

ANALISIS KOMPARATIF GARCH KLASIK DAN *HYBRID* GARCH-GAUSSIAN PROCESS REGRESSION PADA VOLATILITAS NILAI TUKAR USD/IDR 2010–2025

Dina Asia Putri

Program Studi Statistika, Fakultas Sains dan Teknologi, Universitas Terbuka, Tangerang Selatan,
Indonesia

*Penulis korespondensi: dinaasiap@gmail.com

ABSTRAK

Penelitian ini bertujuan untuk menganalisis akurasi peramalan volatilitas mingguan nilai tukar USD/IDR periode 2010–2025 dengan pendekatan *hybrid* yang mengintegrasikan model ekonometrika klasik dan *machine learning*. Tahap awal menggunakan ARIMA(1,0,4) untuk menangkap pola linear pada persamaan rata-rata (*mean equation*) dan memastikan data bebas dari autokorelasi. Selanjutnya model GARCH(1,1) untuk memodelkan varians bersyarat dari residu ARIMA yang bersifat *white noise* dan mengandung efek ARCH. Residu dari hasil pemodelan GARCH yang diasumsikan masih mengandung informasi yang belum terjelaskan, kemudian dimodelkan menggunakan *Gaussian Process Regression* (GPR) dengan fungsi kernel Matern 1,5 untuk menangkap pola hubungan non-linear. Hasil analisis pada data uji menunjukkan bahwa pendekatan *hybrid* mampu meningkatkan kinerja peramalan secara signifikan dibandingkan model tunggal. Model *hybrid* berhasil menurunkan nilai *Root Mean Squared Error* (RMSE) sebesar 8,83%, dari 1,1164 pada model GARCH klasik menjadi 1,0178. Penurunan juga tercatat pada *Mean Absolute Error* (MAE). Temuan ini menunjukkan bahwa integrasi GPR efektif dalam mengatasi keterbatasan GARCH klasik dalam menangkap dinamika volatilitas kompleks, sekaligus memberikan kontribusi praktis bagi pengelolaan risiko nilai tukar di Indonesia.

Kata kunci: volatilitas nilai tukar, garch, *gaussian process regression*, usd/idr, model *hybrid*

1 PENDAHULUAN

Stabilitas nilai tukar merupakan elemen vital dalam perekonomian negara berkembang karena berinteraksi erat dengan indikator makroekonomi seperti neraca perdagangan, suku bunga, dan pertumbuhan ekonomi. Studi empiris menunjukkan bahwa fluktuasi nilai tukar memiliki pengaruh jangka panjang dengan neraca perdagangan (Salim & Shi, 2019). Di samping itu juga terbukti secara simultan berkontribusi pada pertumbuhan ekonomi (Latri & Anis, 2020), serta memiliki dampak yang signifikan terhadap pergerakan suku bunga domestik (Suciany *et al.*, 2024).

Di Indonesia, nilai tukar Rupiah tidak hanya dipengaruhi oleh faktor fundamental ekonomi, tetapi juga sangat responsif terhadap kejutan eksternal dan pengumuman makroekonomi yang sebagaimana terlihat pada masa pandemi COVID-19 (Rahmatullah & Ghuzini, 2023). Studi (Endri *et al.*, 2020) menemukan bahwa volatilitas nilai tukar memiliki dampak signifikan terhadap pasar modal karena dominasi investor asing di Indonesia. Terjadinya depresiasi Rupiah akan cenderung memicu aksi jual (*capital outflow*) oleh investor asing untuk menghindari kerugian kurs. Oleh karena itu, pemodelan volatilitas nilai tukar yang akurat menjadi kebutuhan strategis bagi pembuat kebijakan dan pelaku pasar dalam menghadapi ketidakpastian ekonomi. Model yang mampu menangkap dinamika fluktuasi kurs secara tepat dapat membantu mitigasi risiko dan pengambilan keputusan yang lebih efektif.

Data runtun waktu ekonomi, termasuk nilai tukar, umumnya memiliki ciri-ciri varians bersyarat yang terus berubah dan dipengaruhi oleh kondisi masa lalu. Fenomena ini dikenal

sebagai *volatility clustering* dan dapat dimodelkan secara efektif menggunakan pendekatan *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) (Bollerslev, 1986). Model *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) telah banyak dipercaya oleh akademisi untuk membantu menangkap gejala tersebut dalam berbagai fenomena ekonometrika. Dalam konteks ketidakpastian dari nilai tukar, perilaku investor cenderung beralih ke aset *safe haven* seperti emas yang gejala volatilitasnya juga umum dimodelkan menggunakan pendekatan GARCH (Tardiana *et al.*, 2024). Sejumlah studi terdahulu telah menunjukkan kinerja model GARCH yang baik dalam hal memodelkan volatilitas harga saham di sektor energi yang ditandai oleh MAPE sebesar 2,16% pada evaluasi model (Virginia *et al.*, 2018) dan saat dikombinasikan dengan ARIMA, pemodelan *hybrid* ARIMA-GARCH ini mampu mengikuti pergerakan nilai tukar Rupiah dengan akurat sebagaimana ditunjukkan dalam MAPE sebesar 0,72% (Maharani *et al.*, 2023). Maka dari itu, kedudukan model GARCH cukup kokoh untuk digunakan sebagai alat analisis data runtun waktu, termasuk dalam kajian nilai tukar.

