

Perbandingan Performa MSGARCH, LSTM, dan *Hybrid* MSGARCH-LSTM pada Peramalan Data Deret Waktu yang Mengandung Heteroskedastisitas

Wa Ode Rona Freya^{1*}, Kusman Sadik², Budi Susetyo³

¹²³Sekolah Sains Data, Matematika, dan Informatika - IPB University

*Corresponding author, email: ronafreya@gmail.com

Abstract

Volatility forecasting is crucial for estimating potential portfolio losses, particularly in cryptocurrency markets like Bitcoin, which exhibit high and irregular price fluctuations. Models from the Generalized Autoregressive Conditional Heteroscedasticity (GARCH) family, including Markov Switching GARCH (MSGARCH), are widely used to handle heteroscedastic data and capture regime changes. Meanwhile, Long Short-Term Memory (LSTM) is effective for modeling nonlinear and complex patterns in financial time series. This study proposes a hybrid MSGARCH-LSTM model by incorporating MSGARCH predictions as additional input to the LSTM. The model is evaluated using simulated data resembling Bitcoin's characteristics, with Heteroscedasticity Mean Absolute Error (HMAE) as the primary metric, and analyzed using ANOVA and Tukey's post-hoc test. The results identify four superior hybrid configurations, all of which significantly outperform the standalone MSGARCH and LSTM models. Based on the characteristics of Bitcoin data, the MSGARCH (2-regime with sged error distribution)-LSTM model is selected for empirical analysis. This model achieved an HMAE of 0.3197 and an HMSE of 0.2088, with accuracy improvements of 61.20% and 83.50% compared to the standalone MSGARCH model. These findings indicate that the hybrid MSGARCH-LSTM model improves volatility forecasting accuracy in highly volatile cryptocurrency markets.

Keywords: Time Series, Volatility, MSGARCH, LSTM, Data Simulation, Bitcoin.

Abstrak

Peramalan volatilitas sangat penting untuk memperkirakan potensi kerugian portofolio, khususnya di pasar mata uang kripto seperti Bitcoin, yang menunjukkan fluktuasi harga yang tinggi dan tidak teratur. Model dari keluarga Generalized Autoregressive Conditional Heteroscedasticity (GARCH), termasuk Markov Switching GARCH (MSGARCH), banyak digunakan untuk menangani data heteroskedastik dan menangkap perubahan rezim. Sementara itu, Long Short-Term Memory (LSTM) efektif untuk memodelkan pola nonlinier dan kompleks dalam deret waktu keuangan. Studi ini mengusulkan model Hybrid MSGARCH-LSTM dengan menggabungkan prediksi MSGARCH sebagai input tambahan untuk LSTM. Model dievaluasi menggunakan data simulasi yang menyerupai karakteristik Bitcoin, dengan Heteroscedasticity Mean Absolute Error (HMAE) sebagai metrik utama, dan dianalisis menggunakan ANOVA dan uji post-hoc Tukey. Hasilnya mengidentifikasi empat konfigurasi hibrida yang unggul, semuanya secara signifikan mengungguli model MSGARCH dan LSTM mandiri. Berdasarkan karakteristik data Bitcoin, model MSGARCH (2 rezim dengan distribusi kesalahan sged)-LSTM dipilih untuk analisis empiris. Model ini mencapai HMAE sebesar 0,3197 dan HMSE sebesar 0,2088, dengan peningkatan akurasi sebesar 61,20% dan 83,50% dibandingkan dengan model MSGARCH mandiri. Temuan ini menunjukkan bahwa model Hybrid MSGARCH-LSTM meningkatkan akurasi peramalan volatilitas di pasar mata uang kripto yang sangat fluktuatif.

Kata Kunci: deret waktu, volatilitas, MSGARCH, LSTM, simulasi data, *Bitcoin*.

1. Pendahuluan

Volatilitas merujuk pada besar fluktuasi yang terjadi pada suatu fenomena dari waktu ke waktu. Volatilitas sangat penting dalam bidang keuangan karena berkaitan erat dengan risiko dan imbal hasil (*return*). Pengetahuan tentang volatilitas diperlukan untuk menghindari risiko kerugian besar ketika melakukan perdagangan pada pasar dengan volatilitas tinggi [1, 2]. Deret waktu keuangan umumnya menunjukkan pola *volatility clustering*, yaitu kecenderungan perubahan besar harga aset, baik naik atau turun, diikuti oleh perubahan besar juga. Sebaliknya, perubahan kecil akan diikuti perubahan kecil juga [3]. Pola ini mendukung penggunaan model *Autoregressive Conditional Heteroscedasticity* (ARCH) dan pengembangannya yang dapat menangani volatilitas yang berubah terhadap waktu [4]. Model GARCH banyak digunakan dibandingkan dengan model ARCH karena membutuhkan parameter yang lebih sedikit [5]. Namun, model GARCH tidak mempertimbangkan adanya perubahan *regime* pada data sehingga dapat menghasilkan estimasi yang bias [6].

Model *Markov Switching* GARCH (MSGARCH) dapat mengatasi masalah bias hasil estimasi pada model GARCH ketika terdapat perubahan *regime* pada data [6]. Hal tersebut dikarenakan model MSGARCH memungkinkan adanya pergantian *regime* atau dengan kata lain model MSGARCH mampu menyesuaikan parameter model tergantung pada *regime* yang sedang aktif. Penelitian tentang model MSGARCH terus berkembang, *package* MSGARCH di R dibuat untuk memudahkan implementasi model MSGARCH yang memungkinkan pergantian jumlah *regime*, jenis distribusi *error*, dan jenis model GARCH [7]. Salah satu penelitian yang menggunakan model MSGARCH dalam peramalan volatilitas adalah penelitian yang dilakukan oleh Caporale dan Zekokh (2019) pada data mata uang kripto populer (*Bitcoin*, *Ethereum*, *Ripple*, dan *Litecoin*) dan hasilnya model MSGARCH dengan lebih dari satu *regime* unggul dibandingkan dengan model dengan satu *regime* [8]. *Bitcoin* merupakan mata uang kripto pertama dan terpopuler saat ini. *Bitcoin* memiliki harga dengan lonjakan yang tidak teratur, ciri umum volatilitas ekstrem yang sering terjadi pada pasar mata uang kripto. Hal ini menyebabkan investor mata uang kripto dapat dengan cepat menghasilkan atau kehilangan sejumlah besar uang [9].

