



Prediksi Volatilitas IHSG Dengan Hybrid Model GARCH-Random Forest Berbasis Machine Learning

Jose Julian Hidayat¹, Surya Hasanudin²

¹Program Studi Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa, Bekasi, Indonesia

²Program Studi Manajemen, Fakultas Ekonomi dan Bisnis, Universitas Pelita Bangsa, Bekasi, Indonesia

Email author: josejulianhidayat@gmail.com¹, suryahasanudin922@gmail.com²

Article Info

Article history:

Received March 3, 2026

Revised March 17, 2026

Accepted April 5, 2026

Keywords:

IHSG

GARCH

Machine Learning

Time Series Forecasting

Random Forest

ABSTRACT

In risk analysis and investment decision-making, stock market volatility is very important, especially in the Composite Stock Price Index (IHSG), which is constantly changing and influenced by many economic factors. To predict IHSG volatility, this study uses a Hybrid GARCH-Random Forest approach. This approach combines the strength of Random Forest in modelling non-linear relationships with the ability of the GARCH model to identify financial data heteroscedasticity. To predict volatility on the following day, data from the IHSG closing price is processed into logarithmic returns and then used to estimate volatility using the GARCH(1,1) model. According to performance evaluations, this hybrid model is capable of providing highly accurate predictions. In addition, the model was tested in a volatility classification scheme into three categories: low, medium, and high. In regression testing, an MSE value of 0.000386 and an RMSE value of 0.01965 were obtained, indicating that the volatility prediction error was very low. The accuracy, recall, and f1-values were between 0.99 and 1.00. The results show that the Hybrid GARCH-Random Forest approach is very effective in modelling IHSG volatility. This approach can also be a reliable tool to support risk analysis and decision-making strategies in financial markets.

Corresponding Author:

Jose Julian Hidayat,

Universitas Pelita Bangsa

Jl. Inspeksi Kalimalang No.9, Bekasi, 17530, Indonesia

Email: josejulianhidayat@gmail.com



1. INTRODUCTION

Pasar modal memainkan peran penting dalam perekonomian karena merupakan cara untuk mengumpulkan dana serta merupakan indikator kesehatan ekonomi suatu negara (Fathori, 2023). Pergerakan indeks saham, seperti Indeks Harga Saham Gabungan (IHSG), menunjukkan reaksi investor terhadap sentimen pasar, ekonomi, dan politik (Silalahi & Sihombing, 2021). Pasar saham memiliki volatilitas fluktuatif yang tinggi, yang menunjukkan ketidakpastian pasar dan dapat memengaruhi

keputusan investasi (Hisam, 2024). Oleh karena itu, untuk memahami dinamika risiko pasar, penelitian tentang prediksi volatilitas menjadi sangat penting.

Berbagai studi menunjukkan bahwa volatilitas merupakan elemen krusial dalam manajemen portofolio, penentuan harga aset, dan pengukuran risiko (Maksimiliansyah et al., 2024). Penelitian-penelitian terdahulu menegaskan bahwa akurasi prediksi volatilitas dapat membantu investor dalam menyusun strategi hedging dan manajemen risiko yang lebih efektif (Nurqotimah et al., 2025). Selain itu, volatilitas yang dapat diprediksi dengan baik memberikan nilai tambah bagi lembaga keuangan untuk melakukan penilaian risiko kredit dan pasar secara lebih presisi (Dasman et al., 2024).

Karena kemampuannya untuk menangkap sifat heteroskedastis dalam data keuangan (Rafulta et al., 2025), Model *Generalized Autoregressive Conditional Heteroskedasticity (GARCH)* dan versinya telah menjadi pilihan utama untuk memodelkan volatilitas (Wijoyo, 2016). Namun, *GARCH* tidak dapat menangkap hubungan non-linear dan kompleksitas pola volatilitas jangka panjang (Paulina, 2022). Disebabkan hal ini, diperlukan metode yang dapat menggabungkan keunggulan model statistik dengan teknik pembelajaran mesin.

Keterlibatan pada *hybrid* model yaitu penggabungan metode *machine learning* dan statistik meningkat dalam penelitian baru-baru ini. Studi literatur menunjukkan bahwa model *hybrid*, yang menggabungkan kelebihan kedua metode, dapat meningkatkan akurasi prediksi (Wibowo, 2023). Misalnya, penelitian menunjukkan bahwa penggabungan *GARCH* dengan algoritma jaringan saraf atau pohon keputusan dapat menghasilkan prediksi yang lebih stabil dan responsif terhadap perubahan pola volatilitas pasar (Selyanti et al., 2025).

