

**ANALISIS VOLATILITAS DAN DEPENDENSI DINAMIS CRYPTOCURRENCY
BITCOIN DAN SAHAM MICROSTRATEGY MENGGUNAKAN MODEL EGARCH
DAN COPULA-GARCH**



William Leonardo Wantoro

H081211050



**PROGRAM STUDI ILMU AKTUARIA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN
MAKASSAR**

2025



Optimized using
trial version
www.balesio.com

**ANALISIS VOLATILITAS DAN DEPENDENSI DINAMIS ANTARA
CRYPTOCURRENCY BITCOIN DAN SAHAM MICROSTRATEGY
MENGUNAKAN MODEL EGARCH DAN COPULA-GARCH**



William Leonardo Wantoro

H081211050

PROGRAM STUDI ILMU AKTUARIA

DEPARTEMEN MATEMATIKA

FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM

UNIVERSITAS HASANUDDIN

MAKASSAR

2025



Optimized using
trial version
www.balesio.com

**ANALISIS VOLATILITAS DAN DEPENDENSI DINAMIS ANTARA
CRYPTOCURRENCY BITCOIN DAN SAHAM MICROSTRATEGY
MENGUNAKAN MODEL EGARCH DAN COPULA-GARCH**

William Leonardo Wantoro

H081211050

Skripsi

sebagai salah satu syarat untuk mencapai gelar sarjana

Program Studi Ilmu Aktuaria

pada

PROGRAM STUDI ILMU AKTUARIA

DEPARTEMEN MATEMATIKA

FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM

UNIVERSITAS HASANUDDIN

2025



SKRIPSI

ANALISIS VOLATILITAS DAN DEPENDENSI DINAMIS ANTARA CRYPTOCURRENCY BITCOIN DAN SAHAM MICROSTRATEGY MENGUNAKAN MODEL EGARCH DAN COPULA-GARCH

William Leonardo Wantoro

H081211050

Skripsi,

telah dipertahankan di depan Panitia Ujian Sarjana Ilmu Aktuaria pada 2025 dan
dinyatakan telah memenuhi syarat kelulusan

pada

Program Studi Ilmu Aktuaria

Departemen Matematika

Fakultas Matematika dan Ilmu Pengetahuan Alam

Universitas Hasanuddin

Makassar



Mengesahkan:
Pembimbing Tugas Akhir,

Mengetahui:
Ketua Program Studi,



nie, S.Si., M.Si.,
2024062002

Prof. Dr. Hasmawati, M.Si.
NIP. 19641231199003200

PERNYATAAN KEASLIAN SKRIPSI DAN PELIMPAHAN HAK CIPTA

Dengan ini saya menyatakan bahwa, skripsi berjudul " ANALISIS VOLATILITAS DAN DEPENDENSI DINAMIS ANTARA CRYPTOCURRENCY BITCOIN DAN SAHAM MICROSTRATEGY MENGGUNAKAN MODEL EGARCH DAN COPULA-GARCH" adalah benar karya saya dengan arahan dari pembimbing (Illuminata Wynn timer, S.Si., M.Si.,)._Karya ilmiah ini belum diajukan dan tidak sedang diajukan dalam bentuk apa pun kepada perguruan tinggi mana pun. Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka skripsi ini. Apabila di kemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan skripsi ini adalah karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut berdasarkan aturan yang berlaku.

Dengan ini saya melimpahkan hak cipta (hak ekonomis) dari karya tulis saya berupa skripsi ini kepada Universitas Hasanuddin.

Makassar, 22 Juni 2025



William Leonardo Wantoro

H081211050



Optimized using
trial version
www.balesio.com

UCAPAN TERIMA KASIH

Segala puji dan syukur penulis panjatkan ke hadirat Tuhan Yesus Kristus atas limpahan kasih karunia, penyertaan, dan hikmat-Nya sehingga penulis dapat menyelesaikan penyusunan skripsi ini dengan baik. Doa dan ucapan syukur juga penulis haturkan kepada Yesus Kristus, Sang Juruselamat, yang telah menerangi jalan kehidupan umat manusia dengan kebenaran dan kasih-Nya.

Dengan segala kerendahan hati, penulis menyampaikan rasa terima kasih yang mendalam kepada Ibu **Illuminata Wynn timer, S.Si., M.Si.** selaku dosen pembimbing dan penasehat akademik, yang telah dengan sabar membimbing dan memberikan arahan selama proses penyusunan skripsi ini. Tak lupa penulis juga mengucapkan terima kasih kepada Bapak **Dr. Amran, S.Si., M.Si.** dan Bapak **Dr. Andi Muhammad Anwar, S.Si., M.Si.** selaku dosen penguji atas kritik, masukan, dan waktunya yang sangat berharga. Penulis juga menyampaikan apresiasi kepada pimpinan Universitas Hasanuddin, seluruh dosen, dan staf Departemen Matematika atas ilmu, bimbingan, serta fasilitas yang telah diberikan selama masa studi.

Ucapan terima kasih yang paling tulus penulis persembahkan kepada kedua orang tua tercinta, Ibu **Meilanie Liwang** dan Ayah **Endro Wantoro** atas cinta, doa, dukungan, dan pengorbanan yang tiada pernah surut. Segala pencapaian ini tidak akan mungkin terwujud tanpa kehadiran dan doa dari mereka. Terima kasih pula penulis sampaikan kepada teman-teman seperjuangan, khususnya **AKUA21UM**, yang telah menjadi tempat berbagi semangat dan saling mendukung sejak awal perkuliahan hingga akhir penyusunan skripsi ini. Ucapan khusus untuk **Juliy an, Nanda** dan **Syafiq** atas dukungan, semangat, dan kebersamaan yang dalam menyelesaikan tugas akhir ini. Akhir kata, penulis mengucapkan terima kasih kepada semua pihak yang telah membantu, baik secara langsung maupun tidak langsung. Semoga segala kebaikan mendapat balasan terbaik dari Tuhan Yang Maha Esa. Penulis menyadari masih banyak kekurangan dalam karya ini, dan dengan rendah hati memohon maaf. Semoga tulisan ini bermanfaat dan menjadi amal jariyah bagi semua yang terlibat.

Makassar, 22 Juni 2025

William Leonardo Wantoro

H081211050



ABSTRAK

WILLIAM LEONARDO WANTORO. ANALISIS VOLATILITAS DAN DEPENDENSI DINAMIS CRYPTOCURRENCY BITCOIN DAN SAHAM MICROSTRATEGY MENGGUNAKAN MODEL EGARCH DAN COPULA-GARCH.

Latar Belakang. Ketidakstabilan pasar global dalam beberapa tahun terakhir, mulai dari pandemi, konflik geopolitik, hingga kebijakan suku bunga tinggi, telah mendorong investor untuk lebih cermat dalam mengelola risiko. Dalam situasi ini, Bitcoin mulai dipandang tidak hanya sebagai aset digital, tetapi juga sebagai alternatif penyimpanan nilai. Sementara itu, saham MicroStrategy (MSTR) memperlihatkan keterkaitan yang kuat dengan Bitcoin karena strategi perusahaan yang mengalokasikan cadangan kas ke aset kripto tersebut. Hubungan ini menimbulkan kebutuhan untuk memahami dinamika volatilitas dan keterkaitan antara keduanya secara lebih mendalam. **Tujuan.** Penelitian ini bertujuan untuk mengkaji karakteristik volatilitas serta hubungan ekstrem antara Bitcoin dan MSTR dengan menggunakan model EGARCH, DCC-GARCH, dan Copula-GARCH. **Metode.** Penelitian ini menggunakan data log-return harian Bitcoin dan MSTR dari tahun 2019 hingga 2024. Struktur model rata-rata ditentukan menggunakan ARMA. Volatilitas dianalisis dengan model EGARCH menggunakan distribusi Skewed Student-t, yang mampu menangkap ketidaksimetrian dan ekor distribusi yang tebal. Korelasi dinamis dievaluasi melalui model DCC-GARCH, sedangkan ketergantungan ekstrem diestimasi menggunakan Student-t Copula dengan pendekatan transformasi residual berbasis Probability Integral Transform (PIT). **Hasil.** Model EGARCH menunjukkan bahwa kedua aset memiliki volatilitas yang tinggi, bersifat asimetris, dan sangat responsif terhadap guncangan pasar. Korelasi antara BTC dan MSTR bersifat dinamis dan cenderung meningkat saat pasar berada dalam kondisi ekstrem. Student-t Copula berhasil mengidentifikasi adanya ketergantungan ekstrem pada kedua sisi distribusi, baik saat pasar naik tajam maupun turun drastis. **Kesimpulan.** EGARCH lebih unggul dibandingkan model GARCH standar dalam menangkap dinamika volatilitas yang kompleks. Di sisi lain, Copula memberikan gambaran yang lebih akurat tentang hubungan ekstrem yang tidak dapat dijelaskan hanya melalui korelasi linier. Temuan ini menunjukkan bahwa Bitcoin dan MSTR memiliki risiko bersama yang signifikan, sehingga penting bagi investor untuk mempertimbangkannya dalam perencanaan portofolio dan strategi manajemen risiko.

Kata Kunci: Bitcoin, MicroStrategy, volatilitas, EGARCH, DCC-GARCH, Student-t



ABSTRACT

WILLIAM LEONARDO WANTORO. ANALYSIS OF VOLATILITY AND DYNAMIC DEPENDENCE OF THE CRYPTOCURRENCY BITCOIN AND MICROSTRATEGY STOCK USING EGARCH AND COPULA-GARCH MODELS.

Background. The growing uncertainty in global financial markets, triggered by events such as the COVID-19 pandemic, geopolitical conflicts, and rising interest rates, has compelled investors to adopt more responsive risk management strategies. Bitcoin, as a decentralized cryptocurrency, and MicroStrategy (MSTR), a technology firm with significant Bitcoin holdings, have become increasingly interconnected. This relationship highlights the importance of understanding both the volatility dynamics and dependence structure between the two assets. **Objective.** This study aims to analyze the volatility patterns and dynamic dependence between Bitcoin and MSTR stock using a combination of EGARCH, DCC-GARCH, and Student-t Copula models. **Method.** Daily log-return data from January 2019 to December 2024 are used. The ARMA model is applied to determine the optimal mean equation, followed by volatility modeling with EGARCH(1,1) using a Skewed Student-t distribution to capture asymmetric and heavy-tailed characteristics. The DCC-GARCH model is employed to estimate time-varying correlations, while the Student-t Copula is used to model tail dependence, based on PIT-transformed standardized residuals. **Results.** The EGARCH model reveals that both assets exhibit high volatility, asymmetric responses to market shocks, and strong persistence. DCC-GARCH results show that correlations between Bitcoin and MSTR are dynamic and intensify during turbulent periods. Furthermore, the Student-t Copula captures symmetric tail dependence, indicating the tendency of the two assets to experience joint extreme movements during market stress. **Conclusion.** The EGARCH model outperforms conventional GARCH in capturing volatility asymmetry and persistence. Meanwhile, the Copula approach provides a robust framework for modeling extreme co-movements that linear correlation fails to capture. These findings underscore the systemic link between Bitcoin and MSTR, which should be considered when constructing diversified and resilient investment portfolios.

Keywords: Bitcoin, MicroStrategy, volatility, EGARCH, DCC-GARCH, Student-t Copula.



DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGANTAR	ii
HALAMAN PENGESAHAN	iii
HALAMAN_PERNYATAAN KEASLIAN	iv
UCAPAN TERIMA KASIH	v
ABSTRAK	vi
ABSTRACT	vii
DAFTAR ISI	viii
DAFTAR TABEL	x
DAFTAR GAMBAR	xi
DAFTAR LAMPIRAN	xii
DAFTAR NOTASI	xiii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	2
1.3 Tujuan Penelitian	3
1.4 Landasan Teori	3
1.4.1 Saham	3
1.4.2 Cryptocurrency	3
1.4.3 Return	4
1.4.4 Volatilitas	5
1.4.5 Uji Stasioner	6
1.4.6 Diferensiasi	7
1.4.7 Model ARMA (Autoregressive Moving Average)	7
1.4.8 Uji Autokorelasi	8
1.4.9 Uji Heteroskedastisitas	9
1.4.10 Analisis Regresi	10
1.4.11 ARCH	11
1.4.12 EGARCH	13
1.4.13 Uji Inovasi: Skewed Student- t	14



1.4.14	Kriteria Pemilihan AIC dan BIC	15
1.4.15	Model DCC-GARCH.....	15
1.4.16	Model Copula	16
1.4.17	Model Student- <i>t</i> Copula.....	17
BAB II METODOLOGI PENELITIAN		21
2.1	Hasil Pendekatan dan Jenis Penelitian	21
2.2	Alur kerja	23
BAB III HASIL DAN PEMBAHASAN		25
3.1.	Hasil	25
3.1.1.	Statistik Deskriptif	25
3.1.2.	Uji Stasioner	26
3.1.3.	Permodelan ARMA.....	27
3.1.4.	Uji Autokorelasi.....	28
3.1.5.	Uji Heterokedastistas.....	29
3.1.6.	Uji Normalitas	30
3.1.7.	Estimasi Model GARCH(1,1) dan EGARCH(1,1)	30
3.1.8.	Validasi Residual	32
3.1.9.	Estimasi Model DCC-GARCH(1,1).....	34
3.1.10.	Estimasi Model Copula.....	35
3.2.	Pembahasan	37
BAB IV KESIMPULAN		39
4.1	Kesimpulan	39
DAFTAR PUSTAKA		41
LAMPIRAN		43



DAFTAR TABEL

Tabel 1 Statistik Deskriptif Log Return BTC dan MSTR (2019–2024)	26
Tabel 2 Hasil Uji Stasioneritas ADF untuk BTC dan MSTR	27
Tabel 3 Evaluasi Model ARMA Berdasarkan AIC, BIC, dan Uji Residual.....	28
Tabel 4 Hasil Uji Autokorelasi dan Efek ARCH	29
Tabel 5 Hasil Uji ARCH–LM terhadap Residual ARMA.....	30
Tabel 6 Hasil Uji Normalitas Jarque–Bera	30
Tabel 7 Estimasi Parameter Model GARCH(1,1) dan EGARCH(1,1) dengan Distribusi SSTD.....	31
Tabel 8 Hasil Uji Diagnostik Residual untuk Model GARCH dan EGARCH.....	33
Tabel 9 Hasil Estimasi Parameter Model DCC-GARCH(1,1).....	34
Tabel 10 Perbandingan Model Copula	35



DAFTAR GAMBAR

Gambar 1 Alur Kerja.....	23
Gambar 2 Plot ACF PACF Log Return BTC dan MSTR	27
Gambar 3 Korelasi Dinamis BTC-MSTR Berdasarkan DCC-GARCH(1,1).....	35
Gambar 4 Visualisasi Permukaan 3D Student-t Copula.....	37



DAFTAR LAMPIRAN

Lampiran 1 Tabel Harga Penutupan dan Log-Return BTC dan MSTR dari Bulan Januari 2019 Hingga Desember 2024	43
Lampiran 2 Kode R Untuk Estimasi Model GARCH(1,1) dan EGARCH(1,1) serta Menampilkan Parameter dan Melakukan Validasi Residual	45
Lampiran 3 Kode R Untuk Estimasi dan Visualisasi Model DCC-GARCH.....	47
Lampiran 4 Kode R Untuk Estimasi Model Copula dan Visualisasi Model Student-t Copula	49
Lampiran 5 Tabel Estimasi Parameter GARCH(1,1).....	51
Lampiran 6 Tabel Estimasi Parameter EGARCH(1,1)	52
Lampiran 7 Tabel Hasil Grid Search Model ARMA(p,q)	53
Lampiran 8 Tabel estimasi dua distribusi inovasi (Student- t dan Skewed Student- t)	54



DAFTAR NOTASI

Notasi	Keterangan
r_t	<i>log-return</i> harian pada waktu ke- t
P_t	harga penutupan aset pada hari ke- t
P_{t-1}	harga penutupan aset pada hari ke $t - 1$ atau hari sebelumnya
σ_t^2	Variansi kondisional return pada waktu ke- t , yaitu variansi yang bergantung pada informasi historis hingga waktu ke- $(t - 1)$, seperti residual dan variansi masa lalu.
ε_t	residual dari return pada waktu ke- t
α	Parameter ARCH, menangkap sensitivitas volatilitas terhadap shock jangka pendek
β	Parameter GARCH, menangkap persistensi volatilitas masa lalu
γ	koefisien asimetri; jika berbeda dari nol, maka terdapat <i>leverage effect</i>
L	nilai <i>log-likelihood</i> , yaitu ukuran seberapa besar kemungkinan model menjelaskan data yang diamati
k	jumlah total parameter dalam model (<i>termasuk mean equation, variance equation</i> , dan distribusi inovasi),
n	jumlah observasi dalam sampel
H_t	matriks kovarians kondisional multivariat pada waktu ke- t
D_t	matriks diagonal berisi deviasi standar ($\sigma_{i,t}$) dari masing-masing aset, diperoleh dari estimasi GARCH univariat
R_t	matriks korelasi kondisional dinamis pada waktu ke- t , yang menggambarkan hubungan antar aset yang berubah seiring waktu
Q_t	matriks kovarians dinamis tak ternormalisasi pada waktu ke- t
$t_{v,\rho}$	fungsi distribusi kumulatif dari distribusi <i>bivariate</i> Copula Student- t dengan korelasi ρ dan derajat kebebasan v
v	parameter derajat kebebasan, yang mengontrol ketebalan ekor dari distribusi; semakin kecil nilai v , semakin berat (<i>fat</i>) ekornya
ρ	parameter korelasi, yang menentukan kekuatan hubungan linier dalam distribusi bivariat
δ_i	koefisien dari lag ke- i atas perbedaan nilai variabel untuk menangkap autokorelasi dalam residual
AIC	Akaike Information Criterion
BIC	Bayesian Information Criterion
JB	nilai statistik Jarque-Bera
	ss dari data (mengukur asimetri distribusi)
	dari data (mengukur ketebalan ekor distribusi)



BAB I

PENDAHULUAN

1.1 Latar Belakang

Dalam beberapa tahun terakhir, pasar keuangan global mengalami tekanan yang signifikan akibat akumulasi peristiwa berskala internasional. Pandemi COVID-19 telah mengguncang stabilitas ekonomi dan memicu *volatility* pasar yang luas di berbagai sektor. Ketegangan geopolitik yang berkepanjangan, seperti konflik Rusia–Ukraina dan krisis di Timur Tengah, turut memperbesar ketidakpastian pasar. Di sisi lain, kebijakan suku bunga tinggi yang diterapkan oleh *central banks* utama dunia seperti *The Federal Reserve* dan *European Central Bank* menambah tekanan terhadap likuiditas dan nilai aset global. Berdasarkan laporan dari *Financial News London* (2024), faktor geopolitik dan ketidakpastian moneter diidentifikasi sebagai dua dari tiga sumber risiko terbesar yang dihadapi pasar global pada tahun 2025. Dalam konteks tersebut, investor didorong untuk mengadopsi strategi manajemen risiko dan diversifikasi portofolio yang lebih responsif terhadap dinamika pasar yang cepat berubah.