Peramalan volatilitas ekstrem seperti pada data *Bitcoin* memerlukan model yang tepat. Model ekonometrik tradisional seperti model GARCH dan pengembangannya seringkali kesulitan dalam menangkap ketergantungan nonlinier dan pola rumit dalam data sehingga menyebabkan hasil ramalan yang tidak akurat [10]. Model *deep learning* (DL) dapat menangani masalah tersebut karena dapat mempelajari hubungan kompleks dan nonlinier dalam data deret waktu keuangan. Salah satu model DL yang dapat digunakan untuk tujuan tersebut adalah model *Long Short-Term Memory* (LSTM). Zahid *et al.* (2022) menggunakan hasil prediksi volatilitas model GARCH sebagai salah satu

input model LSTM yang selanjutnya disebut model *hybrid* GARCH-LSTM. Model GARCH-LSTM terbukti memiliki kinerja yang lebih baik dibandingkan dengan model GARCH [9]. Berdasarkan paparan sebelumnya, pada penelitian ini model *hybrid* MSGARCH-LSTM diaplikasikan untuk meramalkan volatilitas data simulasi yang meniru data *Bitcoin* dan volatilitas data *Bitcoin* yang sebenarnya. Pada data simulasi, pengaruh jumlah *regime*, jenis distribusi *error*, dan jenis model (MSGARCH dan *hybrid* MSGARCH-LSTM) terhadap hasil prediksi volatilitas dianalisis, kemudian kombinasi model terbaik dibandingkan dengan model LSTM tunggal. Model terbaik hasil analisis pada data simulasi digunakan untuk peramalan volatilitas pada data empiris.

2. Material dan Metode

2.1. Material

Berikut merupakan materi terkait penelitian ini.

2.1.1. *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH)

Model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) diusulkan oleh Bollerslev pada tahun 1986 yang merupakan pengembangan dari model ARCH untuk menyelesaikan masalah pada spesifikasi model ARCH dengan ordo yang lebih tinggi, sehingga menghasilkan model yang lebih sederhana [11]. Volatilitas σ_t^2 dinyatakan menggunakan model GARCH dengan ordo p dan q , biasanya ditulis sebagai GARCH(p, q) dan didefinisikan oleh Persamaan (1).

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-1}^2 \quad (1)$$

dengan $\beta_j, j = 1, \dots, q$ merepresentasikan koefisien GARCH yang menunjukkan efek dari variansi bersyarat masa lalu σ_{t-1}^2 pada variansi bersyarat saat ini σ_t^2 . Parameter model GARCH harus memenuhi batasan berikut: $\alpha_0 > 0$, $\alpha_i \geq 0$, $\beta_j \geq 0$, dan $\alpha_i + \beta_j < 1$. Parameter α_0 , α_i , dan β_j biasanya diestimasi menggunakan *Maximum Likelihood Estimator* (MLE). Model GARCH konvensional biasanya mengasumsikan *error* berdistribusi normal $\varepsilon_t^2 \sim N(0, \sigma_t^2)$. Namun, untuk mempertimbangkan deret waktu keuangan yang mungkin tidak mengikuti distribusi normal, distribusi lain dapat diasumsikan untuk ε_t^2 [12].

2.1.2. *Markov-Switching* GARCH (MSGARCH)

Model MSGARCH memungkinkan adanya pergantian *regime*. Penelitian Hamilton pada tahun 1989 menjadi dasar pengembangan model MSGARCH. Penelitian tersebut mengusulkan model *Markov Switching* pada model *Autoregressive* (AR) sehingga memungkinkan adanya perpindahan *regime* pada model AR [13]. Cai (1994) serta Hamilton dan Susmel (1994) mengembangkan model pada penelitian Hamilton (1989).

Cai (1994) mengusulkan model gabungan ARCH dan *Markov Switching* yang disebut *Markov-ARCH* [14]. Sementara itu, Hamilton dan Susmel (1994) mengusulkan model gabungan GARCH dan *Markov Switching* yang disebut SWARCH [15]. Selain pergantian *regime*, model SWARCH juga memungkinkan adanya pergantian distribusi *error*, yaitu distribusi normal dan *student-t*. Penelitian ini menggunakan MSGARCH dengan spesifikasi $y_t | (S_t = k, I_{t-1}) \sim D(0, \sigma_{t,k}^2, \theta_k)$. $D(0, \sigma_{t,k}^2, \theta_k)$ adalah distribusi probabilitas kontinu dengan mean 0 dan kondisional varians yang berubah seiring waktu $\sigma_{t,k}^2$ pada *regime* k dengan I_{t-1} informasi yang tersedia pada waktu ke $t - 1$. θ_k merupakan parameter tambahan terkait distribusi *error* yang dipilih. $S_t \in \{1, 2, \dots, k\}$ merupakan *regime* yang perpindahannya mengikuti probabilitas transisi *Markovian*, $P = \{P_{i,j}\}_{i,j=1}^k$ dengan $P_{i,j} = P[S_t = j | S_{t-1} = i]$ [6]. Persamaan (2) menunjukkan persamaan umum model MSGARCH.

$$\sigma_t^2 = \alpha_{0,k} + \sum_{i=1}^p \alpha_{i,k} \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_{j,k} \sigma_{t-1}^2 \quad (2)$$

2.1.3. Long-Short Term Memory (LSTM)

Model LSTM merupakan salah satu jenis *Recurrent Neural Network* (RNN). LSTM memiliki *memory cell* dan *gate* yang berbeda untuk menyimpan informasi untuk diperbarui. Struktur tersebut memungkinkan LSTM untuk melupakan informasi yang tidak relevan di masa lalu. LSTM umumnya berkinerja lebih baik dibandingkan RNN dan cocok untuk pemodelan deret waktu yang kompleks [9]. Model LSTM dirancang untuk mengatasi masalah *vanishing* atau *exploding gradients* yang dapat terjadi karena proses *backpropagation* yang rentan terhadap dependensi jangka panjang [16].