Model GARCH mampu merepresentasikan dinamika volatilitas secara efektif, namun penelitian-penelitian sebelumnya menunjukkan bahwa asumsi linear yang mendasarinya membatasi kemampuan model dalam menangkap hubungan non-linier yang kompleks dalam data keuangan. Seiring perkembangan metode analisis, penelitian terbaru mulai mengeksplorasi integrasi metode statistik dengan pendekatan komputasi modern. Dalam penelitian komparatif antara model konvensional dan model analisis modern, Bi-LSTM atau *Bidirectional Long Short-Term Memory* mampu menangani kondisi pasar yang kompleks dalam ekosistem mata uang kripto (Tripathy *et al.*, 2025) dan LSTM-GRU (*Gate Recurrent Units*) menghasilkan kinerja terbaik dalam perbandingan performa pada peramalan harga saham (Haryono *et al.*, 2024). Hasil kedua penelitian tersebut menunjukkan bahwa metode *Deep Learning* terbukti unggul daripada model konvensional dalam hal peramalan aset kripto dan saham. Secara spesifik pada konteks nilai tukar Rupiah, pendekatan *hybrid* seperti Neuro-GARCH dapat memberikan akurasi yang lebih baik dibandingkan model tunggal GARCH dan ANN (*Artificial Neural Network*) berdasarkan MAPE dan MAE yang lebih kecil. Hal ini mengindikasikan bahwa pergerakan kurs mengandung komponen non-linear yang signifikan (Juliana *et al.*, 2019).

Menanggapi keterbatasan model konvensional, penelitian ini bertujuan untuk melakukan perbandingan kinerja antara model GARCH tunggal dan model *hybrid* yang mengkombinasikannya dengan *Gaussian Process Regression* (GPR). Berbeda dari pendekatan *Neural Network*, GPR merupakan metode nonparametrik yang fleksibel serta memiliki kemampuan probabilistik dalam menangkap ketidakpastian (Williams & Rasmussen, 1995). Dengan kemampuan kernel-nya yang adaptif, GPR diyakini mampu mengatasi keterbatasan GARCH dalam memodelkan struktur data yang kompleks (Liu *et al.*, 2020). Dengan mempertimbangkan potensi tersebut, penelitian ini akan mengevaluasi secara empiris apakah penerapan GPR pada residual GARCH mampu meningkatkan presisi prediksi volatilitas USD/IDR, atau apakah model GARCH yang parsimonius sudah cukup memadai.

2 METODE

2.1 Sumber Data dan Pra-Pemrosesan

Data penelitian berupa harga penutupan mingguan (*weekly closing price*) nilai tukar USD/IDR yang bersumber dari *Yahoo Finance*. Periode pengamatan mencakup rentang waktu dari 1 Januari 2010 hingga 31 Oktober 2025, dengan total observasi awal sebanyak 825 titik data. Keseluruhan data tersebut dibagi menjadi dua bagian yaitu 80% sebagai data *in-sample* dan 20% sebagai data *out-of-sample*. Seluruh proses pengumpulan data, komputasi statistik, dan pemodelan dalam penelitian ini dilakukan menggunakan bahasa pemrograman Python dengan pustaka utama yaitu *yfinance*, *arch*, dan *scikit-learn* yang dijalankan pada lingkungan

komputasi awan *Google Colab*. Sebelum tahap pemodelan dilakukan, data terlebih dahulu melalui pra-pemrosesan yang mencakup beberapa langkah sistematis sebagai berikut:

2.1.1 Pembersihan Data (*Data Cleaning*)

Tahap pra-pemrosesan data diawali dengan pembersihan data. Mengingat data pasar keuangan seringkali memiliki celah kosong akibat hari libur atau gangguan sistem, penelitian ini menerapkan pendekatan *forward-fill* untuk menangani nilai yang hilang. Metode ini dipilih untuk mempertahankan kontinuitas informasi deret waktu tanpa menimbulkan bias masa depan (*look-ahead bias*), sehingga tetap konsisten dengan praktik peramalan volatilitas aset keuangan modern (Dharmaningrat *et al.*, 2025).

