

Pemodelan dan Peramalan Volatilitas Memori Panjang pada Return Saham ANTM Studi Komparatif Model GARCH dan FIGARCH

Elfa Rafulta^{1*}, Ferra Yanuar², Dodi Devianto³, Maiyastri⁴
^{1,2,3,4}Universitas Andalas, Padang, Indonesia

Informasi Artikel

Diterima Redaksi: 26 Mei 2025
Revisi Akhir: 25 Juni 2025
Diterbitkan Online: 29 Juni 2025

Kata Kunci

Pemodelan volatilitas
Return saham
GARCH
FIGARCH
Long memory

Korespondensi

E-mail: elfarafulta10@gmail.com*

A B S T R A C T

This study aims to model and forecast the volatility of ANTM stock returns using FIGARCH and GARCH models to capture both short- and long-memory dynamics. Daily return data spanning from January 1, 2014, to December 31, 2024, were analyzed after stationarity confirmation via ADF test. A mean model was estimated using MA (4), followed by conditional variance modeling with GARCH (1,1) and FIGARCH (1, d, 1). Diagnostic tests confirmed the presence of heteroskedasticity and long memory, justifying FIGARCH usage. The FIGARCH (1, d, 1) model indicated significant long-memory effects ($d = 0.461007$), while GARCH (1,1) effectively captured short-term volatility clustering. Forecast performance comparison showed that although both models yielded equal RMSE (0.029000), GARCH (1,1) performed better in terms of MAE (0.019531 vs. 0.019529) and MAPE (192.0809 vs. 192.3617). However, FIGARCH demonstrated superior ability in modeling persistent volatility patterns with smoother conditional variance distribution and better long-term uncertainty estimation. These findings suggest that while GARCH is preferable for short-term predictive accuracy, FIGARCH offers more robust insights into long-term volatility persistence, making it suitable for strategic financial risk management.

Penelitian ini bertujuan untuk memodelkan dan meramalkan volatilitas return saham ANTM menggunakan model GARCH dan FIGARCH guna menangkap dinamika volatilitas jangka pendek dan panjang. Data *return* harian dari 1 Januari 2014 hingga 31 Desember 2024 dianalisis setelah melalui uji stasioneritas ADF. Model rata-rata ditentukan menggunakan MA (4), dilanjutkan dengan pemodelan varian bersyarat menggunakan GARCH (1,1) dan FIGARCH (1, d, 1). Uji diagnostik menunjukkan adanya heteroskedastisitas dan efek memori panjang, mendukung penggunaan model FIGARCH. Hasil estimasi menunjukkan bahwa model FIGARCH (1, d, 1) memiliki nilai $d = 0,461007$, mengindikasikan adanya efek *long memory* yang signifikan, sedangkan GARCH (1,1) efektif dalam menangkap kluster volatilitas jangka pendek. Evaluasi kinerja peramalan menunjukkan kedua model memiliki nilai RMSE yang sama (0,029000), namun GARCH (1,1) lebih unggul dalam MAE (0,019531 vs. 0,019529) dan MAPE (192,0809 vs. 192,3617). Meskipun demikian, FIGARCH menunjukkan keunggulan dalam menangkap pola volatilitas jangka panjang yang stabil. Dengan demikian, GARCH cocok untuk akurasi prediksi jangka pendek, sementara FIGARCH lebih direkomendasikan untuk estimasi risiko jangka panjang dalam pengelolaan keuangan strategis.



©2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution-ShareAlike 4.0 International License (CC-BY-SA) (<https://creativecommons.org/licenses/by-sa/4.0/>)

1 Pendahuluan

Penelitian empiris dalam bidang keuangan telah menunjukkan bahwa data return saham dan instrumen keuangan lainnya umumnya menunjukkan karakteristik statistik yang kompleks dan berbeda dari asumsi model klasik, seperti normalitas, linearitas, dan independensi [1]. Salah satu ciri yang paling banyak diamati adalah sifat *volatility clustering*, yaitu kecenderungan bahwa periode volatilitas tinggi diikuti oleh periode volatilitas tinggi lainnya, dan sebaliknya [2], [3]. Selain itu, deret waktu keuangan juga sering kali menunjukkan sifat *leptokurtic* (keruncingan berlebih) dan *asimetri* dalam respons terhadap guncangan positif dan negatif. Fenomena-fenomena ini mendorong perkembangan berbagai model ekonometrik yang lebih fleksibel untuk menangkap dinamika volatilitas secara lebih akurat.

Salah satu karakteristik penting dari volatilitas yang kini semakin diakui dalam literatur adalah adanya *long memory* atau memori panjang. *Long memory* merujuk pada keterkaitan jangka panjang dalam proses stokastik, di mana guncangan yang terjadi di masa lalu masih

memiliki pengaruh terhadap variabel yang diamati bahkan setelah jangka waktu yang cukup lama [4]. Dalam konteks volatilitas, hal ini berarti bahwa ekspektasi terhadap variabilitas return tidak hanya bergantung pada observasi baru-baru ini, tetapi juga dipengaruhi oleh dinamika historis yang panjang. Sifat ini tidak dapat dijelaskan secara memadai oleh model-model konvensional berbasis stasioneritas jangka pendek seperti *Autoregressive Conditional Heteroskedasticity* (ARCH) atau *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH), yang mengasumsikan bahwa dampak guncangan terhadap volatilitas menurun secara eksponensial dan cepat.

Untuk mengatasi keterbatasan tersebut, Bollerslev (1986) mengembangkan model GARCH), yang memungkinkan volatilitas bersyarat saat ini dipengaruhi oleh nilai residual dan volatilitas bersyarat pada periode sebelumnya [5], [6], [7]. Meskipun model ini telah terbukti efektif dalam banyak aplikasi empiris, GARCH tetap memiliki kelemahan dalam menangkap struktur memori panjang dalam volatilitas [8]. Oleh karena itu, Baillie, Bollerslev, dan Mikkelsen (1996) memperkenalkan model Fractionally Integrated GARCH (FIGARCH), yang menggabungkan unsur integrasi fraksional dalam proses GARCH, sehingga memungkinkan pola penurunan pengaruh guncangan yang lebih lambat dan realistis terhadap volatilitas jangka panjang.

Model FIGARCH menggunakan operator perbedaan fraksional $(1-L)^d$, di mana d merupakan parameter orde integrasi fraksional ($0 < d < 1$) [9]. Nilai d yang signifikan mengindikasikan adanya memori panjang dalam volatilitas. FIGARCH dapat dianggap sebagai generalisasi dari GARCH, karena pada saat $d = 0$ model ini kembali menjadi GARCH, sedangkan $d > 0$ menunjukkan efek memori panjang yang tidak ditangkap oleh model GARCH konvensional [10], [11]. Kemampuan FIGARCH dalam menangkap dinamika jangka panjang menjadikannya pilihan yang menarik untuk analisis pasar keuangan yang kompleks dan penuh ketidakpastian [12].

Dalam konteks pasar modal Indonesia, khususnya saham sektor pertambangan, fenomena volatilitas menjadi semakin relevan [13]. Salah satu emiten penting di sektor ini adalah PT Aneka Tambang Tbk (ANTM), yang merupakan bagian dari holding industri pertambangan nasional dan memiliki eksposur besar terhadap komoditas logam seperti emas, nikel, dan bauksit [14]. Harga saham ANTM sangat dipengaruhi oleh harga global logam mulia, nilai tukar, serta dinamika kebijakan domestik dan internasional [15]. Fluktuasi harga saham ANTM yang tinggi menjadikannya objek studi yang penting dalam rangka memahami risiko pasar, terutama bagi investor yang menggunakan pendekatan kuantitatif dalam pengambilan keputusan investasi [16], [17].