Random Forest adalah algoritma *ensemble* berbasis pohon keputusan yang dikenal sangat efektif dalam menangani data yang saling berinteraksi dan *non-linear* (Sobari et al., 2025). Karena *Random Forest* tahan terhadap *outlier*, mampu mengurangi *overfitting*, dan memberikan hasil prediksi yang konsisten, beberapa jurnal mengatakan bahwa itu memiliki keunggulan dalam prediksi seri waktu (Simamora et al., 2025). *Random Forest* telah digunakan dalam pasar saham untuk prediksi harga, deteksi volatilitas ekstrem, dan analisis fluktuasi pasar (Rismayadi et al., 2024). Dibandingkan dengan metode konvensional, ia menunjukkan kinerja yang kompetitif.

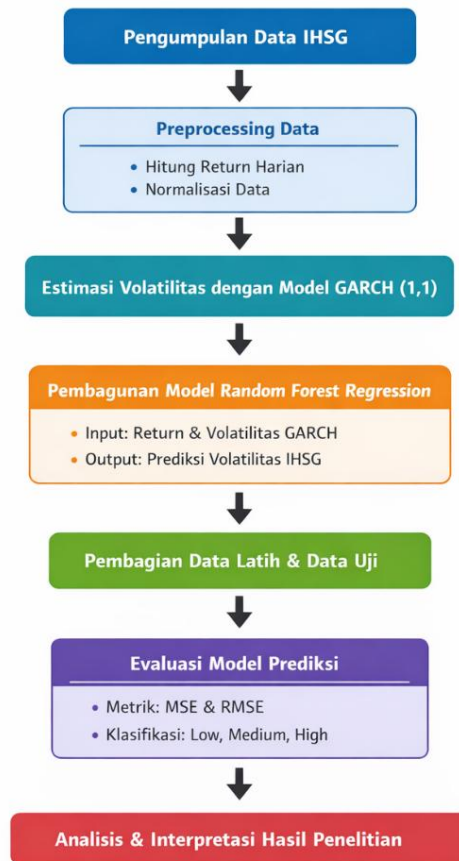
Indeks saham di pasar negara berkembang seperti Indonesia cenderung lebih fluktuatif dan dipengaruhi oleh berbagai faktor internal dan global (Rantina et al., 2025). Untuk kasus IHSG, penelitian yang menggabungkan model *GARCH* sebagai estimator volatilitas dan *Random Forest* sebagai pemodel prediksi masih sedikit (Fakhriyana et al., 2016). Diharapkan *hybrid GARCH-Random Forest* dapat menggunakan data volatilitas sebelumnya untuk mengidentifikasi pola non-linear dalam pergerakan volatilitas IHSG.

Penelitian ini bertujuan untuk menciptakan model *hybrid GARCH-Random Forest* sebagai keterbaruan dalam penelitian ini untuk memprediksi volatilitas IHSG berdasarkan masalah tersebut. Untuk memberikan gambaran menyeluruh tentang performanya, model ini dievaluasi menggunakan metrik regresi dan klasifikasi. Hasil penelitian ini diharapkan dapat menambah literatur tentang prediksi volatilitas di pasar saham Indonesia dan menjadi acuan bagi investor, analis keuangan, dan peneliti yang bekerja untuk mengembangkan model baru.

2. METHOD

Penelitian ini menggunakan pendekatan *hybrid GARCH-Random Forest* untuk menunjukkan alur sistematis dalam memprediksi volatilitas IHSG. Penelitian dimulai dengan pengumpulan data harga saham IHSG, kemudian melalui tahap *preprocessing*, yang mencakup normalisasi data untuk memastikan kualitas input dan perhitungan return harian (Umam et al., 2025). Selanjutnya, volatilitas dihitung menggunakan model *GARCH(1,1)* untuk menangkap karakteristik *heteroskedastisitas* pada data keuangan (Fathoni et al., 2025). Untuk mempertahankan sifat urutan waktu, data dibagi menjadi data latih dan data uji. Akhir dari penelitian adalah mengevaluasi kinerja model menggunakan metrik regresi

seperti *MSE* dan *RMSE*, serta pendekatan untuk membagi *volatilitas* model ke dalam kategori rendah, sedang, dan tinggi. Hasil penelitian kemudian dianalisis dan direpresentasikan.



Gambar 1. Desain Penelitian

2.1 Jenis dan Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental pada data *time series* keuangan. Pendekatan kuantitatif dipilih karena penelitian berfokus pada pengolahan data numerik, pemodelan matematis, serta evaluasi performa model menggunakan metrik statistik dan pembelajaran mesin. Metode eksperimental digunakan untuk membangun, melatih, dan menguji model prediksi *volatilitas* berdasarkan skenario dan parameter tertentu (Natzir & Jatiprasetya, 2025).