2.1.2 Transformasi Data

Selanjutnya, data harga penutupan (P_t) ditransformasi menjadi *Log Return* (r_t) untuk menstabilkan varians dan mendekati asumsi stasioneritas sebagaimana umumnya diterapkan dalam penelitian nilai tukar Rupiah sebelumnya (Awalludin *et al.*, 2018; Maharani *et al.*, 2023).

$$r_t = \ln(P_t) - \ln(P_{t-1}) \times 100 \quad (1)$$

Setelah transformasi dilakukan, uji stasioneritas dilakukan menggunakan *Augmented Dickey-Fuller (ADF) Test*, sedangkan deteksi heteroskedastisitas dilakukan menggunakan uji *ARCH-LM*. Pengujian ini bertujuan untuk memverifikasi keberadaan efek ARCH yang menjadi prasyarat penggunaan model GARCH (Bollerslev, 1986).

2.2 *Autoregressive Integrated Moving Average (ARIMA)*

Tahap awal menggunakan ARIMA untuk menangkap sekaligus menghilangkan pola linear berupa autokorelasi pada data *return*. Pemilihan ordo model terbaik (p,d,q) didasarkan pada kriteria *Akaike Information Criterion (AIC)* terkecil. Residual (ε_t) yang dihasilkan dari model ARIMA dievaluasi melalui analisis visual plot *Autocorrelation Function (ACF)* dan *Partial Autocorrelation Function (PACF)*, serta dikonfirmasi dengan uji Ljung-Box. Langkah diagnostik ganda ini bertujuan untuk memastikan bahwa tidak ada lagi korelasi serial yang tertinggal dan residual telah bersifat acak (*white noise*). Dengan terpenuhinya kondisi tersebut, residual (ε_t) dapat digunakan sebagai input murni untuk tahap pemodelan volatilitas selanjutnya (Virginia *et al.*, 2018).

2.3 *Generalized Autoregressive Conditional Heteroskedasticity (GARCH)*

Untuk mengakomodasi karakteristik *volatility clustering* yang muncul pada residual ARIMA, penelitian ini mengestimasi model *Generalized Autoregressive Conditional Heteroskedasticity (GARCH)*. Model GARCH mendefinisikan varians bersyarat (σ_t^2) sebagai fungsi dari kuadrat error pada periode sebelumnya (komponen ARCH) dan varians masa lalu (komponen GARCH) (Bollerslev, 1986). Secara umum, persamaan varians bersyarat GARCH(p,q) dapat dirumuskan sebagai berikut:

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (2)$$

Model GARCH terbaik ditentukan berdasarkan signifikansi parameter dan kriteria informasi yang digunakan. Selanjutnya, residual dari model GARCH terpilih akan diekstraksi dan digunakan sebagai dasar analisis lanjutan pada tahap permodelan *hybrid*.

2.4 Gaussian Process Regression (GPR)

Tahap ini merupakan inti dari metode *hybrid* yang diusulkan. Untuk menangkap pola non-linear yang kompleks (Tripathy *et al.*, 2025), residual dimodelkan dengan mengimplementasikan *Gaussian Process Regression* (GPR). GPR didefinisikan sebagai distribusi atas fungsi yang sepenuhnya ditentukan oleh fungsi rata-rata $m(x)$ dan fungsi kovarians atau kernel $k(x, x')$ (Williams & Rasmussen, 1995), yang secara formal dinyatakan sebagai:

$$f(x) \sim \mathcal{GP}(m(x), k(x, x')) \quad (3)$$

Mengacu pada Liu *et al.* (2020) dalam konteks pemodelan volatilitas valuta asing, penelitian ini melakukan evaluasi beberapa fungsi kernel untuk memperoleh spesifikasi yang paling mampu menangkap pola non-linear pada data. Beberapa kandidat kernel yang akan diuji yaitu *Radial Basis Function* (RBF), *Rational Quadratic*, serta keluarga kernel Matérn dengan tingkat kehalusan berbeda $\nu = 1,5$ dan $\nu = 2,5$. Pemilihan variasi kernel tersebut dilakukan dengan tujuan untuk mengakomodasi berbagai karakteristik struktur data yang beragam, mulai dari fungsi yang sangat halus hingga yang relatif kasar. Langkah evaluasi ini selaras dengan pandangan Endri *et al.* (2021) yang menekankan pentingnya pemilihan spesifikasi model yang presisi guna menangkap dinamika volatilitas nilai tukar yang fluktuatif. Setiap kandidat kernel dikombinasikan dengan *White Kernel* untuk mengestimasi varians *noise* global sekaligus mencegah risiko terjadinya *overfitting*. Prediksi akhir volatilitas diformulasikan sebagai penjumlahan aditif antara varians bersyarat dari hasil estimasi GARCH dan komponen koreksi yang diprediksi oleh model GPR dengan kernel terpilih.

