


**PERBANDINGAN MODEL *THRESHOLD GENERALIZED AUTOREGRESSIVE
CONDITIONAL HETEROSCEDASTICITY* DAN *EXPONENTIAL GENERALIZED
AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY* PADA
PERAMALAN CURAH HUJAN**



**AMALIA ANDRIANINGRUM
H051181501**



**PROGRAM STUDI STATISTIKA DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN
MAKASSAR
2024**

**PERBANDINGAN MODEL *THRESHOLD GENERALIZED AUTOREGRESSIVE
CONDITIONAL HETEROSCEDASTICITY* DAN *EXPONENTIAL GENERALIZED
AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY* PADA
PERAMALAN CURAH HUJAN**

**AMALIA ANDRIANINGRUM
H051181501**



**PROGRAM STUDI STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM UNIVERSITAS
HASANUDDIN
MAKASSAR
2024**

**PERBANDINGAN MODEL *THRESHOLD GENERALIZED AUTOREGRESSIVE
CONDITIONAL HETEROSCEDASTICITY* DAN *EXPONENTIAL GENERALIZED
AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY* PADA
PERAMALAN CURAH HUJAN**

AMALIA ANDRIANINGRUM
H051181501



Skripsi

Diajukan sebagai salah satu syarat memperoleh gelar Sarjana Statistika

Program Studi Statistika

pada

**PROGRAM STUDI STATISTIKA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN
MAKASSAR
2024**

SKRIPSI

PERBANDINGAN MODEL THRESHOLD GENERALIZED AUTOREGRESSIVE
CONDITIONAL HETEROSCEDASTICITY DAN EXPONENTIAL GENERALIZED
AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY PADA
PERAMALAN CURAH HUJAN

AMALIA ANDRIANINGRUM

H051181501

Skripsi,

telah dipertahankan di depan Panitia Ujian Sarjana Statistika pada 09 Desember
2024 dan dinyatakan telah memenuhi syarat kelulusan

pada

PROGRAM STUDI STATISTIKA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN
MAKASSAR

Mengesahkan:
Pembimbing Utama,



Sitti Sahrman, S.Si., M.Si.

NIP. 19881018 201504 2002

Pembimbing Pertama,



Andi Kresna Jaya, S.Si., M.Si.

NIP. 19731228 200003 1001

Mengetahui:

Ketua Departemen Statistika



Amma Islamiyati, S.Si., M.Si.

NIP. 19770808 200501 2002

PERNYATAAN KEASLIAN SKRIPSI DAN PELIMPAHAN HAK CIPTA

Dengan ini saya menyatakan bahwa, skripsi berjudul "*Perbandingan Model Threshold Generalized Autoregressive Conditional Heteroscedasticity dan Exponential Generalized Autoregressive Conditional Heteroscedasticity Pada Peramalan Curah Hujan*" adalah benar karya saya dengan arahan dari pembimbing Ibu Sitti Sahriaman, S.Si., M.Si. sebagai Pembimbing Utama dan Bapak Andi Kresna Jaya, S.Si., M.Si. sebagai pembimbing pertama. Karya ilmiah ini belum diajukan dan tidak sedang diajukan dalam bentuk apapun 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, 09 Desember 2024



AMALIA ANDRIANINGRUM
NIM H051181501

UCAPAN TERIMA KASIH

Segala puji hanya milik Allah Subhanallahu Wa Ta'ala atas limpahan rahmat dan hidayah-Nya kepada penulis. Shalawat dan salam tercurahkan kepada Rasulullah Shallallahu 'Alaihi Wa sallam, keluarganya, tabi'in, tabi'ut tabi'in, serta orang-orang sholeh yang haq hingga kadar Allah berlaku atas diri mereka. Alhamdulillahirobbil'aalamiin, berkat Rahmat dan kemudahan dari Allah Subhanallahu Wa Ta'ala, penulis dapat menyelesaikan skripsi yang berjudul "**Perbandingan Model *Threshold Generalized Autoregressive Conditional Heteroscedasticity* dan *Exponential Generalized Autoregressive Conditional Heteroscedasticity* Pada Peramalan Curah Hujan**" atas bimbingan dan arahan ibu **Sitti Sahriman, S.Si., M.Si.** serta bapak **Andi Kresna Jaya, S.Si., M.Si.** Terima kasih kepada ibu **Anisa, S.Si., M.Si.** Sebagai dosen penguji serta ibu **Prof.Dr.Dr. Georgina Maria Tinungki, M.Si.** sebagai sebagai dosen penguji sekaligus dosen pembimbing akademik yang telah meluangkan waktu dalam memberikan saran dan kritikan yang membangun dalam penyempurnaan tugas akhir ini.

Penulis menyadari bahwa dalam penyelesaian skripsi ini tidak lepas dari bantuan dan dorongan dari berbagai pihak yang senantiasa turut membantu dalam bentuk moril maupun materil sehingga dengan segala keterbatasan kemampuan dan pengetahuan, penulis dapat menyelesaikan skripsi ini. Oleh karena itu, penulis menyampaikan ucapan terima kasih yang setulus-tulusnya serta penghargaan yang setinggi-tingginya kepada orangtua penulis Ayahanda **Andri Widiyanto** Ibunda **Heni Agus Mafitri** beserta seluruh keluarga yang telah memberikan dukungan penuh, pengorbanan luar biasa, limpahan cinta dan kasih sayang, kesabaran hati, serta dengan ikhlas menemani setiap langkah penulis dengan doa.

Akhirnya, saya juga mengucapkan terima kasih kepada **Satriawan Pratama** yang tak kalah penting kehadirannya, memberikan dukungan, semangat, maupun waktu kepada penulis. Teman-teman yang selalu memberikan dukungan, semangat, dan selalu ada menemani, mendengarkan setiap keluh kesah penulis dalam masa sulit semasa perkuliahan hingga penulisan skripsi (**Wardah, Fahira, Kholifah, Rael, Gibe, Iis, Emmy, Anti, Irma**), Teman-teman Statistika Unhas 2018 dan Integral 2018 yang telah memberikan begitu banyak cerita suka dan duka, kenangan, dan kebersamaan selama menjadi bagian dari anggota Himpunan Mahasiswa Statistika Unhas, terkhususnya (**Ninis, Juni, Marsya, Fitrah, Ikki, Rifqah, Putri, Nurul, Dian, Stevani, Victor, Haksar, Syahrul, Edy, Musafir, Kevin, rizky**) dan teman-teman terdekat (**Ipping, Nani, Icha, Varel, Susan, Shinta, Pitto, Bitha, Kak dwi dan Kak Aira**) tak kalah penting kehadirannya, memberikan dukungan, semangat, maupun waktu kepada penulis.

Makassar, 09 Desember 2024



AMALIA ANDRIANINGRUM

ABSTRAK

AMALIA ANDRIANINGRUM. **Perbandingan Model *Threshold Generalized Autoregressive Conditional Heteroscedasticity* dan *Exponential Generalized Autoregressive Conditional Heteroscedasticity* Pada Peramalan Curah Hujan** (dibimbing oleh Sitti Sahriman dan Andi Kresna Jaya).

Latar Belakang. Model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) merupakan salah satu analisis deret waktu yang dapat mengatasi pelanggaran asumsi kehomogenan ragam sisaan (heteroskedastisitas) pada model *Autoregressive Moving Integrated Average* (ARIMA). Akan tetapi, model GARCH memiliki kelemahan dalam menangkap pengaruh keasimetrian pada volatilitas data sehingga perlu dilakukan analisis lebih lanjut menggunakan model *Threshold Generalized Autoregressive Conditional Heteroscedasticity* (T-GARCH) dan Model *Exponential Generalized Autoregressive Conditional Heteroscedasticity* (E-GARCH). **Tujuan.** Penelitian ini adalah memperoleh hasil model terbaik untuk peramalan curah hujan di Kota Makassar periode 01 Januari 2021 hingga 31 Mei 2023. **Metode.** Penelitian ini menggunakan data curah hujan Kota Makassar yang dikumpulkan dari 01 Januari 2021 sampai tanggal 31 Mei 2023, data tersebut dibagi menjadi dua periode, yaitu data training dari 01 Januari 2021 sampai tanggal 31 Desember 2022, dan data testing dari 01 Januari 2023 sampai tanggal 31 Mei 2023 dengan model T-GARCH dan E-GARCH digunakan untuk meramalkan curah hujan di Kota Makassar. **Hasil.** Pemodelan terbaik untuk data periode 01 Januari 2021 hingga 31 Desember 2022 adalah model ARMA (2,1) E-GARCH (1,2) dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 0,411% dan *Mean Squared Error* (MSE) sebesar 508,480 dibandingkan dengan model ARMA (2,1) T-GARCH (2,1) dan nilai MAPE (9,443%) MSE (510,720). **Kesimpulan.** Hasil peramalan curah hujan data periode 01 Januari 2023 hingga 31 Mei 2023 menunjukkan bahwa model ARMA (2,1) E-GARCH (1,2) merupakan model peramalan terbaik berdasarkan nilai MAPE sebesar 0,924% dan nilai *Root Mean Square Error of Prediction* (RMSEP) sebesar 32,641.