2.2 Sumber dan Deskripsi Data

Data yang digunakan dalam penelitian ini adalah data harga penutupan harian Indeks Harga Saham Gabungan (IHSG) yang diperoleh dari sumber data pasar modal yang kredibel. Data mencakup periode historis yang panjang untuk memastikan keberagaman kondisi pasar. Data terdiri atas atribut tanggal dan harga penutupan (*closing price*) yang selanjutnya diolah menjadi return harian sebagai dasar pemodelan volatilitas (Afnanda et al., 2024).

2.3 Tahap *Preprocessing*

Tahapan *preprocessing* dilakukan untuk memastikan kualitas dan kesiapan data sebelum proses pemodelan dilakukan. Pada tahap ini, data terlebih dahulu dikonversi ke dalam format tanggal yang sesuai dan diurutkan berdasarkan urutan waktu agar mencerminkan karakteristik *time series* (Amin et

al., 2025). Selanjutnya, data yang mengandung nilai hilang (*missing value*) diidentifikasi dan dihapus untuk menghindari bias dalam proses analisis (Hidayat et al., 2025). Setelah itu, harga penutupan harian diolah menjadi return *logaritmik* harian yang digunakan sebagai dasar dalam pemodelan *volatilitas*. Pada tahap tertentu, data juga dinormalisasi atau distandarisasi untuk mendukung kinerja algoritma pembelajaran mesin agar proses pelatihan model menjadi lebih stabil dan akurat (Hidayat et al., 2025).

2.4 Pemodelan Volatilitas Menggunakan GARCH

Untuk mengestimasi volatilitas harian IHSG, model *Generalized Autoregressive Conditional Heteroskedasticity (GARCH)* digunakan (Rafulta et al., 2025). Ini dipilih karena model ini terbukti efektif dan banyak digunakan dalam literatur keuangan. *Volatilitas kondisional (σ_t)*, hasil dari model GARCH, menunjukkan tingkat risiko pasar selama periode tertentu. Nilai *volatilitas* ini kemudian menjadi fitur utama model hybrid.

2.5 Perancangan Model Hybrid GARCH–Random Forest

Model *hybrid* menggabungkan hasil estimasi *volatilitas GARCH* dan algoritma regresi *random forest*. Return harian dan *volatilitas GARCH* adalah fitur input yang digunakan, dan target prediksi adalah *volatilitas IHSG* pada periode berikutnya (Fathoni et al., 2025). Untuk memastikan urutan temporal data, metode pembagian seri waktu tanpa pengacakan digunakan untuk membagi data menjadi data latih dan data uji. Random Forest dipilih karena mampu menangkap hubungan *non-linear*, mengurangi *overfitting*, dan menghasilkan hasil prediksi yang stabil.

2.6 Metode Evaluasi Model

Untuk mengevaluasi model, dua pendekatan digunakan: regresi dan klasifikasi. Untuk evaluasi regresi, tingkat kesalahan prediksi diukur dengan metrik *Mean Squared Error (MSE)* dan *Root Mean Squared Error (RMSE)* (Rosyid et al., 2024). Selain itu, *volatilitas* hasil prediksi juga dikategorikan ke dalam tiga kategori: Low, Medium, dan High, berdasarkan nilai kuantil. Kemampuan model untuk mengklasifikasikan tingkat volatilitas dinilai dengan menggunakan matriks kekacauan, ketepatan, ketepatan, *recall*, dan skor f1 (Hidayat et al., 2025).

3. RESULT DAN ANALISIS

Penelitian ini menggunakan data historis harian Indeks Harga Saham Gabungan (IHSG), yang terdiri dari beberapa atribut utama: tanggal, pembukaan, harga tertinggi, harga terendah, dan harga penutupan. Berdasarkan hasil eksplorasi awal menggunakan fungsi *df.head()*, data menunjukkan bahwa setiap baris menunjukkan harga pembukaan, harga tertinggi, harga terendah, dan harga penutupan pada hari tertentu. Penelitian ini menggunakan data jangka panjang untuk menunjukkan berbagai kondisi pasar, termasuk periode stabil maupun *volatilitas* tinggi. Ini terlihat pada beberapa baris awal data, di mana nilai *Open*, *High*, *Low*, dan *Close* sama, yang menunjukkan bahwa kondisi pasar agak stabil atau sedikit variasi harga selama periode awal pencatatan. Secara umum, struktur data bersifat runtut berdasarkan waktu (seri waktu), yang sangat cocok untuk analisis volatilitas karena memungkinkan untuk melihat pola perubahan harga dan risiko pasar dari waktu ke waktu.

