuantitatif

Evaluasi kuantitatif kinerja model dilakukan menggunakan dua metrik kesalahan prediksi yang umum, yaitu Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE). MAE mengukur rata-rata dari nilai absolut kesalahan prediksi, memberikan gambaran langsung tentang seberapa besar kesalahan prediksi rata-rata tanpa terlalu sensitif terhadap kesalahan besar (outlier). Sementara itu, RMSE mengukur akar dari rata-rata kuadrat kesalahan antara nilai aktual dan prediksi, yang lebih sensitif terhadap outlier dan cocok untuk mendeteksi deviasi besar dalam prediksi. Perbandingan kinerja model LSTM-GARCH dengan model LSTM murni disajikan pada Tabel 4.

Tabel 4. Perbandingan Metrik Evaluasi model

Perbandingan Evaluasi Model		
	LSTM + GARCH	LSTM
Mean Absolute Error (MAE)	1.72	9.15
Root Mean Squared Error (RMSE)	2.26	6.72

Berdasarkan Tabel 4. dapat diamati bahwa model LSTM-GARCH menunjukkan kinerja yang secara signifikan lebih baik dibandingkan dengan model LSTM murni. Nilai MAE untuk model LSTM-GARCH adalah 1.72, jauh lebih rendah dibandingkan dengan MAE model LSTM murni sebesar 9.15. Demikian pula, nilai RMSE untuk model LSTM-GARCH tercatat 2.26, yang juga jauh lebih rendah dibandingkan dengan RMSE model LSTM murni sebesar 6.72.

Hasil ini menunjukkan bahwa model hybrid LSTM-GARCH mampu menghasilkan prediksi harga saham NVIDIA dengan kesalahan yang sangat kecil. Nilai MAE yang rendah mengindikasikan selisih rata-rata antara prediksi dan harga aktual sangat minimal, sedangkan nilai RMSE yang juga rendah menunjukkan model berhasil menghindari deviasi prediksi yang besar, bahkan terhadap outlier. Penurunan signifikan pada kedua metrik ini memperkuat bahwa integrasi informasi volatilitas dari GARCH secara efektif meningkatkan akurasi prediksi dibandingkan penggunaan LSTM tunggal.

3.4 Hasil Prediksi

Tabel 5. Hasil Prediksi Harga Saham NVIDIA

No.	Date	Actual	Prediction
1	7/7/2022	14.989	15.912
2	8/7/2022	15.435	15.699
3	11/7/2022	15.409	15.623
5	13/07/2022	15.247	15.612
6	14/07/2022	14.57	15.584
7	15/07/2022	15.087	15.514
8	18/07/2022	15.638	15.47
9	19/07/2022	16.28	15.509
10	20/07/2022	16.463	15.671
....
387	19/01/2024	57.239	53.157
388	22/01/2024	57.967	53.82
389	23/01/2024	60.026	54.545
390	24/01/2024	59.548	55.353
391	25/01/2024	60.281	56.069
392	26/01/2024	62.327	56.84
393	29/01/2024	60.937	57.62
394	30/01/2024	61.209	58.247
395	31/01/2024	62.876	58.781
396	1/2/2024	61.417	59.336

Tabel 5. menyajikan komparasi antara nilai harga penutupan saham NVIDIA yang aktual (Actual) dan hasil prediksi (Prediction) dari model hybrid Long Short-Term Memory (LSTM) yang diintegrasikan dengan Generalized Autoregressive Conditional Heteroskedasticity (GARCH). Tabel ini berfungsi sebagai representasi kuantitatif dari kemampuan model dalam melakukan peramalan harga saham pada periode pengujian. Data prediksi dimulai pada tanggal 7 Juli 2022 dan berakhir pada 1 Februari 2024. Hal ini dikarenakan dataset yang digunakan dalam penelitian ini, meskipun mencakup periode dari tahun 2015 hingga 2024, telah dibagi menjadi data pelatihan dan data pengujian. Pembagian data dilakukan secara sekuensial, dengan 80% data awal (dari tahun 2015 hingga 6 Juli 2022) dialokasikan untuk pelatihan model, dan 20% data terakhir (dari 7 Juli 2022 hingga 1 Februari 2024) digunakan sebagai set data pengujian. Oleh karena itu, tabel ini secara spesifik menyajikan kinerja model pada data yang belum pernah dilihat selama proses pelatihan, sehingga merefleksikan kemampuan generalisasi model dalam skenario prediksi dunia nyata. Evaluasi kualitas prediksi model dapat dilakukan dengan membandingkan secara langsung nilai pada kolom "Actual" dan "Prediction", di mana semakin kecil selisih antara kedua nilai tersebut mengindikasikan tingkat akurasi prediksi yang lebih tinggi.