Logam mulia seperti emas dan nikel yang diperdagangkan oleh ANTM juga memiliki peran sebagai *safe haven asset* dalam menghadapi ketidakstabilan ekonomi global [18], [19]. Oleh karena itu, memahami perilaku statistik *return* saham ANTM, termasuk dinamika volatilitas jangka pendek dan panjangnya, tidak hanya relevan dalam konteks lokal tetapi juga global. Volatilitas saham komoditas tidak hanya dipengaruhi oleh faktor-faktor fundamental perusahaan, tetapi juga oleh sentimen pasar dan peristiwa eksternal seperti gejolak geopolitik, pandemi, dan kebijakan suku bunga global [20].

Penelitian terdahulu terkait topik ini yaitu Model Volatilitas Return Index Saham Syariah Indonesia Melalui Pendekatan Bayesian Markov Switching GARCH [21]. Penelitian ini secara khusus bertujuan untuk mengevaluasi performa dua model heteroskedastisitas kondisional, yakni GARCH (1,1) dan FIGARCH (1, d , 1), dalam memodelkan dan meramalkan volatilitas *return* saham ANTM. Pemilihan model GARCH (1,1) didasarkan pada prevalensinya dalam literatur sebagai model dasar yang sederhana namun efektif. Sementara itu, FIGARCH (1, d , 1) digunakan untuk menguji adanya sifat memori panjang yang tidak ditangkap oleh model

GARCH. Selain mengevaluasi kecocokan model secara statistik, penelitian ini juga membandingkan akurasi prediksi kedua model menggunakan ukuran kesalahan peramalan seperti *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE) [22], [23]. Evaluasi ini penting untuk mengidentifikasi model yang paling sesuai dalam konteks aplikasi praktis seperti strategi trading dan peramalan risiko.

Kontribusi utama dari studi ini adalah memberikan bukti empiris mengenai efektivitas model FIGARCH dalam menangkap dinamika volatilitas jangka panjang di pasar saham Indonesia. Meskipun model-model *long memory* telah banyak diterapkan di pasar maju seperti Amerika Serikat dan Eropa, penerapan di pasar berkembang masih relatif terbatas. Dengan demikian, hasil dari studi ini diharapkan dapat memperkaya literatur tentang dinamika pasar di negara berkembang, serta memberikan masukan bagi investor, regulator, dan peneliti dalam merumuskan strategi yang berbasis pada pemahaman mendalam terhadap perilaku volatilitas.

Meskipun model *long memory* telah diterapkan untuk volatilitas pasar maju dalam beberapa penelitian, aplikasinya masih sangat terbatas di pasar berkembang, terutama di Indonesia. Beberapa penelitian saat ini lebih banyak berfokus pada penggunaan model klasik seperti GARCH untuk memodelkan volatilitas tanpa mempertimbangkan fenomena memori panjang yang mungkin ada dalam data return saham. Selain itu, meskipun beberapa penelitian di pasar berkembang mulai mempelajari model memori panjang, masih ada perbedaan dalam hal perbandingan dan evaluasi kinerja antara model GARCH dan FIGARCH dalam konteks pasar yang sangat dipengaruhi oleh fluktuasi harga komoditas. Gap Penelitian ini akan membandingkan kinerja dua model volatilitas yang berbasis memori panjang di pasar saham Indonesia untuk menjawab gap ini.

Lebih jauh, pendekatan ini selaras dengan tren riset keuangan modern yang mengedepankan pendekatan kuantitatif berbasis data besar (*big data*) dan model statistik canggih untuk mendukung pengambilan keputusan yang lebih informatif. Dalam jangka panjang, pemodelan volatilitas yang akurat juga dapat membantu pengembangan instrumen keuangan derivatif lokal, peningkatan efisiensi pasar, serta penguatan infrastruktur keuangan Indonesia di tengah kompetisi pasar global yang semakin ketat.

2 Metode Penelitian

2.1 Data Penelitian

Dalam penelitian ini adalah data return harian saham ANTM dari periode 1 Januari 2014 hingga 31 Desember 2024 diambil dari situs resmi <https://www.investing.com/equities/aneka-tambang-historical-data>. Pemilihan data return harian merupakan langkah yang lazim karena return saham mencerminkan perubahan harga relatif antar periode perdagangan, yang secara statistik lebih stabil dan menghilangkan bias dari level harga nominal. Transformasi harga saham menjadi return harian dilakukan dengan menggunakan rumus persentase perubahan logaritmik, yang telah terbukti secara empiris lebih tepat dalam menangkap karakteristik fluktuasi pasar, khususnya volatilitas yang bersifat heteroskedastik dan memiliki memori panjang seperti yang umum dijumpai dalam data keuangan [24]. Dalam pengolahan data dan estimasi model volatilitas, penelitian ini menggunakan software Eviews 13. EViews 13 dipilih karena kemampuannya dalam melakukan analisis statistik untuk mengestimasi model-model heteroskedastik seperti GARCH dan FIGARCH dengan mudah. Dengan menggunakan EViews, proses estimasi parameter model dan pengujian terhadap pola ketergantungan jangka panjang dalam volatilitas dapat dilakukan secara efisien dan akurat. Dengan menggunakan data return ini, penelitian selanjutnya memfokuskan pada analisis dinamika volatilitas saham ANTM melalui model Fractionally Integrated Generalized Autoregressive Conditional Heteroskedasticity

(FIGARCH), yang memungkinkan identifikasi pola-pola ketergantungan jangka panjang dalam volatilitas. Pendekatan ini sangat relevan untuk memahami perilaku pasar saham dalam jangka waktu yang panjang serta implikasinya terhadap pengelolaan risiko dan pengambilan keputusan investasi.

2.2 Volatilitas

Volatilitas merupakan ukuran statistik yang menggambarkan dispersi atau variabilitas *return* dari suatu aset atau indeks pasar, yang secara langsung mencerminkan tingkat risiko yang melekat pada perubahan harga di pasar keuangan [25]. Karakteristik volatilitas pada data keuangan sering kali menunjukkan perilaku yang kompleks dan tidak mudah diprediksi, yang berkontribusi pada ketidakpastian dalam analisis deret waktu keuangan. Ketidakstasioneran dan heteroskedastisitas yang melekat pada volatilitas ini menuntut penggunaan model-model yang mampu menangkap dinamika perubahan volatilitas secara adaptif dan akurat [26]. Dalam konteks aset logam mulia seperti emas, volatilitas *return* menjadi faktor krusial yang harus diperhitungkan dalam pengambilan keputusan investasi, mengingat fluktuasi harga yang signifikan dapat berdampak langsung pada manajemen risiko portofolio. Hasil penelitian ini mendukung temuan sebelumnya yang mengidentifikasi volatilitas sebagai karakteristik utama dan determinan penting dalam perilaku *return* logam mulia, sehingga pemahaman mendalam mengenai pola dan dinamika volatilitas dapat meningkatkan efektivitas strategi investasi dan kebijakan pengelolaan risiko [27]. Dengan demikian, analisis volatilitas tidak hanya memperkaya literatur keuangan, tetapi juga memberikan kontribusi praktis bagi investor dan manajer portofolio dalam menghadapi ketidakpastian pasar.