Tabel 1. Dataset IHSG

No	date	close	high	Low	open
0	1/2/1995	470.121735	470.121735	470.121735	470.121735
1	1/3/1995	472.361633	472.361633	472.361633	472.361633
2	1/4/1995	474.471527	474.471527	474.471527	474.471527
3	1/5/1995	477.801422	477.801422	477.801422	477.801422
4	1/6/1995	481.201263	481.201263	481.201263	481.201263
5	1/9/1995	477.021454	477.021454	477.021454	477.021454
...
...
7485	10/1/2025	8043.821777	8093.693848	8034.25	8069.937012
7486	10/3/2025	8118.301	8118.300781	8076.597168	8099.64502
7487	10/6/2025	8139.894043	8176.308105	8104.551758	8155.365234

Data dirubah kedalam format *datetime*, Kemudian data diurutkan berdasarkan rentang waktu terlampau hingga terbaru. Selanjutnya, data yang mengandung nilai hilang (*missing value*) diidentifikasi dan dihapus untuk menghindari bias dalam proses analisis

Tabel 2. Merubah Format ke *datetime*, mengurutkan tanggal, menghapus *missing value*

No	date	close	high	Low	open
0	1995-01-02	470.121735	470.121735	470.121735	470.121735
1	1995-01-03	472.361633	472.361633	472.361633	472.361633
...
7486	2025-10-05	8118.301	8118.300781	8076.597168	8099.64502
7487	2025-10-06	8139.894043	8176.308105	8104.551758	8155.365234

Setelah mendapatkan data harga penutupan IHSG, *return logaritmik* harian dihitung dan dikalikan 100 untuk mendapatkan nilai persentase. Tujuan dari perhitungan return ini adalah untuk menghitung perubahan harga relatif dari waktu ke waktu dan juga untuk mengurangi dampak skala harga terhadap analisis. Agar data siap untuk digunakan pada tahap pemodelan berikutnya, nilai kosong (*NaN*) yang muncul pada baris pertama sebagai hasil dari proses *differencing* dihapus. Data yang diperoleh dari proses transformasi ini sangat penting untuk estimasi *volatilitas* dan pembuatan model prediksi.

Tabel 3. Menghirung Return Logaritmik

No	Date	Close	Return (%)
1	1995-01-03	472.361633	0.475319
2	1995-01-04	474.471527	0.445675
3	1995-01-05	477.801422	0.699360
4	1995-01-06	481.201263	0.709040
5	1995-01-09	477.021454	-0.872414

Pada tahap estimasi volatilitas, data return IHSG dibagi menjadi data latih dan data uji dengan proporsi 80% untuk data latih dan 20% untuk data uji, di mana sebanyak 5.988 data digunakan untuk pelatihan model $GARCH$ dan 1.497 data digunakan sebagai data pengujian. Model yang digunakan adalah $GARCH(1,1)$ dengan asumsi distribusi normal dan mean nol (*Zero Mean*). Hasil estimasi menunjukkan bahwa parameter ω , $\alpha(1)$, dan $\beta(1)$ bernilai positif dan signifikan secara statistik, yang menandakan adanya pengaruh kuat dari varians periode sebelumnya dan shock masa lalu terhadap *volatilitas* saat ini. Nilai alpha dan beta yang relatif besar juga mengindikasikan bahwa *volatilitas* IHSG bersifat persisten, sehingga model $GARCH(1,1)$ dinilai sesuai untuk mengestimasi *volatilitas* return IHSG sebelum digunakan pada tahap pemodelan selanjutnya.

```

Zero Mean - GARCH Model Results
=====
Dep. Variable:      return      R-squared:      0.000
Mean Model:        Zero Mean    Adj. R-squared:  0.000
Vol Model:         GARCH      Log-Likelihood: -9762.91
Distribution:      Normal     AIC:            19531.8
Method:           Maximum Likelihood BIC:            19551.9
Date:             Thu, Dec 11 2025  No. Observations: 5988
Time:             21:18:42      Df Residuals:    5988
                                      Df Model:        0
                                      Volatility Model
=====
              coef      std err      t      P>|t|      95.0% Conf. Int.
-----+-----+-----+-----+-----+-----
omega         0.0289   1.142e-02    2.529   1.144e-02   [6.501e-03, 5.128e-02]
alpha[1]      0.1206   2.489e-02    4.846   1.260e-06   [7.184e-02, 0.169]
beta[1]       0.8732   2.647e-02   32.983   1.419e-238   [ 0.821, 0.925]
=====
Covariance estimator: robust