2.1.4. Hybrid GARCH-LSTM

Hybrid GARCH-LSTM menggunakan volatilitas hasil prediksi model GARCH *family* sebagai salah satu fitur prediktor dalam memprediksi *realized volatility* (RV). RV merupakan estimator untuk volatilitas aktual yang dihitung dari data *intraday*. Data yang digunakan pada penelitian tersebut adalah data *Bitcoin* USD. Model *deep learning* yang digunakan ada tiga, yaitu model *Long Short-Term Memory* (LSTM), *Generated Recurrent Unit* (GRU), dan *Bidirectional LSTM* (BiLSTM). Hasilnya model *hybrid* GARCH-LSTM mampu memprediksi lebih baik dibandingkan dengan model GARCH *family* saja [9].

2.1.5. Median Realized Variance (medRV)

Estimator volatilitas diperlukan untuk perhitungan metrik evaluasi karena volatilitas aktual tidak diketahui. Estimator yang hanya didasarkan pada data penutupan harian tidaklah tepat [17]. Salah satu estimator volatilitas yang dapat digunakan adalah *median realized variance* yang persamaannya ditunjukkan pada Persamaan (3) dan (4).

$$k = \frac{\pi}{6 - 4\sqrt{3} + \pi} \frac{m}{m - 2} \quad (3)$$

$$MedRV_t = k \times \sum_{j=2}^{m-1} \text{median}(|r_{t,j-1}|, |r_{t,j}|, |r_{t,j+1}|)^2 \quad (4)$$

dengan $medRV_t$ adalah *median realized volatility* pada hari ke- t dan k adalah konstanta untuk mengatur skala $medRV_t$. r_t adalah *log return* pada waktu t yang dihitung menggunakan data *intraday*, m adalah total observasi dalam 1 hari data *intraday*. $\text{median}(|r_{t,j-1}|, |r_{t,j}|, |r_{t,j+1}|)^2$ merupakan kuadrat median dari tiga data absolut *log return* yang berdekatan. $medRV_t$ adalah estimator volatilitas yang lebih *robust* terhadap efek *noise* [18].

2.1.6. Pemilihan Model Terbaik

Pemilihan model terbaik pada penelitian ini didasarkan pada metrik evaluasi *Heteroscedasticity-Adjusted Mean Absolut Error* (HMAE) pada Persamaan (5) dan *Heteroscedasticity-Adjusted Mean Squared Error* (HMSE) pada Persamaan (6) digunakan untuk evaluasi hasil prediksi model.

$$HMSE = \frac{1}{n} \sum_{t=1}^n \left(1 - \frac{\sigma_t}{RV_t}\right)^2 \quad (5)$$

$$HMSE = \frac{1}{n} \sum_{t=1}^n \left|1 - \frac{\sigma_t}{RV_t}\right| \quad (6)$$

σ_t dan RV_t masing-masing adalah hasil prediksi model dan *realized volatility* pada waktu t [9]. Penggunaan RV_t digantikan dengan $MedRV_t$ pada penelitian ini sebagai estimator volatilitas.

2.2. Metode

Tabel 1 Parameter data simulasi

Parameter	Nilai	Keterangan
ω_1	0.000006	
α_1	0.08	Parameter GARCH <i>regime 1</i>
β_1	0.086	
p_{11}	0.96	Peluang tetap pada <i>regime 1</i>
ξ_1	1.11	Parameter asimetris <i>regime 1</i>
K_1	0.84	Parameter kurtosis <i>regime 1</i>
$\sigma_{noise,1}$	0.5	Standar deviasi <i>noise regime 1</i>
P_{11}	0.96	Probabilitas bertahan pada <i>regime 1</i>
ω_2	0.000196	
α_2	0.21	Parameter GARCH <i>regime 2</i>
β_2	0.76	

p_{22}	0.9	Peluang tetap pada <i>regime 2</i>
ξ_2	0.83	Parameter asimetris <i>regime 2</i>
K_2	0.7	Parameter kurtosis <i>regime 2</i>
$\sigma_{noise,2}$	1	Standar deviasi <i>noise regime 2</i>
P_{22}	0.9	Probabilitas bertahan pada <i>regime 2</i>

Model yang dibandingkan pada penelitian ini ada 3, yaitu model MSGARCH, LSTM, dan *hybrid* MSGARCH-LSTM. Model *hybrid* MSGARCH-LSTM menggunakan fitur prediktor volatilitas hasil prediksi model MSGARCH. Peramalan volatilitas menggunakan ketiga model tersebut dilakukan pada data simulasi. Model terbaik yang diperoleh berdasarkan kinerja pada data simulasi digunakan pada data empiris. Data simulasi yang dibangkitkan dengan mengikuti model MSGARCH 2 *regime* dan distribusi *error skew generalized error distribution* (sged). Faktor acak ditambahkan pada proses perhitungan varians kondisional. Persamaan untuk membangkitkan data simulasi adalah sebagai berikut.

$$noise = \exp(a), a \sim N(0, \sigma_{noise} * \sigma_{t-1})$$

$$\sigma_t^2 = (\alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta \sigma_{t-1}^2) * noise$$

$$y_t = \eta_t \sqrt{\sigma_t^2}, \eta_t \sim SGED(0, 1, \xi, K)$$

$\sqrt{\sigma_t^2}$ adalah volatilitas dan y_t adalah *log return* untuk data simulasi. Parameter untuk membangkitkan data simulasi ditunjukkan pada Tabel 1 yang merupakan modifikasi parameter model Ardia *et al.* [19]. $\sqrt{\sigma_t^2}$ dan y_t dihitung menggunakan parameter sesuai *regime* yang sedang aktif. Data simulasi dibangkitkan dengan jumlah observasi sebanyak 2080. Proses membangkitkan data simulasi diulang 30 kali untuk membentuk 30 data simulasi.