Salah satu respons yang menonjol terhadap kondisi tersebut adalah meningkatnya perhatian terhadap aset digital, khususnya *cryptocurrency* seperti Bitcoin. Sebagai aset digital pertama yang bersifat *decentralized*, Bitcoin telah berkembang dari sekadar alat tukar digital menjadi alternatif *store of value* dalam portofolio institusional. Ketahanan teknologinya, likuiditas pasar yang tinggi, serta tingkat volatilitas ekstrem menjadikan Bitcoin subjek penting dalam kajian risiko dan manajemen investasi. Laporan *Reuters* (2024) mencatat bahwa pada akhir tahun 2024, harga Bitcoin menembus level USD 100.000, yang sebagian besar dipicu oleh ekspektasi kebijakan pro-kripto dari pemerintahan Amerika Serikat dan meningkatnya minat institusi melalui produk-produk *exchange-traded fund* (ETF). Kendati demikian, risiko regulasi yang belum pasti dan karakteristik harga yang sangat fluktuatif tetap menjadi perhatian utama dalam mempertimbangkan Bitcoin sebagai komponen portofolio investasi yang stabil.

Di sisi lain, muncul pula dinamika baru dari pasar saham, khususnya melalui saham perusahaan teknologi seperti MicroStrategy (MSTR). Sejak tahun 2020, perusahaan ini mengambil langkah strategis dengan mengalokasikan sebagian besar cadangan kasnya ke dalam Bitcoin. Strategi ini menjadikan MSTR sebagai entitas korporat yang sangat terpapar terhadap fluktuasi harga Bitcoin, sehingga membentuk keterkaitan struktural antara kedua aset tersebut (Phillips & Pohl, 2024). Ketergantungan ini menimbulkan pertanyaan penting mengenai pola keterkaitan

dan MSTR, serta bagaimana risiko gabungan dari keduanya cara statistik.

b persoalan tersebut, berbagai studi terdahulu telah lekatan berbasis *GARCH* (*Generalized Autoregressive kedasticity*) untuk memodelkan dinamika volatilitas aset mampu menangkap fenomena *volatility clustering* yang umum return harian. Namun demikian, model GARCH memiliki



keterbatasan dalam menangani *asymmetric volatility*, yaitu kondisi ketika pasar bereaksi lebih kuat terhadap informasi negatif dibandingkan positif. Untuk mengatasi keterbatasan tersebut, model *Exponential GARCH (EGARCH)* dikembangkan oleh Nelson (1991). Model ini dirancang untuk menangkap *leverage effect* dan dinamika volatilitas yang bersifat tidak simetris, menjadikannya sangat relevan untuk memodelkan perilaku pasar *cryptocurrency* seperti Bitcoin (Eroğlu & Yüce Akıncı, 2021).

Setelah diperoleh model volatilitas terbaik, tahap selanjutnya dalam penelitian ini adalah memahami struktur hubungan dinamis antara kedua aset. Untuk itu digunakan dua pendekatan komplementer, yaitu Dynamic Conditional Correlation-GARCH (DCC-GARCH) dan pendekatan copula. Model DCC-GARCH digunakan untuk menangkap korelasi yang berubah secara dinamis dari waktu ke waktu antara *return* Bitcoin dan MSTR (Queiroz *et al.*, 2024). Sementara itu, pendekatan copula memberikan fleksibilitas dalam memodelkan ketergantungan nonlinier, khususnya pada kondisi pasar ekstrem. Di antara berbagai jenis copula, model Student-*t* copula dipilih karena kemampuannya untuk menangkap *symmetric tail dependence*, yaitu keterkaitan yang signifikan saat dua aset mengalami kejutan ekstrem secara bersamaan (Huynh, 2019).

Melalui Integrasi model GARCH atau EGARCH, DCC-GARCH, dan Student-*t* copula, studi ini berupaya menyajikan pemahaman yang lebih menyeluruh dan mendalam mengenai dinamika volatilitas serta struktur ketergantungan antara aset digital Bitcoin dan saham MicroStrategy. Pendekatan ini tidak hanya menangkap karakteristik volatilitas yang kompleks dan asimetris, tetapi juga memetakan pola hubungan dinamis yang mungkin muncul dalam kondisi pasar yang ekstrem. Melalui pemodelan yang komprehensif ini, diharapkan dapat diperoleh gambaran yang lebih realistis terhadap perilaku gabungan kedua aset dalam menghadapi risiko pasar yang tinggi. Berdasarkan kerangka tersebut, penelitian ini diberi judul:

“Analisis Volatilitas dan Dependensi Dinamis antara Cryptocurrency Bitcoin dan Saham MicroStrategy Menggunakan Model EGARCH dan Copula-GARCH.”

Judul tersebut mencerminkan fokus utama penelitian ini, yaitu memahami keterkaitan antara Bitcoin dan saham MicroStrategy melalui pendekatan kuantitatif EGARCH, DCC-GARCH, dan Student-*t* copula. Pendekatan ini ditujukan untuk menangkap dinamika risiko dalam pasar yang semakin terhubung dan penuh ketidakpastian, serta memberikan landasan yang kuat bagi pengambilan keputusan investasi yang lebih tepat.

1.2 Rumusan Masalah



Salah satu cakupan dan fokus penelitian, pertanyaan-pertanyaan utama dalam studi ini adalah:

Apakah model EGARCH mampu mengestimasi volatilitas Bitcoin (BTC) dan saham MicroStrategy (MSTR) secara lebih baik dibandingkan model GARCH?

2. Bagaimana struktur dependensi dinamis antara Bitcoin (BTC) dan MicroStrategy (MSTR) jika dianalisis menggunakan DCC-GARCH dan Copula?

1.3 Tujuan Penelitian

Penelitian ini bertujuan untuk:

1. Mendapatkan model yang mampu mengestimasi volatilitas dengan baik dari Bitcoin (BTC) dan saham MicroStrategy (MSTR)
2. Mendapatkan struktur dependensi dinamis antara Bitcoin (BTC) dan MicroStrategy (MSTR) menggunakan model DCC-GARCH dan Copula.

1.4 Landasan Teori

1.4.1 Saham

Saham merupakan salah satu instrumen keuangan yang merepresentasikan kepemilikan terhadap suatu entitas perusahaan terbatas. Melalui kepemilikan saham, seorang investor memperoleh hak atas bagian aset perusahaan serta potensi keuntungan berupa dividen. Selain itu, saham juga memberikan hak suara dalam rapat umum pemegang saham, sebanding dengan jumlah kepemilikan yang dimiliki. Dalam konteks pasar keuangan, saham telah menjadi instrumen investasi utama yang diperdagangkan secara luas, baik oleh investor individu maupun institusi. Harga saham di pasar modal cenderung berfluktuasi secara dinamis, yang mencerminkan respons terhadap berbagai faktor fundamental dan sentimen pasar, baik yang berasal dari dalam perusahaan maupun dari kondisi eksternal ekonomi makro (Ma, 2025).

Studi-studi terbaru menunjukkan bahwa volatilitas harga saham tidak hanya dipengaruhi oleh kinerja dan prospek perusahaan, tetapi juga oleh eksposur terhadap aset digital seperti *cryptocurrency*. Salah satu contoh yang relevan adalah saham MicroStrategy (MSTR), yang dalam beberapa tahun terakhir menunjukkan korelasi signifikan dengan pergerakan harga Bitcoin karena strategi alokasi kas perusahaan ke dalam aset kripto tersebut (Aminuddin *et al.*, 2022). Fenomena ini menunjukkan bahwa keterkaitan struktural antara saham dan aset kripto menciptakan pola volatilitas yang lebih kompleks dan saling bergantung. Menurut Eroğlu dan Yüce Akıncı (2021), karakteristik pasar kripto yang sangat sensitif terhadap informasi dan spekulatif turut memengaruhi dinamika harga instrumen lain yang terpapar secara langsung, seperti saham-saham teknologi yang berinvestasi dalam Bitcoin.

1.4.2 Cryptocurrency



ah aset digital yang menggunakan teknologi kriptografi untuk transaksi, mengontrol penciptaan unit baru, serta memverifikasi a dengan mata uang fiat yang diterbitkan oleh otoritas moneter y bersifat terdesentralisasi dan umumnya beroperasi di atas , yaitu sistem pencatatan digital terdistribusi yang bersifat dapat diubah secara sepihak (Huynh, 2019).

Bitcoin (BTC), yang pertama kali diperkenalkan oleh Satoshi Nakamoto pada tahun 2009, merupakan bentuk *cryptocurrency* paling dominan dan telah menjadi perwakilan utama dalam berbagai studi akademik. Aset ini memiliki pasokan terbatas yang dikendalikan melalui mekanisme penambangan berbasis algoritma, dan tidak memiliki nilai intrinsik seperti aset riil pada umumnya (Bouri *et al.*, 2017). Nilai Bitcoin ditentukan sepenuhnya oleh interaksi penawaran dan permintaan di pasar, serta sangat dipengaruhi oleh sentimen investor, regulasi pemerintah, dan dinamika global.

Cryptocurrency memiliki karakteristik yang unik dibandingkan instrumen keuangan tradisional. Salah satu ciri utamanya adalah tingkat volatilitas harga yang sangat tinggi. Perdagangan yang berlangsung 24 jam tanpa jeda serta sifatnya yang relatif anonim membuat aset ini semakin berbeda. Selain itu, responsnya yang cepat terhadap informasi eksternal menciptakan pola pergerakan harga dan risiko yang tidak lazim ditemukan pada saham atau obligasi.

Dalam ranah keuangan modern, *cryptocurrency* diposisikan sebagai aset alternatif yang menarik perhatian investor global. Namun, tingginya volatilitas dan kompleksitas strukturalnya menuntut penggunaan model statistik yang lebih fleksibel dan adaptif, terutama dalam mengukur risiko dan struktur ketergantungan antar aset. Oleh karena itu, Bitcoin sering digunakan dalam kajian empiris sebagai studi kasus utama untuk menguji efektivitas model-model volatilitas seperti GARCH, serta pendekatan dependensi ekstrem seperti copula (Katsiampa, 2017; Huynh, 2019).

1.4.3 Return

Return merupakan indikator utama untuk mengukur tingkat keuntungan atau kerugian dari suatu investasi dalam periode tertentu. Dalam analisis deret waktu finansial, *logarithmic return* lebih sering digunakan dibanding *simple return*, karena memiliki sifat statistik yang lebih sesuai seperti stasioneritas dan kemampuan menjumlahkan perubahan harga antar waktu. Studi oleh Eroğlu dan Yüce Akinci (2021) menunjukkan bahwa *log-return* Bitcoin cenderung bersifat leptokurtik, menunjukkan distribusi dengan ekor berat, serta menunjukkan volatilitas tinggi pada periode tertentu. Untuk dapat diterapkan dalam model seperti GARCH dan EGARCH, deret waktu *return* harus stasioner, dan penggunaan *log-return* membantu memenuhi prasyarat tersebut.

Untuk keperluan analisis deret waktu finansial, *return* biasanya dinyatakan dalam bentuk *log-return*, karena memiliki sifat yang lebih sesuai secara statistik, seperti stasioneritas dan kemampuan untuk menjumlahkan return antar waktu. Rumus *log-return* dirumuskan sebagai berikut:

$$r_t = \ln \left(\frac{P_t}{P_{t-1}} \right) \quad (1)$$



tmik pada hari ke- t ,
upan aset pada hari ke- t ,

P_{t-1} : harga penutupan aset pada hari sebelumnya.

Penggunaan *log-return* memungkinkan transformasi perubahan harga menjadi bentuk kontinu yang lebih sesuai untuk asumsi distribusi log-normal dalam berbagai model stokastik. Selain itu, dalam kerangka model volatilitas seperti GARCH dan EGARCH, penggunaan *log-return* merupakan praktik standar karena dapat membantu mengurangi pengaruh outlier ekstrem dan menjadikan variabel yang dianalisis lebih stasioner (Tsay, 2010).

1.4.4 Volatilitas

Volatilitas merupakan salah satu konsep fundamental dalam analisis pasar keuangan yang digunakan untuk mengukur tingkat ketidakstabilan harga suatu aset dari waktu ke waktu. Secara statistik, volatilitas menggambarkan besar dispersi nilai *return* terhadap rata-ratanya, yang sering kali diinterpretasikan sebagai indikator tingkat risiko pasar jangka pendek. Dalam konteks aset kripto dan saham berisiko tinggi, volatilitas tidak hanya mencerminkan ketidakpastian pasar, tetapi juga menjadi sinyal penting atas reaksi investor terhadap informasi baru, baik bersifat fundamental maupun spekulatif (Eroğlu & Yüce Akıncı, 2021). Studi oleh Ma (2025) menegaskan bahwa aset seperti Bitcoin dan saham MicroStrategy menunjukkan pola volatilitas yang tinggi dan sensitif terhadap kejadian ekstrem, sehingga memerlukan pendekatan pemodelan yang mampu menangkap dinamika tersebut secara akurat.

Secara matematis, volatilitas sering diukur melalui simpangan baku (*standard deviation*) dari *return*:

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{t=1}^n (r_t - \bar{r})^2} \quad (2)$$

Dengan :

σ : volatilitas,

r_t : *return* pada periode ke- t ,

$\bar{r}$: rata-rata *return*,

n : jumlah observasi.

Dalam literatur keuangan modern, volatilitas memiliki sifat yang disebut sebagai *stylized facts*, antara lain:

- *Volatility clustering*: periode volatilitas tinggi diikuti oleh volatilitas tinggi, dan sebaliknya,
- *Asymmetric volatility*: *return* negatif cenderung meningkatkan volatilitas lebih dari *return* positif, *return* memiliki ekor yang lebih tebal dari distribusi normal.



tidak dapat dijelaskan sepenuhnya oleh model linear yang memerlukan pendekatan model yang lebih kompleks seperti turunannya untuk menangkap dinamika volatilitas secara lebih akurat (Bollerslev, 1986).

1.4.5 Uji Stasioner

Dalam analisis deret waktu, memastikan bahwa data bersifat stasioner merupakan langkah awal yang krusial sebelum membangun model lanjutan. Data dikatakan stasioner apabila karakteristik statistiknya—seperti rata-rata, varians, dan autokorelasi—tetap konstan sepanjang waktu. Ketika data tidak memenuhi kondisi ini, model yang dibangun berisiko menghasilkan estimasi yang bias dan tidak dapat diandalkan (Yahaya *et al.*, 2022). Oleh karena itu, seperti yang ditunjukkan dalam studi Ma (2025), pengujian awal menggunakan metode Augmented Dickey–Fuller (ADF) test menjadi penting untuk mendeteksi keberadaan *unit root* dalam data, yang menandakan sifat non-stasioner. Hasil uji ADF pada log-return Bitcoin dan saham MicroStrategy dalam penelitian tersebut menunjukkan bahwa kedua deret telah memenuhi sifat stasioneritas dan layak untuk dianalisis lebih lanjut dalam model volatilitas.