```


Gambar 2. Pemodelan $GARCH(1,1)$

Untuk menghasilkan volatilitas kondisional atau *volatilitas* kondisional pada setiap periode pengamatan, parameter model $GARCH(1,1)$ digunakan pada seluruh data return IHSG. Hasil estimasi ini ditunjukkan dalam kolom *garch_vol*, yang menunjukkan tingkat volatilitas harian IHSG berdasarkan informasi return dan varians sebelumnya. Nilai *volatilitas* kondisional, berdasarkan hasil awal data, menunjukkan bahwa model $GARCH$ dapat menangkap karakteristik kelompok *volatilitas* pada data IHSG, yaitu kondisi ketika periode *volatilitas* tinggi cenderung diikuti oleh periode *volatilitas* yang lebih tinggi. Nilai *volatilitas* kondisional ini berubah secara dinamis dan mengikuti *fluktuasi return* harian.

Tabel 4. Volatilitas Kondisional Parameter GARCH(1,1) untuk return IHSG

No	Date	Return (%)	Volatilitas GARCH
1	1995-01-03	0.475319	1.085391
2	1995-01-04	0.445675	1.038810
3	1995-01-05	0.699360	0.994016
4	1995-01-06	0.709040	0.973757
5	1995-01-09	-0.872414	0.955888

Ada peningkatan *volatilitas* yang signifikan selama periode pengamatan, seperti yang ditunjukkan oleh grafik volatilitas IHSG hasil estimasi model *GARCH*. Dalam pola ini, terlihat beberapa periode *volatilitas* yang tinggi yang mencerminkan pergeseran pasar atau ketidakpastian ekonomi, diikuti oleh periode yang lebih stabil. Pola ini menunjukkan terjadinya *clustering volatilitas*, di mana periode yang sangat *volatil* cenderung diikuti oleh periode yang relatif lebih stabil, sesuai dengan karakteristik pasar saham.

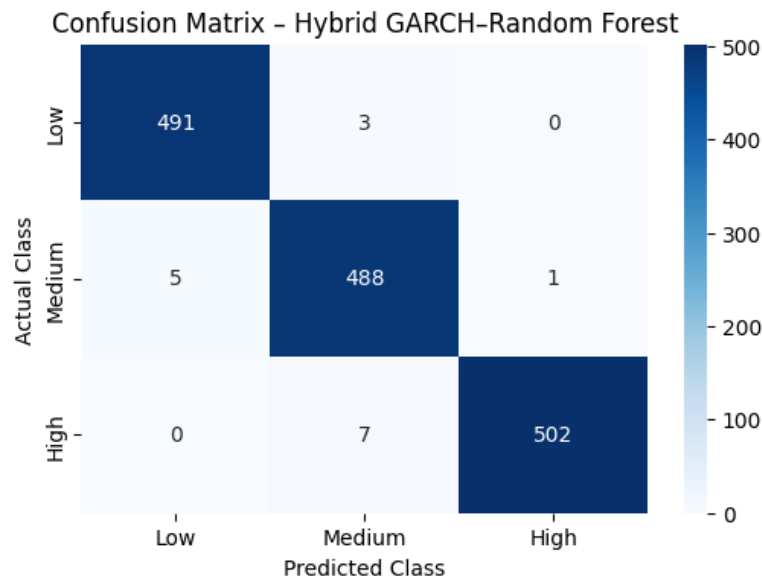
**Gambar 3.** Volatilitas IHSG (GARCH)

Algoritma *Random Forest* memprediksi *volatilitas* pada periode berikutnya dengan menggunakan return dan *volatilitas GARCH* sebagai fitur input. Di sisi lain, model *GARCH(1,1)* digunakan untuk mengestimasi *volatilitas* harian berdasarkan *return logaritmik* IHSG. Hasil pengujian regresi menunjukkan bahwa model *hybrid* memiliki tingkat kesalahan prediksi yang sangat rendah. Dengan nilai *Mean Squared Error (MSE)* sebesar 0,000386 dan *Root Mean Squared Error (RMSE)* sebesar 0,01965, nilai *RMSE* yang kecil menunjukkan bahwa selisih antara *volatilitas* hasil prediksi dan *volatilitas* aktual relatif rendah. Ini menunjukkan bahwa model *hybrid* sangat akurat dalam memprediksi *volatilitas* IHSG.