Dalam analisis deret waktu keuangan yang mengandung volatilitas, pendekatan pemodelan varians menjadi langkah utama untuk menangkap dinamika perubahan variabilitas data secara efektif. Namun, sebelum melakukan pemodelan varians, tahap awal yang penting adalah melakukan pemodelan mean dari deret waktu tersebut, umumnya menggunakan model *Autoregressive Moving Average* (ARMA) [28]. Penentuan ordo ARMA, yakni jumlah lag dari komponen *autoregressive* (AR) dan *moving average* (MA), didasarkan pada analisis grafik *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF), yang merupakan alat diagnostik utama dalam pemilihan model yang tepat [29]. Autokorelasi menggambarkan korelasi antara pengamatan dalam deret waktu pada interval waktu tertentu (lag), sehingga fungsi autokorelasi adalah kumpulan nilai korelasi tersebut untuk berbagai lag yang dianalisis. Fungsi ini membantu dalam mengidentifikasi pola keterkaitan jangka pendek dan jangka panjang dalam data [28]. Sedangkan autokorelasi parsial mengukur korelasi langsung antara pengamatan pada lag tertentu setelah menghilangkan pengaruh lag-lag di antara keduanya, sehingga memberikan gambaran yang lebih spesifik mengenai hubungan langsung antar pengamatan dalam deret waktu. Fungsi autokorelasi parsial merupakan sekumpulan nilai korelasi parsial untuk berbagai lag, yang juga digunakan sebagai panduan dalam menentukan struktur model ARMA yang paling sesuai [29].

Kriteria informasi seperti *Akaike Information Criterion* (AIC) dan *Bayesian Information Criterion* (BIC) dapat membantu pemilihan ordo ARMA secara kuantitatif [30]. Kriteria informasi ini juga digunakan sebagai alat statistik yang objektif untuk memilih model terbaik berdasarkan keseimbangan antara keakuratan dan kompleksitas model. AIC dan BIC menghitung skor berdasarkan jumlah parameter dan kecocokan model terhadap data, model dengan nilai AIC atau BIC terendah dianggap paling optimal [31]. Secara matematis AIC dan BIC sebagai berikut:

$$AIC = -2p - 2 \ln(L) \quad (2.2.1)$$

$$BIC = p \ln(L) - 2 \ln(L) \quad (2.2.2)$$

Dengan demikian, pemodelan mean melalui ARMA yang tepat akan menjadi dasar yang kuat sebelum melanjutkan ke pemodelan volatilitas menggunakan model-model varians seperti GARCH dan turunannya.

2.3 GARCH

Dalam rangka memahami dinamika volatilitas return saham, penelitian ini memulai proses pemodelan dengan menggunakan pendekatan ARCH dan GARCH (*Generalized ARCH*). Model ARCH diperkenalkan pertama kali oleh Engle (1982) sebagai alat untuk menangkap perubahan varians yang bersifat time-varying dan heteroskedastis dalam data deret waktu keuangan. Namun, keterbatasan model ARCH dalam menjelaskan efek volatilitas yang persisten mendorong pengembangan model GARCH oleh Bollerslev (1986), yang mengakomodasi ketergantungan volatilitas pada periode-periode sebelumnya dengan cara yang lebih efisien. GARCH merupakan pengembangan dari model ARCH yang pertama kali diperkenalkan oleh Engle [32] telah terbukti efektif dalam penerapannya terhadap data keuangan yang menunjukkan karakteristik heteroskedastisitas yang bersifat *time-varying*.

Untuk mengatasi permasalahan heteroskedastisitas, diperkenalkan model ARCH(r), yang mempertimbangkan pengaruh kuadrat residual dimasa lalu a_{t-1}^2 terhadap varians bersyarat saat ini σ_t^2 . Secara umum, struktur model ARCH diformulasikan dengan persamaan berikut [33], [34]:

$$\sigma_t^2 = \omega + \sum_{i=1}^r \varphi_i a_{t-i}^2 \quad (2.3.1)$$

dengan $\omega > 0, \varphi_i > 0$, dan $i = 1, 2, \dots, r$.

Untuk mengatasi keterbatasan model ARCH yang seringkali memerlukan orde yang sangat tinggi agar dapat menangkap fluktuasi volatilitas dengan baik, Bollerslev (1986) mengajukan perluasan model tersebut melalui pengembangan GARCH. Model GARCH ini memperkenalkan mekanisme yang lebih efisien dengan memasukkan komponen varians bersyarat dari periode sebelumnya, sehingga memungkinkan pemodelan volatilitas yang lebih akurat dan parsimonious tanpa harus meningkatkan orde model secara signifikan. Dengan demikian, GARCH mampu menangkap pola clustering volatilitas dalam data keuangan secara lebih efektif dibandingkan dengan model ARCH konvensional. Menurut [35], varians bersyarat dalam model GARCH(r,s) dipengaruhi tidak hanya oleh nilai kuadrat residual pada periode sebelumnya a_{t-i}^2 , tetapi juga oleh variansi bersyarat masa lalu (σ_{t-j}^2). Secara umum model GARCH(r,s) dirumuskan sebagai berikut:

$$\sigma_t^2 = \omega + \sum_{i=1}^r \varphi_i a_{t-i}^2 + \sum_{j=1}^s \beta_j \sigma_{t-j}^2 \quad (2.3.2)$$

Dengan $\beta_j > 0$, dan $j = 1, 2, \dots, s$.

2.4 FIGARCH

Estimasi model FIGARCH merupakan langkah krusial dalam penelitian ini untuk mengkaji dinamika volatilitas jangka panjang pada data return saham. Model FIGARCH dipilih karena kemampuannya dalam menangkap efek memori panjang yang sering muncul pada volatilitas pasar keuangan, yang tidak dapat diakomodasi secara optimal oleh model GARCH konvensional [36], [37]. Dengan menerapkan model ini, diharapkan dapat diperoleh pemahaman yang lebih mendalam mengenai pola ketergantungan volatilitas yang berkelanjutan serta peran shock masa lalu dalam membentuk variabilitas harga saham saat ini.

Pada tahap ini, dilakukan proses estimasi parameter FIGARCH menggunakan metode *Maximum Likelihood Estimation* (MLE) dengan data return saham yang telah melalui tahap pra-pemrosesan dan verifikasi asumsi stasioneritas. Estimasi model ini juga dilengkapi dengan uji diagnostik untuk memastikan kesesuaian model serta validitas hasil yang diperoleh. Melalui proses estimasi ini, penelitian berupaya memberikan kontribusi empiris yang signifikan dalam literatur pemodelan volatilitas keuangan, khususnya dalam konteks pasar saham Indonesia.