Secara umum, bentuk regresi untuk uji ADF dapat dituliskan sebagai:

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \sum_{i=1}^p \delta_i \Delta y_{t-i} + \varepsilon_t \quad (3)$$

dengan:

- y_t : nilai deret waktu pada waktu t ,
- Δy_t : perubahan nilai dari deret waktu y_t , yaitu $y_t - y_{t-1}$,
- t : waktu,
- α : konstanta atau *drift term*,
- βt : komponen tren linier waktu,
- γ : parameter kunci untuk mendeteksi unit root,
- y_{t-1} : lag satu dari deret waktu asli,
- δ_i : koefisien dari lag perbedaan untuk menangkap autokorelasi dalam residual,
- p : jumlah lag untuk mengatasi autokorelasi dalam residual,
- ε_t : residual *white noise*,

Hipotesis yang diuji adalah:

- H_0 : Data mengandung *unit root* (non-stasioner),
- H_1 : Data tidak mengandung *unit root* (stasioner).

Jika nilai statistik uji ADF lebih kecil daripada nilai kritis (pada tingkat signifikansi 1%, 5%, atau 10%), maka hipotesis nol ditolak, yang berarti data dianggap stasioner.

Dalam penelitian ini, uji ADF dilakukan terhadap data *log-return* dari Bitcoin dan



log-return membantu meningkatkan kemungkinan stasioneritas engaruh tren dan skala harga. Hasil uji stasioneritas ini menjadi pemodelan volatilitas seperti GARCH dan EGARCH, yang data input sudah bebas dari tren jangka panjang.

1.4.6 Diferensiasi

Dalam analisis deret waktu, kestasioneran merupakan salah satu prasyarat utama sebelum suatu model statistik dapat diterapkan secara valid, terutama pada model-model stokastik seperti *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* (ARMA), dan *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH). Salah satu teknik transformasi yang digunakan untuk mengatasi masalah ketidakstasioneran adalah proses *differencing* atau diferensiasi. Diferensiasi bertujuan untuk menghilangkan komponen tren dan menghasilkan deret waktu baru yang bersifat stasioner, yaitu deret yang memiliki rata-rata dan variansi yang konstan sepanjang waktu. Hal ini penting untuk memastikan bahwa hasil estimasi parameter model tidak bias dan dapat diinterpretasikan secara ekonometrik (Ramadhan, 2015). Proses diferensiasi dilakukan dengan menghitung selisih antara nilai data pada periode sekarang dan nilai data pada periode sebelumnya. Secara matematis, proses diferensiasi orde pertama dirumuskan sebagai berikut:

$$\Delta y_t = y_t - y_{t-1} \quad (4)$$

Dengan demikian, derajat diferensiasi yang diperlukan untuk menjadikan data stasioner dinyatakan dalam parameter d pada model $ARIMA(p, d, q)$. Apabila nilai $d = 1$, berarti data mengalami proses diferensiasi satu kali sebelum dianalisis lebih lanjut.

Adapun notasi yang digunakan dalam transformasi diferensiasi adalah sebagai berikut:

y_t : nilai deret waktu pada periode ke- t

y_{t-1} : nilai deret waktu pada periode sebelumnya

∇y_t : hasil diferensiasi orde pertama dari deret waktu

$\nabla^2 y_t$: hasil diferensiasi orde kedua, yaitu diferensiasi atas hasil diferensiasi orde pertama

Dengan diterapkannya diferensiasi, data yang semula mengandung tren atau perubahan pola jangka panjang dapat diubah menjadi deret yang bersifat stasioner. Oleh karena itu, proses ini menjadi bagian penting dalam tahap prapemodelan agar metode ekonometrika yang digunakan dapat memberikan estimasi yang valid dan reliabel (Ramadhan, 2015).

1.4.7 Model ARMA (Autoregressive Moving Average)

Model *Autoregressive Moving Average* (ARMA) digunakan untuk menangkap struktur rata-rata (*mean equation*) dalam data deret waktu yang telah stasioner.



Model ARMA terdiri dari dua komponen utama: *autoregressive* (AR) yang menunjukkan ketergantungan nilai sekarang terhadap nilai masa lalu, dan *moving average* (MA) yang mengakomodasi pengaruh dari shock atau residual pada periode sebelumnya. Dalam studi oleh Eroğlu dan Yüce Akıncı (2021), ARMA digunakan sebagai fondasi dalam membentuk komponen rata-rata sebelum masuk ke dalam model seperti EGARCH, karena mampu mengurangi autokorelasi dalam

residual dan menghasilkan model yang lebih stabil secara statistik. Selain itu, pemilihan orde AR dan MA yang tepat biasanya dilakukan dengan mengamati pola pada grafik ACF dan PACF, serta mempertimbangkan kriteria informasi seperti AIC dan BIC untuk menghindari *overfitting*.

Secara umum, bentuk ARMA(p, q) dituliskan sebagai:

$$r_t = \mu + \sum_{i=1}^p \phi_i r_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (5)$$

dengan:

- r_t : *log-return*,
- μ : rata-rata jangka panjang,
- ϕ_i, θ_j : koefisien AR dan MA,
- ε_t : residual acak.

Pemilihan orde optimal dari model ARMA biasanya dilakukan dengan menganalisis pola pada grafik ACF dan PACF untuk menentukan lag yang signifikan dalam komponen AR dan MA. Pendekatan ini dibantu oleh perangkat lunak statistik seperti *R*, yang memungkinkan dilakukannya eksplorasi sistematis melalui teknik *grid search* untuk mencari kombinasi ordo (p, q) terbaik. Dalam proses *grid search* ini, berbagai pasangan nilai p dan q dievaluasi berdasarkan kriteria informasi seperti AIC dan BIC dengan tujuan untuk memilih model yang paling efisien tanpa mengalami *overfitting* (Aminuddin *et al.*, 2022). Setelah model ARMA diestimasi, uji Ljung–Box dilakukan terhadap residual untuk memastikan tidak adanya autokorelasi yang tersisa. Langkah ini penting agar residual benar-benar menyerupai *white noise* sebelum masuk ke tahap pemodelan volatilitas seperti GARCH atau EGARCH.

1.4.8 Uji Autokorelasi

Uji autokorelasi dilakukan untuk mengevaluasi apakah residual dari suatu model deret waktu masih menyimpan pola hubungan dengan nilai-nilai masa lalu. Jika residual menunjukkan autokorelasi yang signifikan, hal ini mengindikasikan bahwa struktur model belum sepenuhnya menangkap dinamika data yang ada, dan dengan demikian, model perlu disempurnakan lebih lanjut. Dalam konteks evaluasi model ARMA–GARCH atau ARMA–EGARCH, pengujian ini menjadi langkah penting untuk memastikan bahwa residual telah menyerupai *white noise* sebelum digunakan dalam pemodelan volatilitas lanjutan (Aminuddin *et al.*, 2022).

Salah satu metode yang paling banyak digunakan untuk mendeteksi autokorelasi adalah Ljung–Box Test, yang memeriksa signifikansi autokorelasi hingga lag statistik Ljung–Box dirumuskan sebagai berikut:

$$Q = n(n+2) \sum_{k=1}^h \frac{\hat{\rho}_k^2}{n-k} \quad (6)$$



dengan:

Q : statistik Ljung–Box,

n : jumlah observasi,

h : jumlah lag yang diuji,

$\hat{\rho}_k$: koefisien autokorelasi pada lag ke- k .

Hipotesis yang diuji:

- H_0 : Tidak terdapat autokorelasi hingga lag ke- h (residual bersifat *white noise*),
- H_1 : Terdapat autokorelasi hingga lag ke- h .

Jika nilai Q melebihi nilai kritis dari distribusi χ^2 atau memiliki *p-value* lebih kecil dari tingkat signifikansi (misalnya 5%), maka H_0 ditolak dan disimpulkan bahwa residual masih mengandung autokorelasi.

Dalam konteks pemodelan ARMA, pengujian autokorelasi merupakan tahap penting setelah proses estimasi. Nilai orde AR (p) dan MA (q) biasanya ditentukan dengan menganalisis pola dari plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF), yang dihasilkan melalui perangkat lunak statistik seperti R atau Python. Kedua grafik ini membantu mengidentifikasi jumlah lag signifikan yang relevan untuk dimasukkan ke dalam model. Setelah model ARMA diestimasi, uji Ljung–Box diterapkan pada residual untuk memastikan bahwa tidak ada struktur ketergantungan serial yang tersisa. Seperti dijelaskan oleh Aminuddin *et al.* (2022), hanya jika residual telah bebas dari autokorelasi, maka model mean dapat dianggap memadai dan analisis dapat dilanjutkan ke tahap pemodelan volatilitas dengan GARCH atau EGARCH.

1.4.9 Uji Heterokedastistas

Dalam deret waktu keuangan, variansi return sering kali tidak konstan dan menunjukkan pola yang berubah seiring waktu. Fenomena ini dikenal sebagai *heteroskedastisitas*, dan salah satu bentuknya yang paling umum adalah *volatility clustering*, yaitu kondisi ketika periode volatilitas tinggi cenderung diikuti oleh periode serupa. Untuk menguji keberadaan pola ini, digunakan ARCH–LM (*Lagrange Multiplier*) test yang diperkenalkan oleh Engle (1982). Uji ini bertujuan untuk mendeteksi apakah variansi residual bergantung pada nilai-nilai residual sebelumnya. Jika efek ARCH terdeteksi, maka pemodelan lanjutan menggunakan ARCH atau EGARCH menjadi relevan untuk menangkap dinamika volatilitas akurat (Yahaya *et al.*, 2022).

Setelah terdeteksi, langkah selanjutnya adalah dengan meregresikan kuadrat residual terhadap lag-lag kuadrat. Bentuk regresinya adalah:



$$\varepsilon_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \cdots + \alpha_p \varepsilon_{t-p}^2 + u_t \quad (7)$$

Dari hasil regresi tersebut, dihitung nilai statistik:

$$LM = n \cdot R^2 \quad (8)$$

di mana:

LM : statistik uji ARCH–LM,

n : jumlah observasi,

R^2 : koefisien determinasi dari regresi kuadrat residual.

Hipotesis yang diuji adalah sebagai berikut:

- H_0 : Tidak terdapat heteroskedastisitas.
- H_1 : Terdapat heteroskedastisitas.

Jika nilai LM lebih besar dari nilai kritis distribusi χ^2 , atau nilai *p-value* lebih kecil dari tingkat signifikansi (misalnya 5%), maka H_0 ditolak, dan dapat disimpulkan bahwa residual mengandung efek ARCH. Dalam konteks ini, penerapan model GARCH atau EGARCH menjadi sangat relevan, karena model tersebut dirancang untuk memodelkan dinamika variansi yang tidak konstan.

1.4.10 Uji Normalitas

Dalam pemodelan deret waktu keuangan, asumsi distribusi normal sering kali dijadikan titik awal dalam menganalisis residual. Namun, berbagai studi menunjukkan bahwa data return keuangan umumnya menyimpang dari distribusi normal, ditandai oleh keberadaan *fat tails* dan pola asimetris. Yahaya *et al.* (2022) menekankan bahwa penyimpangan ini umum terjadi pada return *cryptocurrency*, sehingga mengharuskan penggunaan distribusi alternatif seperti Student-*t* atau *Skewed Student-t* dalam model GARCH. Untuk menguji normalitas residual secara statistik, digunakan Jarque–Bera (JB) test, yang mengevaluasi apakah nilai skewness dan kurtosis residual berbeda secara signifikan dari nilai ideal dalam distribusi normal (Tsay, 2010).

Rumus statistik JB adalah:

$$JB = \frac{n}{6} \left(S^2 + \frac{(K - 3)^2}{4} \right) \quad (9)$$



Jarque–Bera,

vari,

ukuran kemencengan distribusi,

ukuran keruncingan distribusi.

Hipotesis yang diuji:

- H_0 : Residual berdistribusi normal,
- H_1 : Residual tidak berdistribusi normal.

Jika nilai statistik JB tinggi atau menghasilkan p -value yang signifikan, maka hipotesis nol tentang normalitas residual ditolak. Kondisi ini menunjukkan bahwa residual tidak mengikuti distribusi normal dan mengindikasikan perlunya pendekatan alternatif. Dalam konteks ini, model dengan asumsi distribusi inovasi non-normal seperti Student- t atau Skewed Student- t menjadi pilihan yang lebih tepat karena mampu menangkap karakteristik *fat tails* dan asimetri yang umum ditemukan dalam return aset keuangan berisiko tinggi (Tsay, 2010; Yahaya *et al.*, 2022).

1.4.11 Model GARCH

Model GARCH menjadi salah satu pilihan paling populer dalam literatur karena bentuknya yang sederhana namun cukup efektif dalam menangkap pola *volatility clustering* yang sering muncul dalam data keuangan. Meski begitu, model ini memiliki keterbatasan penting: ia mengasumsikan bahwa kejutan pasar, baik positif maupun negatif, memberikan dampak yang simetris terhadap volatilitas. Padahal dalam kenyataannya, pasar sering kali bereaksi lebih kuat terhadap berita buruk dibandingkan berita baik, yang dikenal sebagai *leverage effect*. Sejumlah studi, seperti yang dilakukan oleh Eroğlu dan Yüce Akıncı (2021) serta Katsiampa (2017), menunjukkan bahwa model GARCH standar belum mampu merepresentasikan dinamika asimetris ini secara akurat. Karena itu, pendekatan alternatif seperti EGARCH menjadi lebih relevan, terutama ketika kita berhadapan dengan data keuangan yang cenderung tidak simetris dalam merespons informasi pasar.

Dalam model GARCH(p,q) variansi bersyarat (σ_t^2) pada waktu t bergantung pada residual masa lalu (ϵ_{t-1}^2) dan variansi bersyarat sebelumnya (σ_{t-1}^2):

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \epsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (10)$$

dengan ketentuan:

$\omega > 0$: konstanta,

$\alpha \geq 0$: koefisien efek ARCH,

$\beta \geq 0$: koefisien efek GARCH,

ϵ_t : residual dari model mean,

σ_t^2 : variansi bersyarat pada waktu ke- t .



asumsikan bahwa kejutan pasar memiliki dampak simetris. Artinya, return positif dan negatif diasumsikan memberikan dampak yang sama terhadap variansi bersyarat. Meskipun asumsi ini tidak akurat dalam perhitungan, dalam praktiknya pasar sering menunjukkan

dinamika yang lebih kompleks. Dalam proses estimasi model GARCH, parameter α dan β memberikan wawasan penting terhadap dinamika volatilitas:

- Parameter α menggambarkan sensitivitas volatilitas terhadap *shock* yang baru terjadi. Nilai α yang besar menunjukkan bahwa variansi bersyarat sangat responsif terhadap peristiwa kejutan di pasar.
- Parameter β menunjukkan persistensi volatilitas dari waktu ke waktu. Nilai β yang tinggi menunjukkan bahwa efek *shock* akan bertahan dalam waktu yang lama (*long memory*).

Interpretasi terhadap parameter α dalam model GARCH dapat dijelaskan sebagai berikut:

- Jika nilai $\alpha < 0$, maka volatilitas bersifat kurang responsif terhadap kejutan pasar, yang mengindikasikan *low impact* atau sensitivitas rendah.
- Jika nilai α berada dalam rentang $0,1 \leq \alpha \leq 0,3$, maka efek *shock* bersifat sedang (*moderate impact*), di mana volatilitas mulai menunjukkan respons terhadap perubahan signifikan dalam return.
- Apabila $\alpha \geq 0,3$, maka model menunjukkan adanya sensitivitas tinggi terhadap *shock*, yang mengindikasikan bahwa variansi sangat reaktif terhadap perubahan informasi pasar, baik positif maupun negatif (*shock-sensitive*).

Sedangkan Interpretasi terhadap parameter β dapat dijelaskan sebagai berikut:

- Jika $\beta < 0,5$, maka persistensi volatilitas tergolong rendah. Efek dari *shock* pasar cenderung cepat mereda dan variansi kembali ke kondisi stabil dalam waktu singkat.
- Jika nilai β berada dalam rentang $0,5 \leq \beta < 0,7$, maka persistensi volatilitas dikategorikan sedang, yang menunjukkan bahwa dampak *shock* bertahan dalam jangka menengah.
- Untuk nilai β antara $0,7 \leq \beta < 0,9$, maka volatilitas bersifat sangat persisten. Artinya, kejutan yang terjadi akan memiliki dampak jangka panjang terhadap variansi.
- Apabila $\beta \geq 0,9$, maka efek *shock* cenderung menetap dalam waktu yang sangat lama. Kondisi ini sering disebut sebagai persistensi ekstrem yang mendekati sifat *non-stationary*, dan umum dijumpai pada aset berisiko tinggi seperti *cryptocurrency*.

Jika nilai $\alpha + \beta$ mendekati 1, maka model menunjukkan bahwa volatilitas memiliki memori panjang dan akan cenderung lama untuk kembali ke tingkat normalnya. Studi



(2022) dan Aminuddin et al. (2022) menunjukkan bahwa aset seperti *cryptocurrency* cenderung memiliki nilai α dan β yang tinggi, yang menunjukkan sensitivitas terhadap informasi pasar dan kuatnya pengaruhnya. Dalam konteks estimasi, model GARCH(1,1) sering kali digunakan sebagai model awal atau *baseline model* karena bentuknya yang sederhana yang mampu menangkap dinamika dasar dari volatilitas. Jika hasil dari

model ini sudah menunjukkan kecocokan yang baik terhadap data yang ditinjau dari log-likelihood, AIC/BIC, serta validasi residual, maka tidak selalu diperlukan eksplorasi ke ordo yang lebih tinggi. Pendekatan ini juga membantu menjaga efisiensi model tanpa kehilangan akurasi estimasi yang esensial.