Kata Kunci: ARIMA, Volatilitas, GARCH, T-GARCH, E-GARCH, Curah Hujan

ABSTRACT

AMALIA ANDRIANINGRUM. **Comparison of *Threshold Generalized Autoregressive Conditional Heteroscedasticity* and *Exponential Generalized Autoregressive Conditional Heteroscedasticity* Models in Rainfall Forecasting** (supervised by Sitti Sahriman and Andi Kresna Jaya).

Background. The *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) model is a time series analysis that can overcome violations of the assumption of homogeneity of residual variance (heteroscedasticity) in the *Autoregressive Moving Integrated Average* (ARIMA) model. However, the GARCH model has weaknesses in capturing the effect of asymmetry on data volatility, so further analysis needs to be carried out using the *Threshold Generalized Autoregressive Conditional Heteroscedasticity* (T-GARCH) model and the *Exponential Generalized Autoregressive Conditional Heteroscedasticity* (E-GARCH) model. **Objective.** This research is to obtain the best model results for forecasting rainfall in Makassar City for the period 01 January 2021 to 31 May 2023. **Method.** This research uses Makassar City rainfall data collected from 01 January 2021 to 31 May 2023, the data is divided into two periods, namely training data from 01 January 2021 to 31 December 2022, and testing data from 01 January 2023 to 31 May 2023 with the T-GARCH and E-GARCH models used to predict rainfall in Makassar City. **Results.** The best modeling for data for the period 01 January 2021 to 31 December 2022 is the ARMA (2,1) E-GARCH (1,2) model with a *Mean Absolute Percentage Error* (MAPE) value of 0.411% and a *Mean Squared Error* (MSE) of 508.480 compared with ARMA (2.1) T-GARCH (2.1) model and MAPE (9.443%) MSE value (510,720). **Conclusion.** The results of rainfall forecasting data for the period 01 January 2023 to 31 May 2023 show that the ARMA (2,1) E-GARCH (1,2) model is the best forecasting model based on a MAPE value of 0.924% and a *Root Mean Square Error of Prediction* (RMSEP) value.) of 32,641.

Keywords: ARIMA, Volatility, GARCH, T-GARCH, E-GARCH, Rainfall

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
HALAMAN PENGANTAR	ii
HALAMAN PENGESAHAN.....	iii
PERNYATAAN KEASLIAN SKRIPSI	iv
UCAPAN TERIMA KASIH	v
ABSTRAK.....	vi
ABSTRACT	vii
DAFTAR ISI	viii
DAFTAR TABEL	x
DAFTAR GAMBAR	xi
DAFTAR LAMPIRAN.....	xii
DAFTAR ISTILAH.....	xiii
DAFTAR SINGKATAN DAN LAMBANG	xvi
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Batasan Masalah	3
1.3 Tujuan Penelitian.....	3
1.4 Manfaat Penelitian	3
1.5 Landasan Teori.....	3
1.5.1 Analisis Runtun Waktu	3
1.5.2 Stasioneritas	6
1.5.3 Differencing	6
1.5.4 Uji Augmented Dickey Fuller	6
1.5.5 Uji Kesesuaian Model	6
1.5.6 Uji Normalitas Residual	7
1.5.7 Uji Lagrange Multiplier	7
1.5.8 Model ARCH dan GARCH	8
1.5.9 Efek Asimetris	9
1.5.10 Model T-GARCH	9
1.5.11 Model E-GARCH	10
1.5.12 <i>Akaike's Information Criterion</i>	10
1.5.13 Kriteria Tingkat Kesalahan	10
1.5.14 Curah Hujan	12
BAB II METODE PENELITIAN.....	13
2.1 Sumber Data	13
2.2 Variabel Penelitian	13
2.3 Tahapan Analisis Data.....	13
BAB III HASIL DAN PEMBAHASAN	16
3.1 Eksplorasi Data	16
3.2 Uji Stasioner	18
3.3 Model ARMA	18
3.3.1 Identifikasi Model ARMA	18
3.3.2 Estimasi Model ARMA	18

3.3.3 Uji Diagnostik Model	20
3.4 Model GARCH	21
3.4.1 Estimasi Model GARCH	21
3.4.2 Uji Diagnostik Model GARCH	22
3.4.3 Uji Volatilitas.....	24
3.4.4 Uji Asimetris	25
3.5 Model Threshold GARCH	25
3.5.1 Estimasi Model T-GARCH	25
3.5.2 Uji diagnostik Model.....	26
3.5.3 Uji Asimetris T-GARCH	28
3.6 Model Exponential GARCH	28
3.6.1 Estimasi Model E-GARCH	28
3.6.2 Uji Diagnostik Model	30
3.6.3 Uji Asimetris E-GARCH	32
3.7 Uji Kebaikan Model	32
3.8 Validasi Model	32
BAB IV KESIMPULAN	35
4.1 Kesimpulan	35
4.2 Saran.....	35
DAFTAR PUSTAKA.....	36
LAMPIRAN	39

DAFTAR TABEL

Nomor Urut	Halaman
1 Range Nilai MAPE	11
2 Eksplorasi Data	16
3 Uji Augmented Dickey-Fuller.....	18
4 Estimasi Model ARMA.....	19
5 Uji Ljung-Box Model ARMA.....	20
6 Uji Lagrange Multiplier Model ARMA	21
7 Estimasi Model GARCH.....	22
8 Uji Ljung-Box Model GARCH.....	23
9 Uji Lagrange Multiplier Model GARCH	24
10 Persamaan Volatilitas.....	24
11 Uji Sign Bias	25
12 Estimasi Model T-GARCH.....	25
13 Uji Ljung-Box Model T-GARCH.....	27
14 Uji Lagrange Multiplier Model T-GARCH	28
15 Uji Sign Bias T-GARCH.....	28
16 Estimasi Model E-GARCH	29
17 Uji Ljung-Box Model E-GARCH	30
18 Uji Lagrange Multiplier Model E-GARCH.....	31
19 Uji Sign Bias E-GARCH	32
20 Uji Keباikan Model Data Traning	32
21 Validitas Model Data Testing Periode Januari – Mei 2023.....	33

DAFTAR GAMBAR

Nomor Urut	Halaman
1 Plot Time Series Curah Hujan Harian	16
2 Plot Kurtosis dan Skweness Data Curah Hujan Harian	17
3 Plot ACF dan PACF.....	18
4 Uji Jarque-Bera	21
5 Uji Jarque-Bera GARCH	23
6 Uji Jarque-Bera T-GARCH	27
7 Uji Jarque-Bera E-GARCH	31
8 Grafik Curah Hujan dan Peramalan Data Testing	34

DAFTAR LAMPIRAN

Nomor urut	Halaman
1 Data Curah Hujan di Kota Makassar	39
2 Uji Augmented Dickey-Fuller.....	40
3 ACF dan PACF	41
4 Pendugaan Model ARIMA Sementara	43
5 Uji Ljung-Box Model ARIMA.....	48
6 Uji Jarque-Bera Model ARIMA	49
7 Uji Lagrange Multiplier Model ARIMA	49
8 Pendugaan Model GARCH Sementara	50
9 Uji Ljung-Box Model GARCH.....	54
10 Uji Jarque-Bera Model GARCH	55
11 Uji Lagrange Multiplier Model GARCH.....	55
12 Uji Asimetris GARCH	56
13 Uji Sign Bias GARCH.....	57
14 Pendugaan Model T-GARCH Sementara	58
15 Uji Ljung-Box Model T-GARCH.....	62
16 Uji Jarque-Bera Model T-GARCH	63
17 Uji Lagrange Multiplier Model T-GARCH	63
18 Uji Asimetris T-GARCH	64
19 Uji Sign Bias.....	65
20 Pendugaan Model E-GARCH Sementara.....	65
21 Uji Ljung-Box Model E-GARCH	69
22 Uji Jarque-Bera Model E-GARCH.....	70
23 Uji Lagrange Multiplier Model E-GARCH.....	70
24 Uji Asimetris E-GARCH.....	71
25 Uji Sign Bias E-GARCH	72
26 Validasi Data Menggunakan Testing.....	73
27 Model Akhir ARMA-E-GARCH (1,2).....	74
28 Nilai Peramalan Data Curah Hujan.....	75