Tabel 2 Faktor dan level untuk ANOVA

Faktor	Level
Jumlah <i>Regime</i> (R)	1
	2
Jenis Distribusi <i>Error</i> (E)	<i>Skew normal distribution</i> (snorm)
	<i>Skew generalized error distribution</i> (sged)
	MSGARCH
Jenis Model (M)	<i>Hybrid</i> MSGARCH-LSTM

Analisis varians (ANOVA) dilakukan pada data simulasi untuk melihat pengaruh faktor berbeda terhadap nilai HMAE. ANOVA pada data simulasi dilakukan dua kali, yang pertama untuk melihat pengaruh 3 faktor berbeda, yaitu jumlah *regime*, jenis

distribusi error, dan jenis model (secara rinci ditunjukkan pada Tabel 2) dan yang kedua untuk melihat pengaruh jenis model terbaik dari ANOVA pertama dibandingkan dengan model LSTM.

Sementara itu, data empiris yang digunakan adalah data harga *Bitcoin* (dalam rupiah) dari tanggal 1 Januari 2017 sampai dengan 11 September 2022. Peramalan volatilitas data harga *Bitcoin* menggunakan *log return* yang dihitung menggunakan Persamaan (10).

$$r_t = \log(p_t) - \log(p_{t-1}) \quad (10)$$

dengan r_t adalah *log return* pada waktu t , p_t adalah harga penutupan *Bitcoin* pada waktu t , dan p_{t-1} adalah harga penutupan *Bitcoin* pada waktu $t - 1$. Data harga *Bitcoin* (dalam Rupiah) *intraday* per 15 menit juga digunakan untuk menghitung estimator volatilitas *median realized volatility*.

3. Hasil dan Diskusi

3.1. Data Simulasi

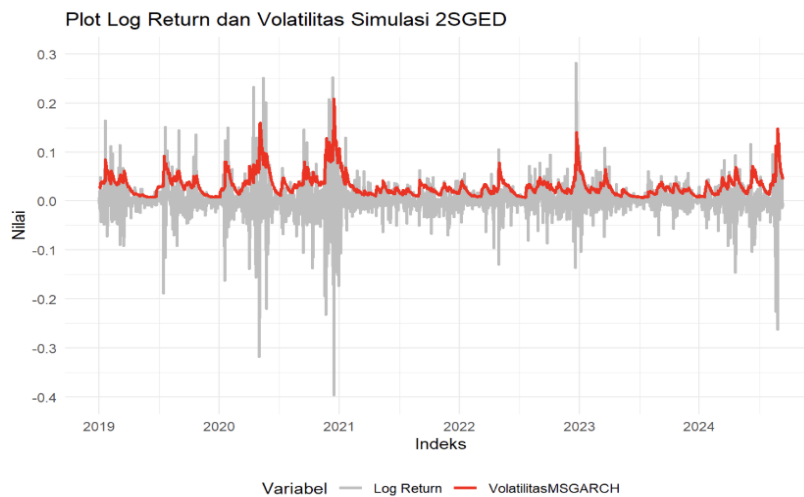
Model GARCH dapat menghasilkan estimasi yang bias jika terdapat perubahan *regime* pada data [6] sehingga data simulasi sengaja dibangkitkan dengan dua *regime* berbeda, yaitu *regime* dengan volatilitas rendah dan tinggi, untuk mengetahui perbedaan performa model yang tidak mempertimbangkan pergantian *regime* (MSGARCH 1 *regime*) dan yang mempertimbangkan pergantian *regime* (MSGARCH 2 *regime*). Sementara itu, distribusi *error* sged digunakan karena data *Bitcoin* umumnya *skew* negatif dengan kurtosis tinggi. *KSComplement* dapat digunakan untuk mengukur kemiripan data simulasi dan data empiris [20]. Berdasarkan *KSComplement*, data simulasi *log return* yang dibangkitkan memiliki rata-rata kemiripan 90.22% dengan data *log return bitcoin* dan volatilitas yang dibangkitkan memiliki rata-rata kemiripan 89.95% dengan data volatilitas bitcoin. Rata-rata kurtosis dan *skewness* data simulasi masing-masing adalah 18.26 dan -0.74.

Tabel 3. Statistik salah satu data simulasi

Statistik	Log Return
Jumlah observasi	2080
Rata-rata	5.7924×10^{-4}
Median	1.2013×10^{-4}
Standar deviasi	0.0038
Skewness	-0.0690
Kurtosis	18.6589
Maksimum	0.0281
Minimum	-0.3959
Uji <i>Jarque-Bera</i> (nilai-p)	0*
Uji ADF (nilai-p)	< 0.01 *

*** signifikan pada interval kepercayaan 95%

Statistik salah satu data hasil bangkitan ditampilkan pada Tabel 3. Data yang dibangkitkan memiliki rata-rata, standar deviasi, dan median yang nilainya disekitar rata-rata data *log return bitcoin* pada umumnya. Data memiliki distribusi yang tidak normal, sesuai hasil uji *Jarque-Bera* yang signifikan, dengan *skew* negatif dan kurtosis yang tinggi. Dengan kata lain, data memiliki banyak nilai pencilan dan banyak penurunan harga dibandingkan dengan kenaikan. Data hasil bangkitan juga sudah bersifat stasioner sebagaimana ditunjukkan pada hasil uji *Augmented Dickey-Fuller (ADF)* yang signifikan.



Gambar 1. Perbandingan *log return* dan volatilitas salah satu data simulasi

Beberapa titik data menunjukkan *log return* yang ekstrem baik negatif maupun positif. *Log return* dengan nilai terkecil ada disekitar tahun 2021. Volatilitas yang berwarna merah juga paling tinggi disekitar tahun 2021 ketika nilai *log return* paling rendah. Volatilitas tinggi terlihat diikuti oleh periode volatilitas tinggi juga, sebaliknya volatilitas rendah diikuti oleh periode volatilitas rendah. Hal tersebut didukung penggunaan parameter $\alpha + \beta$ yang mendekati 1. Parameter yang digunakan dapat dilihat pada Tabel 1.