GARCH banyak digunakan karena kesederhanaannya dan kemampuannya menangkap pola *volatility clustering*. Namun, model ini mengasumsikan respons simetris terhadap shock, sehingga return positif dan negatif dianggap berdampak sama terhadap variansi. Asumsi ini sering kali tidak sesuai dengan data keuangan yang menunjukkan *leverage effect*, di mana kejutan negatif cenderung meningkatkan volatilitas lebih besar daripada kejutan positif (Eroğlu & Yüce Akıncı, 2021; Katsiampa, 2017). Karena itu, model seperti EGARCH dikembangkan untuk mengakomodasi asimetri tersebut secara lebih akurat. Oleh karena itu, model GARCH sering dijadikan baseline dalam pemodelan volatilitas, sebelum dikembangkan ke bentuk yang lebih kompleks seperti EGARCH, yang mampu menangani asimetri dan efek leverage dalam return aset (Aminuddin *et al.*, 2022).

1.4.12 Model EGARCH

Model *Exponential Generalized Autoregressive Conditional Heteroskedasticity* (EGARCH) yang dikembangkan oleh Nelson (1991) merupakan perluasan dari model GARCH yang dirancang untuk menangkap karakteristik khas dari data keuangan, seperti *asymmetric volatility* dan *leverage effect*. Tidak seperti model GARCH konvensional yang mengharuskan pembatasan eksplisit pada parameter agar variansi tetap positif, model EGARCH memodelkan variansi bersyarat dalam bentuk logaritmik, sehingga secara inheren menjamin nilai variansi selalu positif. Selain itu, model ini memungkinkan respons volatilitas terhadap *shock* bersifat asimetris, di mana guncangan negatif memiliki pengaruh yang lebih besar terhadap volatilitas dibandingkan guncangan positif yang besarnya sama (Eroğlu Sevinç & Yüce Akıncı, 2021; Yahaya *et al.*, 2022). Keunggulan inilah yang menjadikan EGARCH sebagai model yang relevan untuk menganalisis volatilitas pada aset-aset berisiko tinggi seperti kripto dan saham teknologi.

Spesifikasi model EGARCH(p,q) adalah sebagai berikut:

$$\ln(\sigma_t^2) = \omega + \sum_{i=1}^q \beta_i \ln(\sigma_{t-i}^2) + \sum_{i=1}^q \alpha_i \left| \frac{\varepsilon_{t-i}}{\sigma_{t-i}} \right| + \sum_{i=1}^q \gamma_i \left(\frac{\varepsilon_{t-i}}{\sigma_{t-i}} \right) \quad (11)$$

dengan:

ω : konstanta,



β_i : parameter GARCH (persistensi volatilitas),

α_i : parameter shock (magnitude effect),

γ_i : parameter leverage effect),

ω : model mean,

σ_t^2 : variansi bersyarat pada waktu ke- t

Parameter γ memiliki peran penting dalam mengidentifikasi karakter asimetris dari volatilitas pasar:

- Jika $\gamma < 0$ maka terdapat *leverage effect*, di mana *shock* negatif meningkatkan volatilitas lebih besar dibandingkan *shock* positif yang sama besar.
- Jika $\gamma = 0$, maka tidak ada efek asimetri—respon pasar terhadap *shock* bersifat simetris.
- Jika $\gamma > 0$, terjadi *reverse asymmetry*, di mana *shock* positif justru memicu lonjakan volatilitas yang lebih tinggi daripada *shock* negatif. Meskipun jarang terjadi, kondisi ini mungkin muncul dalam pasar spekulatif yang reaktif terhadap berita baik.

Agar interpretasi atas parameter-parameter dalam model EGARCH valid secara statistik, setiap estimasi nilai α , β , dan γ dievaluasi menggunakan uji-*t*. Pengujian ini bertujuan untuk memastikan bahwa parameter yang dihasilkan signifikan secara statistik, yaitu memiliki nilai *t*-statistic yang cukup besar dan *p-value* yang lebih kecil dari tingkat signifikansi yang umum digunakan (misalnya 5%). Hanya parameter yang memenuhi kriteria ini yang dapat diandalkan dalam menjelaskan dinamika volatilitas, seperti sensitivitas terhadap *shock*, tingkat persistensi, dan keberadaan efek asimetri. Dengan demikian, validasi ini menjadi landasan penting bahwa implikasi ekonometrik dari model tidak hanya muncul karena kebetulan statistik, tetapi benar-benar tercermin dari pola data historis yang diamati (Yahaya *et al.*, 2022).

Dalam penelitian ini, proses estimasi volatilitas dimulai dengan menetapkan model *baseline* EGARCH(1,1), yang secara luas digunakan dalam literatur sebagai bentuk paling sederhana namun efektif untuk menangkap dinamika volatilitas yang kompleks. Jika model ini menunjukkan performa yang memadai yang ditinjau dari kecocokan data dan validitas parameter, maka tidak selalu diperlukan eksplorasi ke ordo yang lebih tinggi, sehingga efisiensi model tetap terjaga. Model EGARCH sangat relevan digunakan dalam analisis aset berisiko tinggi seperti *cryptocurrency* dan saham teknologi, yang sering menunjukkan sensitivitas tinggi terhadap sentimen pasar negatif (Katsiampa, 2017; Huynh, 2019). Selain itu, EGARCH lebih fleksibel dalam menangani data dengan distribusi non-normal, menjadikannya pilihan tepat untuk penelitian ini.

1.4.13 Distribusi Inovasi: Skewed Student-*t*

Dalam pemodelan tipe GARCH, distribusi normal sering digunakan untuk merepresentasikan inovasi (*error term*). Namun, return keuangan riil umumnya bersifat tidak simetris dan menunjukkan karakteristik *fat tails*. Oleh karena itu,



alternatif yang lebih fleksibel, salah satunya adalah *Skewed Student-*t** (Giannakis, 2004).

Ini merupakan perluasan dari distribusi Student-*t* dengan parameter asimetri, sehingga memiliki dua keunggulan utama:

1. Parameter ν yang mampu menangkap ekor distribusi yang tebal (*fat*

2. Parameter skewness (λ) yang memungkinkan model menyesuaikan diri terhadap distribusi residual yang tidak simetris.

Dalam konteks model EGARCH, penggunaan SSTD meningkatkan akurasi estimasi volatilitas karena mampu merefleksikan sifat ekstrem dan ketidaksimetrian yang umum ditemukan pada data return keuangan. Oleh karena itu, distribusi ini banyak digunakan dalam studi empiris untuk meningkatkan kualitas pemodelan volatilitas pada aset berisiko tinggi (Degiannakis, 2004).

1.4.14 Kriteria Pemilihan AIC dan BIC

Akaike Information Criterion (AIC) dan *Bayesian Information Criterion* (BIC) merupakan dua ukuran yang umum digunakan dalam pemilihan model statistik, khususnya untuk menilai keseimbangan antara tingkat kecocokan model dan kompleksitas parameter. Dalam studi empiris, kedua kriteria ini digunakan untuk membandingkan performa berbagai spesifikasi model GARCH dan Copula, di mana model dengan nilai AIC atau BIC terendah dipilih sebagai model terbaik (Aminuddin *et al.*, 2022)

Secara matematis:

Akaike Information Criterion (AIC)

$$AIC = -2\ln(L) + 2k \quad (12)$$

Bayesian Information Criterion (BIC)

$$BIC = -2\ln(L) + k\ln(n) \quad (13)$$

Keterangan:

- L : nilai *log-likelihood*, yaitu ukuran seberapa besar kemungkinan model menjelaskan data yang diamati,
- k : jumlah total parameter dalam model (termasuk mean equation, variance equation, dan distribusi inovasi),
- n : jumlah observasi dalam sampel,
- $\ln$: fungsi logaritma natural.

AIC lebih fleksibel terhadap jumlah parameter (*under-penalized*), sedangkan BIC memberikan penalti lebih berat pada model kompleks (*over-penalized*) (Degiannakis, 2004). Menurut Aminuddin *et al.* (2022), AIC dan BIC tidak hanya digunakan untuk memilih model GARCH, tetapi juga dalam pemilihan model ARMA, jenis distribusi inovasi (*Student-t*, *Skewed-t*), serta struktur copula. Kriteria ini membantu model yang dipilih efisien secara statistik dan tidak berlebihan



GARCH

Conditional Correlation GARCH (DCC-GARCH) diperkenalkan oleh [nama] sebagai perluasan dari model GARCH multivariat yang mampu

menangkap dinamika korelasi antar aset keuangan secara fleksibel. Tidak seperti model korelasi statis, DCC-GARCH memungkinkan korelasi antar aset berubah dari waktu ke waktu mengikuti dinamika pasar, yang sangat relevan dalam konteks analisis portofolio dan manajemen risiko.

Model DCC-GARCH terdiri dari dua tahap utama:

1. Estimasi model volatilitas univariat untuk setiap aset (biasanya menggunakan GARCH atau EGARCH),
2. Estimasi matriks korelasi bersyarat yang bersifat dinamis.

Secara matematis, model DCC-GARCH(1,1) dirumuskan sebagai:

$$H_t = D_t R_t D_t \quad (14)$$

dengan:

H_t : matriks kovariansi bersyarat,

D_t : matriks diagonal dari standar deviasi bersyarat ($\sqrt{h_{ii,t}}$),

R_t : matriks korelasi bersyarat dinamis.

Matriks R_t dikonstruksi dari:

$$Q_t = (1 - \alpha - \beta)Q + \alpha\epsilon_{t-1}\epsilon_{t-1}^T + \beta Q_{t-1} \quad (15)$$

$$R_t = \text{diag}(Q_t)^{-1/2} Q_t \text{diag}(Q_t)^{-1/2} \quad (16)$$

dengan:

Q_t : matriks kovariansi sementara,

Q : kovariansi rata-rata dari residual standar,

α, β : parameter dinamis korelasi,

ϵ_t : residual standar dari model marginal.

Model DCC-GARCH populer dalam studi empiris karena sifatnya yang parsimonious, yaitu mampu menangkap dinamika dependensi tanpa memerlukan estimasi parameter dalam jumlah besar. Menurut Aminuddin *et al.* (2022), model ini sangat efektif digunakan dalam mengukur keterkaitan risiko antar aset dalam periode krisis dan stabil.

1.4.16 Model Copula



ngsi statistik yang menghubungkan distribusi marginal dari dua ak ke dalam satu distribusi gabungan multivariat. Pendekatan emisahan antara struktur dependensi dan perilaku marginal, n fleksibilitas yang tinggi dalam pemodelan hubungan antar angka copula, fungsi distribusi gabungan dapat dinyatakan dari fungsi distribusi marginal dan suatu fungsi copula yang

mengikat keduanya (Aminuddin *et al.*, 2022). Hal ini menjadikan copula sebagai alat yang efisien dalam menganalisis struktur ketergantungan, terutama pada data keuangan yang memiliki distribusi tidak normal dan menunjukkan perilaku ekstrem

Secara matematis, fungsi distribusi kumulatif gabungan $H(x, y)$ dari dua variabel acak X dan Y dengan fungsi distribusi marginal masing-masing $F(x)$ dan $G(y)$, dapat dituliskan sebagai:

$$H(x, y) = C(F(x), G(y)) \quad (17)$$

di mana C adalah fungsi copula yang menangkap struktur ketergantungan antara X dan Y , terlepas dari bentuk distribusi marginalnya.

Pendekatan copula menawarkan keunggulan dalam memodelkan dependensi non-linear dan ekstrem, termasuk dalam menangkap *tail dependence*—yakni keterkaitan antara pergerakan ekstrem dua variabel acak yang umumnya tidak dapat ditangkap oleh korelasi Pearson biasa. Hal ini sangat penting dalam analisis risiko keuangan yang melibatkan distribusi non-normal dan fenomena ekstrem (Embrechts *et al.*, 2002, dalam Aminuddin *et al.*, 2022) Beberapa bentuk copula yang umum digunakan dalam literatur keuangan antara lain:

1. Gaussian Copula: Menangkap ketergantungan linier, tetapi tidak dapat merepresentasikan *tail dependence*.
2. Clayton Copula: Cocok untuk menangkap ketergantungan ekstrem sisi kiri (*lower tail dependence*).
3. Gumbel Copula: Menangkap *upper tail dependence* (ketergantungan ekstrem sisi kanan).
4. Student- t Copula: Simetris, dan mampu menangkap *tail dependence* di kedua sisi distribusi.

Pemodelan copula dilakukan dalam dua tahap melalui pendekatan *Inference Functions for Margins (IFM)* (Joe, 1997):

1. Estimasi model marginal menggunakan ARMA–GARCH atau EGARCH,
2. Transformasi residual menjadi distribusi uniform dengan *Probability Integral Transform* (PIT), kemudian dilanjutkan dengan estimasi parameter copula.

Menurut Aminuddin *et al.* (2022), pendekatan ini efektif untuk mengukur ketergantungan antara dua pasar yang memiliki karakteristik distribusi berbeda. Dalam konteks aset kripto dan saham teknologi yang cenderung menunjukkan fluktuasi ekstrem, penggunaan Student- t Copula sering menjadi pilihan utama karena kemampuannya dalam menangkap ketergantungan pada kondisi pasar yang volatil



Student- t Copula

Salah satu jenis fungsi copula yang digunakan untuk struktur ketergantungan antara dua variabel acak, khususnya digunakan di mana hubungan tersebut bersifat non-linear dan

ekstrem. Keunggulan utama dari Student- t Copula adalah kemampuannya dalam menangkap *tail dependence*, yaitu kecenderungan dua aset mengalami pergerakan ekstrem secara bersamaan, baik di sisi atas (*upper tail*) maupun bawah (*lower tail*). Pendekatan ini sangat relevan dalam pengukuran risiko sistemik dan *contagion* antar aset kripto atau saham, sebagaimana ditunjukkan oleh hasil estimasi pada data kripto yang menunjukkan struktur dependensi ekstrem yang lebih baik ditangkap oleh Student- t Copula dibanding Gaussian Copula (Huynh, 2019).. Secara matematis, struktur Student- t Copula untuk dua variabel didefinisikan sebagai berikut:

$$C_{v,\rho}(u, v) = t_{v,\rho}(t_v^{-1}(u), t_v^{-1}(v)) \quad (18)$$

Penjelasan simbol:

$C_{v,\rho}$: fungsi copula Student- t dengan parameter korelasi ρ dan derajat kebebasan v ,

$t_v^{-1}(\cdot)$: fungsi kuantil dari distribusi Student- t univariat,

$t_{v,\rho}$: distribusi kumulatif gabungan Student- t dua variabel,

u, v : nilai dari distribusi marginal yang telah ditransformasi ke skala uniform $[0,1]$.

Dua parameter utama yang membentuk struktur copula ini adalah:

1. ρ , yang menunjukkan kekuatan korelasi linier antara dua variabel,
2. v , yang menunjukkan derajat kebebasan dan menentukan seberapa tebal ekor distribusi—semakin kecil v , semakin besar kemungkinan munculnya pergerakan ekstrem.

Salah satu keunggulan utama dari Student- t Copula adalah kemampuannya menangkap *tail dependence* secara simetris, baik di sisi atas (*upper tail*) maupun sisi bawah (*lower tail*). Karakteristik ini dihitung melalui koefisien λ , dengan rumus sebagai berikut:

$$\lambda_L = \lambda_U = 2 \cdot t_{v+1} \left(- \sqrt{\frac{(v+1)(1-\rho)}{1+\rho}} \right) \quad (19)$$

Keterangan:

λ_L dan λ_U : koefisien ketergantungan ekstrem di sisi kiri dan kanan,



fungsi distribusi kumulatif dari distribusi Student- t dengan $v+1$ derajat kebebasan.

Dalam konteks model copula merepresentasikan tingkat *tail* seberapa besar kemungkinan dua variabel mengalami pergerakan ekstrem secara bersamaan. Semakin tinggi nilainya, semakin kuat ketergantungan yang tercermin antara kedua aset. Dalam penelitian ini,

student- t copula digunakan karena Bitcoin dan saham MSTR memiliki karakteristik distribusi yang *heavy-tailed* dan menunjukkan potensi pergerakan ekstrem, terutama ketika pasar berada dalam kondisi tidak stabil. Hal ini konsisten dengan temuan Huynh (2019), yang menyatakan bahwa student- t copula memberikan estimasi ketergantungan yang lebih baik dibandingkan copula lainnya, seperti Gaussian, karena mampu menangkap struktur tail secara simetris di kedua sisi distribusi.

Model ini juga dinilai unggul dalam mengidentifikasi risiko bersama (*joint risk*), karena tidak mengasumsikan bentuk distribusi marginal yang spesifik. Sebagaimana dijelaskan dalam studi oleh Aminuddin *et al.* (2022), penggunaan pendekatan copula memungkinkan analisis struktur ketergantungan dilakukan secara fleksibel dan robust terhadap dinamika pasar ekstrem.