Menurut beberapa studi terdahulu [38], antara lain model FIGARCH(p,d,q) dirumuskan secara matematis untuk mengakomodasi sifat memori panjang dalam volatilitas deret waktu keuangan. Model ini merupakan perluasan dari model GARCH tradisional dengan memasukkan komponen integrasi fraksional, yang memungkinkan derajat diferensiasi volatilitas menjadi fraksional (d), sehingga memberikan fleksibilitas lebih besar dalam menangkap dinamika volatilitas yang berkelanjutan. Secara formal, pemodelan FIGARCH(p,d,q) dapat dinyatakan sebagai berikut:

$$\phi(L)(1-L)^d \varepsilon_t^2 = \omega + [(1-\beta(L))]v_t \quad (2.4.1)$$

Bentuk lain dari model ini dapat diungkapkan melalui persamaan berikut:

$$\sigma_t^2 = \omega + (1 - [1 - \beta(L)]^{-1} \phi(L)(1-L)^d) \varepsilon_t^2 \quad (2.4.2)$$

$$\sigma_t^2 = \omega + \lambda(L) \sigma_t^2 \quad (2.4.3)$$


Dimana $\lambda(L) = \lambda_1 L + \lambda_2 L^2 - \dots - \lambda_q L^q$ untuk $0 < d < 1$, model FIGARCH mengindikasikan perilaku *long memory*, yaitu, pengaruh dampak dari guncangan volatilitas yang lambat. Selain itu, perlu dicatat bahwa tipe proses ini bukanlah stasioner kovarians, melainkan stasioner ketat dan ergodik untuk $d \in [0,1]$ [39], [40]. Keberadaan long memory ini dapat difaktorisasikan melalui polynomial autoregressive $[1 + \beta(L)] = \phi(L)(1-L)^d$ [41].

Kualitas hasil peramalan model volatilitas seperti FIGARCH dan GARCH biasanya dievaluasi dengan menggunakan metrik kesalahan prediksi yang objektif dan komprehensif, antara lain *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE) [42]. RMSE mengukur akar kuadrat dari rata-rata kuadrat selisih antara nilai observasi dan nilai prediksi, sehingga memberikan penalti lebih besar terhadap kesalahan yang besar dan sangat sensitif terhadap outlier. MAE menghitung rata-rata nilai absolut dari selisih antara hasil observasi dan prediksi, memberikan gambaran langsung mengenai besarnya kesalahan tanpa memperhatikan arah kesalahan. Sementara itu, MAPE menilai rata-rata persentase kesalahan absolut terhadap nilai observasi, yang memungkinkan interpretasi kesalahan dalam konteks proporsi relatif terhadap nilai sebenarnya, sehingga memudahkan perbandingan antar model dengan skala data yang berbeda. Ketiga metrik ini secara bersama-sama memberikan gambaran menyeluruh tentang akurasi model, di mana nilai yang lebih rendah menunjukkan performa peramalan yang lebih baik dan konsisten dalam merepresentasikan dinamika volatilitas pasar. Oleh karena itu, pemilihan model volatilitas yang optimal seringkali berdasarkan perbandingan nilai RMSE, MAE, dan MAPE yang dihasilkan dalam proses evaluasi *forecasting*.

3 Hasil dan Pembahasan

3.1 Deskripsi Data

Penelitian ini memanfaatkan data historis harian harga saham PT Aneka Tambang Tbk (ANTM) yang mencakup rentang waktu dari 1 Januari 2014 hingga 31 Desember 2024, dengan jumlah observasi sebanyak 2.668 titik data. Data tersebut dianalisis untuk mengamati perilaku dinamis harga saham selama periode tersebut. Sebagai langkah awal dalam analisis deret waktu, disajikan plot harga harian saham ANTM guna memberikan gambaran tren dan fluktuasi harga. Selanjutnya, dilakukan uji stasioneritas menggunakan metode *Augmented Dickey-Fuller* (ADF) untuk memastikan kestabilan statistik data, yang merupakan prasyarat penting sebelum melanjutkan ke pemodelan volatilitas dan analisis lanjutan.




Gambar 1. Plot data harian saham ANTM

Tabel 1. Hasil Uji Augmented Dickey-Fuller data harian saham ANTM

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.699911	0.4312
Test critical values:		
1%	-3.432612	
5%	-2.862425	
10%	-2.567286	

Plot *return* saham ANTM yang ditampilkan memperlihatkan fluktuasi nilai *return* yang cenderung tidak stabil dan menunjukkan pola tren yang berpotensi persisten. Terlihat bahwa *return* saham ini tampak memiliki variasi volatilitas yang tinggi dan perubahan rata-rata yang tidak konstan sepanjang periode pengamatan, yang merupakan indikasi awal bahwa data *return* mungkin belum memenuhi asumsi stasioneritas. Hasil uji (ADF) terhadap data *return* tersebut memperkuat dugaan ini. Nilai statistik uji ADF yang diperoleh lebih besar (lebih positif) dari nilai kritis pada level signifikansi 1%, 5%, dan 10%, serta nilai probabilitas (p-value) yang lebih tinggi dari 0.05, mengindikasikan gagal menolak hipotesis nol bahwa data mengandung akar unit (*unit root*). Dengan demikian, data *return* saham ANTM secara statistik dapat dikatakan belum stasioner, yang berarti rata-rata dan variansnya kemungkinan berubah seiring waktu. Ketidakstasioneran ini penting diperhatikan karena banyak metode analisis deret waktu, termasuk model volatilitas seperti GARCH dan FIGARCH, mensyaratkan data *return* yang stasioner agar estimasi parameter menjadi valid dan hasil model dapat diinterpretasikan secara tepat. Oleh karena itu, transformasi data lebih lanjut, seperti *differencing* atau pengambilan log-*return*, diperlukan untuk menghilangkan sifat *non-stasioner* ini dan menghasilkan data yang stasioner sebelum dilanjutkan dengan pemodelan volatilitas yang lebih kompleks.

Selanjutnya, data harga saham harian tersebut ditransformasikan menjadi data *return* harian dengan menggunakan metode selisih nilai *return*, yang bertujuan untuk mengubah data harga nominal menjadi perubahan harga relatif antar periode. Transformasi ini penting untuk menghilangkan tren dan membuat data lebih sesuai untuk analisis volatilitas. Setelah transformasi, dilakukan plot data *return* mengamati pola fluktuasi *return* harian. Selain itu, uji stasioneritas ADF juga diterapkan pada data *return* untuk menguji keberadaan unit root dan memastikan bahwa data *return* sudah memenuhi asumsi stasioneritas yang diperlukan dalam pemodelan deret waktu.



Gambar 2. Plot data return saham ANMT

Tabel 2. Hasil Uji Augmented Dickey-Fuller data return saham ANTM


	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-51.27588	0.0001
Test critical values:		
1%	-3.432610	
5%	-2.862424	
10%	-2.567286	

Berdasarkan hasil transformasi data *return* dilakukan ADF untuk menguji stasioneritas data deret waktu. Hasil uji ADF menunjukkan nilai statistik sebesar -51.27588, yang jauh lebih kecil dari nilai kritis pada tingkat signifikansi 1% (-3.432610), 5% (-2.862424), dan 10% (-2.567286). Selain itu, nilai probabilitas (p-value) sebesar 0.0001, yang berada jauh di bawah batas signifikansi ($\alpha = 0.05$), mengindikasikan bahwa hipotesis nol (data mengandung akar unit atau tidak stationer) ditolak.