DAFTAR ISTILAH

Istilah	Arti dan Penjelasan
<i>Homoskedastisitas</i>	Istilah dalam statistik yang merujuk pada kondisi Dimana <i>variance</i> (ragam) dari galat (<i>residual</i>) dalam model regresi bersifat konstan untuk semua nilai <i>variable independent</i> .
<i>Heteroskedastisitas</i>	Istilah dalam statistik yang merujuk pada situasi Dimana <i>variance</i> (keragaman) dari <i>residual</i> atau galat dalam suatu model regresi tidak konstan sepanjang nilai <i>variable independent</i>
<i>Autoregressive</i>	Istilah dalam analisis deret waktu (<i>time series analysis</i>) yang merujuk pada model statistik Dimana nilai saat ini dari suatu <i>variable</i> dipengaruhi oleh nilai-nilai sebelumnya dari <i>variable</i> yang sama
<i>Moving Average</i>	Istilah dalam analisis deret waktu (<i>time series analysis</i>) yang digunakan untuk merujuk pada model statistik Dimana nilai saat ini dari suatu <i>variable</i> dipengaruhi oleh rata-rata tetimbang dari galat (<i>error</i>) atau gangguan acak di masa lalu
<i>Autoregressive Moving Average</i>	Model dalam analisis deret waktu yang menggabungkan dua komponen utama <i>Autoregressive</i> (AR) dan <i>Moving Average</i> (MA), yang digunakan untuk memodelkan data deret waktu yang bersifat stasioner, yaitu data dengan rata-rata, variansi, dan autokorelasi yang tidak berubah seiring waktu
<i>Autoregressive Integrated Moving Average</i>	Model statistik yang digunakan dalam analisis deret waktu untuk memodelkan dan memprediksi data yang tidak stasioner. ARIMA menggabungkan tiga komponen utama yaitu <i>Autoregressive</i> (AR), <i>Integrated</i> (I) dan <i>Moving Average</i> (MA), untuk menangani data deret waktu yang memiliki tren atau pola yang berubah seiring waktu
<i>Autoregressive Conditional Heteroskedasticity</i>	Model statistik yang digunakan untuk menganalisis dan memodelkan variabilitas (<i>volatilitas</i>) yang berubah-ubah pada data deret waktu. Model ini dirancang untuk menangani situasi di mana variansi <i>error</i> (gangguan) tidak konstan seiring waktu, tetapi bergantung pada nilai <i>error</i> sebelumnya.

Istilah	Arti dan Penjelasan
<i>Generalized Autoregressive Conditional Heteroskedasticity</i>	Model statistik yang digunakan untuk memodelkan dan menganalisis volatilitas yang berubah-ubah pada data deret waktu, terutama dalam konteks keuangan. GARCH merupakan pengembangan dari model ARCH (<i>Autoregressive Conditional Heteroskedasticity</i>), dengan menambahkan elemen autoregresif pada variansi kondisional. Model ini sangat berguna untuk menangkap pola volatilitas yang berkelompok (<i>volatility clustering</i>), di mana periode volatilitas tinggi atau rendah cenderung saling mengikuti.
<i>Threshold Generalized Autoregressive Conditional Heteroskedasticity</i>	Model statistik yang dikembangkan untuk menangkap efek asimetri dalam volatilitas deret waktu. Model ini memungkinkan dampak positif dan negatif dari error (kejutan) masa lalu terhadap volatilitas memiliki efek yang berbeda
<i>Exponential Generalized Autoregressive Conditional Heteroskedasticity</i>	Model statistik yang dikembangkan untuk menangkap volatilitas dalam data deret waktu, khususnya dengan mempertimbangkan asimetri dan efek <i>leverage</i> .
Volatilitas	Ukuran statistik yang menggambarkan tingkat variasi atau perubahan harga suatu aset
<i>Autocorelation Function</i>	Fungsi yang menunjukkan besarnya korelasi antara pengamatan pada waktu ke- t dengan pengamatan waktu sebelumnya
<i>Partial Autocorelation Function</i>	Fungsi yang mengukur korelasi antara nilai dalam deret waktu dengan nilai pada <i>lag</i> tertentu, setelah mengontrol efek dari <i>lag-lag</i> yang ada di antaranya
<i>Differencing</i>	Teknik dalam analisis deret waktu yang digunakan untuk membuat data menjadi stasioner dilakukan dengan menghitung selisih antara nilai observasi pada waktu t dengan nilai observasi pada waktu $t-1$
Stasioner	Sifat deret waktu di mana karakteristik statistik seperti rata-rata, variansi, dan autokorelasi tidak berubah seiring waktu.
<i>Augmented Dickey-Fuller</i>	Sebuah uji statistik yang digunakan dalam analisis deret waktu untuk memeriksa stasioneritas suatu data
<i>Jarque-Bera</i>	Uji statistik yang digunakan untuk menentukan apakah suatu data mengikuti distribusi normal (normalitas)

Istilah	Arti dan Penjelasan
<i>White Noise</i>	Sinyal acak yang memiliki rata-rata konstan (biasanya nol), variansi konstan, dan tidak ada autokorelasi
<i>Lagrange Multiplier</i>	Konsep yang digunakan untuk menemukan titik optimum dari sebuah fungsi objektif yang terikat oleh satu atau lebih persamaan pembatas
<i>Lag</i>	Pergeseran waktu antara observasi dalam dataset yang digunakan untuk mengukur hubungan antara nilai-nilai dalam deret waktu dengan nilai-nilai sebelumnya
<i>Mean Absolute Percentage Error</i>	Ukuran statistik yang digunakan untuk mengukur rata-rata kesalahan absolut dalam bentuk persentase relatif terhadap nilai aktual, sehingga memberikan gambaran seberapa besar deviasi prediksi dari nilai sebenarnya
<i>Root Mean Square Error of Prediction</i>	Ukuran statistik yang digunakan untuk mengukur kesalahan prediksi yang menghitung akar rata-rata kuadrat dari selisih antara nilai aktual dan nilai prediksi
<i>Ordo</i>	Tingkat atau derajat komponen yang digunakan dalam model
<i>Asimetris</i>	Istilah yang digunakan untuk menggambarkan sesuatu yang tidak memiliki simetri atau keselarasan dalam bentuk, ukuran, atau susunan
<i>Akaike Information Criterion</i>	Suatu ukuran yang digunakan untuk menilai seberapa baik suatu model statistik menjelaskan data sambil memperhitungkan kompleksitas model tersebut
<i>Testing</i>	Data yang digunakan untuk menguji kinerja model yang telah dilatih dengan data <i>training</i> .
<i>Training</i>	Kumpulan data yang digunakan untuk membangun atau melatih model.

DAFTAR SINGKATAN DAN LAMBANG

LAMBANG/SINGKATAN	Arti dan Penjelasan
Y_t	Observasi deret waktu ke- t yang stasioner
μ	Rataan umum
ϕ_p	Koefisien AR orde p
θ_q	Koefisien MA orde q
$\hat{\phi}_1$	Estimasi dari koefisien lag pertama dalam regresi AR(1)
$\hat{\rho}_k^2$	Autokorelasi sisaan pada lag k
n	Banyaknya data
t	Banyaknya pengamatan
ω	Konstanta model GARCH
σ_t^2	Variansi dari residual pada waktu ke- t
$\hat{y}_t$	Nilai hasil peramalan
e_t	Residual pada waktu ke- t
ε	<i>Residual error</i>
$\hat{\rho}_k^2$	Autokorelasi sisaan pada lag k
$\ln$	<i>Natural Log</i>
SSE	<i>Sum Square Error</i>
ADF	<i>Augmented Dickey-Fuller</i>
AIC	<i>Akaike Information Criterion</i>
GARCH	<i>Generalized Autoregressive Conditional Heteroskedasticity</i>
T-GARCH	<i>Threshold Generalized Autoregressive Conditional Heteroskedasticity</i>
E-GARCH	<i>Exponential Generalized Autoregressive Conditional Heteroskedasticity</i>
ACF	<i>Autocorrelation Function</i>
PACF	<i>Partial Autocorrelation Function</i>
MAPE	<i>Mean Absolute Percentage Error</i>
RMSEP	<i>Root Mean Square Error of Prediction</i>