Optimized using
trial version
www.balesio.com

BAB II METODOLOGI PENELITIAN

2.1 Hasil Pendekatan dan Jenis Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksploratif dan eksplanatori untuk menganalisis karakteristik volatilitas dan ketergantungan dinamis antara Bitcoin dan saham MicroStrategy (MSTR). Penelitian ini bertujuan untuk membangun model volatilitas serta mengukur ketergantungan ekstrem antara dua aset dengan pendekatan GARCH, EGARCH, DCC-GARCH, dan copula. Data yang digunakan merupakan data sekunder berupa harga penutupan harian (*daily closing price*) Bitcoin (BTC) dan saham MicroStrategy Inc. (MSTR) dari situs *Investing.com*, dengan periode pengamatan 1 Januari 2019 hingga 31 Desember 2024. Data ini kemudian diolah menjadi return logaritmik harian menggunakan persamaan (1). Langkah-langkah penelitian dilakukan secara bertahap sebagai berikut:

1. Pengumpulan dan Transformasi Data
Mengumpulkan data harga penutupan harian Bitcoin (BTC/USD) dan saham MicroStrategy (MSTR) dari *Investing.com* untuk periode 1 Januari 2019 hingga 31 Desember 2024, lalu menghitung log-return untuk masing-masing aset.
2. Analisis Awal dan Statistik Deskriptif
 - a) Visualisasi harga dan log-return BTC dan MSTR
 - b) Menghitung statistik deskriptif: rata-rata, standar deviasi, skewness, dan kurtosis
3. Estimasi Model ARMA
 - a) Eksplorasi ordo ARMA(p,q) berdasarkan pola ACF dan PACF
 - b) Evaluasi model menggunakan AIC, BIC, dan uji residual
 - c) Model ini digunakan sebagai mean equation untuk tahap berikutnya
4. Uji Statistik Dasar
 - a) Uji stasioneritas dengan Augmented Dickey-Fuller (ADF)
 - b) Uji autokorelasi dengan Ljung-Box
 - c) Uji heteroskedastisitas dengan ARCH-LM
 - d) Uji normalitas dengan Jarque-Bera
3. Estimasi Model Volatilitas GARCH dan EGARCH
 - a) Mengestimasi GARCH(1,1) dan EGARCH(1,1)
 - b) Menggunakan distribusi skewed Student-*t* untuk menangani sifat fat tails
4. Validasi Residual Model
 - a) Uji autokorelasi dan ARCH effect pada residual model volatilitas




residual bersih sebagai syarat analisis copula
 idual ke Distribusi Uniform
 bility Integral Transform (PIT) pada residual terstandarisasi
 ik copula
 Dinamis dengan DCC-GARCH
 korelasi time-varying antara BTC dan MSTR

- b) Visualisasi grafik korelasi dinamis sepanjang waktu
- 7. Estimasi Struktur Ketergantungan dengan Copula
 - a) Mengestimasi beberapa jenis copula: Gaussian, Clayton, Gumbel, dan Student- t
 - b) Memilih Student- t copula karena kemampuannya menangkap *tail dependence*
- 8. Visualisasi Permukaan Copula
Visualisasi 3D dari fungsi densitas Student- t copula untuk interpretasi hubungan ekstrem BTC–MSTR



2.2 Alur kerja



Gambar 1 Alur Kerja





Optimized using
trial version
www.balesio.com

BAB III HASIL DAN PEMBAHASAN

3.1. Hasil

3.1.1. Statistik Deskriptif

Data yang digunakan dalam penelitian ini merupakan harga penutupan harian dari dua aset, yaitu *cryptocurrency* Bitcoin (BTC/USD) dan saham perusahaan MicroStrategy (MSTR), yang telah ditransformasi ke dalam bentuk *log-return* menggunakan Persamaan (1) sebagaimana dijelaskan pada Subbab 1.4.3. Transformasi ini bertujuan untuk menghilangkan efek skala harga, meningkatkan stasioneritas, serta menjadikan data lebih sesuai untuk analisis volatilitas berbasis deret waktu.

Sebagai ilustrasi, apabila harga penutupan Bitcoin pada tanggal 2 Januari 2019 adalah sebesar USD 3.467,90 dan meningkat menjadi USD 3.821,90 pada tanggal 3 Januari 2019, maka *log-return* pada tanggal 3 Januari 2019 dihitung sebagai berikut:

$$\begin{aligned} r_t &= \ln \left(\frac{3.821,90}{3.467,90} \right) \\ &= \ln(1,102049) \\ &= 0,097190 \end{aligned}$$

Nilai tersebut menyatakan bahwa dalam satu hari perdagangan, yaitu dari tanggal 2 ke 3 Januari 2019, harga Bitcoin mengalami peningkatan sekitar 9,72% dalam bentuk *log-return*. Angka ini mencerminkan tingkat fluktuasi yang relatif tinggi, dan menjadi contoh nyata dari volatilitas harian yang kerap ditemukan dalam pasar *cryptocurrency*. Transformasi *log-return* BTC dan MSTR yang dapat dilihat pada lampiran 1. Hasil perhitungan statistik deskriptif dari *log-return* BTC dan MSTR selama periode 1 Januari 2019 hingga 31 Desember 2024 disajikan pada Tabel 1.



Tabel 1 Statistik Deskriptif Log Return BTC dan MSTR (2019–2024)

Statistik	BTC	MSTR
Count	1510	1510
Mean	0,002138	0,002067
Median	0,001222	0,000673
Min	−1,247029	−2,077044
Max	0,939129	1,149.612
Std Dev	0,204060	0,255846
Skewness	−0,5898	−0,9411
Kurtosis	8,9943	13,225

Sumber : Data Diolah, 2025.

Berdasarkan nilai *mean*, baik BTC maupun MSTR mencatatkan rata-rata return harian yang positif. Namun, nilai *standard deviation* menunjukkan bahwa fluktuasi return harian MSTR relatif lebih tinggi dibandingkan BTC, yang mencerminkan tingkat volatilitas yang lebih besar. Distribusi return kedua aset juga tidak simetris, ditunjukkan oleh nilai skewness negatif, yang mengindikasikan bahwa kejadian ekstrem penurunan harga (*negative outliers*) lebih sering terjadi dibandingkan kenaikan. Selain itu, nilai kurtosis yang jauh di atas angka 3 menunjukkan bahwa distribusi memiliki *fat tails*, yaitu kecenderungan untuk mengalami pergerakan harga ekstrem yang lebih sering dari yang diprediksi oleh distribusi normal.

Karakteristik ini memperkuat bukti bahwa BTC dan MSTR menunjukkan pola distribusi return yang bersifat leptokurtik dan left-skewed, selaras dengan sifat umum dalam literatur keuangan. Temuan ini akan menjadi dasar penting dalam pemilihan distribusi non-normal pada tahap pemodelan volatilitas lanjutan dengan pendekatan GARCH dan EGARCH.

3.1.2. Uji Stasioner

Pengujian stasioneritas dilakukan menggunakan metode Augmented Dickey–Fuller (ADF) terhadap data log-return Bitcoin (BTC) dan saham MicroStrategy (MSTR). Hasil pengujian disajikan dalam Tabel 2.



Tabel 2 Hasil Uji Stasioneritas ADF untuk BTC dan MSTR


Aset	Statistik ADF	Nilai Kritis 5%	<i>p-value</i>	Keputusan
BTC	-19,1446	-2,8600	< 0,01	Stasioner
MSTR	-18,3094	-2,8600	< 0,01	Stasioner

Sumber : Data Diolah, 2025.

Berdasarkan hasil pada Tabel 2, statistik ADF untuk BTC dan MSTR lebih kecil dari nilai kritis pada tingkat signifikansi 5%, serta memiliki *p-value* di bawah 0,01. Dengan demikian, H_0 ditolak, yang berarti kedua deret log-return bersifat stasioner dan memenuhi prasyarat untuk pemodelan volatilitas selanjutnya.

3.1.3. Permodelan ARMA

Sebagai langkah awal dalam perancangan model volatilitas, dilakukan identifikasi struktur model mean untuk data *log-return* harian dari Bitcoin (BTC) dan MicroStrategy (MSTR). Analisis ini diawali dengan mengamati pola *autocorrelation* dan *partial autocorrelation* melalui grafik *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) hingga lag ke-20. Visualisasi dapat dilihat pada Gambar 2.

**Gambar 2** Plot ACF PACF Log Return BTC dan MSTR

Berdasarkan pola pada Gambar 2, terlihat bahwa baik BTC maupun MSTR menunjukkan adanya autokorelasi yang signifikan pada lag-lag awal, baik pada grafik *autocorrelation function* (ACF) maupun *partial autocorrelation function* (PACF). Temuan ini menjadi dasar untuk menyusun kandidat model ARMA(p,q). Meskipun



ilakukan hingga lag ke-20, pemilihan orde AR dan MA dibatasi j 6 untuk menjaga efisiensi model dan menghindari risiko mengingat model yang terlalu kompleks sering kali tidak t signifikan dalam konteks prediktif.

model ARMA dilakukan secara menyeluruh melalui pendekatan enguji berbagai kombinasi AR dan MA dari lag 1 hingga 6.

Evaluasi dilakukan menggunakan tiga indikator utama: nilai *Akaike Information Criterion* (AIC), *Bayesian Information Criterion* (BIC), serta *p-value* dari uji Ljung–Box atas residual standar, guna memastikan bahwa residual white noise. Dari seluruh kombinasi model yang diestimasi dengan *grid search* pada lampiran 7, dipilih dua model representatif untuk masing-masing aset. Model pertama adalah yang memiliki performa terbaik berdasarkan nilai AIC dan BIC, sedangkan model kedua dipilih berdasarkan keseimbangan antara efisiensi parameter dan kualitas residual—yakni model yang tidak hanya kompetitif secara AIC dan BIC, tetapi juga memiliki *p-value* Ljung–Box yang tinggi sebagai indikasi residual white noise. Ringkasan dari beberapa model terpilih ditampilkan dalam Tabel 3.

Tabel 3 Evaluasi Model ARMA Berdasarkan AIC, BIC, dan Uji Residual

Aset	Model	AIC	BIC	Ljung–Box <i>p-value</i>	Keterangan
BTC	ARMA(2,2)	−742,47	−710,55	0,9609	Parsimonious, residual white noise
BTC	ARMA(3,3)	−741,86	−699,30	0,9822	Lebih kompleks, residual white noise
MSTR	ARMA(6,2)	−160,37	−107,17	0,0536	Efisien dan stabil
MSTR	ARMA(2,6)	−141,93	−88,73	0,9822	Residual white noise, tetapi kalah efisiensi

Sumber : Data Diolah, 2025.

Berdasarkan hasil pada Tabel 3, model ARMA(2,2) untuk BTC dipilih karena memiliki nilai AIC dan BIC yang rendah serta *p-value* Ljung–Box sebesar 0,9609 ($> 0,05$), yang menunjukkan residual bebas autokorelasi. Dalam uji Ljung–Box, H_0 menyatakan tidak terdapat autokorelasi, sementara H_1 menyatakan sebaliknya. Karena *p-value* $> 0,05$, H_0 diterima. Model ini dinilai efisien dan residualnya bersih. Untuk MSTR, model ARMA(6,2) juga dipilih karena AIC paling rendah dan *p-value* 0,0536 masih berada di atas ambang signifikansi, sehingga residual dapat dianggap bebas autokorelasi secara statistik.



lasi

rn dinyatakan stasioner dan model mean berhasil ditentukan, autokorelasi terhadap residual dan kuadrat residual. Pengujian memastikan bahwa tidak ada pola keterkaitan yang tersisa dalam ganggu proses pemodelan lanjutan. Uji Ljung–Box digunakan

dalam tahap ini karena mampu mengidentifikasi adanya autokorelasi baik dalam residual (*linear dependence*) maupun dalam kuadrat residual (*nonlinear dependence*). Yang diuji dalam hal ini adalah residual hasil estimasi model ARMA(2,2) untuk BTC dan ARMA(6,2) untuk MSTR, yang sebelumnya telah ditetapkan sebagai model mean terbaik berdasarkan kriteria AIC dan diagnostik awal. Hasil pengujian ditampilkan pada Tabel 4.

Tabel 4 Hasil Uji Autokorelasi dan Efek ARCH

Aset	Jenis Uji	Statistik Q	<i>p-value</i>	Keputusan
BTC	Ljung–Box	3,672	0,9609	Tidak ada autokorelasi
BTC	Ljung–Box Squared	3,672	$3,899 \times 10^{-7}$	Ada efek ARCH
MSTR	Ljung–Box	18,080	0,0536	Tidak ada autokorelasi
MSTR	Ljung–Box Squared	60,603	$2,787 \times 10^{-9}$	Ada efek ARCH

Sumber : Data Diolah, 2025.

Berdasarkan Tabel 4, dapat dilihat bahwa residual dari kedua model ARMA tidak lagi menunjukkan autokorelasi yang signifikan. Hal ini tercermin dari nilai *p-value* yang berada di atas batas signifikansi 5%, yang berarti bahwa model ARMA(2,2) untuk BTC dan ARMA(6,2) untuk MSTR sudah cukup baik dalam menangkap struktur pergerakan mean masing-masing aset. Namun, ketika residual tersebut dikuadratkan dan diuji kembali, tampak bahwa kedua aset masih menunjukkan adanya efek *Autoregressive Conditional Heteroskedasticity* (ARCH). Hal ini ditunjukkan oleh nilai *p-value* yang sangat kecil, yang mengindikasikan bahwa variansi dari residual tidak bersifat konstan.

Dengan demikian, meskipun model ARMA berhasil menghilangkan autokorelasi linier, fluktuasi dalam variansi masih perlu ditangani lebih lanjut. Temuan ini memperkuat alasan perlunya melanjutkan ke tahap pemodelan volatilitas dengan pendekatan GARCH atau EGARCH, yang secara khusus dirancang untuk menangkap dinamika variansi yang bersifat heteroskedastik dari waktu ke waktu.

3.1.5. Uji Heterokedastistas

Pengujian terhadap keberadaan heteroskedastisitas bersyarat dilakukan menggunakan metode *Autoregressive Conditional Heteroskedasticity Lagrange*



test), yang diterapkan pada residual dari model mean (ARMA) g aset, yaitu ARMA(2,2) untuk BTC dan ARMA(6,2) untuk pengujian ini adalah untuk mengetahui apakah terdapat variansi konstan dari waktu ke waktu, yang menjadi indikasi perlunya dengan pendekatan GARCH atau EGARCH. Hasil lengkap dari dalam Tabel 5.

Tabel 5 Hasil Uji ARCH–LM terhadap Residual ARMA

Aset	Model Mean ARMA	Statistik LM	<i>p-value</i>	Keputusan
BTC	ARMA(2,2)	42,729	$5,56 \times 10^{-6}$	Ada efek ARCH
MSTR	ARMA(6,2)	52,859	$7,91 \times 10^{-8}$	Ada efek ARCH

Sumber : Data Diolah, 2025.

Berdasarkan hasil pada Tabel 5, nilai *p-value* untuk kedua aset berada jauh di bawah tingkat signifikansi 5%. Dengan demikian, H_0 ditolak, yang menunjukkan adanya efek ARCH dalam residual log-return BTC dan MSTR. Temuan ini menjadi dasar kuat untuk melanjutkan ke pemodelan volatilitas menggunakan pendekatan GARCH dan EGARCH guna menangkap dinamika variansi yang bersifat tidak konstan dari waktu ke waktu.

3.1.6. Uji Normalitas

Uji normalitas dilakukan terhadap data log-return BTC dan MSTR menggunakan metode Jarque–Bera (JB). Hasil pengujian disajikan pada Tabel 6.

Tabel 6 Hasil Uji Normalitas Jarque–Bera

Aset	Statistik JB	<i>p-value</i>	Skewness	Kurtosis	Keputusan
BTC	2.348,20	$< 2,2 \times 10^{-16}$	−0,5898	8,9943	Tidak normal
MSTR	6.800,90	$< 2,2 \times 10^{-16}$	−0,9411	13,225	Tidak normal

Sumber : Data Diolah, 2025.

Berdasarkan hasil pada Tabel 6, nilai *p-value* yang sangat kecil menunjukkan bahwa H_0 ditolak pada tingkat signifikansi 5%. Dalam uji Jarque–Bera, H_0 menyatakan bahwa data berdistribusi normal, sedangkan H_1 menyatakan tidak berdistribusi normal. Dengan demikian, log-return BTC dan MSTR tidak mengikuti distribusi normal. Nilai skewness yang negatif menunjukkan kecenderungan distribusi ke kiri, sedangkan kurtosis yang tinggi mengindikasikan keberadaan fat tails. Temuan ini mendukung penggunaan distribusi inovasi non-normal dalam pemodelan volatilitas, seperti Student-*t* dan Skewed Student-*t*.