Hal ini menguatkan bahwa data *return* bersifat stationer secara statistik yaitu memiliki rata-rata dan varians yang konstan dari waktu ke waktu. Secara visual, dapat dilihat melalui plot deret waktu *return* saham yang berfluktuasi secara acak di sekitar nilai nol tanpa pola tren yang mencolok. Meskipun terdapat lonjakan volatilitas pada periode-periode tertentu (seperti sekitar tahun 2020), secara umum amplitudo dan dispersi *return* berada dalam kisaran yang stabil. Dengan demikian, data *return* saham ANTM telah memenuhi asumsi stasioneritas untuk pemodelan deret waktu berbasis volatilitas seperti ARCH, GARCH, atau FIGARCH. Hal ini memungkinkan untuk dilanjutkannya proses estimasi model volatilitas untuk mengidentifikasi pola heteroskedastisitas dalam return saham ANTM secara lebih akurat.

3.2 Model ARMA

Penentuan model ARMA dilakukan melalui analisis visual terhadap grafik ACF dan PACF. Grafik ACF dan PACF berfungsi sebagai alat diagnostik utama untuk mengidentifikasi ordo komponen AR dan MA yang paling sesuai dalam model ARMA. Hasil plot ACF dan PACF yang diperoleh dari data ditampilkan pada gambar berikut sebagai dasar pemilihan parameter model.



Gambar 3. Plot ACF dan PACF return ANTM

Berdasarkan pengamatan terhadap plot ACF dan PACF yang telah disajikan, terlihat adanya *cut-off* yang signifikan pada lag ketiga dan keempat. Pola ini mengindikasikan bahwa model ARMA yang paling sesuai untuk merepresentasikan karakteristik deret waktu tersebut melibatkan komponen *autoregressive* dan *moving average* hingga orde tiga dan empat. Oleh karena itu, model ARMA yang dihasilkan dapat dirumuskan sebagai berikut:

Tabel 3. Estimasi Parameter model-model ARMA dan nilai AIC saham ANTM

Model	Koef (AR)	Koefisien (MA)	AIC
AR (3)	0.048205	-	-4.241882
ARMA (3,3)	-0.094607	0.143339	-4.241199
ARMA (3,4)	0.047081	0.033329	-4.242298
MA (3)	-	0.048949	-4.241918
AR (4)	0.036629	-	-4.240900
ARMA (4,3)	0.035022	0.047727	-4.242392
ARMA (4,4)	0.820566	-0.792140	-4.241285
MA (4)	-	0.034881	-4.240835

Berdasarkan hasil analisis tabel di atas, dapat disimpulkan bahwa model MA (4), merupakan model yang paling sesuai untuk merepresentasikan karakteristik deret waktu yang diamati. Hal ini didasarkan pada nilai *Akaike Information Criterion* (AIC) yang paling rendah, yaitu -4.240835, dibandingkan dengan berbagai model ARMA lainnya yang diuji. Nilai AIC yang lebih rendah menunjukkan keseimbangan terbaik antara kompleksitas model dan kecocokan data, sehingga model MA (4) dipilih sebagai model optimal. Dengan demikian, persamaan matematis untuk model MA (4) yang merefleksikan pola ketergantungan pada empat lag residual dapat dirumuskan sebagai berikut:

$$X_t = \varepsilon_t + 0.034881\varepsilon_{t-4} \quad (3.2.1)$$

dimana X_t adalah data *return* pada waktu t , ε_t error saat t , ε_{t-4} adalah error saat $t - 4$

3.3 Pemeriksaan Diagnostik

Proses pemeriksaan diagnostik dalam penelitian ini meliputi serangkaian uji penting, yaitu uji heteroskedastisitas untuk mendeteksi adanya varians yang tidak konstan pada residual model, uji autokorelasi guna memeriksa keterkaitan antar residual pada berbagai lag, serta uji normalitas yang bertujuan memastikan distribusi residual mengikuti distribusi normal. Hasil

dari ketiga uji diagnostik tersebut disajikan secara komprehensif pada bagian berikut sebagai dasar evaluasi kesesuaian model yang digunakan.


a. Uji Heteroskedastisitas

Tabel 4. Hasil uji heteroskedastisitas residual model ARMA saham ANTM

Heteroskedasticity Test: ARCH			
F-statistic	27.92544	Prob. F (1,2664)	0.0000
Obs*R-Squared	27.65649	Prob. Chi-Square (1)	0.0000

Nilai probabilitas yang diperoleh dari uji heteroskedastisitas berada jauh di bawah tingkat signifikansi 0,05, yang secara statistik mengindikasikan keberadaan heteroskedastisitas dalam bentuk efek ARCH pada residual model. Hal ini menunjukkan bahwa varians residual tidak bersifat konstan sepanjang waktu, melainkan bersifat *time-varying* dan dipengaruhi oleh nilai residual pada periode sebelumnya. Temuan ini menegaskan perlunya penerapan model volatilitas yang mampu menangkap dinamika heteroskedastisitas kondisional tersebut, seperti model ARCH, *Generalized* ARCH (GARCH), atau turunannya. Dengan demikian, dapat disimpulkan bahwa residual model menunjukkan pola heteroskedastisitas yang signifikan, yang memerlukan pemodelan khusus untuk memperoleh estimasi volatilitas yang lebih akurat dan representatif terhadap kondisi pasar yang sebenarnya.

b. Uji Autokorelasi




Gambar 4. Plot ACF dan PACF residual model ARMA

Dari plot residual terlihat bahwa nilai probabilitas tidak signifikan, sehingga dapat disimpulkan adanya korelasi residual antar lag pada model MA (4). Jika diamati nilai autokorelasi (AC) dan *partial autocorrelation* (PAC) dari residual model hingga lag ke-20. Berdasarkan hasil tersebut, dapat diamati bahwa hampir semua nilai autokorelasi dan partial autokorelasi berada di dalam batas signifikansi pada level 5%, yang ditunjukkan oleh nilai probabilitas yang lebih besar dari 0,05 pada sebagian besar lag. Secara khusus, nilai autokorelasi pada lag 1 sebesar 0,005 dengan probabilitas 0,6514 menandakan bahwa residual model tidak menunjukkan adanya autokorelasi signifikan pada lag tersebut. Hal ini juga konsisten dengan nilai probabilitas untuk uji Ljung-Box (Q-Stat) yang pada semua lag menunjukkan nilai p-value lebih besar dari 0,05, yang berarti tidak ada bukti statistik untuk menolak hipotesis nol bahwa residual adalah *white noise* (bersifat acak). Kondisi ini mengindikasikan bahwa model yang

digunakan telah berhasil menangkap pola struktural pada data dan residual yang dihasilkan bersifat *white noise*, sehingga model tersebut layak digunakan untuk prediksi selanjutnya.

c. Uji Normalitas



Gambar 4. Hasil uji normalitas residual model ARMA

Dengan nilai probabilitas residual yang sangat kecil, yaitu sebesar 0,000000, dapat disimpulkan secara tegas bahwa residual model tidak mengikuti distribusi normal. Fenomena ini bukanlah hal yang jarang dalam konteks pemodelan volatilitas keuangan, di mana model-model seperti GARCH dan turunannya, termasuk FIGARCH, sering kali menghadapi residual yang memiliki distribusi *non-normal*. Karakteristik tersebut mencerminkan kompleksitas dinamika volatilitas pada pasar keuangan yang bersifat *non-Gaussian* dan menunjukkan kejadian ekstrem yang lebih sering daripada yang diasumsikan oleh distribusi normal [18]; (Bollerslev, 1986). Meskipun demikian, model GARCH dan FIGARCH tetap dapat diestimasi dan digunakan secara efektif untuk menangkap pola volatilitas tersebut karena sifat fleksibilitas model dalam memodelkan varians kondisional yang berubah-ubah sepanjang waktu. Oleh karena itu, ketidaksesuaian asumsi normalitas residual tidak menjadi penghalang utama dalam penerapan dan interpretasi hasil model-model volatilitas ini.