BAB I

PENDAHULUAN

1.1 Latar Belakang

Cuaca dan iklim merupakan salah satu komponen ekosistem alam. Kehidupan manusia, hewan dan tumbuh-tumbuhan tidak berubah dari pengaruh alam dengan segala prosesnya. Cuaca dan iklim memiliki hubungan dinamis terhadap unsur-unsur cuaca yang lain seperti kelembapan udara, temperature udara dan curah hujan. Informasi data curah hujan sangat berguna dalam berbagai bidang, diantaranya perairan, perhubungan dan pertanian. Peramalan curah hujan digunakan untuk menentukan musim curah hujan atau musim kemarau. Peramalan dapat membantu permasalahan yang akan timbul seperti kekurangan ataupun kekeringan air. Secara umum manfaat informasi data curah hujan adalah meningkatkan kewaspadaan terhadap akibat negatif yang dapat ditimbulkan oleh curah hujan sehingga terhindar dari kerugian dan bencana (Desvina & Ratnawati, 2014). Pengamatan analisis tentang curah hujan sangat kompleks yang melibatkan kondisi ruang dan waktu, sehingga data curah hujan dapat di kelompokkan sesuai ruang dan waktu. Umumnya data curah hujan bersumber dari sebuah stasiun pengamatan pada wilayah tertentu dan disajikan dalam bentuk data time series baik itu harian maupun bulanan (Sinay dkk., 2020).

Curah hujan merupakan fenomena alam yang memiliki dampak yang signifikan bagi kehidupan sehari-hari. Kemampuan untuk dapat memahami serta memprediksi pola curah hujan menjadi sangat penting dan krusial dalam upaya mengatasi risiko bencana alam, perencanaan sumber daya air, dan dilakukannya manajemen lingkungan (Silfiani dkk., 2024). Kota Makassar adalah salah satu wilayah sekaligus ibukota Provinsi Sulawesi Selatan. Secara astronomis, Kota Makassar terletak antara 119°24'17"38" BT dan 5°8'6"19" LS dngan luas wilayah tercatat 175,77 kilometer persegi dari 15 kecamatan. Bahwa peramalan curah hujan menjadi penting sebagai salah satu langkah strategis dalam mengatasi perubahan cuaca.

Berdasarkan penelitian yang dilakukan oleh Sanusi dkk(2017), curah hujan di Makassar menunjukkan variabilitas yang signifikan yang dapat mempengaruhi berbagai sektor, termasuk pengelolaan sumber daya air dan pertanian. Memahami pola curah hujan yang sering menyebabkan banjir dan kekeringan menjadi sangat penting agar risiko tersebut dapat dikelola dengan lebih baik. Karena itu, peramalan yang akurat sangatlah krusial untuk mengurangi dampak negatif dan memastikan manajemen air yang efektif di wilayah ini. Di sinilah peran model-model peramalan cuaca menjadi sangat penting. Model-model ini dipilih karena kemampuannya untuk menganalisis data curah hujan historis dan memproyeksikan pola cuaca di masa depan dengan lebih tepat. Kelebihan utama curah hujan di Makassar, seperti yang dicatat oleh Sanusi dkk (2017), adalah kemampuannya untuk meningkatkan ketersediaan air yang penting bagi pertanian, terutama selama musim hujan. Namun, potensi banjir akibat intensitas hujan yang tinggi dan kekeringan selama musim kemarau menjadi tantangan serius yang dapat diatasi melalui prediksi yang lebih akurat. Dengan peramalan curah hujan yang tepat, pengambil keputusan di sektor-

sektor tersebut dapat merencanakan langkah-langkah antisipatif yang lebih efektif, mulai dari pengaturan sumber daya air hingga mitigasi bencana.

Dalam analisis runtun waktu, terdapat berbagai model peramalan yang digunakan. Salah satu tantangan dalam memodelkan data curah hujan adalah variabilitasnya yang tinggi, di mana fluktuasi curah hujan sering kali tidak stabil dan sulit diprediksi dengan baik oleh model-model konvensional. Variabilitas ini menciptakan heteroskedastisitas, yaitu kondisi di mana varians data berubah dari waktu ke waktu. Untuk itu, penggunaan model yang mampu menangani variabilitas ini menjadi sangat penting. Di sinilah model ARCH dan GARCH menawarkan solusi yang lebih unggul dibandingkan model sebelumnya. Ada dua kategori utama model peramalan dalam runtun waktu, yaitu model dengan varians konstan (*homoskedastisitas*) seperti *Autoregressive Moving Average* (ARMA) dan *Autoregressive Integrated Moving Average* (ARIMA), serta model dengan varians tidak konstan (*heteroskedastisitas*) seperti *Autoregressive Conditional Heteroscedastic* (ARCH) yang dikembangkan oleh Robert Engle (1982) dan *Generalized Autoregressive Conditional Heteroscedastic* (GARCH) yang dikembangkan oleh Bollerslev (1986). Model ARCH/GARCH lebih efektif dalam menangani data yang variabilitasnya berubah-ubah, seperti curah hujan, karena mampu memodelkan ketidakstabilan varians yang sering terjadi dalam data cuaca (Darmawan dkk., 2015).

Pengembangan model GARCH yang selanjutnya mengakomodasi kemungkinan adanya respon volatilitas yang asimetris. Ada beberapa teknik pemodelan respon GARCH asimetris diantaranya yaitu model *Threshold* GARCH oleh Glosten, et al (1993) dan *Exponential* GARCH (E-GARCH) dari Nelson(1991). Pengaruh efek *leverage* yaitu volatilitas meningkat lebih setelah penurunan dari pada setelah kenaikan dalam jumlah yang sama dapat diketahui dengan menggunakan model asimetris berupa model *Threshold* GARCH. E-GARCH diajukan nelson pada tahun 1991 untuk menutupi kelemahan model ARCH/GARCH dalam menangkap fenomena asimetris *good news* dan *bad news* dalam volatilitas. Keadaan yang disebut efek *leverage* ini ditangkap oleh model *Exponential* GARCH (Julia dkk., 2018).

Berdasarkan penelitian yang dilakukan oleh Winata & Hapsari, (2017) yang menerapkan metode *Threshold* GARCH dalam memprediksi harga saham PT. Gudang Garam, Tbk, dari hasil yang diperoleh didapat model terbaik yaitu T-GARCH (1,1). Kemudian pada tahun 2015 Prihandini dkk, melakukan penelitian mengenai Penerapan Model E-GARCH Pada Estimasi Volatilitas Harga Minyak Kelapa Sawit, hasil yang diperoleh yaitu model terbaik untuk harga Minyak Kelapa Sawit adalah E-GARCH (1,1). Selanjutnya penelitian yang dilakukan oleh Wibowo dkk (2016) yang melakukan penelitian Pemodelan Return Saham Perbankan menggunakan *Exponential Generalized Autoregressive Conditional Heteroscedasticity* (E-GARCH), hasil yang diperoleh yaitu model terbaik adalah ARIMA ([2,4],0,[2,4]) E-GARCH (1,1).

Berdasarkan uraian di atas, maka dalam penelitian ini penulis mengkaji mengenai *Threshold Generalized Autoregressive Conditional Heteroscedasticity* dan *Exponential Generalized Autoregressive Conditional Heteroscedasticity* untuk meramalkan curah hujan di Kota Makassar yang dituliskan dalam sebuah tugas akhir

dengan judul “**Perbandingan Model *Threshold Generalized Autoregressive Conditional Heteroscedasticity* dan Model *Exponential Generalized Autoregressive Conditional Heteroscedasticity* Pada Peramalan Curah Hujan**”.

1.2 Batasan Masalah

Berdasarkan permasalahan yang telah diuraikan sebelumnya, batasan masalah pada penelitian ini adalah sebagai berikut.

1. Data curah hujan yang digunakan adalah data curah hujan Kota Makassar dari tanggal 01 Januari 2021 sampai tanggal 31 Mei 2023.
2. Ukuran kebaikan hasil prediksi ditinjau berdasarkan nilai *Root Mean Square Error of Prediction* (RMSEP) dan *Mean Absolute Percentage* (MAPE).

1.3 Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut.