2.5 Kriteria Evaluasi Model

Kinerja prediktif model GARCH tunggal dengan model *hybrid* GARCH-GPR dievaluasi menggunakan proksi volatilitas aktual berupa nilai mutlak *return* (r_t). Akurasi model diukur menggunakan dua metrik statistik yang umum digunakan dalam studi komparatif volatilitas, yaitu *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE) (Juliana *et al.*, 2019; Tripathy *et al.*, 2025). Secara matematis, kedua metrik tersebut dirumuskan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (|r_t| - \hat{\sigma}_t)^2} \quad (4)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n ||r_t| - \hat{\sigma}_t| \quad (5)$$

Keterangan:

n = Jumlah observasi data *out-of-sample*

$|r_t|$ = Nilai mutlak *return* aktual pada waktu ke- t , yang digunakan sebagai proksi volatilitas aktual

$\hat{\sigma}_t$ = Nilai volatilitas prediksi model pada waktu ke- t

Penggunaan kedua metrik ini bertujuan untuk mendapatkan evaluasi kinerja yang komprehensif. RMSE memberikan bobot penalti yang lebih besar terhadap kesalahan prediksi yang ekstrem, sementara MAE memberikan gambaran rata-rata kesalahan yang lebih linear


dan tidak terlalu sensitif terhadap *outlier*. Model dengan nilai RMSE dan MAE yang lebih rendah menunjukkan kemampuan peramalan yang lebih presisi dalam mengikuti dinamika volatilitas USD/IDR.

Evaluasi kinerja model dalam penelitian ini berfokus pada metrik berbasis skala absolut dan tidak menggunakan *Mean Absolute Percentage Error* (MAPE). Hal ini dikarenakan karakteristik dari data volatilitas berbasis *log return* memiliki nilai yang sangat kecil dan seringkali mendekati nol, sehingga penggunaan MAPE berisiko menghasilkan perhitungan yang tidak terdefinisi atau nilai kesalahan yang bias menuju tak hingga akibat pembagian dengan nilai nol (Hyndman & Koehler, 2006).


3 HASIL DAN PEMBAHASAN

3.1 Analisis Statistika Deskriptif

Analisis diawali dengan mendeskripsikan perilaku data nilai tukar Rupiah terhadap Dolar AS (USD/IDR) selama periode 2010–2025. Berdasarkan visualisasi data pada Gambar 1 dan Gambar 2, terlihat bahwa nilai tukar Rupiah menunjukkan kecenderungan depresiasi dalam jangka panjang. Selain itu, gejolak volatilitas yang signifikan terdeteksi pada beberapa periode krisis, terutama pada masa pandemi COVID-19 tahun 2020. Hal ini ditandai dengan terjadinya lonjakan *return* yang ekstrem. Fenomena ini mengindikasikan bahwa pasar valuta asing sangat sensitif terhadap guncangan eksternal (Rahmatullah & Ghuzini, 2023).



Gambar 1. Tren Nilai Tukar USD/IDR (Mingguan 2010-2025)



Gambar 2. Volatilitas *Log Return* Mingguan (%)

Berikut adalah rangkuman statistik deskriptif data *Log Return* dari data mingguan yang disajikan pada Tabel 1. Terdapat jumlah titik data, rerata, standar deviasi, nilai minimum, kuartil 1 hingga 3, nilai maksimum, *skewness*, dan *kurtosis*.

Tabel 1. Ringkasan Statistik Deskriptif

	Log Return Pct
Count	825,000000
Mean	0,070310
Std	1,106237
Min	-6,896275
25%	-0,464711
50%	0,071498
75%	0,577566
Max	7,422596
Skew	0,208378
Kurt	7,925759

Data *log return* USD/IDR periode 2010–2025 menunjukkan kecenderungan depresiasi Rupiah dalam jangka panjang, dengan lonjakan volatilitas signifikan pada periode krisis, khususnya pandemi COVID-19 tahun 2020. Indikator terpenting pada Tabel 1 adalah nilai kurtosis yang mencapai 7,92. Nilai ini jauh melampaui angka kurtosis distribusi normal 3,0, yang menandakan bahwa distribusi data bersifat *leptokurtic* atau berekor gemuk (*fat-tailed*). Hal ini membuktikan bahwa asumsi normalitas tidak terpenuhi dan peluang terjadinya kejadian ekstrem atau terdapat outlier lebih tinggi dari prediksi model Gaussian biasa. Kondisi ini memperkuat alasan menggunakan model GARCH untuk menangkap heteroskedastisitas yang kuat (Suciany *et al.*, 2024).

3.2 Uji Prasyarat Model

Sebelum dilakukan pemodelan, dilakukan uji stasioneritas dan uji heteroskedastisitas untuk memastikan validitas asumsi *time series*. Hasil dari kedua uji tersebut ditampilkan dalam Tabel 2.