3.4 Identifikasi Model GARCH

Dependent Variable: RT_ANTM
Method: ML ARCH - Normal distribution (OPG - BHHH / Marquardt steps)
Date: 05/24/25 Time: 15:41
Sample (adjusted): 2 2668
Included observations: 2667 after adjustments
Failure to improve likelihood (non-zero gradients) after 311 iterations
Coefficient covariance computed using outer product of gradients
MA Backcast: -2 1
Presample variance: backcast (parameter = 0.7)
GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
MA(4)	0.030768	0.020794	1.479674	0.1390

Variance Equation

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000547	5.11E-05	10.71442	0.0000
RESID(-1)^2	0.149447	0.021908	6.821535	0.0000
GARCH(-1)	0.360945	0.051965	6.945914	0.0000

R-squared	0.001219	Mean dependent var	0.000191
Adjusted R-squared	0.001219	S.D. dependent var	0.029023
S.E. of regression	0.029006	Akaike info criterion	-4.275258
Sum squared resid	2.242976	Schwarz criterion	-4.266426
Log likelihood	5705.056	Hannan-Quinn criter.	-4.272062
Durbin-Watson stat	1.989863		

Gambar 5. Hasil estimasi model GARCH (1,1)

Hasil estimasi output menggunakan model GARCH (1,1) dengan persamaan mean menunjukkan bahwa koefisien komponen MA (4) memiliki nilai sebesar 0,030768 dengan probabilitas sebesar 0,1390, yang secara statistik tidak signifikan pada tingkat signifikansi 5%. Hal ini mengindikasikan bahwa pengaruh guncangan (*shock*) atau residual pada empat periode sebelumnya tidak memberikan kontribusi yang signifikan terhadap *return* saham pada periode saat ini. Dengan kata lain, pola jangka pendek dalam deret *return* saham ANTAM tidak menunjukkan dampak yang berarti dalam mempengaruhi fluktuasi harga terkini dalam konteks

model yang digunakan. Temuan ini memperkuat asumsi bahwa pergerakan harga saham lebih dipengaruhi oleh faktor-faktor lain di luar efek residual jangka pendek yang ditangkap oleh komponen MA (4), sehingga model GARCH (1,1) lebih menekankan pada dinamika volatilitas daripada efek mean jangka pendek pada *return*.

$$X_t = 0.030768\varepsilon_{t-4} + \varepsilon_t \quad (3.4.1)$$

Pada model varians GARCH (1,1), nilai konstanta (C) tercatat sebesar 0,000547 dan signifikan secara statistik, yang menunjukkan adanya komponen varians residual yang tidak bergantung pada variabel lag. Koefisien ARCH sebesar 0,149447, yang juga signifikan, mengindikasikan adanya pengaruh langsung dari guncangan (shock) pada periode sebelumnya terhadap volatilitas saat ini. Besarnya nilai koefisien ini menunjukkan bahwa return masa lalu memiliki dampak yang cukup kuat dalam memengaruhi dinamika volatilitas pada periode berjalan. Selanjutnya, koefisien GARCH sebesar 0,360945 dan signifikan menggambarkan tingkat persistensi volatilitas, yaitu kemampuan volatilitas periode sebelumnya untuk bertahan dan memengaruhi varians pada periode berikutnya. Kombinasi kedua koefisien ini mengonfirmasi karakteristik *clustering* volatilitas yang umum ditemui dalam data keuangan, di mana periode volatilitas tinggi cenderung diikuti oleh volatilitas tinggi, dan demikian pula sebaliknya. Berdasarkan nilai-nilai parameter tersebut, persamaan varians dari model GARCH (1,1) dapat dirumuskan sebagai berikut:

$$\sigma_t^2 = 0.000547 + 0.149447 \cdot \varepsilon_{t-1}^2 + 0.360945 \cdot \sigma_{t-1}^2 \quad (3.4.2)$$

Apabila kedua persamaan mean dan persamaan varians digabungkan secara komprehensif, maka model lengkap dapat dirumuskan sebagai berikut:

$$X_t = 0.030768\varepsilon_{t-4} + \varepsilon_t, \varepsilon_t \sim N(0, \sigma_t^2) \quad (3.4.3)$$

$$\sigma_t^2 = 0.000547 + 0.149447 \cdot \varepsilon_{t-1}^2 + 0.360945 \cdot \sigma_{t-1}^2 \quad (3.4.4)$$

3.5 identifikasi Model FIGARCH

Dependent Variable: RT_ANTM
Method: ML ARCH - Normal distribution (OPG - BHHH / Marquardt steps)
Date: 05/24/25 Time: 15:44
Sample (adjusted): 2 2668
Included observations: 2667 after adjustments
Convergence achieved after 100 iterations
Coefficient covariance computed using outer product of gradients
MA Backcast: -2 1
Presample variance: backcast (parameter = 0.7)
GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
MA(4)	0.029549	0.019683	1.501297	0.1333
Variance Equation				
C(2)	5.27E-05	7.44E-06	7.075618	0.0000
RESID(-1)^2	0.187191	0.023246	8.052666	0.0000
GARCH(-1)	0.571716	0.048585	11.76731	0.0000
D	0.461007	0.044245	10.41950	0.0000
R-squared	0.001206	Mean dependent var		0.000191
Adjusted R-squared	0.001206	S.D. dependent var		0.029023
S.E. of regression	0.029006	Akaike info criterion		-4.373898
Sum squared resid	2.243003	Schwarz criterion		-4.362858
Log likelihood	5837.594	Hannan-Quinn criter.		-4.369904
Durbin-Watson stat	1.989739			

Gambar 5. Hasil estimasi model FIGARCH (1, d,1)

Dilakukan estimasi model FIGARCH yang digunakan untuk memodelkan volatilitas yang memiliki efek long memory yaitu efek shock terhadap volatilitas bersifat bertahan lama namun tetap menurun perlahan. Tidak seperti GARCH biasa yang mengasumsikan penurunan eksponensial, FIGARCH mengasumsikan penurunan secara hipergeometrik, sehingga lebih cocok

untuk data keuangan dengan volatilitas jangka panjang. Model menggabungkan MA (4) sebagai persamaan rata-rata serta komponen GARCH dengan parameter fraksional pada persamaan variansnya. Koefisien MA (4) sebesar 0.029549 dengan nilai *p-value* 0.1333 (tidak sig.), menunjukkan bahwa efek MA (4) tidak signifikan secara statistik terhadap nilai return saat ini. Namun, komponen ini tetap dapat memberikan kontribusi terhadap model prediksi jangka pendek. Konstanta model variansi sebesar 5.27×10^{-5} , nilainya kecil namun signifikan sebagai basis. Koefisien ARCH sebesar 0.187191 menunjukkan efek dari kejutan masa lalu (ARCH) terhadap volatilitas saat ini. Koefisien GARCH sebesar 0.571716 efek dari volatilitas masa lalu (GARCH) terhadap volatilitas saat ini. Nilai *d* sebesar 0.461007 menunjukkan derajat memori jangka panjang volatilitas yang disebut dengan *long memory*. Berdasarkan nilai statistik diatas dapat diestimasi model FIGARCH sebagai berikut:

$$(1 - 0.187191L)(1 - L)^{0.461007}\varepsilon_t^2 = 5.27 \cdot 10^{-5} + (1 - 0.571716)v_t \quad (3.5.1)$$


atau dapat disajikan dalam bentuk persamaan varians bersyarat sebagai berikut:

$$\sigma_t^2 = 5.27 \cdot 10^{-5} + (1 - [1 - 0.571716]^{-1}(1 - 0.187191L)(1 - L)^{0.461007})\varepsilon_t^2 \quad (3.5.2)$$

Model FIGARCH (1, d,1) ini lebih baik digunakan ketika volatilitas return saham menunjukkan pola memori panjang (*long memory*), seperti pada *return* saham ini dengan $d = 0.461007$, yang artinya volatilitas dimasa lalu memiliki pengaruh jangka Panjang terhadap volatilitas masa kini dan mendatang.