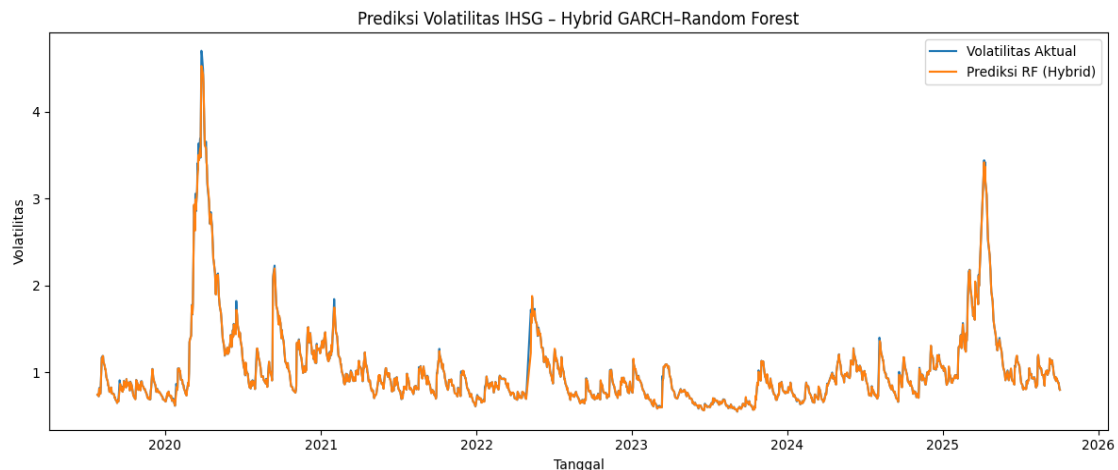
Tabel 5. Classification Report

	precision	recall	f1-score	support
Low	0.99	0.99	0.99	494
Medium	0.98	0.99	0.98	494
High	1.00	0.99	0.99	509
accuracy			0.99	1497
macro avg	0.99	0.99	0.99	1497
weighted avg	0.99	0.99	0.99	1497

Dengan menggunakan model *Hybrid GARCH-Random Forest*, *confusion matrix* hasil klasifikasi menunjukkan bahwa sebagian besar data *volatilitas* telah diklasifikasikan dengan sangat baik ke dalam kelas yang sesuai. Sebanyak 491 data berhasil diprediksi dengan benar di kelas *Low*, sementara hanya 3 data salah di kelas *Medium* dan tidak ada kesalahan di kelas *High*. Di kelas *Medium*, 488 data diprediksi dengan benar, dengan 5 data salah di kelas *Low* dan 1 data di kelas *High*. Di kelas *High*, model mampu mengklasifikasikan 502 data dengan benar, dengan hanya 7 data salah di kelas *Medium* dan tidak ada kesalahan di kelas *High*.

**Gambar 4. Confusion Matrix**

Grafik perbandingan volatilitas aktual dan hasil prediksi menggunakan model *Hybrid GARCH-Random Forest* menunjukkan bahwa garis prediksi mampu mengikuti pola pergerakan volatilitas IHSG dengan sangat baik. Terlihat bahwa model berhasil menangkap lonjakan volatilitas yang signifikan pada periode tertentu, seperti pada saat terjadi peningkatan ketidakpastian pasar, serta mampu menyesuaikan kembali pada periode volatilitas yang lebih stabil. Kesesuaian antara volatilitas aktual dan prediksi ini mengindikasikan bahwa pendekatan hybrid efektif dalam memodelkan dinamika volatilitas IHSG, baik pada kondisi pasar yang tenang maupun pada periode dengan fluktuasi yang tinggi.