Tabel 2. Hasil Uji Stasioneritas (ADF) dan Heteroskedastisitas (ARCH-LM)

Jenis Pengujian	Statistik Uji	Probabilitas (<i>P-Value</i>)	Keterangan
Uji Stasioneritas (ADF)	-11.9929	0.0000*	Stasioner (Menolak H ₀)
Uji Heteroskedastisitas (ARCH-LM)	141.4197	0.0000*	Ada Efek ARCH (Menolak H ₀)

Berdasarkan Tabel 2, hasil uji *Augmented Dickey-Fuller* (ADF) pada tingkat level menunjukkan nilai probabilitas $p < 0.05$, yang berarti data *return* mingguan telah stasioner. Selanjutnya, pada uji *Lagrange Multiplier* (ARCH-LM) menunjukkan penolakan terhadap H₀ yang berarti keberadaan efek ARCH atau varians yang tidak konstan. Keberadaan heteroskedastisitas ini menegaskan bahwa penggunaan model ARIMA saja tidak cukup dalam menangkap dinamika varians, sehingga memerlukan model GARCH (Bollerslev, 1986).

3.3 Persamaan Rerata (*Mean Equation*)

Pemilihan model ARIMA terbaik dilakukan melalui metode *grid search* berdasarkan kriteria *Akaike Information Criterion* (AIC) terendah. Hasil seleksi menunjukkan bahwa model

ARIMA(1,0,4) merupakan model terbaik dengan nilai AIC sebesar 2510,49. Estimasi parameter model dilakukan untuk menguji signifikansi pengaruh lag masa lalu terhadap data saat ini, sebagaimana disajikan pada Tabel 3.


Tabel 3. Hasil Estimasi Parameter Model ARIMA(1,0,4)

Variabel	Koefisien	Std. Error	Prob. (P-Value)	Keterangan
Konstanta	0,0705	0,043	0,105	Tidak Signifikan
AR(1)	-0,7710	0,139	0,000*	Signifikan
MA(1)	0,7608	0,143	0,000*	Signifikan
MA(2)	0,0000	0,030	0,999	Tidak Signifikan
MA(3)	0,0559	0,035	0,115	Tidak Signifikan
MA(4)	0,1037	0,034	0,002*	Signifikan
Sigma2	1,2069	0,028	0,000*	Signifikan

Hasil estimasi menunjukkan bahwa variabel *Autoregressive* lag 1 (AR1) dan *Moving Average* lag 4 (MA4) signifikan secara statistik pada taraf nyata 5%. Signifikansi MA(4) pada data mingguan mengindikasikan adanya pola memori 4 minggu atau bulanan dalam pergerakan kurs yang kemungkinan berkaitan dengan siklus rilis data makroekonomi bulanan.

Meskipun terdapat parameter lag 2 dan 3 yang tidak signifikan, parameter tersebut tetap dipertahankan dalam model berdasarkan Prinsip Hierarki. Keputusan ini diperkuat oleh fakta bahwa kandidat model alternatif lainnya dalam proses *grid search* juga menunjukkan karakteristik serupa. Tidak terdapat satupun model yang signifikan secara menyeluruh pada semua lag. Oleh karena itu, model ARIMA(1,0,4) dipilih karena memberikan keseimbangan terbaik antara nilai AIC terendah dan stabilitas struktur model.

Validitas model ini dikonfirmasi melalui uji diagnostik ganda. Secara statistik, uji Ljung-Box pada residual menunjukkan probabilitas $> 0,05$ yaitu 0,66. Secara visual, hal ini didukung oleh Gambar 3 di bawah. Plot ACF sisaan memperlihatkan seluruh *lag* berada dalam batas interval kepercayaan. Kedua indikator ini menyimpulkan bahwa sisaan telah bersifat acak (*white noise*) dan seluruh informasi linear telah diambil sepenuhnya oleh model ARIMA(1,0,4).



Gambar 3. Plot Autokorelasi (ACF) dari Sisaan Model ARIMA(1,0,4)

3.4 Persamaan Variansi (*Variance Equation*)

Tahap ini merupakan langkah penting dalam penelitian. Berdasarkan evaluasi awal menggunakan kriteria AIC, model GARCH(1,3) sempat terindikasi sebagai model terbaik. Namun, validasi statistik menunjukkan kelemahan struktural pada model tersebut. Parameter model GARCH(1,3) tidak signifikan secara statistik dengan $P\text{-Value} > 0.05$. Mengacu pada prinsip validitas statistik dan parsimoni (*Occam's Razor*), penelitian ini memutuskan untuk menggunakan spesifikasi GARCH(1,1) sehingga, dilakukan uji signifikansi kepada model klasikal GARCH (1,1) dengan hasil pada Tabel 4.