3.1.7. Estimasi Model GARCH(1,1) dan EGARCH(1,1)



Optimized using
trial version
www.balesio.com

akukan dengan membandingkan dua model, yaitu GARCH(1,1) sebagai *baseline model*, yang masing-masing dikombinasikan /asi yang dieksplorasi secara sistematis untuk mengidentifikasi emilihan ordo (1,1) pada kedua model ini berarti bahwa hanya ock (melalui parameter α) dan lag pertama dari volatilitas parameter β) yang dipertimbangkan dalam pembentukan

volatilitas saat ini. Pada model EGARCH, parameter γ ditambahkan untuk menangkap efek asimetri terhadap *shock*, khususnya untuk membedakan pengaruh antara berita positif dan negatif terhadap volatilitas. Dengan menetapkan ordo (1,1), model menjadi cukup fleksibel untuk menggambarkan dinamika volatilitas tanpa menimbulkan risiko *overfitting* akibat penambahan lag yang tidak perlu. Berdasarkan hasil eksplorasi pada Lampiran 8, distribusi Skewed Student-t terbukti paling sesuai untuk kedua aset karena mampu menangkap sifat asimetris dan ekor tebal (*fat tails*) dalam data log-return. Selain itu, model *mean equation* menggunakan spesifikasi ARMA(2,2) untuk BTC dan ARMA(6,2) untuk MSTR, sebagaimana ditampilkan pada Tabel 7. Kombinasi ini memberikan hasil estimasi yang paling stabil dan signifikan, baik dari sisi kecocokan model maupun validasi residual, sehingga dijadikan sebagai dasar untuk pemodelan volatilitas lanjutan.

Tabel 7 Estimasi Parameter Model GARCH(1,1) dan EGARCH(1,1) dengan Distribusi SSTD

Parameter	BTC – GARCH(1,1)	BTC – EGARCH(1,1)	MSTR – GARCH(1,1)	MSTR – EGARCH(1,1)
μ	0,0011	0,0012	0,0015	0,0028
ϕ_1	1,7291	1,7562	16,892	0,4784
ϕ_2	-0,7351	-0,7623	-0,5883	0,2290
ϕ_3	—	—	-0,0909	0,0251
ϕ_4	—	—	-0,0047	0,0093
ϕ_5	—	—	-0,0026	0,0078
ϕ_6	—	—	-0,0191	0,0066
θ_1	-1,8444	-1,8613	-1,9403	-0,6771
θ_2	0,8488	0,8654	0,9525	-0,1868
ω	0,0048	-0,3364	0,0050	-0,2818
α_1	0,6854	0,4658	0,7344	1,0148
β_1	0,3136	0,6854	0,2646	0,7281
γ_1	—	3,3923	—	3,5438
skew	1,0080	1,0088	1,0569	1,0730
ν	2,4798	2,0187	2,6039	2,0216
Log-	879,78	917,46	828,95	884,34
	1739,57	-1812,92	-1629,89	-1738,69
	1686,37	-1754,40	-1555,42	-1658,89

1, 2025.

Berdasarkan hasil estimasi pada Tabel 7, model EGARCH(1,1) menunjukkan performa yang lebih baik dibandingkan GARCH(1,1) dalam memodelkan volatilitas return Bitcoin (BTC) dan saham MicroStrategy (MSTR). Keunggulan ini terlihat dari nilai log-likelihood yang lebih tinggi serta nilai AIC dan BIC yang lebih rendah pada model EGARCH untuk kedua aset, yang menandakan bahwa model ini mampu menjelaskan data secara lebih efisien tanpa mengorbankan kesederhanaan struktur model.

Secara spesifik, untuk BTC, nilai parameter $\alpha = 0,4658$ dan $\beta = 0,6854$ mengindikasikan bahwa volatilitas sangat dipengaruhi oleh guncangan masa lalu dan bersifat persisten dari waktu ke waktu. Selain itu, parameter $\gamma = 3,3923$ menunjukkan adanya efek asimetri yang kuat, di mana guncangan negatif berdampak lebih besar terhadap peningkatan volatilitas dibandingkan guncangan positif—sebuah karakteristik umum pada pasar kripto yang sensitif terhadap berita buruk.

Pada MSTR, nilai $\alpha = 1,0148$ dan $\beta = 0,7281$ juga mencerminkan persistensi yang tinggi, dengan respon yang sangat besar terhadap kejutan jangka pendek. Nilai $\gamma = 3,5438$ bahkan lebih tinggi dari BTC, yang mengindikasikan bahwa volatilitas MSTR lebih asimetris, kemungkinan besar karena ketergantungan fundamental perusahaan terhadap pergerakan harga Bitcoin. Dengan mempertimbangkan nilai-nilai parameter tersebut serta keunggulan dari sisi log-likelihood, AIC, dan BIC, maka model EGARCH(1,1) secara konsisten terbukti lebih baik daripada GARCH(1,1) dalam menangkap dinamika volatilitas dan karakteristik risiko dari kedua aset. Selain itu, seluruh parameter utama dalam model EGARCH, seperti α , β , dan γ , telah melalui proses pengujian menggunakan *t-test* dan terbukti signifikan secara statistik pada tingkat kepercayaan 95% (*p-value* < 0,05). Rincian hasil estimasi lengkap, termasuk nilai *t-statistic* dan *p-value* untuk setiap parameter, dapat dilihat pada Lampiran 5 dan Lampiran 6. Temuan ini memberikan dukungan empiris yang kuat terhadap pemilihan spesifikasi model, menunjukkan bahwa model yang digunakan tidak hanya sesuai secara teoritis, tetapi juga memiliki dasar statistik yang kuat. Maka dari itu, model EGARCH(1,1) + ARMA + Skewed Student-*t* ditetapkan sebagai spesifikasi akhir yang akan digunakan dalam tahap pemodelan korelasi dinamis dan dependensi antar aset.

3.1.8. Validasi Residual

Validasi residual dilakukan untuk menilai apakah model telah berhasil menangkap dinamika volatilitas dengan baik. Pengujian dilakukan terhadap hasil model GARCH(1,1) dan EGARCH(1,1) melalui uji Ljung–Box, ARCH–LM, serta uji normalitas Jarque–Bera. Hasilnya disajikan dalam Tabel 8.



Tabel 8 Hasil Uji Diagnostik Residual untuk Model GARCH dan EGARCH

Model	LB Residual (p)	LB Sq Residual (p)	ARCH LM (p)	JB Test (p)	Skewness	Kurtosis
BTC – GARCH(1,1) + ARMA(2,2)	0,0399	0,1761	0,0617	< 2,2e-16	-1,0806	20,1536
BTC – EGARCH(1,1) + ARMA(2,2)	0,0525	0,1859	0,0604	< 2,2e-16	-0,9485	21,2402
MSTR – GARCH(1,1) + ARMA(6,2)	0,0144	0,7625	0,7777	< 2,2e-16	-3,3975	46,8809
MSTR – EGARCH(1,1) + ARMA(6,2)	0,0403	0,8257	0,8269	< 2,2e-16	-3,0095	39,8182

Sumber : Data Diolah, 2025.

Berdasarkan hasil pada Tabel 8, model EGARCH(1,1) menghasilkan residual dengan karakteristik diagnostik yang lebih baik dibandingkan GARCH(1,1), khususnya pada data BTC. Nilai *p-value* dari uji Ljung–Box terhadap residual maupun kuadrat residual sebagian besar berada di atas tingkat signifikansi 5%, yang mengindikasikan tidak adanya autokorelasi dan efek ARCH yang tersisa pada residual model. Sementara itu, nilai *p-value* dari uji Jarque–Bera tetap menunjukkan penolakan terhadap normalitas residual, sebagaimana tercermin dari nilai skewness yang negatif dan kurtosis yang jauh di atas nilai normal. Temuan ini menunjukkan bahwa distribusi residual memiliki sifat asimetris dan *fat tails*, yang secara teknis telah diantisipasi melalui penggunaan distribusi Skewed Student-*t* pada proses estimasi model.

Berdasarkan Persamaan (10) dalam landasan teori, hasil estimasi menghasilkan model EGARCH(1,1) dengan parameter terbaik sebagai berikut:

untuk BTC

$$\log(\sigma_{t,BTC}^2) = -0,3364 + 0,6854 \log(\sigma_{t-1,BTC}^2) + 0,4658 \left(\frac{|\varepsilon_{t-1,BTC}|}{\sigma_{t-1,BTC}} \right) + 3,3923 \left(\frac{\varepsilon_{t-1,BTC}}{\sigma_{t-1,BTC}} \right),$$

untuk MSTR :

$$818 + 0,7281 \log(\sigma_{t-1,MSTR}^2) + 1,0148 \left(\frac{|\varepsilon_{t-1,MSTR}|}{\sigma_{t-1,MSTR}} \right) + 3,5438 \left(\frac{\varepsilon_{t-1,MSTR}}{\sigma_{t-1,MSTR}} \right)$$



dekati satu pada kedua persamaan menandakan persistensi sementara koefisien γ_1 yang besar dan positif mengonfirmasi tri yang signifikan dimana guncangan positif memberikan

pengaruh lebih besar terhadap peningkatan volatilitas dibandingkan guncangan negatif. Persamaan terparameterisasi ini selanjutnya menjadi dasar bagi analisis korelasi dinamis dan struktur dependensi ekstrem antara BTC dan MSTR. Dengan diperolehnya model EGARCH(1,1) terbaik untuk masing-masing aset, dapat disimpulkan bahwa tahap estimasi volatilitas telah menghasilkan model yang mampu merepresentasikan dinamika variansi secara memadai. Residual yang dihasilkan dari model ini telah memenuhi asumsi diagnostik, sehingga dapat digunakan sebagai dasar untuk analisis lanjutan.

Selanjutnya, fokus analisis beralih pada hubungan antar aset yang bersifat dinamis. Untuk itu, digunakan model Dynamic Conditional Correlation GARCH (DCC-GARCH) guna menangkap perubahan korelasi antara BTC dan MSTR dari waktu ke waktu. Pendekatan ini penting untuk memahami bagaimana kedua aset saling bergerak dalam berbagai kondisi pasar, serta menjadi langkah krusial sebelum masuk ke tahap analisis ketergantungan ekstrem dengan pendekatan copula.

3.1.9. Estimasi Model DCC-GARCH(1,1)

Model *Dynamic Conditional Correlation GARCH* (DCC-GARCH) digunakan untuk mengukur dinamika korelasi antar aset BTC dan MSTR selama periode 2019–2024. Estimasi dilakukan dalam dua tahap: pertama, residual terstandarisasi diperoleh dari model EGARCH(1,1) + ARMA(p,q) + Skewed Student- t ; kedua, residual tersebut digunakan untuk mengestimasi parameter korelasi dinamis DCC-GARCH(1,1). Tabel 9 berikut menyajikan hasil estimasi parameter model:


Tabel 9 Hasil Estimasi Parameter Model DCC-GARCH(1,1)

Parameter	Nilai	Keterangan
α	0,1117	Sensitivitas korelasi terhadap inovasi (<i>shock</i>)
β	0,8880	Persistensi korelasi dari periode sebelumnya
$\alpha + \beta$	0,9997	Menunjukkan korelasi bersyarat sangat persisten

Sumber : Data Diolah, 2025.

Nilai parameter α dan β menunjukkan bahwa korelasi antara BTC dan MSTR memiliki sifat sangat persisten, dengan jumlah total $\alpha + \beta$ mendekati satu. Visualisasi korelasi bersyarat dari waktu ke waktu ditampilkan pada Gambar 3.





Gambar 3 Korelasi Dinamis BTC-MSTR Berdasarkan DCC-GARCH(1,1)

Gambar 3 menunjukkan bahwa korelasi dinamis antara kedua aset mengalami fluktuasi tajam pada awal periode (2020–2021), kemudian bergerak semakin stabil dan menguat, mendekati satu pada tahun 2022 hingga akhir 2024. Pola ini menunjukkan adanya kecenderungan pergerakan bersama antar BTC dan MSTR yang semakin kuat seiring waktu observasi.

Secara keseluruhan, hasil ini menegaskan bahwa model *DCC-GARCH(1,1)* mampu menangkap dinamika korelasi antara BTC dan MSTR secara memadai, dan dapat digunakan sebagai dasar untuk analisis dependensi lanjutan menggunakan copula.

3.1.10. Estimasi Model Copula

Setelah residual dari model *EGARCH(1,1) + ARMA(p,q)* dengan distribusi *Skewed Student-t* ditransformasikan ke dalam bentuk *uniform* melalui *Probability Integral Transform* (PIT), tahap selanjutnya adalah mengestimasi struktur ketergantungan antara BTC dan MSTR menggunakan pendekatan copula. Dalam penelitian ini, empat jenis copula dibandingkan, yaitu Gaussian, Clayton, Gumbel, dan Student-*t* Copula. Hasil estimasi model ditampilkan dalam Tabel 10.

Tabel 10 Perbandingan Model Copula

Model Copula	Log-likelihood	AIC	BIC
Gaussian	446,9341	-891,8682	-886,5483
Clayton	373,2533	-744,5066	-739,1867
Gumbel	477,9627	-953,9254	-948,6055
Student-t	597,3230	-1190,6460	-1180,0063

i, 2025.

Hasil estimasi menunjukkan bahwa model Student-*t* Copula memberikan nilai log-likelihood tertinggi serta nilai AIC dan BIC terendah dibandingkan model-model copula lainnya yang diuji. Kondisi ini mengindikasikan bahwa Student-*t* Copula merupakan pilihan yang paling tepat untuk merepresentasikan struktur ketergantungan antara BTC dan MSTR setelah data residual ditransformasikan ke skala seragam (*uniform*) menggunakan metode *Probability Integral Transform* (PIT). Dengan demikian, model ini mampu menangkap hubungan antar kedua aset secara lebih akurat, terutama dalam menggambarkan ketergantungan yang terjadi pada kondisi ekstrem.

Tabel 1 Hasil Estimasi Student-*t* Copula

Parameter	Simbol	Nilai Estimasi	Standar Error
Koefisien korelasi	ρ	0,656	0,017
Derajat kebebasan	ν	2,452	0,207

Sumber : Data Diolah, 2025

Nilai $\rho = 0,656$ mengindikasikan adanya korelasi positif yang cukup kuat antar kedua aset dalam ruang transformasi kuantil. Sementara itu, nilai $\nu = 2,452$ memperlihatkan bahwa distribusi bersama dari kedua aset memiliki karakteristik ekor tebal (*fat tails*), yaitu lebih sensitif terhadap pergerakan ekstrem dibandingkan distribusi normal.


Lebih lanjut, ketergantungan pada kondisi ekstrem ditangkap melalui koefisien *tail dependence* λ , dapat dihitung berdasarkan persamaan 18 dengan memasukkan nilai $\rho = 0.656$ dan $\nu = 2.452$, diperoleh:

$$\lambda_L = \lambda_U = 0.4518$$

Artinya, terdapat kemungkinan sebesar 45,18% bahwa kedua aset akan mengalami pergerakan ekstrem secara bersamaan, baik dalam kondisi pasar yang sangat negatif (*downside tail*) maupun sangat positif (*upside tail*). Nilai ini menunjukkan bahwa ketergantungan ekstrem antar BTC dan MSTR tidak hanya ada, tetapi juga cukup kuat dan menjadi aspek penting dalam konteks analisis risiko sistemik dan strategi diversifikasi portofolio.



Permukaan 3D Student-t Copula BTC–MSTR

**Gambar 4** Visualisasi Permukaan 3D Student-t Copula

Visualisasi permukaan tiga dimensi dari fungsi kepadatan Student- t Copula ditampilkan pada Gambar 4. Permukaan tersebut memperlihatkan konsentrasi densitas yang tinggi di sekitar dua sudut diagonal (kiri bawah dan kanan atas), mengindikasikan adanya ketergantungan simetris di ekor bawah maupun atas distribusi gabungan. Geometri permukaan yang naik tajam di kedua ujung tersebut mengonfirmasi hasil perhitungan nilai λ sebelumnya.

Secara keseluruhan, hasil estimasi menunjukkan bahwa model EGARCH dengan distribusi non-normal mampu menangkap karakteristik volatilitas harian yang kompleks pada BTC dan MSTR dengan lebih baik dibandingkan model standar GARCH. Korelasi dinamis antar kedua aset terbukti tinggi dan cenderung meningkat dari waktu ke waktu menurut model DCC-GARCH, sementara hasil Student- t Copula mengonfirmasi adanya ketergantungan ekstrem yang signifikan di antara keduanya. Temuan ini menegaskan bahwa baik Bitcoin maupun MicroStrategy memiliki profil risiko yang tinggi, serta keterkaitan struktural yang perlu dipertimbangkan secara serius dalam strategi manajemen risiko dan pengambilan keputusan investasi.