Tabel 4. Hasil ANOVA ART 3 faktor

	F	Df	Df.res	nilai-p
R	1.0858	1	203	0.2986400
E	9.4764	1	203	0.0023689*
M	777.8682	1	203	2.2200×10^{-16} *
R:E	5.4419	1	203	0.0206388*
R:M	4.9709	1	203	0.0268723*

E:M	24.1959	1	203	1.7900×10^{-6} *
R:E:M	3.9386	1	203	0.0485358*

*Faktor signifikan pada interval kepercayaan 95% ; R, E, dan M berturut-turut adalah jumlah *regime*, jenis distribusi *error*, dan jenis model.

Nilai metrik evaluasi HMAE untuk data uji pada masing-masing data simulasi baik untuk model MSGARCH maupun *hybrid* MSGARCH-LSTM dicatat. Data HMAE disusun menjadi 240 baris yang berisi data nilai HMAE untuk setiap kombinasi level faktor dan setiap data simulasi. Data tersebut kemudian dianalisis menggunakan ANOVA yang ditunjukkan pada Tabel 4. ANOVA yang digunakan adalah ANOVA nonparametrik menggunakan *package* ARTool di R. ANOVA nonparametrik digunakan karena asumsi normalitas ANOVA parametrik tidak terpenuhi. ANOVA ARTool dapat digunakan untuk analisis rancangan acak faktorial nonparametrik [21]. Data nilai HMAE diubah menjadi bentuk rank dengan ART (*Aligned Rank Transform*) sehingga untuk selanjutnya perbandingan yang dilakukan adalah perbandingan *rank* HMAE, bukan perbandingan nilai HMAE mentah. Berdasarkan hasil ANOVA pada Tabel 4, interaksi tiga arah signifikan sehingga faktor-faktor yang digunakan tidak bisa dilihat pengaruhnya secara terpisah sebagai efek utama, melainkan harus melihat efek interaksi ketiga faktor.

Uji lanjut *Tukey* dilakukan untuk melihat interaksi tiga arah yang berbeda signifikan. Hasilnya menunjukkan model *hybrid* MSGARCH (1 *regime* dan distribusi *error* snorm)-LSTM, model *hybrid* MSGARCH (1 *regime* dan distribusi *error* sged)-LSTM, model *hybrid* MSGARCH (2 *regime* dan distribusi *error* snorm)-LSTM, dan model *hybrid* MSGARCH (2 *regime* dan distribusi *error* sged)-LSTM masing-masing signifikan lebih baik dibandingkan dengan model MSGARCH 1 *regime* dan distribusi *error* snorm, MSGARCH 2 *regime* dan distribusi *error* snorm, MSGARCH 1 *regime* dan distribusi *error* sged, dan MSGARCH 2 *regime* dan distribusi *error* sged. Selain itu, perbedaan signifikan juga terlihat pada interaksi yang melibatkan model MSGARCH 2 *regime* dan distribusi *error* snorm. Model MSGARCH 2 *regime* dan distribusi *error* snorm signifikan lebih buruk dibandingkan dengan model MSGARCH 1 *regime* dan distribusi *error* snorm, MSGARCH 1 *regime* dan distribusi *error* sged, serta MSGARCH 2 *regime* dan distribusi *error* sged. Selain perbedaan interaksi tiga arah yang telah disebutkan, hasilnya tidak berbeda signifikan. Berdasarkan pertimbangan signifikansi uji lanjut, diperoleh empat model terbaik dengan performa yang tidak berbeda signifikan, yaitu model *hybrid* MSGARCH (1 *regime* dan distribusi *error* snorm)-LSTM, model *hybrid* MSGARCH (1 *regime* dan distribusi *error* sged)-LSTM, model *hybrid* MSGARCH (2 *regime* dan distribusi *error* snorm)-LSTM, dan model *hybrid* MSGARCH (2 *regime* dan distribusi *error* sged)-LSTM

Tabel 5. Statistik nilai HMAE model LSTM dan *hybrid* MSGARCH-LSTM

Jenis Model	Rata-rata	Std	Min	Maks
-------------	-----------	-----	-----	------

2-snorm-Hybrid MSGARCH-LSTM	0.0694	0.0247	0.0437	0.1880
1-snorm-Hybrid MSGARCH-LSTM	0.0719	0.0250	0.0507	0.1810
2-sged-Hybrid MSGARCH-LSTM	0.0733	0.0267	0.0478	0.1750
1-sged-Hybrid MSGARCH-LSTM	0.0898	0.0910	0.0500	0.5530
LSTM	0.1070	0.1340	0.0561	0.7980

Selanjutnya, dilakukan ANOVA untuk melihat perbedaan antara model terbaik yang telah dipilih dengan model LSTM. Model LSTM yang dimaksud adalah model yang memprediksi volatilitas hanya menggunakan volatilitas aktual masa lalu tanpa tambahan fitur prediktor lain. Tabel 5 menunjukkan ada perbedaan sekitar 16% sampai dengan 35% antara rata-rata nilai HMAE model *hybrid* MSGARCH-LSTM dengan model LSTM. Selanjutnya, ANOVA ART dilakukan pada data nilai HMAE yang terdiri dari satu faktor, yaitu jenis model. Hasil ANOVA pada Tabel 6 menunjukkan jenis model memiliki nilai- $p < 0.01$ yang berarti ada pengaruh signifikan jenis model terhadap peringkat rata-rata HMAE. Uji lanjut kemudian dilakukan pada data HMAE dengan faktor jenis model tersebut. Hasil uji lanjut menunjukkan bahwa keempat model *hybrid* MSGARCH-LSTM memiliki peringkat rata-rata HMAE lebih baik secara signifikan dibandingkan dengan model LSTM. Berdasarkan hasil yang diperoleh diketahui bahwa fitur prediktor hasil prediksi volatilitas model MSGARCH dapat memberikan informasi tambahan dalam memprediksi volatilitas aktual sehingga dapat meningkatkan keakuratan prediksi volatilitas.