Tabel 4. Hasil Uji Signifikansi GARCH (1,1)

Parameter	Koefisien	<i>Std. Error</i>	<i>t-Statistic</i>	Prob.	Keterangan
Omega (ω)	0.0326	0.0245	1.328	0.184	
Alpha (α_1)	0.1889	0.0617	3.060	0.002*	Signifikan
Beta (β_1)	0.8059	0.0511	15.758	0.000*	Signifikan
AIC	1819.97		R-squared	0.000	
BIC	1833.44		Log-L	-906.98	

Berdasarkan Tabel 4, hasil estimasi menunjukkan bahwa parameter ARCH ($\alpha = 0,1889$) dan GARCH ($\beta = 0,8059$) pada model GARCH(1,1) bernilai signifikan dengan $p < 0,05$. Signifikansi kedua parameter ini mengonfirmasi adanya fenomena *volatility clustering*, di mana volatilitas saat ini sangat dipengaruhi oleh gejolak dan variansi masa lalu.

Selanjutnya, validasi model dilakukan melalui uji Ljung-Box pada *Squared Standardized Residuals*. Hasil pengujian menunjukkan nilai $P\text{-Value}$ sebesar 0,6870 ($> 0,05$), sehingga hipotesis nol diterima. Hal ini mengindikasikan bahwa tidak terdapat lagi efek ARCH yang tertinggal pada sisaan model. Dengan kata lain, model GARCH(1,1) telah berhasil menghilangkan masalah heteroskedastisitas dan menghasilkan sisaan yang bersifat homoskedastis. Hal ini sejalan dengan temuan (Endri *et al.*, 2020) yang menyatakan bahwa GARCH(1,1) merupakan model yang paling *robust* untuk pasar keuangan Indonesia.

3.5 Model *Hybrid* GARCH-GPR

Untuk menangkap pola non-linear yang tidak terjelaskan oleh GARCH(1,1), diterapkan metode *Gaussian Process Regression* (GPR) pada sisaan volatilitas. Eksperimen dilakukan menggunakan berbagai fungsi kernel untuk mendapatkan spesifikasi terbaik yang cocok untuk menangkap pola data. Pada Tabel 5, hasil perbandingan dari masing-masing jenis kernel pada model *hybrid* ditampilkan.

Tabel 5. Hasil Perbandingan Jenis Kernel pada Model *Hybrid*

Jenis Kernel	RMSE	MAE
RBF	1,02381	0,72048
Matern 1.5	1,01781	0,71835
Matern 2.5	1,02285	0,72400
Rational Quadratic	1,02383	0,72049

Hasil eksperimen menunjukkan bahwa integrasi GPR berhasil meningkatkan akurasi. Model *hybrid* dengan kernel Matern 1,5 tercatat sebagai model terbaik dengan RMSE dan MAE terendah yaitu RMSE sebesar 1,01781 dan MAE sebesar 0,71835. Penurunan RMSE sebesar 8,83% menunjukkan bahwa integrasi GPR efektif dalam menangkap pola non-linear yang tidak terakomodasi oleh GARCH. Kernel ini dinilai paling efektif dalam

menyeimbangkan fleksibilitas model terhadap pola volatilitas kasar tanpa mengalami *overfitting* yang sering terjadi pada kernel RBF murni (Liu *et al.*, 2020).

3.6 Evaluasi Model


Evaluasi akhir dilakukan dengan membandingkan kinerja model dasar GARCH(1,1) parametrik dengan model *hybrid* GARCH-GPR (Matern 1,5) pada data *out-of-sample*. Berikut hasil perbandingan tersebut ditampilkan dalam Tabel 6.

Tabel 6. Perbandingan Akhir (RMSE dan MAE GARCH vs *Hybrid*)

Model	RMSE	MAE	Status
GARCH (1,1) Murni	1,11642	0,76959	Model Dasar
Hybrid + RBF	1,02381	0,72048	-
Hybrid + Matern 1.5	1,01781	0,71835	Terbaik
Hybrid + Matern 2.5	1,02285	0,72400	-
Hybrid + <i>Rational Quadratic</i>	1,02383	0,72049	-

Berdasarkan Tabel 6, model *hybrid* GARCH-GPR terbukti lebih unggul dibandingkan model konvensional. Nilai RMSE yang didapat pada model GARCH tunggal sebesar 1,1164 turun menjadi 1,01781 pada model *hybrid* dengan Matern 1,5, setara dengan peningkatan akurasi sebesar 8.83%. Penurunan juga terjadi pada metrik MAE.