1. Memperoleh estimasi model *Threshold* GARCH dan *Exponential* GARCH untuk data curah hujan.
2. Memperoleh hasil peramalan curah hujan terbaik antara model *Threshold* GARCH dan *Exponential* GARCH.

1.4 Manfaat Penelitian

Diharapkan penelitian ini dapat memberikan informasi ilmiah kepada pembaca mengenai model *Threshold* GARCH, *Exponential* GARCH dan penerapannya dalam kehidupan nyata. Selain itu dapat bermanfaat sebagai sumber informasi tentang curah hujan di Kota Makassar serta memberikan kontribusi terhadap pengembangan ilmu pengetahuan dan teknologi kedepannya.

1.5 Landasan Teori

1.5.1 Analisis Runtun Waktu

Runtun waktu adalah suatu deret observasi yang berturut dalam waktu. Analisis data runtun waktu digunakan untuk melakukan analisis data yang mempertimbangkan pengaruh waktu. Dasar pemikiran runtun waktu adalah pengamatan sekarang (Z_t), $k = 1, 2, \dots, q$. Dengan kata lain. Model runtun waktu dibuat karena secara statistik ada korelasi (dependen) antara deret pengamatan (Arifin dkk., 2017).

Dalam pemodelan data runtun waktu biasanya digunakan model yang diperkenalkan oleh Box dan Jenkins pada tahun 1970 atau biasa disebut dengan model Box Jenkins. Model ini terdiri dari model runtun waktu stasioner adalah model Autoregressive (AR), Moving Average (MA) dan Autoregressive Moving Average (ARMA) dan model runtun waktu tidak stasioner adalah model Autoregressive Integrated Moving Average (ARIMA) (Kelikume & Salami, 2014).

1. Model Autoregressive (AR)

Model *autoregressive* (AR) adalah model yang menggunakan bahwa variabel dependen dipengaruhi oleh variabel depebdeb itu sendiri. Bentuk umum persamaan model AR (p) adalah sebagai berikut (Aritonang & Lerbin, 2009):

$$\phi_p(B)Y_t = \mu + \varepsilon_t$$

$$Y_t = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (1)$$

Dengan :

Y_t	:	observasi deret waktu ke- t yang stasioner
μ	:	rataan umum
$\phi_1, \phi_2, \dots, \phi_p$	:	koefisien model <i>autoregressive</i>
Y_{t-k}	:	observasi pada waktu ke $t - k$, untuk $k = 1, 2, \dots, p$
ε_t	:	sisaaan waktu ke- t

2. Model Moving Average (MA)

Model *moving average* disebut juga sebagai model rata-rata bergerak. *Moving average* (MA) digunakan untuk menjelaskan suatu fenomena bahwa suatu observasi pada waktu ke t dinyatakan sebagai kombinasi linear dari sejumlah acak. Bentuk umum persamaan model MA (q) adalah sebagai berikut (Sugiarto & Harijono, 2000):

$$Y_t = \mu + \phi_p(B)\varepsilon_t$$

$$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2)$$

Dengan :

Y_t	:	observasi deret waktu ke- t yang stasioner
μ	:	rataan umum
$\theta_1, \theta_2, \dots, \theta_q$	:	koefisien model moving average
ε_{t-k}	:	sisaaan pada waktu ke- $t - k$, untuk $k = 1, 2, \dots, q$
ε_t	:	sisaaan waktu ke- t

3. Model Autoregressive-Moving Average (ARMA)

Model ARMA merupakan gabungan dari model AR pada persamaan (2.2) dan MA pada persamaan (2.4). secara umum model ARMA dapat dituliskan sebagai berikut (Aritonang & Lerbin, 2009):

$$\phi_p(B)Y_t = \mu + \theta_q(B)\varepsilon_t$$

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)Y_t = \mu + (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)\varepsilon_t$$

$$Y_t = \mu + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (3)$$

Di mana Y_t adalah kombinasi dari model autoregresi dan model rata-rata bergerak. Y_{t-p} dan ε_{t-q} sama seperti persamaan 1 dan persamaan 2, ϕ dan θ adalah koefisien model p dan q yang menandakan orde dari model ARMA.

Estimasi parameter untuk model *time series* untuk model AR dan model MA menggunakan metode *Conditional Least Squares*, dengan cara meminimumkan jumlah kuadrat *error* (Mokorimban dkk., 2021). Misalkan estimasi parameter untuk Model AR (1) yaitu sebagai berikut.

$$Z_t - \mu = \phi_1(Z_{t-1} - \mu) + a_t$$

Pada model AR (1), parameter yang diestimasi yaitu μ dan ϕ_1 . Jumlah kuadrat error a_t dapat dinotasikan sebagai $S_c(\phi_1, \mu)$ dengan persamaan sebagai berikut.

$$S_c(\phi_1, \mu) = \sum_{t=2}^n [(Z_t - \mu) - \phi_1(Z_{t-1} - \mu)]^2$$

Pada metode *Conditional Least Squares*, nilai estimasi ϕ dan μ didapatkan dengan meminimalkan atau meminimumkan $S_c(\phi_1, \mu)$ yang diamati dari $Z_1, Z_2, Z_3, Z_4, \dots, Z_t$.

Kemudian Persamaan (3.2) dapat diturunkan terhadap parameter μ dan disamakan dengan nol sebagai berikut.

$$\frac{\partial S_c(\phi, \mu)}{\partial \mu} = \sum_{t=2}^n 2[(Z_t - \hat{\mu}) - \hat{\phi}(Z_{t-1} - \hat{\mu})](-1 + \hat{\phi}) = 0$$

Persamaan (3.3) dapat disederhanakan sebagai berikut.

$$\mu = \frac{1}{(n-1)(1-\phi)} \left[\sum_{t=2}^n Z_t - \phi \sum_{t=2}^n Z_{t-1} \right]$$

Untuk n yang besar Persamaan (3.4) dapat disederhanakan sebagai berikut.

$$\hat{\mu} \approx \frac{1}{1-\phi} (Z - \phi \bar{Z}) = \bar{Z}$$

Berdasarkan Persamaan (3.5) didapatkan $\hat{\mu} = \bar{Z}$. Selanjutnya $S_c(\phi, \bar{Z})$ dapat diturunkan terhadap parameter ϕ dan disamakan dengan nol sebagai berikut.

$$\frac{\partial S_c(\phi, \bar{Z})}{\partial \phi} = \sum_{t=2}^n 2[(Z_t - \bar{Z}) - \phi(Z_{t-1} - \bar{Z})](\bar{Z}_{t-1} + \bar{Z}) = 0$$

Persamaan (3.6) menghasilkan nilai parameter ϕ sebagai berikut.

$$\hat{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2}$$

Selanjutnya, estimasi parameter model MA menggunakan metode *Conditional Least Squares* dengan menyamakan $a_0 = 0$ sehingga dapat menentukan nilai θ . Misalkan estimasi parameter model MA (1) yaitu sebagai berikut.

$$Z_t = a_t - \theta a_{t-1}$$

Berdasarkan Persamaan (3.8), nilai $a_1, a_2, a_3, \dots, a_n$ dapat dihitung secara rekursif jika memiliki nilai awal a_0 . Pendekatannya yaitu menetapkan $a_0 = 0$ dan didapatkan Persamaan (3.9) sebagai berikut.

$$\left. \begin{aligned} a_1 &= Z_1 \\ a_2 &= Z_2 + \theta a_1 \\ a_3 &= Z_3 + \theta a_2 \\ &\vdots \\ a_t &= Z_t + \theta a_{t-1} \end{aligned} \right\}$$

Sehingga dapat menghitung $S_c(\theta) = \sum [a_t]^2$, bersyarat pada $a_0 = 0$, untuk nilai tunggal yang diberikan pada θ .

4. Model Autoregressive Integrated Moving Average (ARIMA)

Menurut Wei (2006), model ARIMA merupakan model runtun waktu non stasioner maka perlu dilakukan proses *differencing* agar data menjadi stasioner. Model umum *autoregressive* orde p , *integrate* orde d , dan *moving average* orde q (ARIMA(p,d,q)) merupakan hasil penggabungan antara model AR(p) dengan MA(q) dengan proses non stasioner yang telah distasionerkan. Dalam hal ini, d merupakan orde dari *differencing*. Persamaan umum :

$$\phi_p(B)(1-B)^d Y_t = \theta_q(B) + \varepsilon_t \quad (4)$$

Di mana, $\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$ dan $\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$

1.5.2 Stasioneritas

Secara sederhana suatu data bersifat stasioner jika ia memiliki tendensi untuk bergerak di sekitar nilai tertentu dengan rentang yang konstan serta autokovarians yang konstan. Stasioneritas berarti bahwa tidak terdapat perubahan yang drastis pada data. Fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan variansi dari fluktuasi tersebut (Wibowo dkk., 2016). Dalam mengatasi data yang tidak stasioner terhadap nilai tengah dapat dilakukan proses *differencing* (pembedaan) terhadap data (Aulia dkk., 2019).