Berdasarkan metrik evaluasi kinerja model pada tabel 4. model ini menunjukkan hasil yang sangat baik. Nilai Mean Absolute Error (MAE) sebesar 1.72 mengindikasikan bahwa rata-rata selisih absolut antara

harga aktual dan harga prediksi adalah sebesar \$1.72. Selanjutnya, Root Mean Squared Error (RMSE) sebesar 2.26 menunjukkan rata-rata deviasi kuadrat akar dari prediksi adalah sekitar \$2.26. Angka-angka ini menunjukkan tingkat kesalahan prediksi yang relatif rendah mengingat skala harga saham NVIDIA

4. DISKUSI

Model hybrid LSTM-GARCH yang diterapkan dalam penelitian ini terbukti mampu meningkatkan akurasi prediksi harga saham NVIDIA dibandingkan model LSTM murni. Hal ini ditunjukkan oleh nilai MAE dan RMSE yang jauh lebih rendah pada model hybrid. Temuan ini sejalan dengan penelitian sebelumnya yang menyebutkan bahwa integrasi model volatilitas seperti GARCH dapat memberikan konteks risiko tambahan yang tidak dapat ditangkap oleh LSTM secara tunggal. Secara visual, model menunjukkan kemampuan yang konsisten dalam mengikuti arah pergerakan harga, baik tren naik maupun turun. Bahkan pada kondisi volatilitas tinggi, model masih mampu menghasilkan prediksi yang berada dalam rentang kesalahan yang dapat diterima. Hasil ini mengonfirmasi efektivitas LSTM dalam menangkap pola temporal jangka pendek dan panjang.

Dibandingkan dengan penelitian Pipin (2023) yang hanya menggunakan LSTM dan mencapai akurasi tinggi pada saham lain, penelitian ini membuktikan bahwa penambahan informasi volatilitas dari GARCH memberikan peningkatan signifikan. Selain itu, penelitian Zhao (2024) juga menunjukkan pentingnya pemodelan volatilitas dalam analisis pasar yang bersifat heteroskedastik. Dengan demikian, temuan penelitian ini menegaskan bahwa pendekatan hybrid yang menggabungkan GARCH dan LSTM lebih adaptif terhadap dinamika pasar modern yang sarat ketidakpastian. Namun, akurasi model masih dapat ditingkatkan dengan memasukkan faktor eksternal seperti sentimen berita atau indikator teknikal tambahan dalam penelitian selanjutnya.

5. KESIMPULAN

Penelitian ini menyimpulkan bahwa penggunaan model hybrid LSTM-GARCH dalam memprediksi harga saham NVIDIA mampu meningkatkan akurasi prediksi dibandingkan dengan model LSTM tunggal. Model GARCH secara efektif menangkap volatilitas pasar melalui fenomena volatility clustering, yang kemudian membantu LSTM dalam memahami fluktuasi harga saham, terutama di kondisi pasar yang tidak stabil. LSTM sendiri menunjukkan performa yang baik dalam mengenali pola waktu dari data historis, apalagi setelah dikombinasikan dengan teknik batch normalization dan dropout, sehingga mampu mencegah overfitting. Evaluasi model menunjukkan performa yang memuaskan, dengan MAE sebesar 1.72 dan RMSE sebesar 2.26, menandakan tingkat kesalahan prediksi yang rendah. Adapun saran untuk penelitian selanjutnya adalah untuk menambahkan faktor eksternal seperti berita keuangan atau sentimen pasar agar model menjadi lebih adaptif terhadap dinamika global. Penelitian lanjutan juga disarankan mengeksplorasi varian lain dari GARCH, seperti EGARCH atau GJR-GARCH, untuk menangkap efek asimetri dalam volatilitas. Pengujian pada saham perusahaan lain atau indeks pasar juga penting untuk menguji generalisasi model. Selain itu, penambahan indikator teknikal seperti moving average, RSI, dan MACD dapat memperkaya fitur input LSTM. Terakhir, pengembangan sistem prediksi secara real-time berbasis web atau aplikasi desktop diharapkan dapat membantu investor dalam mengambil keputusan secara cepat dan berbasis data.