Temuan ini mendukung hipotesis penelitian bahwa pendekatan *hybrid* mampu meningkatkan presisi peramalan volatilitas nilai tukar. Keunggulan model *hybrid* terletak pada kemampuannya dalam mengoreksi kesalahan sistematis yang tidak sepenuhnya tertangkap oleh model parametrik. Sisaan GARCH yang semula dianggap sebagai *noise* acak ternyata masih mengandung struktur informasi non-linear yang berhasil dipetakan oleh GPR. Hasil ini mendukung temuan (Juliana *et al.*, 2019) dan (Tripathy *et al.*, 2025), yang menyimpulkan bahwa integrasi model statistik klasik dengan metode *machine learning* nonparametrik menghasilkan performa peramalan yang lebih unggul dibandingkan penggunaan model tunggal. Grafik perbandingan antara performa model GARCH tunggal dan model *hybrid* pada data *out-of-sample* ditampilkan pada Gambar 4.



Gambar 4. Perbandingan Akurasi: GARCH vs Hybrid + Matern 1,5

Tabel 7. Perbandingan Deviasi Standar Data Aktual vs RMSE Model *Hybrid*

Deviasi Standar Data Aktual	0,9455
RMSE Model <i>Hybrid</i> (Matern 1.5)	1,0178

Pada Tabel 7 menyajikan perbandingan dari deviasi standar data aktual dan RMSE model *hybrid* GARCH-GPR dengan kernel Matern 1,5. Perlu dicatat bahwa nilai RMSE model terbaik sebesar 1,0178 masih sedikit lebih tinggi dibandingkan deviasi standar data aktual sebesar 0,9455. Kondisi ini merupakan fenomena yang umum terjadi pada peramalan runtun waktu keuangan dengan frekuensi mingguan, di mana rasio *signal-to-noise* cenderung rendah. Dominasi komponen acak (*noise*) dalam pergerakan kurs menyebabkan model dinamis, baik GARCH maupun model *hybrid* menghadapi keterbatasan dalam memprediksi lonjakan volatilitas secara presisi.

Namun demikian, kontribusi utama penelitian ini terletak pada peningkatan kinerja relatif. Model *hybrid* terbukti mampu mereduksi *error* secara signifikan dibandingkan model GARCH murni sekaligus mendekati tingkat akurasi prediksi ke batas variabilitas alami yang melekat pada data.

4 SIMPULAN

Penelitian ini menunjukkan bahwa USD/IDR periode 2010-2025 memiliki karakteristik *heavy-tail* dan heteroskedastisitas yang kuat, sehingga dapat disimpulkan bahwa data nilai tukar mingguan USD/IDR memiliki karakteristik distribusi *heavy-tail* yang ditunjukkan oleh nilai kurtosis yang lebih besar dari 3 dan menunjukkan efek heteroskedastisitas yang kuat. Kondisi tersebut mengonfirmasi bahwa pendekatan model GARCH lebih tepat digunakan dibandingkan model regresi homoskedastis. Model parametrik terbaik yang valid secara statistik adalah kombinasi ARIMA(1,0,4) untuk persamaan rata-rata dan GARCH(1,1) untuk persamaan varians. Meskipun model GARCH orde lebih tinggi (1,3) menghasilkan nilai AIC yang lebih rendah, parameter pada model GARCH(1,1) terbukti lebih signifikan dan stabil dalam menjelaskan persistensi volatilitas jangka panjang. Selanjutnya, metode usulan *hybrid* GARCH-GPR dengan fungsi kernel Matern 1,5 secara empiris menunjukkan kinerja yang lebih baik dibandingkan model GARCH(1,1) konvensional yang ditunjukkan oleh penurunan nilai RMSE sebesar 8,83% serta MAE yang lebih rendah dan konsisten pada data uji. Temuan ini menegaskan bahwa integrasi GPR efektif dalam menangkap komponen non-linear yang tidak sepenuhnya terakomodasi oleh model ekonometrika standar. Secara praktis, hasil penelitian dapat mendukung kebijakan moneter dan strategi manajemen risiko di Indonesia. Namun, keterbatasan berupa dominasi *noise* acak masih terlihat, sehingga penelitian lanjutan disarankan menggunakan data frekuensi lebih tinggi atau menambahkan variabel eksogen melalui GARCH-X untuk meningkatkan akurasi.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada seluruh pihak yang telah memberikan dukungan dan kontribusi selama proses penelitian ini berlangsung. Apresiasi disampaikan atas arahan akademik yang berharga, serta kepada rekan-rekan yang turut memberikan masukan konstruktif. Penelitian ini juga tidak terlepas dari ketersediaan data dan literatur yang memungkinkan eksplorasi ilmiah dilakukan secara komprehensif. Semoga hasil penelitian ini dapat memberikan manfaat dan menjadi pijakan bagi pengembangan kajian selanjutnya.