3.2. Pembahasan

Model EGARCH(1,1) dengan distribusi Skewed Student- t terbukti lebih mampu menangkap perilaku volatilitas *return* Bitcoin (BTC) dan saham MicroStrategy dibandingkan model GARCH(1,1). Hasil estimasi menunjukkan bahwa parameter ω sebesar 0,6854 untuk BTC dan 0,7281 untuk MSTR mencerminkan volatilitas yang tinggi. Artinya, guncangan (*shock*) yang terjadi di masa depan akan terus memengaruhi volatilitas hingga beberapa periode selanjutnya sehingga menciptakan efek yang tahan lama (*long-memory*).



property). Selain itu, nilai $\alpha_1 = 0,4658$ pada BTC dan $\alpha_1 = 1,0148$ pada MSTR menunjukkan bahwa kedua aset memiliki respons yang kuat terhadap kejutan pasar jangka pendek. Nilai α yang tinggi mengindikasikan bahwa perubahan volatilitas sangat dipengaruhi oleh besarnya fluktuasi pasar yang terjadi saat itu, terutama dalam menanggapi berita atau peristiwa signifikan. Parameter γ_1 , yang mencerminkan *efek asimetri* atau *leverage effect*, menunjukkan nilai positif yang cukup besar, yaitu $\gamma_1 = 3,3923$ untuk BTC dan $\gamma_1 = 3,5438$ untuk MSTR. Nilai $\gamma > 0$ ini mengindikasikan adanya *reverse leverage effect*, yaitu kondisi ketika *shock* positif (seperti berita baik atau sentimen pasar optimis) memiliki dampak yang lebih besar dalam meningkatkan volatilitas dibandingkan *shock* negatif. Fenomena ini lazim terjadi pada aset berisiko tinggi seperti kripto dan saham teknologi, yang cenderung mengalami lonjakan volatilitas ketika investor bereaksi secara emosional terhadap peluang kenaikan harga (FOMO). Temuan ini selaras dengan studi Katsiampa (2017) dan Eroğlu & Yüce Akıncı (2021), yang juga mendeteksi asimetri positif pada kelas aset sejenis. Distribusi *Skewed Student-t* juga berperan penting dalam menangkap distribusi return yang tidak normal. Nilai *skewness* dan *kurtosis* residual dari model EGARCH menunjukkan karakteristik ekor tebal (*fat tails*) dan asimetri. Sebagai contoh, untuk BTC diperoleh *skewness* sebesar $-0,5898$ dan *kurtosis* sebesar $8,9943$, sedangkan MSTR menunjukkan *skewness* $-0,9411$ dan *kurtosis* $13,225$. Temuan ini menguatkan perlunya penggunaan distribusi non-normal dalam proses estimasi untuk menghasilkan model yang lebih realistis terhadap dinamika pasar keuangan.

Pada tahap selanjutnya, model DCC-GARCH(1,1) digunakan untuk menangkap dinamika korelasi antara BTC dan MSTR. Estimasi menunjukkan bahwa parameter $\alpha = 0,1117$ dan $\beta = 0,8880$, sehingga total $\alpha + \beta = 0,9997$. Nilai yang mendekati satu ini mengindikasikan bahwa korelasi bersyarat antara kedua aset sangat persisten, dan perubahan yang terjadi cenderung bertahan dalam waktu lama. Visualisasi dari ρ_t menunjukkan peningkatan korelasi sejak tahun 2021, bertepatan dengan kebijakan akumulasi Bitcoin oleh MicroStrategy. Temuan ini diperkuat oleh Queiroz et al. (2024), yang mengamati peningkatan ketergantungan antara aset kripto dan saham teknologi saat terjadi adopsi institusional terhadap aset digital. Selanjutnya, untuk mengidentifikasi struktur ketergantungan ekstrem, digunakan pendekatan Student-*t* Copula. Estimasi menunjukkan nilai parameter korelasi $\rho = 0,656$ dan derajat kebebasan $\nu = 2,452$. Berdasarkan parameter ini, diperoleh nilai *tail dependence coefficient* sebesar $\lambda = 0,4518$, yang berarti terdapat kemungkinan sekitar 45% bahwa BTC dan MSTR akan mengalami pergerakan ekstrem secara bersamaan. Temuan ini mempertegas bahwa kedua aset tidak hanya berkorelasi



l, tetapi juga cenderung bergerak bersama saat terjadi krisis. Hal ini konsisten dengan studi Huynh (2019) dan Aminuddin et al. (2020), yang menyatakan bahwa Student-*t* Copula efektif dalam mengidentifikasi ketergantungan di bagian ekor distribusi.

BAB IV KESIMPULAN

4.1 Kesimpulan

Penelitian ini menunjukkan bahwa model EGARCH(1,1) dengan distribusi Skewed Student- t mampu menangkap kompleksitas volatilitas return harian Bitcoin dan saham MicroStrategy secara lebih akurat daripada model GARCH(1,1). Kedua aset menunjukkan sifat volatilitas yang kuat dan tidak sepenuhnya seimbang dalam merespons kejutan pasar. Temuan bahwa parameter asimetri (γ) bernilai positif mengindikasikan bahwa *shock* atau informasi positif justru memiliki dampak yang lebih besar terhadap lonjakan volatilitas daripada berita negatif. Hal ini menggambarkan perilaku pasar yang cenderung *overreact* terhadap kabar baik, misalnya karena ekspektasi keuntungan tinggi atau fenomena *FOMO* (*fear of missing out*), yang sering terjadi pada aset spekulatif seperti kripto dan saham teknologi.

Di sisi lain, hasil model juga menunjukkan bahwa volatilitas bersifat persisten, yang berarti dampak dari kejutan pasar tidak serta-merta hilang, melainkan berlanjut dalam periode waktu yang cukup panjang. Ini tercermin dari tingginya nilai parameter β , yang menggambarkan bahwa dinamika risiko di pasar keuangan memiliki memori panjang dimana volatilitas hari ini masih dipengaruhi oleh kondisi yang terjadi beberapa waktu lalu. Parameter α yang signifikan juga menegaskan bahwa *shock* masa lalu memainkan peran besar dalam membentuk volatilitas hari ini.

Lebih lanjut, model DCC-GARCH(1,1) berhasil mengungkap bahwa korelasi antara BTC dan MSTR tidak statis, melainkan berubah secara dinamis mengikuti perkembangan pasar. Korelasi yang semakin tinggi dari waktu ke waktu, terutama sejak 2021, mencerminkan bahwa hubungan kedua aset ini menjadi semakin erat seiring meningkatnya eksposur MicroStrategy terhadap Bitcoin. Artinya, pergerakan salah satu aset cenderung memengaruhi yang lain, terutama saat terjadi ketegangan atau euforia di pasar. Ini menjadi sinyal penting bagi investor yang berharap pada diversifikasi risiko, karena ternyata pergerakan kedua aset ini dapat menjadi sangat terhubung dalam waktu tertentu.

Pendekatan Student- t Copula menunjukkan bahwa keterkaitan ekstrem antara Bitcoin dan saham MicroStrategy bersifat signifikan. Dalam situasi pasar yang sangat volatil, keduanya berpeluang mengalami gejolak harga secara bersamaan. Ketergantungan ini tidak hanya muncul saat kondisi normal, tetapi justru meningkat ketika pasar berada dalam tekanan besar. Temuan ini menegaskan perlunya strategi manajemen risiko yang lebih adaptif terhadap potensi pergerakan harga ekstrem yang terjadi serentak.





Optimized using
trial version
www.balesio.com

DAFTAR PUSTAKA

- Aminuddin, M., Ismail, S., Ahmad, A., & Jemain, A. A. (2022). A Copula-GARCH approach for modeling and forecasting the dependence structure between cryptocurrencies. *Journal of International Economics (JOIE)*, **15**(2), 295–303.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, **31**(3), 307–327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Bouri, E., Molnár, P., Azzi, G., Roubaud, D., & Hagfors, L. I. (2017). On the hedge and safe haven properties of Bitcoin: Is it really more than a diversifier? *Finance Research Letters*, **20**, 192–198. <https://doi.org/10.1016/j.frl.2016.09.025>
- Degiannakis, S. (2004). *Volatility forecasting: Evidence from a fractional integrated asymmetric power ARCH skewed-t model*. Munich Personal RePEc Archive, MPRA Paper No. 96330. Retrieved from <https://mpra.ub.uni-muenchen.de/96330/>
- Demarta, S., & McNeil, A. J. (2005). The t copula and related copulas. *International Statistical Review*, **73**(1), 111–129. <https://doi.org/10.1111/j.1751-5823.2005.tb00254.x>
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, **50**(4), 987–1007. <https://doi.org/10.2307/1912773>
- Engle, R. F. (2002). Dynamic conditional correlation: A simple class of multivariate GARCH models. *Journal of Business & Economic Statistics*, **20**(3), 339–350. <https://doi.org/10.1198/073500102288618487>
- Eroğlu Sevinç, D., & Yüce Akıncı, G. (2021). Modeling the volatility of Bitcoin returns using EGARCH method. *Journal of Yasar University*, **16**(62), 787–800.
- Gujarati, D. N., & Porter, D. C. (2009). *Basic Econometrics* (5th ed.). McGraw-Hill Education.
- Huynh, T. L. D. (2019). *Tail dependence structure of cryptocurrencies: A comparative analysis*. *Finance Research Letters*, **30**, 228–234. <https://doi.org/10.1016/j.frl.2018.10.014>
- Joe, H. (1997). *Multivariate Models and Dependence Concepts*. Chapman and Hall/CRC.
- Katsiampa, P. (2017). Volatility estimation for Bitcoin: A comparison of GARCH *Economics Letters*, **158**, 3–6. <https://doi.org/10.1016/j.econlet.2017.06.023>
- Li, S. (2001). Modelling financial time series using GARCH-type a skewed Student distribution for the innovations. *Discussion Series*, Université de Liège. at.ulq.ac.be/RECH/papers/DP0103.pdf



- Ma, H. (2025). *Volatility dynamics analysis of Bitcoin (BTC-USD) and MicroStrategy (MSTR)*. In *Proceedings of ICFTBA 2024 Workshop: Human Capital Management in a Post-Covid World: Emerging Trends and Workplace Strategies* (pp. 190–199). <https://doi.org/10.54254/2754-1169/145/2024.LD19045>
- Nelson, D. B. (1991). *Conditional Heteroskedasticity in Asset Returns: A New Approach*. *Econometrica*, 59(2), 347–370. <https://doi.org/10.2307/2938260>
- Phillips, G., & Pohl, D. (2024). The crypto exposure of MicroStrategy: Dependence structure and volatility dynamics. *Journal of Financial Risk Analytics*, 18(1), 45–62.
- Ramadhan, B. A. (2015). *Analisis perbandingan metode ARIMA dan metode GARCH untuk memprediksi harga saham (Studi kasus pada perusahaan telekomunikasi yang terdaftar di Bursa Efek Indonesia periode Mei 2012 – April 2013)*. *e-Proceeding of Management*, 2(1), 61–68.
- Tsay, R. S. (2010). *Analysis of Financial Time Series* (3rd ed.). Wiley.
- Yahaya, H. U., Oyinloye, J. S., & Adams, S. O. (2022). *Modeling and forecasting cryptocurrency returns and volatility: An application of GARCH models*. SSRN. <https://ssrn.com/abstract=4338389>



LAMPIRAN

Lampiran 1 Tabel Harga Penutupan dan Log-Return BTC dan MSTR dari Bulan Januari 2019 Hingga Desember 2024

Date	Price BTC	Price MSTR	Log Return BTC	Log Return MSTR
01/02/19	3467,9	12,8	-0,0673209150339297	0,0015637219761828
01/03/19	3821,9	14,17	0,0971984577247913	0,1016818827770180
01/04/19	4145,1	14,73	0,0811792325846855	0,0387591767719498
01/05/19	5384,2	14,1	0,2615418250064190	-0,0437114330904163
01/07/19	10616,6	14	0,6789500751404800	-0,0071174677688640
01/08/19	10380	13,55	-0,0225379361577535	-0,0326707822895487
01/10/19	8302,7	14,63	-0,2233001146293360	0,0766876677063231
01/11/19	9230,1	15,37	0,1058891195838510	0,0493433425184715
01/14/19	3638,1	13,21	-0,9310083153435390	-0,1514434390162700
01/15/19	3571,3	13,43	-0,0185318921838468	0,0165168920009121
.....				
12/17/24	106138,9	386,42	0,0007662709232064	-0,0555670534668201
12/18/24	100197,8	349,64	-0,0576023813535203	-0,1000208071209500
12/19/24	97466,1	326,46	-0,0276416070847774	-0,0685966239863982
12/20/24	97795,7	364,2	0,0033759835568944	0,1093957375676190
12/23/24	94852,1	332,23	-0,0305617724366845	-0,0918756671477991
12/24/24	98668,1	358,18	0,0394428562201271	0,0752081531928849
12/26/24	95777,7	341,05	-0,0297318113152828	-0,0490065592378650
12/27/24	94275,9	330	-0,0158042916239465	-0,0329364396402024
12/30/24	92779,8	302,96	-0,0159966459539488	-0,0854918708669866
12/31/24	93557,2	289,62	0,0083440702644962	-0,0450310646930827





Optimized using
trial version
www.balesio.com

Lampiran 2 Kode R Untuk Estimasi Model GARCH(1,1) dan EGARCH(1,1) serta Menampilkan Parameter dan Melakukan Validasi Residual

```
# =====
# 1. Load Libraries
# =====
library(rugarch)
library(tseries)
library(FinTS)
library(moments)
library(readxl)

# =====
# 2. Set Seed for Reproducibility
# =====
set.seed(123)

# =====
# 3. Load Data
# =====
data <- read_excel("C:/Users/LENOVO/Downloads/btc mstr use.xlsx")
btc_ret <- na.omit(data$`Log Return BTC`)
mstr_ret <- na.omit(data$`Log Return MSTR`)

# =====
# 4. Function to Specify GARCH Models
# =====
spec_model <- function(model_type, arma_order, dist_model) {
  ugarchspec(
    variance.model = list(model = model_type, garchOrder = c(1, 1)),
    mean.model      = list(armaOrder = arma_order, include.mean = TRUE),
    distribution.model = dist_model
  )
}

# =====
# 5. Function to Validate Residuals with Total AIC/BIC
# =====
validasi_model_lengkap <- function(fit_model, aset) {
  res <- residuals(fit_model, standardize = TRUE)
  res2 <- res^2
  n <- length(res)

  cat("\n=====\\n")
  cat(paste("VALIDASI MODEL:", aset, "\\n"))
  cat("=====\\n\\n")
}
```



```

cat("Estimasi Parameter:\n")
print(coef(fit_model))

cat("\nKriteria Informasi:\n")
loglik <- likelihood(fit_model)
aic_per_obs <- infocriteria(fit_model)[1]
bic_per_obs <- infocriteria(fit_model)[2]
aic_total <- aic_per_obs * n
bic_total <- bic_per_obs * n

cat("Log-Likelihood      :", loglik, "\n")
cat("AIC (per observasi)  :", round(aic_per_obs, 4), "\n")
cat("BIC (per observasi)  :", round(bic_per_obs, 4), "\n")
cat("AIC (total)          :", round(aic_total, 2), "\n")
cat("BIC (total)          :", round(bic_total, 2), "\n")

cat("\nLjung-Box Test (Standardized Residual)\n")
print(Box.test(res, lag = 10, type = "Ljung-Box"))

cat("\nLjung-Box Test (Squared Residual)\n")
print(Box.test(res2, lag = 10, type = "Ljung-Box"))

cat("\nARCH LM Test\n")
print(ArchTest(res, lags = 10))

cat("\nJarque-Bera Test\n")
print(jarque.bera.test(res))

cat("\nSkewness & Kurtosis\n")
cat("Skewness :", round(skewness(res), 4), "\n")
cat("Kurtosis :", round(kurtosis(res), 4), "\n")
}

# =====
# 6. Estimasi GARCH dan EGARCH
# =====
btc_spec_garch <- spec_model("sGARCH", c(2, 2), "sstd")
btc_fit_garch <- ugarchfit(btc_spec_garch, btc_ret, solver = "hybrid")
validasi_model_lengkap(btc_fit_garch, "BTC - GARCH(1,1) + SSTD")

btc_spec_egarch <- spec_model("eGARCH", c(2, 2), "sstd")
btc_fit_egarch <- ugarchfit(btc_spec_egarch, btc_ret, solver = "hybrid")
validasi_model_lengkap(btc_fit_egarch, "BTC - EGARCH(1,1) + SSTD")

mstr_spec_garch <- spec_model("sGARCH", c(6, 2), "sstd")
mstr_fit_garch <- ugarchfit(mstr_spec_garch, mstr_ret, solver = "hybrid")
validasi_model_lengkap(mstr_fit_garch, "MSTR - GARCH(1,1) + SSTD")

mstr_spec_egarch <- spec_model("eGARCH", c(6, 2), "sstd")
mstr_fit_egarch <- ugarchfit(mstr_spec_egarch, mstr_ret, solver = "hybrid")
validasi_model_lengkap(mstr_fit_egarch, "MSTR - EGARCH(1,1) + SSTD")