4 Kesimpulan

Berikut ditampilkan hasil forecast Model GARCH (1,1) dan FIGARCH (1, d,1)



Forecast GARCH (1,1)

Forecast FIGARCH (1, d,1)

Gambar 6. Hasil estimasi forecast model GARCH (1,1) dan FIGARCH (1, d,1)

Tabel 5. Perbandingan RMSE, MAE, dan MAPE

Model	RMSE	MAE	MAPE
GARCH (1,1)	0.029000	0.019531	192.0809
FIGARCH (1, d,1)	0.029000	0.019529	192.3617

Setelah dilakukan forecast untuk model GARCH (1,1) dan FIGARCH (1, d,1), nilai RMSE model GARCH (1,1) sedikit lebih rendah dibandingkan FIGARCH (1, d,1), menunjukkan bahwa GARCH (1,1) memiliki prediksi yang sedikit lebih akurat dalam konkes deviasi kuadrat. Nilai

MAE kedua model hampir sama namun MAE model FIGARCH (1, d,1) sedikit lebih rendah dari model GARCH (1,1) yang artinya model FIGARCH (1, d,1) menghasilkan prediksi *return* yang lebih akurat. Dengan demikian, berdasarkan nilai RMSE GARCH (1,1) lebih unggul dalam memprediksi *return* ANTM karena biasmeminimalkan kesalahan relatif pada jangka pendek, sedangkan model FIGARCH (1, d,1) lebih baik dalam menangkap kestabilan pola dan dinamika volatilitas *return* yang berkesinambungan (jangka panjang). Pemilihan model terbaik dapat disesuaikan dengan tujuan penelitian ini adalah pada *forecasting risk* dan estimasi volatilitas jangka panjang, maka model FIGARCH (1, d,1) lebih direkomendasikan. Bagi investor, model FIGARCH (1, d,1) memberikan gambaran risiko yang lebih realistis terhadap fluktuasi pasar dalam jangka panjang sehingga investor cenderung lebih berhati-hati dalam menyusun portofolio mereka. Nilai MAPE yang sangat tinggi untuk kedua model (lebih dari 190%), menunjukkan GARCH (1,1) maupun FIGARCH (1, d,1) belum memberikan prediksi yang cukup akurat ketika dibandingkan dengan nilai aktualnya, sehingga untuk penelitian lanjutan bisa dilakukan diantaranya dengan merubah periode data harian dengan mingguan atau bulanan, dan pengembangan model hybrid lainnya dengan menggunakan *mechine learning*.

5 Daftar Pustaka

- [1] P. Taylor *et al.*, “Journal of the American Statistical Association the Distribution of Realized Exchange Rate Volatility the Distribution of Realized Exchange Rate Volatility,” *J. Am. Stat. Assoc.*, vol. 96, no. January 2013, pp. 37–41, 2011.
- [2] A. Aljandali and M. Tatahi, *Modelling Volatility in Finance and Economics: ARCH, GARCH and EGARCH Models*. 2018. doi: 10.1007/978-3-319-92985-9_8.
- [3] G. G. A. Perez, “Volatility clustering at a sector level in the Chinese equity market,” *Int. J. Financ. Res.*, vol. 9, no. 3, pp. 103–107, 2018, doi: 10.5430/ijfr.v9n3p103.
- [4] R. T. Baillie, T. Bollerslev, and H. O. Mikkelsen, “Fractionally integrated generalized autoregressive conditional heteroskedasticity,” *J. Econom.*, vol. 74, no. 1, pp. 3–30, 1996, doi: 10.1016/S0304-4076(95)01749-6.
- [5] S. Akbar, T. Saba, S. A. Bahaj, M. Inshal, and A. R. Khan, “Forecasting Volatility in Generalized Autoregressive Conditional Heteroscedastic (GARCH) Model with Outliers,” *J. Adv. Inf. Technol.*, vol. 14, no. 2, pp. 311–318, 2023, doi: 10.12720/jait.14.2.311-318.
- [6] G. S. Osho, “A Generalized Autoregressive Conditional Heteroscedasticity GARCH for Forecasting and Modeling Crude Oil Price Volatility,” vol. 26, no. 6, pp. 39–53, 2024.
- [7] R. F. Engle, S. M. Focardi, and F. J. Fabozzi, “ARCH / GARCH Models in Applied Financial Econometrics,” *Encycl. Financ. Model.*, pp. 359–374, 2012, doi: 10.1002/9781118182635.efm0062.
- [8] R. F. Engle and T. Bollerslev, “Modelling the persistence of conditional variances,” *Econometric Reviews*, vol. 5, no. 1, pp. 1–50, 1986. doi: 10.1080/07474938608800095.
- [9] H. E. Roman and M. Porto, “Fractional derivatives of random walks: Time series with long-time memory,” *Phys. Rev. E - Stat. Nonlinear, Soft Matter Phys.*, vol. 78, no. 3, pp. 1–10, 2008, doi: 10.1103/PhysRevE.78.031127.
- [10] D. Rakshit and R. K. Paul, “Long Memory in Volatility: Application of Fractionally Integrated GARCH Model,” *Founded 1998*, no. February, pp. 107–118, 2023.
- [11] S. Mabrouk, “Forecasting Financial Assets Volatility Using Integrated GARCH-Type Models: International Evidence,” *J. Financ. Econ.*, vol. 4, no. 2, pp. 54–62, 2016, doi: 10.12691/jfe-4-2-3.
- [12] S. R. Bentes, “Measuring persistence in stock market volatility using the FIGARCH approach,” *Phys. A Stat. Mech. its Appl.*, vol. 408, pp. 190–197, Aug. 2014, doi: 10.1016/j.physa.2014.04.032.
- [13] R. A. Biantoro and R. A. Rahadi, “Stock Valuation and Financial Performance of Nickel Mining Company in Indonesia (Case Study: PT Vale Indonesia Tbk),” *Int. J. Curr. Sci. Res. Rev.*, vol. 06, no. 02, pp. 959–985, 2023, doi: 10.47191/ijcsrr/v6-i2-13.
- [14] N. Malla and A. Asianto, “The Determinant of Mining Sector Stock Price Index at Indonesia Stock Exchange,” *Int. J. Acad. Res. Accounting, Financ. Manag. Sci.*, vol. 10, no. 3, pp. 28–37, 2020, doi: 10.6007/ijarafms/v10-i3/7678.
- [15] A. R. Putra and R. Robiyanto, “The effect of commodity price changes and USD/IDR exchange rate on Indonesian mining companies’ stock return,” *J. Keuang. dan Perbank.*, vol. 23, no. 1, pp. 103–115, 2019, doi: 10.26905/jkdp.v23i1.2084.
- [16] W. Liu, “Leveraging probability and statistical algorithms for enhanced financial risk management,” *Theor. Nat. Sci.*, vol. 38, no. 1, pp. 32–38, 2024, doi: 10.54254/2753-8818/38/20240553.