DAFTAR PUSTAKA

Awalludin, S. A., Ulfah, S., & Soro, S. (2018). Modeling the stock price returns volatility using GARCH (1, 1) in some Indonesia stock prices. *Journal of Physics: Conference Series*. <https://doi.org/10.1088/1742-6596/948/1/012068>

- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31, 307–327.
- Dharmaningrat, I. M. A., Margaretha, H., & Saputra, K. V. I. (2025). Predicting the Volatility of Jakarta Composite Index Using GARCH and LSTM with Volume-Up Strategy Approach. *Journal of Information System Engineering and Business Intelligence*, 11(3), 311–322. <https://doi.org/10.20473/jisebi.11.3.311-322>
- Endri, E., Abidin, Z., Simanjuntak, T. P., & Nurhayati, I. (2020). Indonesian Stock Market Volatility: GARCH Model. *Montenegrin Journal of Economics*, 16(2), 7–17. <https://doi.org/10.14254/1800-5845/2020.16-2.1>
- Endri, E., Aipama, W., Razak, A., Sari, L., & Septiano, R. (2021). Stock price volatility during the COVID-19 pandemic: The GARCH model. *Investment Management and Financial Innovations*, 18(4), 12–20. [https://doi.org/10.21511/imfi.18\(4\).2021.02](https://doi.org/10.21511/imfi.18(4).2021.02)
- Haryono, A. T., Sarno, R., & Sungkono, K. R. (2024). Stock price forecasting in Indonesia stock exchange using deep learning: a comparative study. *International Journal of Electrical and Computer Engineering*, 14(1), 861–869. <https://doi.org/10.11591/ijece.v14i1.pp861-869>
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22, 679–688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Juliana, A., Hamidatun, H., & Padliansyah, R. (2019). Study Of GARCH, Ann , & Neuro-Garch Models To Predict Rupiah-Us Dollars (Usd) Exchange Rate. *International Journal of Scientific and Technology Research*, 8(11), 2021–2028.
- Lastri, W. A., & Anis, A. (2020). Pengaruh E-Commerce, Inflasi dan Nilai Tukar Tukar Terhadap Pertumbuhan Ekonomi Indonesia. *Jurnal Kajian Ekonomi Dan Pembangunan*, 2(2), 25–28.
- Liu, B., Kiskin, I., & Roberts, S. (2020). An overview of gaussian process regression for volatility forecasting. *2020 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)*, 681–686. <https://doi.org/10.1109/ICAIIIC48513.2020.9065045>
- Maharani, N. S., Angraini, Y., Rahmawan, M. A., Putri, O. A., Kurniawan, S., Safitri, T. A., Rizki, A., Ningsih, W. A. L., Hidayatulloh, N. G. T., & Ratnasari, A. P. (2023). Aplikasi model arima GARCH dalam peramalan data nilai tukar Rupiah terhadap Dolar tahun 2017-2022. *Jurnal Matematika, Sains, Dan Teknologi*, 24(1), 37–50. <https://doi.org/10.33830/jmst.v24i1.4875.2023>
- Rahmatullah, D., & Ghuzini, D. (2023). Exchange rate responses to macroeconomic announcement on the COVID-19 pandemic. *Jurnal Ekonomi Dan Bisnis*, 26(1), 45–66. <https://doi.org/10.24914/jeb.v26i1.4868>
- Salim, A., & Shi, K. (2019). A Cointegration of the Exchange Rate and Macroeconomic Fundamentals: The Case of the Indonesian Rupiah vis- á -vis Currencies of Primary Trade Partners. *Journal of Risk and Financial Management*. <https://doi.org/https://doi.org/10.3390/jrfm12020087>
- Suciany, A. D., Damayanti, C. R., & Darmawan, A. (2024). Exchange Rate, Inflation, Interest Rate and Economic Growth: How They Interact in ASEAN. *PROFIT: Jurnal Administrasi Bisnis*, 18(2), 245–256. <https://doi.org/10.21776/ub.profit.2024.018.02.8>
- Tardiana, A. L., Akbar, H., & Firmansyah, G. (2024). Integration of garch models and external factors in gold price volatility prediction: analysis and comparison of GARCH-M approach. *Journal Eduvest*, 4(05), 4011–4023.
- Tripathy, N., Mishra, D., Hota, S., & Mishra, S. (2025). Bitcoin volatility forecasting: a comparative analysis of conventional econometric models with deep learning models. *International Journal of Electrical and Computer Engineering*, 15(1), 614–623.

<https://doi.org/10.11591/ijece.v15i1.pp614-623>

- Virginia, E., Ginting, J., & Elfaki, F. A. M. (2018). Application of GARCH Model to Forecast Data and Volatility of Share Price of Energy (Study on Adaro Energy Tbk, LQ45). *International Journal of Energy Economics and Policy*, 8(3), 131–140.
- Williams, C. K. I., & Rasmussen, C. E. (1995). Gaussian Processes for Regression. *Neural Information Processing Systems*.