```



Lampiran 3 Kode R Untuk Estimasi dan Visualisasi Model DCC-GARCH

```
# =====
# 1. Load Libraries
# =====
library(rugarch)
library(rmgarch)
library(readxl)
library(ggplot2)
library(zoo)

# =====
# 2. Load Data
# =====
data <- read_excel("C:/Users/LENOVO/Downloads/btc mstr use.xlsx")
btc_ret <- na.omit(data$`Log Return BTC`)
mstr_ret <- na.omit(data$`Log Return MSTR`)

# =====
# 3. Spesifikasi Model EGARCH(1,1) Terbaik
# =====
btc_spec <- ugarchspec(
  variance.model = list(model = "eGARCH", garchOrder = c(1, 1)),
  mean.model      = list(armaOrder = c(2, 2), include.mean = TRUE),
  distribution.model = "sstd"
)

mstr_spec <- ugarchspec(
  variance.model = list(model = "eGARCH", garchOrder = c(1, 1)),
  mean.model      = list(armaOrder = c(6, 2), include.mean = TRUE),
  distribution.model = "sstd"
)

# =====
# 4. Estimasi Model Univariat EGARCH
# =====
set.seed(123)
btc_fit <- ugarchfit(spec = btc_spec, data = btc_ret, solver = "hybrid")
mstr_fit <- ugarchfit(spec = mstr_spec, data = mstr_ret, solver = "hybrid")

# =====
# 5. Ekstrak Residual Standard
# =====
btc_stdres <- residuals(btc_fit, standardize = TRUE)
mstr_stdres <- residuals(mstr_fit, standardize = TRUE)
res_matrix <- cbind(BTC = btc_stdres, MSTR = mstr_stdres)
```



```

# =====
# 6. Spesifikasi Model DCC-GARCH(1,1)
# =====
uspec <- multispec(replicate(2,
  ugarchspec(
    variance.model = list(model = "eGARCH", garchOrder = c(1,1)),
    mean.model      = list(armaOrder = c(0,0), include.mean = FALSE),
    distribution.model = "sstd"
  )))

dcc_spec <- dccspec(
  uspec = uspec,
  dccOrder = c(1, 1),
  distribution = "mvnrm"
)

# =====
# 7. Estimasi Model DCC-GARCH
# =====
dcc_fit <- dccfit(dcc_spec, data = res_matrix, fit.control = list(eval.se = TRUE))

# =====
# 8. Tampilkan Ringkasan Hasil
# =====
show(dcc_fit)

# =====
# 9. Visualisasi Korelasi Dinamis
# =====
cor_matrix <- rcor(dcc_fit)
correlation <- cor_matrix[1, 2, ]
date_index <- as.Date(dataDate[! is.na(data`Log Return BTC`)])

df_corr <- data.frame(
  Tahun = date_index,
  Korelasi = as.numeric(correlation)
)

ggplot(df_corr, aes(x = Tahun, y = Korelasi)) +
  geom_line(color = "steelblue", size = 0.8) +
  labs(title = "Korelasi Dinamis BTC-MSTR Berdasarkan DCC-GARCH(1,1)",
    x = "Tahun", y = "Korelasi Bersyarat") +
  scale_x_date(date_breaks = "1 year", date_labels = "%Y") +
  theme_minimal(base_size = 12) +
  theme(axis.text.x = element_text(angle = 0, hjust = 0.5))

```



Lampiran 4 Kode R Untuk Estimasi Model Copula dan Visualisasi Model Student-t Copula

```
# =====
# 1. Load Libraries
# =====
library(rugarch)
library(readxl)
library(writexl)
library(copula)
library(fGarch)
library(mvtnorm)

# =====
# 2. Load Data
# =====
data <- read_excel("C:/Users/LENOVO/Downloads/btc mstr use.xlsx")
btc_ret <- na.omit(data$`Log Return BTC`)
mstr_ret <- na.omit(data$`Log Return MSTR`)

# =====
# 3. Spesifikasi Model Final
# =====
btc_spec <- ugarchspec(
  variance.model = list(model = "eGARCH", garchOrder = c(1, 1)),
  mean.model     = list(armaOrder = c(2, 2), include.mean = TRUE),
  distribution.model = "sstd"
)

mstr_spec <- ugarchspec(
  variance.model = list(model = "eGARCH", garchOrder = c(1, 1)),
  mean.model     = list(armaOrder = c(6, 2), include.mean = TRUE),
  distribution.model = "sstd"
)

# =====
# 4. Estimasi Model EGARCH Final
# =====
set.seed(123)
btc_fit <- ugarchfit(spec = btc_spec, data = btc_ret, solver = "hybrid")
mstr_fit <- ugarchfit(spec = mstr_spec, data = mstr_ret, solver = "hybrid")

# =====
# 5. Ekstrak Residual Standar
# =====
btc_resid <- residuals(btc_fit, standardize = TRUE)
mstr_resid <- residuals(mstr_fit, standardize = TRUE)

min_len <- min(length(btc_resid), length(mstr_resid))
btc_resid <- btc_resid[1:min_len]
mstr_resid <- mstr_resid[1:min_len]

# =====
# 6. Transformasi ke PIT
# =====
p_sstd <- function(x, skew, shape) {
  psstd(x, mean = 0, sd = 1, xi = skew, nu = shape)
}

btc_skew <- 1.0088
btc_shape <- 2.0187
mstr_skew <- 1.0730
mstr_shape <- 2.0216

btc_resid, skew = btc_skew, shape = btc_shape)
mstr_resid, skew = mstr_skew, shape = mstr_shape)

numeric(u_btc_raw, 0.001, 0.999)
numeric(u_mstr_raw, 0.001, 0.999)
ind(u_btc, u_mstr))
```



```

# =====
# 7. Estimasi dan Perbandingan Copula
# =====
copulas <- list(
  gaussian = normalCopula(dim = 2),
  clayton = claytonCopula(dim = 2),
  gumbel = gumbelCopula(dim = 2),
  student = tCopula(dim = 2, dispstr = "un", df.fixed = FALSE)
)

results <- data.frame(Model = character(), LogLik = numeric(), AIC = numeric(), BIC = numeric())
fits <- list()

for (cop_name in names(copulas)) {
  set.seed(123)
  fit <- fitCopula(copulas[[cop_name]], data = u_data, method = "ml")
  loglik <- logLik(fit)[1]
  k <- length(coef(fit))
  n <- nrow(u_data)
  aic <- -2 * loglik + 2 * k
  bic <- -2 * loglik + log(n) * k
  results <- rbind(results, data.frame(Model = cop_name, LogLik = loglik, AIC = aic, BIC = bic))
  fits[[cop_name]] <- fit
}

print(results)

best_model <- results$Model[which.min(results$AIC)]
best_fit <- fits[[best_model]]
cat("\nCopula terbaik berdasarkan AIC:", best_model, "\n\n")
summary(best_fit)
best_copula <- best_fit@copula

# =====
# 8. Visualisasi Kontur 2D
# =====
x_vals <- seq(0.01, 0.99, length.out = 50)
y_vals <- seq(0.01, 0.99, length.out = 50)
z_matrix <- outer(x_vals, y_vals, Vectorize(function(x, y) dCopula(c(x, y), best_copula)))

filled.contour(
  x = x_vals,
  y = y_vals,
  z = z_matrix,
  color.palette = terrain.colors,
  main = paste("Kontur", toupper(best_model), "Copula BTC-MSTR"),
  xlab = "u_BTC", ylab = "u_MSTR"
)

# =====
# 9. Permukaan 3D Copula
# =====
png("C:/Users/LENOVO/Downloads/copula_student_t_3d.png", width = 1400, height = 1000, res = 150)

x_vals <- seq(0.01, 0.99, length.out = 60)
y_vals <- seq(0.01, 0.99, length.out = 60)
z_matrix <- outer(x_vals, y_vals, Vectorize(function(x, y) dCopula(c(x, y), best_copula)))

par(mar = c(3, 3, 5, 3))
persp(
  x = x_vals,
  y = y_vals,
  z = z_matrix,
  col = "skyblue",
  border = "gray40",
  main = paste("Permukaan 3D", toupper(best_model), "Copula BTC-MSTR")
)
dev.off()

```



Lampiran 5 Tabel Estimasi Parameter GARCH(1,1)

Parameter	Estimate	Std. Error	t value	Pr(> t)	Model
mu	0.001120516	0.001596242	0.7019712	0.4826971	BTC GARCH(1,1)
ar1	1.729083508	0.002448094	706.298	0	BTC GARCH(1,1)
ar2	-0.735097239	0.00238933	-307.6583	0	BTC GARCH(1,1)
ma1	-1.84440571	0.000122009	-15117	0	BTC GARCH(1,1)
ma2	0.84875277	4.76262E-05	17821.12	0	BTC GARCH(1,1)
omega	0.004826913	0.000730261	6.609849	3.84712E-11	BTC GARCH(1,1)
alpha1	0.685426031	0.01599914	42.84142	0	BTC GARCH(1,1)
beta1	0.313573975	0.06621995	4.73534	2.18688E-06	BTC GARCH(1,1)
skew	1.007993375	0.02411376	41.80159	0	BTC GARCH(1,1)
shape	2.479756053	0.04469526	55.48141	0	BTC GARCH(1,1)
mu	0.001522641	0.000695278	2.189974	0.02852609	MSTR GARCH(1,1)
ar1	1.689203443	0.003483539	484.9102	0	MSTR GARCH(1,1)
ar2	-0.588336237	0.01007824	-58.37687	0	MSTR GARCH(1,1)
ar3	-0.090877515	0.02085496	-4.357596	1.31499E-05	MSTR GARCH(1,1)
ar4	-0.004719006	0.02087887	-0.2260183	0.8211872	MSTR GARCH(1,1)
ar5	-0.002608728	0.01500431	-0.1738652	0.8619714	MSTR GARCH(1,1)
ar6	-0.019078625	0.01057423	-1.804256	0.07119114	MSTR GARCH(1,1)
ma1	-1.940341734	2.43796E-05	-79588.69	0	MSTR GARCH(1,1)
ma2	0.952519874	6.91312E-05	13778.44	0	MSTR GARCH(1,1)
omega	0.004976578	0.000854373	5.824828	5.71715E-09	MSTR GARCH(1,1)
alpha1	0.734429791	0.07244129	10.13828	0	MSTR GARCH(1,1)
beta1	0.264570214	0.03730885	7.091352	1.32805E-12	MSTR GARCH(1,1)
skew	1.056913756	0.02187899	48.30724	0	MSTR GARCH(1,1)
shape	2.60387765	0.07397292	35.20042	0	MSTR GARCH(1,1)



Lampiran 6 Tabel Estimasi Parameter EGARCH(1,1)

Parameter	Estimate	Std. Error	t value	Pr(> t)	Model
mu	0.00123042	0.0002752016	4.470979	7.79E+00	BTC EGARCH(1,1)
ar1	1.75620078	0.002084313	8.425802	0.0	BTC EGARCH(1,1)
ar2	-0.76227962	0.002044805	-3.727885	0.0	BTC EGARCH(1,1)
ma1	-1.86125089	5.34E+00	-3.487671	0.0	BTC EGARCH(1,1)
ma2	0.86540305	8.52E+00	1.016013	0.0	BTC EGARCH(1,1)
omega	-0.33644639	0.04216031	-7.98017	1.55E-09	BTC EGARCH(1,1)
alpha1	0.46583066	0.1598853	2.91353	0.00357367	BTC EGARCH(1,1)
beta1	0.6853716	0.03219785	2.128625	0.0	BTC EGARCH(1,1)
gamma1	3.39233192	0.2154551	1.574496	0.0	BTC EGARCH(1,1)
skew	1.00875323	0.01503903	6.70757	0.0	BTC EGARCH(1,1)
shape	2.0186982	8.63E+01	2.338086	0.0	BTC EGARCH(1,1)
mu	0.002797674	0.0001150149	24.3244556	0.0	MSTR EGARCH(1,1)
ar1	0.478442379	0.0326731359	14.6432953	0.0	MSTR EGARCH(1,1)
ar2	0.228962708	0.0100169556	22.8575146	0.0	MSTR EGARCH(1,1)
ar3	0.025130127	0.0111847749	2.2468156	0.02465181	MSTR EGARCH(1,1)
ar4	0.0092894	0.0119092395	0.7800162	0.4353813	MSTR EGARCH(1,1)
ar5	0.007814104	0.0050247861	1.5551118	0.1199194	MSTR EGARCH(1,1)
ar6	0.006604273	0.0033118975	1.9941054	0.04614053	MSTR EGARCH(1,1)
ma1	-0.677111994	0.0280646032	-24.1269043	0.0	MSTR EGARCH(1,1)
ma2	-0.186802227	0.0204385194	-9.1397143	0.0	MSTR EGARCH(1,1)
omega	-0.281836461	0.0411026965	-6.856885	7.04E-06	MSTR EGARCH(1,1)
alpha1	1.014758483	0.1558010916	6.5131667	7.36E-06	MSTR EGARCH(1,1)
beta1	0.728089586	0.0274718319	26.5031319	0.0	MSTR EGARCH(1,1)
gamma1	3.543769995	0.2573343602	13.771072	0.0	MSTR EGARCH(1,1)
	7756	0.0185846538	57.7373014	0.0	MSTR EGARCH(1,1)
	3776	0.0023052054	876.9746916	0.0	MSTR EGARCH(1,1)



Lampiran 7 Tabel Hasil Grid Search Model ARMA(p,q)

Model	AIC	BIC	LB_pval	Asset
ARMA(6,6)	-740,0118	-665,53373	0,998924976	BTC
ARMA(3,3)	-741,8636	-699,3047	0,982185657	BTC
ARMA(4,4)	-737,9389	-684,74022	0,97939657	BTC
ARMA(3,4)	-739,9284	-692,04957	0,976436133	BTC
ARMA(2,2)	-742,472	-710,55283	0,960932525	BTC
ARMA(2,3)	-740,9055	-703,66645	0,953903093	BTC
ARMA(3,2)	-740,929	-703,68999	0,945223369	BTC
ARMA(4,3)	-737,1354	-689,2566	0,943699048	BTC
ARMA(6,1)	-706,2064	-658,32758	0,939898688	BTC
ARMA(2,4)	-738,9378	-696,3789	0,939545127	BTC
ARMA(6,3)	-737,0758	-678,55726	0,915292885	BTC
ARMA(1,6)	-702,7122	-654,83342	0,895939685	BTC
ARMA(3,1)	-708,9168	-676,9976	0,874267662	BTC
ARMA(4,1)	-707,3092	-670,07016	0,860414319	BTC
ARMA(1,4)	-705,6723	-668,43321	0,858436123	BTC
ARMA(4,2)	-707,171	-664,6121	0,856807888	BTC
ARMA(1,3)	-707,3017	-675,38251	0,856331937	BTC
ARMA(6,2)	-740,9681	-687,76944	0,754360458	BTC
ARMA(2,1)	-703,6813	-677,08193	0,447839742	BTC
ARMA(1,2)	-702,8083	-676,20902	0,423582186	BTC
ARMA(6,4)	-766,7481	-702,90973	0,422699802	BTC
ARMA(1,1)	-700,8034	-679,52398	0,249905431	BTC
ARMA(4,6)	-741,2427	-677,40437	0,220237477	BTC
ARMA(3,6)	-757,8205	-699,30199	0,019272126	BTC
ARMA(2,6)	-732,498	-679,29933	0,003849194	BTC
ARMA(3,6)	-139,9772	-81,4587	0,984986844	MSTR
ARMA(2,6)	-141,9284	-88,72977	0,982170202	MSTR
ARMA(6,3)	-149,8273	-91,30884	0,938232724	MSTR
ARMA(6,6)	-161,8383	-87,36017	0,702338112	MSTR
ARMA(1,6)	-127,9931	-80,11427	0,283211561	MSTR
	-124,1493	-76,27049	0,072974635	MSTR
	-160,3709	-107,17224	0,053623491	MSTR
	-116,6776	-79,43859	0,006487373	MSTR
	-118,211	-86,29186	0,005820604	MSTR
	-116,27	-79,03099	0,005572128	MSTR



ARMA(2,2)	-117,7457	-85,82651	0,004722757	MSTR
ARMA(3,3)	-113,798	-71,23904	0,004621923	MSTR
ARMA(3,1)	-118,0612	-86,14202	0,003950743	MSTR
ARMA(1,2)	-118,5199	-91,92056	0,002071764	MSTR
ARMA(2,1)	-116,9201	-90,32077	0,001526362	MSTR
ARMA(1,1)	-111,7063	-90,42683	0,000360485	MSTR

Lampiran 8 Tabel estimasi dua distribusi inovasi (Student- t dan Skewed Student- t)

No.	Aset	Model	Distribusi	AR	MA	GARCH (p,q)	AIC	BIC	Log- Likelihood
1	BTC	GARCH	Student-t	2	2	1,1	-1.741.455	-1.693.577	8.797.277
2	BTC	GARCH	Skewed t	2	2	1,1	-1.739.566	-1.686.368	8.797.832
3	BTC	EGARCH	Student-t	2	2	1,1	-1.797.940	-1.744.742	9.089.701
4	BTC	EGARCH	Skewed t	2	2	1,1	-1.812.919	-1.754.400	9.174.595
5	MSTR	GARCH	Student-t	2	2	1,1	-1.625.666	-1.577.787	8.218.331
6	MSTR	GARCH	Skewed t	2	2	1,1	-1.634.268	-1.581.069	8.271.340
7	MSTR	EGARCH	Student-t	2	2	1,1	-1.731.038	-1.677.839	8.755.190
8	MSTR	EGARCH	Skewed t	2	2	1,1	-1.745.470	-1.686.951	8.837.349