1.5.3 Differencing

Proses pembedaan (*differencing*) dilakukan setelah data stasioner dalam varians. Proses pembedaan dilakukan jika data tidak stasioner dalam mean. Proses *differencing* pada orde pertama merupakan selisih antara data ke- t dengan data ke- $t - 1$, yaitu.

$$\Delta Y_t = Y_t - Y_{t-1} \quad (5)$$

Adapun bentuk *differencing* untuk orde kedua, yaitu (Kafara dkk., 2017).

$$\Delta^2 Y_t = \Delta Y_t - \Delta Y_{t-1} = (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) = Y_t - 2Y_{t-1} + Y_{t-2}$$

1.5.4 Uji Augmented Dickey Fuller

Ada beberapa metode uji stasioneritas, salah satunya adalah uji Augmented Dickey-Fuller (ADF) yang dikembangkan oleh Dickey-Fuller. Dalam praktiknya uji ADF inilah yang sering digunakan untuk mendeteksi stasioneritas atau tidaknya data (Iqbal & Ningsih, 2021). Uji ADF dapat dilakukan dengan tahap pengujian hipotesis sebagai berikut :

$H_0: |\phi_1| = 1$ (terdapat akar unit dalam data atau data tidak stasioner)

$H_1: |\phi_1| < 1$ (tidak terdapat akar unit dalam data atau data stasioner)

Statistik uji :

$$T = \frac{\hat{\phi}_1 - 1}{SE(\hat{\phi}_1 - 1)} \quad (6)$$

Kriteria Uji :

H_0 ditolak jika $T < ADF_{n;\alpha}$ atau $P\text{-value} < \alpha$, sehingga Z_t adalah proses stasioner (Wibowo dkk., 2016).

1.5.5 Uji Kesesuaian Model

Sebelum melakukan peramalan maka perlu memeriksa kelayakan dari model yang diperoleh. Uji kelayakan dilakukan yakni pemeriksaan asumsi *white noise* terhadap sisaan atau dugaan kata lain sisaan tidak berkorelasi. Statistik uji yang digunakan dalam memeriksa kelayakan model atau *white noise* adalah uji *Ljung-Box* (*Ljung-Box Test*). Hipotesis yang diuji adalah sebagai berikut :

H_0 : $\rho_1 = \rho_2 = \dots = \rho_k = 0$ (residual bersifat *white noise*)

H_1 : Minimal terdapat satu $\rho_m \neq 0, m = 1, 2, \dots, k$ (residual tidak bersifat *white noise*)

Rumus statistic Uji Ljung-Box (Q) adalah (Cryer & Chan, 2008):

$$Q = N(N + 2) \sum_{n=1}^k \frac{\hat{\rho}_n^2}{N - n} \quad (7)$$

dengan ,

$\hat{\rho}_k^2$: Autokorelasi sisaan pada lag k

N : jumlah data

k : lag waktu ke k

Statistik uji Ljung-Box mengikuti sebaran *chi-square* dengan derajat bebas k. Kriteria Keputusan yaitu H_0 akan ditolak apabila $Q > X_{(k,\alpha)}^2$ atau Ketika $p - value$ lebih kecil dari α , dengan α merupakan taraf nyata yang digunakan pada data (Panjaitan dkk., 2018).

1.5.6 Uji Normalitas Residual

Uji normalitas residual dilakukan untuk mengetahui apakah residual secara normal atau tidak. Nilai residual yang tidak berdistribusi normal juga mengindikasikan adanya respon volatilitas yang asimetris. Pengujian normalitas residual dapat menggunakan uji jarque bera. Hipotesis yang digunakan yaitu :

H_0 : residual berdistribusi normal

H_1 : residual tidak berdistribusi normal

Statistik uji yang digunakan untuk menguji hipotesis adalah :

$$JB = \left[\left(\frac{n}{6} \right) S^2 + \left(\frac{n}{24} \right) (K - 3)^2 \right] \quad (8)$$

Dimana JB adalah *Jarque Bera*, n adalah banyaknya data, S^2 adalah *skewness* dan K adalah *kurtosis*. Jika nilai JB lebih besar dari nilai tabel $X_{(a,n)}^2$ atau probabilitasnya kurang dari 5% maka H_0 ditolak atau residual tidak berdistribusi normal (Fitri dkk., 2021).

1.5.7 Uji Lagrange Multiplier

Robert Engle (1928) mengembangkan pengujian untuk mengetahui masalah heterokedastisitas dalam data deret waktu yang dikenal dengan uji ARCH *Lagrange Multiplier* (ARCH-LM). Ide dasar uji ini adalah bahwa variansi sisaan bukan hanya fungsi dari variabel independen tetapi tergantung pada sisaan kuadrat pada periode sebelumnya. Statistik uji *Lagrange Multiplier* adalah sebagai berikut (Iqbal & Ningsih, 2021) :

Hipotesis :

$H_0: \alpha_1 = \alpha_2 = \dots = \alpha_t = 0$ (sisaan memiliki heterokedastisitas)

H_1 : Minimal ada satu nilai $\alpha_t \neq 0$; $t = 1, 2, \dots, K$ (sisaan tidak memiliki masalah heterokedastisitas)

$$F = \frac{SSR_0/h}{SSR_1/T - h - 1} \quad (9)$$

dengan

$$SSR_0 = \sum_{t=1}^T (\hat{\varepsilon}_t^2 - \bar{\omega})^2$$

$$\bar{\omega} = \frac{\sum_{t=1}^T \varepsilon_t^2}{T}$$

$$SSR_1 = \sum_{t=1}^T u_t^2$$

dimana:

- h : derajat bebas
- $\bar{\omega}$: rata-rata sampel ε_t^2
- u_t^2 : sisaan kuadrat terkecil
- T : merupakan banyaknya pengamatan

1.5.8 Model ARCH dan GARCH

Model ARCH mengasumsikan bahwa varian residual pada suatu titik waktu adalah fungsi dari residual di titik waktu lain. Bentuk umum dari model ARCH(p) (Wibowo dkk., 2016) :

$$\sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \dots + \alpha_p a_{t-p}^2 \quad (10)$$

Bollersleve (1986) mengembangkan model ARCH ke dalam model yang lebih umum yang dikenal sebagai *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). Model ini digunakan untuk mengatasi orde yang terlalu besar pada model ARCH. Bentuk umum model GARCH(p,q) adalah sebagai berikut (Tsay, 2002).

$$\sigma_t^2 = \omega + \sum_k^q \alpha_k \varepsilon_t^2 + \sum_k^p \beta_k \sigma_{t-k}^2 \quad (11)$$

dengan :

- ω : konstanta model GARCH
- σ_t^2 : ragam bersyarat dugaan pada waktu ke $-t$
- α_k : parameter sisaan pada waktu ke $t - k$, untuk $k = 1, 2, \dots, q$
- ε_{t-k} : sisaan pada waktu ke $t - k$, untuk $k = 1, 2, \dots, q$
- β_k : parameter ragam sisaan pada waktu ke k , untuk $k = 1, 2, \dots, q$
- σ_{t-k}^2 : ragam bersyarat pada waktu ke $t - k$, untuk $k = 1, 2, \dots, q$

Koefisien estimasi α_k dan β_k dapat dijumlahkan yang menunjukkan tingkat dari volatilitas. Sehingga volatilitas dapat diketahui dengan melihat dari nilai penjumlahan α_k dan β_k , dimana α_k adalah koefisien ARCH dan β_k adalah koefisien GARCH. Terdapat tolak pengukuran dalam volatilitas yaitu sebagai berikut.