- [17] M. Zhou, "Predict stock price fluctuations using Realized Volatility, CEEMDAN, LSTM models," *SHS Web Conf.*, vol. 196, p. 02003, 2024, doi: 10.1051/shsconf/202419602003.
- [18] G. P. Kumar and F. Crises, "The Safe Heaven Appeal of Gold: A Comparative Analysis of Gold Price and Nifty50 Index during Financial Crises," *Int. J. Emerg. Knowl. Stud.*, vol. 03, no. 09, pp. 734–741, 2024.
- [19] H. Boubaker, J. Cunado, L. A. Gil-Alana, and R. Gupta, "Global crises and gold as a safe haven: Evidence from over seven and a half centuries of data," *Phys. A Stat. Mech. its Appl.*, vol. 540, 2020, doi: 10.1016/j.physa.2019.123093.
- [20] D. G. Baur and T. K. McDermott, "Is gold a safe haven? International evidence," *J. Bank. Financ.*, vol. 34, no. 8, pp. 1886–1898, 2010, doi: 10.1016/j.jbankfin.2009.12.008.
- [21] A. Afnanda, M. Maiyastri, and D. Devianto, "Model Volatilitas Return Index Saham Syariah Indonesia Melalui Pendekatan Bayesian Markov Switching GARCH," *Lattice J. J. Math. Educ. Appl.*, vol. 4, no. 1, pp. 14–26, 2024, doi: 10.30983/lattice.v4i1.8381.
- [22] S. B. Kwarteng and P. A. Andreevich, "Comparative Analysis of ARIMA, SARIMA and Prophet Model in Forecasting," vol. 5, no. 4, pp. 110–120, 2024.
- [23] M. Iaousse, Y. Jouilil, M. Bouincha, and D. Mentagui, "A Comparative Simulation Study of Classical and Machine Learning Techniques for Forecasting Time Series Data," *Int. J. online Biomed. Eng.*, vol. 19, no. 8, pp. 56–65, 2023, doi: 10.3991/ijoe.v19i08.39853.
- [24] R. S. Tsay, *Analysis of financial time series*. Wiley, 2010.
- [25] R. S. Dhankar, "Stock Market Return Volatility," in *Capital Markets and Investment Decision Making*, Springer India, 2019, pp. 123–133. doi: 10.1007/978-81-322-3748-8_7.
- [26] A. Opschoor, *Understanding Financial Market Volatility*. Rotterdram, 2013.
- [27] S. R. Bentes, "Forecasting volatility in gold returns under the GARCH, IGARCH and FIGARCH frameworks: New evidence," *Phys. A Stat. Mech. its Appl.*, vol. 438, pp. 355–364, 2015, doi: 10.1016/j.physa.2015.07.011.
- [28] Z. Zhang and J. C. Moore, "Autoregressive Moving Average Models," *Math. Phys. Fundam. Clim. Chang.*, pp. 239–290, 2015, doi: 10.1016/b978-0-12-800066-3.00008-5.
- [29] Sukono, E. Lesmana, D. Susanti, H. Napitupulu, and Y. Hidayat, "Estimating the Value-at-Risk for some stocks at the capital market in Indonesia based on ARMA-FIGARCH models," in *Journal of Physics: Conference Series*, Nov. 2017, vol. 909, no. 1. doi: 10.1088/1742-6596/909/1/012040.
- [30] C. S. Chen, Y. H. Lee, and H. W. Hsu, "Adaptive order selection for autoregressive models," *J. Stat. Comput. Simul.*, vol. 84, no. 9, pp. 1963–1974, 2014, doi: 10.1080/00949655.2013.776559.
- [31] C. Agiakloglou and A. Tsimpanos, "Evaluating information criteria for selecting spatial processes," *Ann. Reg. Sci.*, vol. 66, no. 3, pp. 677–697, 2021, doi: 10.1007/s00168-020-01033-y.
- [32] F. C. Palm, "7 GARCH models of volatility," *Handb. Stat.*, vol. 14, pp. 209–240, 1996, doi: 10.1016/S0169-7161(96)14009-8.
- [33] D. Fakhriyana, A. Hoyyi, and T. Widiharah, "PERBANDINGAN MODEL ARCH/GARCH MODEL ARIMA DAN MODEL FUNGSI TRANSFER (Studi Kasus Indeks Harga Saham Gabungan dan Harga Minyak Mentah Dunia Tahun 2013 sampai 2015)," *J. Gaussian*, vol. 5, no. 4, pp. 633–640, 2016.
- [34] K. Daly, "Financial volatility: Issues and measuring techniques," *Phys. A Stat. Mech. its Appl.*, vol. 387, no. 11, pp. 2377–2393, 2008, doi: 10.1016/j.physa.2008.01.009.
- [35] J. Arnerić, T. Poklepović, and Z. Aljinović, "GARCH based artificial neural networks in forecasting conditional variance of stock returns," *Croat. Oper. Res. Rev.*, vol. 5, no. 2, pp. 329–343, 2014, doi: 10.17535/corr.2014.0017.
- [36] L. Zhang, "Testing for long memory volatility of Chinese stock markets with FIGARCH model," *Int. Conf. Manag. Sci. Eng. - Annu. Conf. Proc.*, pp. 1450–1455, 2014, doi: 10.1109/ICMSE.2014.6930402.
- [37] G. S. Hiremath, "Indian Stock Market," *SpringerBriefs Econ.*, 2014, doi: 10.1007/978-81-322-1590-5.
- [38] O. Saltik, S. Degirmen, and M. Ural, "Volatility Modelling in Crude Oil and Natural Gas Prices," *Procedia Econ. Financ.*, vol. 38, pp. 476–491, 2016, doi: 10.1016/s2212-5671(16)30219-2.
- [39] S. J. Cochran, I. Mansur, and B. Odusami, "Volatility persistence in metal returns: A FIGARCH approach," *J. Econ. Bus.*, vol. 64, no. 4, pp. 287–305, 2012, doi: 10.1016/j.jeconbus.2012.03.001.
- [40] E. S. Ramadhani, D. Devianto, and F. Yanuar, "MODEL PERGERAKAN HARGA MINYAK MENTAH BRENT MENGGUNAKAN PENDEKATAN TIME SERIES DENGAN EFEK LONG MEMORY," *J. Lebesgue J. Ilm. Pendidik. Mat. Mat. dan Stat.*, vol. 5, no. 3, pp. 1673–1686, Dec. 2024, doi: 10.46306/lb.v5i3.746.
- [41] N. Rismawati, "Long Memory Volatility Model dengan ARFIMA-HYGARCH untuk Meramalkan Return Indeks Harga Saham Gabungan (IHSG)," 2022.
- [42] D. Rakshit and R. K. Paul, "Modeling Time Series with Asymmetric Volatility and Long Memory," *Indian J. Agric. Econ.*, vol. 79, no. 2, pp. 231–244, Apr. 2024, doi: 10.63040/25827510.2024.02.004.