Tabel 6 Hasil ANOVA ART untuk perbandingan LSTM dan *hybrid* MSGARCH-LSTM

	F	Df	Df.res	nilai-p
Jenis Model	6.5627	4	116	$8.5050 \times 10^{-5*}$

*Faktor signifikan pada interval kepercayaan 95%

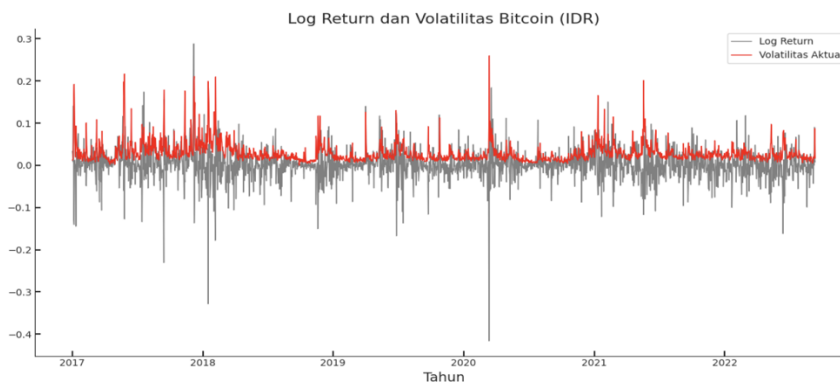
3.2. Data Empiris

Sekitar awal tahun 2020 terjadi penurunan ekstrem harga *Bitcoin* sekitar 34% dengan nilai *log return* turun hingga -0.4162 sebagaimana dapat dilihat pada Gambar 2. Setelah penurunan harga *Bitcoin* tersebut, pada tanggal 13 Maret 2020 terjadi peningkatan volatilitas tertinggi selama periode yang diteliti, yaitu sebesar 0.2598. Tabel 7 menunjukkan bahwa data *log return* tidak normal berdasarkan uji *Jarque-Bera* dengan kurtosis 14.45 dan *skewness* -0.75. Kurtosis tinggi berarti data *log return* memiliki nilai-nilai ekstrem dan *skew* negatif berarti ada banyak penurunan harga dibandingkan dengan kenaikan harga. Data *log return* sudah stasioner berdasarkan uji ADF dan memiliki perubahan *regime* berdasarkan uji *Zivot-Andrews*. *Demean* menggunakan model ARMA(2, 2) dilakukan pada data *log return* sebelum masuk tahap pemodelan karena model MSGARCH pada *package* MSGARCH di R mengasumsikan data *input* sudah memiliki rata-rata 0 dan tidak memiliki korelasi serial.

Tabel 7. Statistik data *log return*

Statistik	Log Return
Jumlah observasi	2080
Rata-rata	1.5436×10^{-3}
Median	1.4699×10^{-3}
Standar deviasi	3.8118×10^{-2}
Skewness	-0.7471
Kurtosis	14.4458
Maksimum	0.2881
Minimum	-0.4163
Uji Jarque-Bera (nilai-p)	0*
Uji ADF (nilai-p)	< 0.01*
Uji Zivot-Andrews (<i>teststatistic</i>)	-12.0097*

*** signifikan pada interval kepercayaan 95%



Gambar 2. *Log return* dan volatilitas aktual data *Bitcoin*

Model yang digunakan untuk data *Bitcoin* adalah salah satu dari empat model terbaik hasil analisis pada data simulasi, yaitu model dengan kombinasi jumlah *regime* 2, jenis distribusi *error* sged, dan model *hybrid* MSGARCH-LSTM. Pemilihan model ini dilakukan dengan mempertimbangkan karakteristik data *Bitcoin*. Uji *Zivot-Andrews* pada data *log return Bitcoin* signifikan berarti terdapat perubahan *regime* pada data sehingga model MSGARCH dengan lebih dari 1 *regime* lebih tepat digunakan. Selain itu, data tidak berdistribusi normal dengan *skew* negatif dan kurtosis tinggi sehingga model MSGARCH dengan distribusi *error* sged lebih tepat digunakan karena sged dapat menangani data asimetris dengan kurtosis tinggi.

Tabel 8. Nilai dugaan parameter model MSGARCH

Parameter	Nilai Dugaan	Standar Error	Nilai-p
ω_1	0.0000	0.0000	0.0405

α_1	0.0621	0.0272	0.0112
β_1	0.8967	0.0104	0.0000
ξ_1	1.0390	0.0298	0.0000
K_1	1.1524	0.0905	0.0000
ω_2	0.0021	0.0004	0.0000
α_2	0.2138	0.1159	0.0325
β_2	0.0976	0.1275	0.2221
ξ_2	0.9278	0.0149	0.0000
K_2	0.9269	0.1009	0.0000
P_{11}	0.8696	0.0730	0.0000
P_{21}	0.2857	0.0633	0.0000

Nilai dugaan parameter model MSGARCH 2 *regime* dan distribusi *error* sged untuk data *Bitcoin* ditunjukkan pada Tabel 8. Parameter $\alpha + \beta$ yang mendekati 1 berarti volatilitas memiliki persistensi tinggi, dengan kata lain volatilitas tinggi cenderung tetap tinggi pada waktu selanjutnya dan volatilitas rendah cenderung tetap rendah pada waktu selanjutnya [3]. Parameter $\alpha + \beta$ hasil dugaan sebesar 0.9588 untuk *regime* pertama menunjukkan volatilitas pada *regime* pertama memiliki persistensi tinggi, sedangkan untuk *regime* kedua sebesar 0.3114 berarti volatilitas pada *regime* kedua tidak memiliki persistensi tinggi. Parameter *skewness* yang digunakan sebesar 1.0390 untuk *regime* pertama dan 0.9278 untuk *regime* kedua menggambarkan ketidaksimetrisan distribusi *error* pada kedua *regime*. Parameter kurtosis untuk *regime* pertama sebesar 1.1524 dan untuk *regime* kedua sebesar 0.9269 menggambarkan distribusi *error* yang leptokurtik. Ketika berada pada suatu *regime*, model akan cenderung tetap pada *regime* tersebut karena peluang tetap pada suatu *regime* lebih tinggi dibandingkan peluang untuk berpindah *regime*. Peluang tetap pada *regime* pertama sebesar 0.8696 dan tetap pada *regime* kedua sebesar 0.7143. Namun, perpindahan dari *regime* kedua menuju *regime* pertama lebih mungkin dibandingkan perpindahan dari *regime* pertama menuju *regime* kedua. Peluang berpindah dari *regime* pertama menuju *regime* kedua sebesar 0.1304 dan berpindah dari *regime* kedua menuju *regime* pertama sebesar 0.2857. Probabilitas transisi juga menunjukkan bahwa *regime* pertama lebih persisten dibandingkan dengan *regime* kedua. Persamaan model MSGARCH 2 *regime* dan distribusi *error* sged ditunjukkan pada persamaan berikut:

$$\sigma_{t,1}^2 = 0.0000 + 0.0621\varepsilon_{t-1}^2 + 0.8967\sigma_{t-1}^2$$

$$y_{t,1} = \eta_{t,1} \sqrt{\sigma_{t,1}^2}, \eta_{t,1} \sim SGED(0, 1, 1.0390, 1.1524)$$


$$\sigma_{t,2}^2 = 0.0021 + 0.2138\varepsilon_{t-1}^2 + 0.0976\sigma_{t-1}^2$$

$$y_{t,2} = \eta_{t,2} \sqrt{\sigma_{t,2}^2}, \eta_{t,2} \sim SGED(0, 1, 0.9278, 0.9269)$$

$$P = \begin{pmatrix} P_{11} & P_{12} \\ P_{21} & P_{22} \end{pmatrix} = \begin{pmatrix} 0.8696 & 0.1304 \\ 0.2857 & 0.7143 \end{pmatrix}$$

dengan $\sigma_{t,1}^2$ dan $\sigma_{t,2}^2$ masing-masing adalah varians kondisional untuk *regime* pertama dan kedua, $y_{t,1}$ dan $y_{t,2}$ masing-masing adalah *log return* untuk *regime* pertama dan kedua, dan P adalah matriks probabilitas transisi.

Model *hybrid* MSGARCH-LSTM menggunakan hasil prediksi volatilitas MSGARCH sebagai fitur prediktor pada model LSTM. Target model LSTM adalah volatilitas aktual (*median realized volatility*). Arsitektur model LSTM yang digunakan seperti arsitektur model LSTM terbaik pada Zahid *et al.* (2022), yaitu model LSTM dengan 2 layer [9]. Jumlah unit LSTM layer pertama di-*tuning* antara 128, 64, dan 32, setengah jumlah unit layer LSTM pertama adalah jumlah unit layer LSTM kedua. Learning rate juga di-*tuning* antara 0.001 dan 0.0001. Banyak *epoch* dan *timesteps* yang digunakan masing-masing adalah 150 dan 12. Untuk mencegah terjadinya *overfitting*, model menggunakan *modelcheckpoint* sehingga walaupun model berjalan hingga 150 *epoch*, model yang tersimpan adalah model dengan metrik evaluasi terbaik pada data validasi.



Gambar 3. Perbandingan prediksi volatilitas model MSGARCH dan *hybrid* MSGARCH-LSTM

Gambar 3 menunjukkan adanya perbedaan antara hasil prediksi volatilitas yang diperoleh model MSGARCH 2 *regime* dan jenis distribusi *error* sged dengan hasil prediksi volatilitas *hybrid* MSGARCH (2 *regime* dan jenis distribusi *error* sged)-LSTM. Model *hybrid* MSGARCH (2 *regime* dan jenis distribusi *error* sged)-LSTM menghasilkan prediksi volatilitas yang lebih dekat dengan volatilitas aktual dibandingkan dengan model MSGARCH 2 *regime* dan jenis distribusi *error* sged yang cenderung *overestimate* volatilitas aktual. Metrik evaluasi HMAE dan HMSE juga digunakan untuk membandingkan hasil prediksi volatilitas pada data empiris. Model *hybrid* MSGARCH (2 *regime* dan jenis distribusi *error* sged)-LSTM secara konsisten lebih baik dibandingkan dengan model MSGARCH (2 *regime* dan jenis distribusi *error* sged) sebagaimana ditunjukkan pada Tabel 9. Pada data latih model *hybrid* MSGARCH (2 *regime* dan jenis distribusi *error* sged)-LSTM mampu meningkatkan keakuratan prediksi

volatilitas berdasarkan nilai HMAE sebesar 54.65% dan nilai HMSE sebesar 69.84%. Peningkatan keakuratan prediksi juga terjadi pada data uji, yaitu model *hybrid* MSGARCH (2 *regime* dan jenis distribusi *error* sged)-LSTM mampu meningkatkan keakuratan prediksi volatilitas berdasarkan nilai HMAE sebesar 61.20% dan nilai HMSE sebesar 83.50%.

Tabel 9. Nilai metrik evaluasi hasil prediksi model MSGARCH dan *Hybrid* MSGARCH-LSTM

Model	Data Latih		Data Uji	
	HMAE	HMSE	HMAE	HMSE
MSGARCH	0.7412	5.5062	0.8240	1.2654
<i>Hybrid</i> MSGARCH-LSTM	0.3361	1.6609	0.3197	0.2088

4. Kesimpulan

Berdasarkan hasil penelitian pada data simulasi menggunakan ANOVA disimpulkan bahwa terdapat perbedaan signifikan peringkat rata-rata HMAE pada interaksi tiga arah jumlah *regime*, jenis distribusi *error*, dan jenis model. Kombinasi interaksi tiga arah terbaik yang diperoleh adalah model *hybrid* MSGARCH (1 *regime* dan distribusi *error* snorm)-LSTM, *hybrid* MSGARCH (2 *regime* dan distribusi *error* snorm)-LSTM, *hybrid* MSGARCH (1 *regime* dan distribusi *error* sged)-LSTM, dan *hybrid* MSGARCH (2 *regime* dan distribusi *error* sged)-LSTM. Keempat kombinasi tersebut signifikan lebih baik dibandingkan dengan model LSTM. Sementara itu, berdasarkan penerapan model *hybrid* MSGARCH (2 *regime* dan distribusi *error* sged)-LSTM terhadap data *Bitcoin* diperoleh HMAE sebesar 0.3197 dan HMSE sebesar 0.2088. Metode ini mampu meningkatkan keakuratan prediksi berdasarkan nilai HMAE sebesar 61.20% dan nilai HMSE sebesar 83.50% dibandingkan dengan model MSGARCH (2 *regime* dan distribusi *error* sged).