1. *Low volatility* menunjukkan volatilitas yang terjadi rendah ketika $\alpha_k + \beta_k < 1$
2. *High volatility* menunjukkan volatilitas yang terjadi tinggi ketika $\alpha_k + \beta_k = 1$
3. *Extremely high volatility* menunjukkan volatilitas yang terjadi tinggi ketika $\alpha_k + \beta_k > 1$

Nilai penjumlahan koefisien estimasi yang semakin mendekati 1, menunjukkan terjadinya volatilitas atau dapat dikatakan kecenderungan volatilitas berlangsung dalam waktu yang lama atau menunjukkan tingkat volatilitas yang lebih besar. Apabila nilai dari hasil penjumlahan koefisien estimasi semakin mendekati 1.

Sedangkan nilai penjumlahan koefisien estimasi lebih besar dari 1, menunjukkan terjadinya *explosive series* atau gejolak yang besar pada data dan mengakibatkan nilai yang menyimpang lebih besar dari nilai tengah (Lepetit, 2011 dalam Bakari, 2013).

Kelemahan dari model GARCH adalah tidak bisa menangkap pengaruh asimetrik. Pengaruh asimetrik adalah perbedaan besarnya perubahan pada volatilitas ketika terjadi pergerakan nilai return. Keasimetrian yang terjadi dapat berupa korelasi negatif atau positif antara nilai *return* sekarang dengan volatilitas yang akan datang (Untari dkk., 2009). Korelasi negative antara perubahan volatilitas dengan nilai *return*, kecenderungan volatilitas mengalami kenaikan ketika *return* negatif dan akan mengalami penurunan ketika *return* positif disebut efek Leverage (Enders, 2004).

1.5.9 Efek Asimetris

Pengaruh asimetris (*leverage effect*) pada data *time series* dapat di uji setelah membentuk model GARCH, yang kemudian melihat korelasi silang antara kuadrat residual model ARIMA terhadap lag residualnya (Tagliafichi, 2003). Nilai korelasi yang tidak sama dengan nol, atau secara grafik terdapat lag yang keluar dari batas signifikansi menunjukkan adanya efek asimetris pada model. Menurut Tasy, sifat asimetris yaitu perbedaan kenaikan harga atau penurunan harga (*leverage effect*). Sedangkan efek asimetris merupakan kecenderungan penurunan atau kenaikan tingkat volatilitasnya ketika return naik atau turun (Enders, 1995). Pemeriksaan efek asimetris dapat menggunakan uji *sign bias* sebagai berikut.

Hipotesis:

$H_0 = \varphi_1 = \varphi_2 = \dots = \varphi_k = 0$ (residual bersifat simetris)

$H_0 =$ minimal terdapat satu $\varphi_j \neq 0, j = 1, 2, \dots, k$ (residual bersifat asimetris)

Statistik uji:

$$F = \frac{SSR_0/k}{SSR_1/(N - k - 1)} \quad (12)$$

Keterangan:

k = derajat bebas

$SSR_0 = \sum_{t=1}^N (\hat{e}_t^2 - \bar{\omega})^2$

$SSR_1 = \sum_{t=1}^N (u_t^2)$

$\omega = \frac{\sum_{t=1}^N e_t^2}{n}$

u_t^2 = residual kuadrat

n = jumlah data

Kriteria pengujian yaitu tolak H_0 jika $p\text{-value} < \alpha$

1.5.10 Model T-GARCH

Pembahasan ARCH/GARCH sebelumnya berangkat dari asumsi bahwa terdapat gejolak yang bersifat simetris terhadap volatilitas (*symmetric shock to volatility*). Ada dua model yang mengakomodasi gejolak asimetris ini yaitu model T-GARCH dan E-GARCH. Sedangkan spesifikasi untuk varian (*conditional variance*) sebagai berikut :

$$\sigma_t^2 = \alpha_0 + \alpha_1 \sigma_t^2 + \dots + \alpha_p \sigma_{t-p}^p + \phi e_{t-1} d_{t-1} + \lambda_1 \sigma_{t-1}^2 + \dots + \lambda_q \sigma_{t-q}^2 \quad (13)$$

Didalam model T-GARCH ini, berita baik (*good news*) pada periode $t - 1$ ($a_{t-1} < 0$) dan berita buruk (*bad news*) pada periode $t - 1$ ($a_{t-1} > 0$) mempunyai efek yang berbeda terhadap *conditional varian*. Berita baik mempunyai dampak terhadap α dan berita buruk mempunyai dampak terhadap $\alpha + \phi$ jika $\phi \neq 0$ maka terjadi efek asimetris (Julia dkk., 2018).

1.5.11 Model E-GARCH

E-GARCH merupakan eksponensial GARCH. E-GARCH sebagaimana T-GARCH juga mengakomodasi adanya gejala asimetris tersebut. Maka spesifikasi untuk *conditional variance* sebagai berikut :

$$\ln \sigma_t^2 = \sigma^2 + \alpha_1 \left| \frac{a_{t-1}}{\sigma_{t-1}} \right| + \phi_1 \frac{a_{t-1}}{\sigma_{t-1}} + \dots + \alpha_p \left| \frac{a_{t-p}}{\sigma_{t-p}} \right| + \phi_p \frac{a_{t-p}}{\sigma_{t-p}} + \lambda_1 \ln \sigma_{t-1}^2 + \dots + \lambda_q \sigma_{t-q}^2 \quad (14)$$

Pemakaian bentuk $\ln$ pada persamaan *conditional variance* menunjukkan bahwa *conditional* bersifat eksponensial bukan dalam bentuk kuadratik seperti persamaan *conditional variance* di dalam model ARCH/GARCH maupun T-GARCH. Selain itu penggunaan $\ln$ juga menjamin bahwa varian tidak pernah negative. Efek asimetris terjadi jika $\phi \neq 0$ (Julia dkk., 2018).

1.5.12 Akaike's Information Criterion

Akaike's Information Criterion (AIC) adalah salah satu kriteria pemilihan model terbaik yang diperkenalkan oleh Akaike pada tahun 1973 dengan mempertimbangkan banyaknya parameter dalam model. Kriteria AIC dapat dirumuskan sebagai berikut :

$$AIC = n \times \ln \left(\frac{SSE}{n} \right) + 2f + n \times \ln(2\pi) \quad (15)$$

dengan:

- $\ln$: *natural Log*
- SSE : *Sum Square Error*
- n : banyaknya data
- f : banyaknya parameter dalam model
- π : 3,14

Semakin kecil nilai AIC yang diperoleh berarti semakin baik model yang digunakan (Aswi & Sukma, 2006).

1.5.13 Kriteria Tingkat Kesalahan

Dalam semua situasi peramalan pasti mengandung derajat ketidakpastian karena adanya unsur kesalahan dalam perumusan sebuah peramalan deret waktu. Sumber penyimpangan dalam peramalan bukan hanya disebabkan oleh unsur error, tetapi ketidakmampuan suatu model peramalan mengenali unsur yang lain dalam deret data juga dapat mempengaruhi besarnya penyimpangan dalam peramalan. Jadi besarnya penyimpangan hasil peramalan bisa disebabkan oleh besarnya faktor yang tidak diduga (*outliers*) dimana tidak ada metode peramalan yang mampu menghasilkan peramalan yang akurat, atau bisa juga disebabkan metode peramalan yang digunakan tidak dapat memprediksi dengan tepat komponen *trend*, komponen

musiman, atau komponen siklus yang mungkin terdapat dalam deret data, yang berarti metode yang digunakan tidak tepat (Bowerman & O'Connell, 1987).

a. *Mean Absolute Percentage Error*

Mean Absolute Percentage Error (MAPE) adalah nilai rata-rata perbedaan absokute yang ada diantara nilai hasil peramalan dan nilai actual yang disebutkan sebagai hasil presentasi dari nilai actual. Penggunaan MAPE dan RMSEP pada evaluasi dari hasil peramalan dapat melihat tingkat akurasi hasil peramalan dan nilai aktual. Nilai MAPE dapat dihitung menggunakan persamaan berikut :

$$MAPE = \frac{1}{T} \sum_{t=1}^T \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\% \quad (16)$$

dengan

y_t : nilai aktual

$\hat{y}_t$: nilai hasil peramalan

T : Jumlah banyaknya pengamatan

Semakin rendah nilai MAPE, kemampuan dari model peramalan yang digunakan dapat dikatakan baik, dan untuk MAPE terdapat *range* nilai yang dapat dijadikan bahan pengukuran mengenai kemampuan dari suatu model peramalan, *range* nilai tersebut dapat dilihat pada Tabel 2.1 (Maricar, 2019).