4. DISCUSSION/CONCLUSION

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa pendekatan Hybrid GARCH-Random Forest mampu memprediksi volatilitas Indeks Harga Saham Gabungan (IHSG) dengan sangat baik. Model GARCH berhasil mengestimasi volatilitas harian dengan menangkap karakteristik heteroskedastisitas dan volatility clustering pada data return IHSG, sementara Random Forest efektif dalam memodelkan hubungan non-linear untuk memprediksi volatilitas pada periode berikutnya. Hasil evaluasi menunjukkan bahwa model hybrid ini memiliki tingkat kesalahan prediksi yang rendah, ditunjukkan oleh nilai MSE dan RMSE yang kecil, serta performa klasifikasi yang sangat tinggi dengan akurasi mencapai 0,99. Confusion matrix juga memperlihatkan bahwa sebagian besar data volatilitas berhasil diklasifikasikan dengan benar ke dalam kategori rendah, sedang, dan tinggi, tanpa adanya bias yang signifikan terhadap kelas tertentu. Meskipun demikian, penelitian ini masih memiliki keterbatasan karena hanya menggunakan return dan volatilitas GARCH sebagai fitur input, serta belum mempertimbangkan pengaruh faktor eksternal yang dapat memengaruhi volatilitas pasar saham. Berdasarkan keterbatasan yang terdapat dalam penelitian ini, penelitian selanjutnya disarankan untuk menambahkan variabel lain seperti volume perdagangan, indikator makroekonomi, indeks saham global, maupun data sentimen pasar agar model dapat menangkap dinamika volatilitas secara lebih komprehensif. Selain itu, pengembangan model hybrid dapat dilakukan dengan mengombinasikan GARCH dengan algoritma pembelajaran mesin lain atau menggunakan varian GARCH yang lebih kompleks, seperti EGARCH atau GJR-GARCH, untuk menangkap efek asimetri volatilitas. Penelitian selanjutnya juga disarankan untuk menggunakan periode data yang berbeda atau metode validasi time series yang lebih beragam guna menguji kestabilan dan konsistensi kinerja model dalam jangka panjang.

REFERENCES

- Fathori, F. (2023). Peran pasar modal dalam pembangunan ekonomi: Studi kasus tentang kontribusi pasar saham terhadap pertumbuhan ekonomi di negara berkembang. *Currency*, 2(1), 233–242. <https://doi.org/10.32806/ccy.v2i1.240>
- Silalahi, E., & Sihombing, R. (2021). Pengaruh faktor makro ekonomi terhadap pergerakan indeks harga saham gabungan (IHSG) di Bursa Efek Indonesia periode 2017–2020. *JRAK*, 7(2), 139–152. <https://doi.org/10.54367/jrak.v7i2.1361>
- Hisam, M. (2024). Menavigasi volatilitas pasar: Wawasan tentang instrumen keuangan dan strategi investasi. *Currency*, 2(2), 315–328. <https://doi.org/10.32806/ccy.v2i2.248>
- Maksimiliansyah, A., Putri, D. N., Hamzah, Z. Z., & S. S. (2024). Manajemen risiko keuangan: Strategi untuk menghadapi ketidakpastian. PT Media Penerbit Indonesia.
- Nurqotimah, I. D., Putri, R. R. K., Ayu, D. S. F., & Sumual, A. K. (2025). Analysis of financial risk management failure with ISO 31000: Bankruptcy case study at PT Sri Rejeki Isman Tbk (Sritex). *Scripta Economica: Journal of Economics, Management, and Accounting*, 1(1). <https://doi.org/10.65310/tyxbrv23>
- Dasman, H. S., Puspitasari, D. M., Wijoyo, T. I., & Widiastuti. (2024). Manajemen investasi modern: Panduan praktis untuk portofolio yang sukses. PT Media Penerbit Indonesia.
- Rafulta, E., Yanuar, F., Devianto, D., & Maiyastri. (2025). Pemodelan dan peramalan volatilitas memori panjang pada return saham ANTM: Studi komparatif model GARCH dan FIGARCH. *Lattice*, 5(1), 75–89. <https://doi.org/10.30983/lattice.v5i1.9525>
- Wijoyo, N. A. (2016). Peramalan nilai tukar rupiah terhadap USD dengan menggunakan model GARCH. *Kajian Ekonomi dan Keuangan*, 20(2). <https://doi.org/10.31685/kek.v20i2.187>
- Paulina, P. (2022). Analisis volatilitas variabel makroekonomi dan harga saham menggunakan generalized autoregressive conditional heteroscedasticity (GARCH model). *JMSAB*, 5(1), 127–141. <https://doi.org/10.36407/jmsab.v5i1.533>
- Wibowo, A. (2023). Artificial intelligence (AI) dalam bisnis. Yayasan Prima Agus Teknik.
- Selyanti, N., Putra, D. A., Trimono, T., & Idham, M. (2025). Prediksi harga penutupan saham BBRI dengan model hybrid LSTM-XGBoost. *MEJ: Jurnal Informatika dan Multimedia*, 5(1). <https://doi.org/10.54340/informatika.v5i1.1011>
- Sobari, S., Purnamasari, A. I., Bahtiar, A., & Kaslani, K. (2025). Meningkatkan model prediksi kelulusan santri tahfidz di pondok pesantren Al-Kautsar menggunakan algoritma random forest. *JITET*, 13(1). <https://doi.org/10.23960/jitet.v13i1.5704>
- Simamora, P., Pasaribu, S. A., & Wijaya, V. (2025). Peningkatan dan optimalisasi prediksi harga emas menggunakan metode combine machine learning random forest dan gradient boosting. *Jurnal Mahkota Informatika*, 1(1), 42–52. <https://doi.org/10.59929/mahtik.v1i1.37>
- Rismayadi, A. A., Febrianto, R. W., Raharja, A. R., & Hariyanti, I. (2024). Perbandingan kinerja metode machine learning support vector machine (SVM), random forest, dan k-nearest neighbors (KNN)