Daftar Pustaka

- [1] Andersen, T. G., Bollerslev, T., Christoffersen, P. F., & Diebold, F. X. Volatility and Correlation Forecasting. *Handbook of Volatility Forecasting*, 1, 777–878, 2006.
- [2] Kumar, P. H., & Patil, S. B. Volatility Forecasting: A Performance Measure of GARCH Techniques with Different Distribution Models. *International Journal of Soft Computing, Mathematics and Control*, 5(2–3), 1–14, 2016. <https://doi.org/10.14810/ijscmc.2016.5301>
- [3] Candra, F. L. A. Perbandingan Kinerja Model GARCH dan Copula-GARCH untuk Pendugaan Value at Risk pada Bitcoin dan Ethereum. *Tesis, Institut Pertanian Bogor*, 2025.

- [4] Maingo, I., Ravele, T., & Sigauke, C. Volatility Modelling of the Johannesburg Stock Exchange All Share Index Using the Family GARCH Model. *Forecasting*, 7(2), 16, 2025. <https://doi.org/10.3390/forecast7020016>
- [5] Akgun, O. B., & Gulay, E. Dynamics in Realized Volatility Forecasting: Evaluating GARCH Models and Deep Learning Algorithms Across Parameter Variations. *Computational Economics*, 65(6), 3971–4013, 2025. <https://doi.org/10.1007/s10614-024-10694-2>
- [6] Shiferaw, Y. A. An Analysis of East African Tea Crop Prices Using the MCMC Approach to Estimate Volatility and Forecast the In-Sample Value-at-Risk. *Scientific African*, 19, e01442, 2023. <https://doi.org/10.1016/j.sciaf.2022.e01442>
- [7] Ardia, D., Bluteau, K., Boudt, K., Catania, L., & Trottier, D. A. Markov-Switching GARCH Models in R: The MSGARCH Package. *Journal of Statistical Software*, 91(4), 2019. <https://doi.org/10.18637/jss.v091.i04>
- [8] Caporale, G. M., & Zekokh, T. Modelling Volatility of Cryptocurrencies Using Markov-Switching GARCH Models. *Research in International Business and Finance*, 48, 143–155, 2019. <https://doi.org/10.1016/j.ribaf.2018.12.009>
- [9] Zahid, M., Iqbal, F., & Koutmos, D. Forecasting Bitcoin Volatility Using Hybrid GARCH Models with Machine Learning. *Risks*, 10(12), 237, 2022. <https://doi.org/10.3390/risks10120237>
- [10] Manogna, R. L., Dharmaji, V., & Sarang, S. A Novel Hybrid Neural Network-Based Volatility Forecasting of Agricultural Commodity Prices: Empirical Evidence from India. *Journal of Big Data*, 12(1), 2025. <https://doi.org/10.1186/s40537-025-01131-8>
- [11] Bollerslev, T. Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31, 307–327, 1986. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- [12] Ampadu, S., Mensah, E. T., Aidoo, E. N., Boateng, A., & Maposa, D. A Comparative Study of Error Distributions in the GARCH Model Through a Monte Carlo Simulation Approach. *Scientific African*, 23, e01988, 2024. <https://doi.org/10.1016/j.sciaf.2023.e01988>
- [13] Hamilton, J. D. A New Approach to the Economic Analysis of Nonstationary Time Series and the Business Cycle. *Econometrica*, 57(2), 357–384, 1989. <https://doi.org/10.2307/1912559>
- [14] Cai, J. Markov Model of Switching-Regime ARCH. *Journal of Business & Economic Statistics*, 12(3), 309–316, 1994. <https://doi.org/10.2307/1392087>
- [15] Hamilton, J. D., & Susmel, R. Autoregressive Conditional Heteroskedasticity and Changes in Regime. *Journal of Econometrics*, 64(1–2), 307–333, 1994. [https://doi.org/10.1016/0304-4076\(94\)90067-1](https://doi.org/10.1016/0304-4076(94)90067-1)

- [16] Kim, H. Y., & Won, C. H. Forecasting the Volatility of Stock Price Index: A Hybrid Model Integrating LSTM with Multiple GARCH-Type Models. *Expert Systems with Applications*, 103, 25–37, 2018. <https://doi.org/10.1016/j.eswa.2018.03.002>
- [17] Molnar, P. Properties of Range-Based Volatility Estimators. *International Review of Financial Analysis*, 23, 20–29, 2012. <https://doi.org/10.1016/j.irfa.2011.06.012>
- [18] Floros, C., Gkillas, K., Konstantatos, C., & Tsaganos, A. Realized Measures to Explain Volatility Changes over Time. *Journal of Risk and Financial Management*, 13(6), 2020. <https://doi.org/10.3390/jrfm13060125>
- [19] Ardia, D., Bluteau, K., & Ruede, M. Regime Changes in Bitcoin GARCH Volatility Dynamics. *Finance Research Letters*, 29, 266–271, 2019. <https://doi.org/10.1016/j.frl.2018.08.009>
- [20] Alabdulwahab, S., Kim, Y. T., & Son, Y. Privacy-Preserving Synthetic Data Generation Method for IoT-Sensor Network IDS Using CTGAN. *Sensors*, 24(22), 2024. <https://doi.org/10.3390/s24227389>
- [21] Wobbrock, J. O., Findlater, L., Gergle, D., & Higgins, J. J. The Aligned Rank Transform for Nonparametric Factorial Analysis Using Only ANOVA Procedures. *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI 2011)*, 2011. <https://doi.org/10.1145/1978942.1978963>