Tabel 1 *Range* Nilai MAPE

Range MAPE	Kemampuan Peramalan Model
< 10%	Sangat Baik
10% – 20%	Baik
21% – 50%	Layak
> 50%	Buruk

b. *Root Mean Square Error of Prediction*

Root Mean Square Error of Prediction (RMSEP) merupakan metode alternatif untuk mengevaluasi model yang digunakan dalam peramalan untuk mengukur tingkat akurasi hasil perkiraan dari model tersebut. Nilai yang dihasilkan RMSEP merupakan nilai rata – rata kuadrat dari jumlah kesalahan pada model prediksi. RMSEP merupakan besarnya tingkat kesalahan hasil prediksi, dimana semakin kecil (mendekati 0) nilai RMSEP maka hasil prediksi akan semakin akurat. Nilai RMSEP dapat dihitung dengan persamaan sebagai berikut (Sanjaya & Heksaputra, 2020).

$$RMSEP = \sqrt{\frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2} \quad (17)$$

dengan:

y_t : nilai aktual

$\hat{y}_t$: nilai hasil peramalan

T : jumlah data

1.5.14 Curah Hujan

Curah hujan (mm) merupakan ketinggian air hujan yang jatuh pada tempat yang datar dengan asumsi tidak menguap, tidak meresap dan tidak mengalir. Curah hujan 1 (mm) adalah air hujan setinggi 1 (mm) yang jatuh (tertampung) pada tempat yang datar seluas 1 m^2 dengan asumsi tidak ada yang menguap, mengalir dan meresap. Kepulauan Maritim Indonesia yang berada di wilayah tropik memiliki curah hujan tahunan yang tinggi, curah hujan semakin tinggi di daerah pegunungan. Curah hujan yang tinggi di wilayah tropis pada umumnya dihasilkan dari proses konveksi dan pembentukan awan hujan panas. Pada dasarnya curah hujan dihasilkan dari gerakan massa udara lembab ke atas. Agar terjadi gerakan ke atas, atmosfer harus dalam kondisi tidak stabil. Kondisi tidak stabil terjadi jika udara yang naik lembab dan *lapse rate* udara lingkungannya berada antara *lapse rate* adiabatik kering dan *lapse rate adiabatik* jenuh. Jadi kestabilan udara ditentukan oleh kondisi kelembapan. Karena itu jumlah hujan tahunan, intensitas, durasi, frekuensi dan distribusinya terhadap ruang dan waktu sangat bervariasi. Karena proses konveksi, intensitas curah hujan di wilayah tropis pada umumnya tinggi. Sementara itu di Indonesia, presentase curah hujan yang diterima bervariasi antara 8% sampai 37% dengan rata-rata 22% (Mulyono dkk., 2014).

BAB II METODE PENELITIAN

2.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data skunder yaitu data curah hujan kota makassar dari tanggal 1 Januari 2021 sampai tanggal 30 Mei 2023. Data curah hujan rata-rata di kota Makassar Sulawesi Selatan tahun 2021-2023 diperoleh dari stasiun BMKG wilayah IV Makassar. Data yang di pakai adalah data curah hujan. Di dalam penelitian ini digunakan data harian yang berjumlah 881 data dan akan diramalkan menggunakan *software Eviews*.

2.2 Variabel Penelitian

Variabel yang digunakan dalam penelitian ini adalah curah hujan dari tanggal 01 Januari 2021 sampai tanggal 31 Mei 2023 yang terdiri dari 881 observasi. Data dibagi menjadi dua bagian yaitu data *training* dan data *testing* dengan perbandingan 80% dan 20%. Data *training* terdiri dari 730 observasi yang merupakan data pada interval waktu 01 Januari 2021 sampai tanggal 31 Desember 2022, sedangkan untuk data *testing* terdiri atas 151 observasi yaitu data pada interval waktu 01 Januari 2023 sampai tanggal 31 Mei 2023.

2.3 Tahapan Analisis Data

Langkah-langkah analisis data yang dilakukan dalam penelitian ini adalah sebagai berikut :

1. Melakukan eksplorasi data dengan melihat plot *time series* curah hujan dan mengidentifikasi terjadinya fluktuasi serta karakteristik data dengan menggunakan statistic deskriptif.
2. Melakukan uji stasioneritas data menggunakan uji *Augmented Dickey Fuller* (ADF) Jika data yang dianalisis tidak stasioner maka dapat diatasi dengan melakukan *differencing*, yaitu menghitung perubahan data pengamatan ke- t dan $t - 1$.
3. Mengidentifikasi model ARIMA (p, d, q) dengan melihat plot ACF dan PACF
4. Melakukan pemeriksaan diagnostic sisaan yang meliputi pengujian sisaan saling bebas dengan menggunakan uji *Ljung-Box*, pengujian sisaan saling menyebar normal dengan menggunakan uji *Jarque-Bera*, dan pengujian sisaan homogen menggunakan uji *Langrange Multiplier* untuk medeteksi adanya pengaruh ARCH/GARCH pada data.

Pengujian *Ljung-Box* menggunakan Persamaan (21)

$$Q = n(n+2) \sum_{i=1}^k (n-i)^{-1} \hat{\rho}_i^2$$

Hipotesisi:

H_0 : $\rho_1 = \rho_2 = \dots = \rho_k = 0$ (residual bersifat *white noise*)

H_1 : Minimal terdapat satu $\rho_m \neq 0, m = 1, 2, \dots, k$ (residual tidak bersifat *white noise*)

Pengujian *Jarque-Bera* menggunakan Persamaan (8) :

$$JB = \left[\left(\frac{n}{6} \right) S^2 + \left(\frac{n}{24} \right) (K - 3)^2 \right] \quad (8)$$

Hipotesis :

H_0 : residual berdistribusi normal

H_1 : residual tidak berdistribusi normal

Pengujian *Langrange Multiplier* menggunakan Persamaan (9) :

$$F = \frac{SSR_0/h}{SSR_1/(T-h-1)} \quad (9)$$

Hipotesis :

$H_0: \alpha_1 = \alpha_2 = \dots = \alpha_t = 0$ (sisaan memiliki heterokedastisitas)

H_1 : Minimal ada satu nilai $\alpha_t \neq 0$; $t = 1, 2, \dots, K$ (sisaan tidak memiliki masalah *hetrokedastisitas*)

5. Uji asimetris

Uji asimetris menggunakan *Sign Bias* dengan Persamaan (12) :

$$F = \frac{SSR_0/k}{SSR_1/(N-k-1)} \quad (12)$$

Untuk mengetahui efek asimetris pada residual data.

6. Estimasi parameter model varian

Pada model varian GARCH, T-GARCH, dan E-GARCH akan dilakukan estimasi parameter menggunakan *Maximum Likelihood Estimation* dengan menetapkan persamaan yang tepat untuk mean dan varians.

7. Melakukan estimasi model GARCH

8. Pemodelan *Threshold Generalized Autoregressive Conditional Heteroscedastic* (T-GARCH)

Persamaan T-GARCH(p, q) adalah sebagai berikut :

$$\sigma_t^2 = \alpha_0 + \sum_{j=1}^q (\alpha_j + \gamma_j S_{t-1}^-) \sigma_{t-j}^2 + \sum_{i=1}^p \beta_i \sigma_{t-i}^2 \quad (13)$$

9. Pemodelan *Exponential Generalized Autoregressive Conditional Heteroscedastic* (E-GARCH)

$$\ln(\sigma_t^2) = \omega + \beta \sum_{j=1}^q \ln(\sigma_{t-j}^2) + \sum_{i=1}^p \left\{ \alpha_i \left(\left| \frac{\varepsilon_{t-i}}{\sigma_{t-i}} \right| - \sqrt{\frac{2}{\pi}} \right) - \gamma_i \frac{\varepsilon_{t-i}}{\sigma_{t-i}} \right\} \quad (14)$$

10. Menghitung nilai AIC model T-GARCH dan E-GARCH dan dipilih nilai AIC terkecil dari model T-GARCH dan E-GARCH.

11. Validasi model

Setelah didapatkan model terbaik, maka dilakukan validasi untuk memastikan keakuratan dan ketepatan model dengan menggunakan data Training periode 01 Januari 2021 hingga 31 Desember 2022

12. Melakukan perhitungan ketepatan hasil peramalan menggunakan model Threshold GARCH dan Exponential GARCH dengan melihat MAPE pada persamaan (16) dan RMSEP pada Persamaan (17).

$$MAPE = \frac{1}{T} \sum_{t=1}^T \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\% \quad (16)$$

$$RMSEP = \sqrt{\frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2} \quad (17)$$