DAFTAR PUSTAKA

- [1] N. Raisa Hanum, U. Jambi, F. Sains dan Teknologi, A. Waladi, and Y. Perdana, "Implementation of Machine Learning for Stock Price Prediction Using the LSTM Algorithm Hasanatul Iftitah," 2024. [Online]. Available: <http://www.mase.or.id>
- [2] L. Zhang and L. Hua, "Major Issues in High-Frequency Financial Data Analysis: A Survey of Solutions," *Mathematics*, vol. 13, no. 3, Feb. 2025, doi: 10.3390/math13030347.
- [3] S. J. Pipin, R. Purba, and H. Kurniawan, "Prediksi Saham Menggunakan Recurrent Neural Network (RNN-LSTM) dengan Optimasi Adaptive Moment Estimation," *Journal of Computer System and Informatics (JoSYC)*, vol. 4, no. 4, pp. 806–815, Aug. 2023, doi: 10.47065/josyc.v4i4.4014.
- [4] D. H. Vo, "Market risk, financial distress and firm performance in Vietnam," *PLoS One*, vol. 18, no. 7 July, Jul. 2023, doi: 10.1371/journal.pone.0288621.
- [5] D. Anisha and I. Putri, "MARKET VALUE ADDED (MVA) ON STOCK RETURN MARKET VALUE ADDED (MVA) DALAM PENGEMBALIAN SAHAM," 2021.

- [6] W. Y. Rusyida and V. Y. Pratama, "Prediksi Harga Saham Garuda Indonesia di Tengah Pandemi Covid-19 Menggunakan Metode ARIMA," *Square: Journal of Mathematics and Mathematics Education*, vol. 2, no. 1, p. 73, Apr. 2020, doi: 10.21580/square.2020.2.1.5626.
- [7] G. Papageorgiou, D. Gkaimanis, and C. Tjortjis, "Enhancing Stock Market Forecasts with Double Deep Q-Network in Volatile Stock Market Environments," *Electronics (Switzerland)*, vol. 13, no. 9, May 2024, doi: 10.3390/electronics13091629.
- [8] S. Chen, "Research on Nvidia Investment Strategies and Analysis," 2024.
- [9] Y. Xing, C. Yan, and C. C. Xie, "Predicting NVIDIA's Next-Day Stock Price: A Comparative Analysis of LSTM, MLP, ARIMA, and ARIMA-GARCH Models."
- [10] C. Bartneck, C. Lütge, A. Wagner, and S. Welsh, "An Introduction to Ethics in Robotics and AI," *cham*, Aug. 2021.
- [11] A. Hanafiah, Y. Arta, H. O. Nasution, and Y. D. Lestari, "Penerapan Metode Recurrent Neural Network dengan Pendekatan Long Short-Term Memory (LSTM) Untuk Prediksi Harga Saham," *Bulletin of Computer Science Research*, vol. 4, no. 1, pp. 27–33, Dec. 2023, doi: 10.47065/bulletincsr.v4i1.321.
- [12] S. M. Al-Selwi *et al.*, "RNN-LSTM: From applications to modeling techniques and beyond—Systematic review," Jun. 01, 2024, *King Saud bin Abdulaziz University*. doi: 10.1016/j.jksuci.2024.102068.
- [13] R. Julian and M. R. Pribadi, "Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM)," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 8, no. 3, 2021, [Online]. Available: <http://jurnal.mdp.ac.id>
- [14] M. Z. Rahman, Y. A. Sari, and N. Yudistira, "Analisis Sentimen Tweet COVID-19 menggunakan Word Embedding dan Metode Long Short-Term Memory (LSTM)," 2021. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [15] B. Jange, "Prediksi Volatilitas Indeks Harga Saham Gabungan Menggunakan GARCH," *ARBITRASE: Journal of Economics and Accounting*, vol. 4, no. 1, pp. 1–6, Jul. 2023, doi: 10.47065/arbitrase.v4i1.1122.
- [16] 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
- [17] Y. S. Siregar, M. Darwis, R. Baroroh, and W. Andriyani, "Peningkatan Minat Belajar Peserta Didik dengan Menggunakan Media Pembelajaran yang Menarik pada Masa Pandemi Covid 19 di SD Swasta HKBP 1 Padang Sidempuan," *Jurnal Ilmiah Kampus Mengajar*, pp. 69–75, Apr. 2022, doi: 10.56972/jikm.v2i1.33.
- [18] Nurdin, N. Suarna, and W. Prihartono, "ALGORITMA REGRESI LINIER SEDERHANA UNTUK PREDIKSI PENGGUNAAN VOLUME AIR BERDASARKAN JENIS PELANGGAN PDAM," *Jurnal Kecerdasan Buatan dan Teknologi Informasi*, vol. 4, no. 1, pp. 43–52, Jan. 2025, doi: 10.69916/jkbt.v4i1.187.
- [19] T. O. Hodson, "Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not," Jul. 19, 2022, *Copernicus GmbH*. doi: 10.5194/gmd-15-5481-2022.
- [20] Z. Li, "A Comparative Study of Regression Models for Housing Price Prediction," 2024.