- dalam prediksi harga saham Apple. *MI*, 23(3), 152–160. <https://doi.org/10.37595/mediainfo.v23i3.299>
- Rantina, M., Santoso, G., & Wilarsio. (2025). Analisis pengaruh faktor eksternal terhadap perilaku investor di pasar modal. *Jurnal Manajemen*, 1(2), 93–102. <https://doi.org/10.37373/ejm.v1i2.1704>
- Fakhriyana, D., Hoyyi, A., & Widiharih, T. (2016). Perbandingan model ARCH/GARCH, model ARIMA, dan model fungsi transfer. *Jurnal Gaussian*, 5(4), 633–640. <https://doi.org/10.14710/j.gauss.5.4.633-640>
- Umam, M. J., Jazuli, A., & Khotimah, T. (2025). Prediksi harga saham Aneka Tambang Persero Tbk (ANTM) menggunakan metode machine learning. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(6), 9289–9294. <https://doi.org/10.36040/jati.v9i6.15570>
- Fathoni, Irwansyah, A., Triana, A., Simanullang, E. D., Alinda, Y. N., & Ibrahim, A. (2025). Prediksi harga dan volatilitas emas dunia harian: Perbandingan model GARCH dan long short-term memory. *ZONAsi: Jurnal Sistem Informasi*, 7(2). <https://doi.org/10.31849/zn.v7i2.26764>
- Hidayat, J. J. (2026). Prediksi diabetes menggunakan deep neural network dengan penyesuaian hiperparameter berbasis Bayesian optimization. *J. Pract. Computer Sci.*, 5(2), 130–143.
- Hidayat, J. J., Setyowati, C., & Werdana, A. P. (2025). Analisis penyakit pada daun padi menggunakan VGG-16 transfer learning dan teknik segmentasi K-mean. *Jurnal Media Infotama*, 21(1), 98–104.
- Natzir, S. M., & Jatiprasetya, H. (2025). Prediksi harga cryptocurrency XLM menggunakan metode deep learning LSTM dan GRU. *HOAQ*, 16(1), 49–58. <https://doi.org/10.52972/hoaq.vol16no1.p49-58>
- Afnanda, A., Maiyastri, M., & Devianto, D. (2024). Model volatilitas return index saham syariah Indonesia melalui pendekatan Bayesian Markov switching GARCH. *Lattice*, 4(1), 14–26. <https://doi.org/10.30983/lattice.v4i1.8381>
- Amin, M. D. I., Hidayat, J. J., Setyowati, C., Fitri, E. K., Anggraini, A. N., & Werdana, A. P. (2025). Implementasi model LSTM untuk peramalan curah hujan di Bekasi dengan pemanfaatan data cuaca BMKG. *JTID*, 1(2), 90–99.
- Hidayat, J. J., Setyowati, C., Amin, M. D. I., Bimasakti, K., & Werdana, A. P. (2025). Deep learning-based sentiment analysis of public comments on military education using RoBERTa algorithm and rule-based hybrid parameters. *JMCS*, 4(2), 277–292.
- Rosyid, M. R., Mawaddah, L., & Akrom, M. (2024). Investigasi model machine learning regresi pada senyawa obat sebagai inhibitor korosi. *Jurnal Algoritma*, 21(1), 332–342.
- Hidayat, J. J., Setyowati, C., & Werdana, A. P. (2025). Perancangan sistem prediksi penyakit pada tanaman padi berbasis image processing menggunakan algoritma VGG-16 transfer learning dan K-means segmentation. *J. Pract. Computer Sci.*, 5(1), 1–15.
- Hidayat, J. J., Amin, M. D. I., Fitri, E. K., Anggraini, A. N., Werdana, A. P., & Setyowati, C. (2025). Implementasi model EfficientNetB0 pada pembuatan aplikasi desktop untuk identifikasi hama tanaman sawi berbasis deep learning. *JTID*, 1(2), 82–89.
- Hidayat, J. J., Setyowati, C., & Werdana, A. P. (2025). Sentiment analysis of Instagram user comments related to the inauguration of Mr. Prabowo Subianto as President of the Republic of Indonesia using natural language processing. *International Journal of Data Science*, 6(2), 94–102.