

**ESTIMASI GAUSS-NEWTON DALAM MODEL
LOGISTIC SMOOTH TRANSITION AUTOREGRESSIVE
PADA DATA HARGA SAHAM
PT TELKOM INDONESIA (PERSERO)**

SKRIPSI

**OLEH
MELY RAHMATILLAH
NIM. 220601110085**



**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG
2026**

**ESTIMASI *GAUSS-NEWTON* DALAM MODEL
LOGISTIC SMOOTH TRANSITION AUTOREGRESSIVE
PADA DATA HARGA SAHAM
PT TELKOM INDONESIA (PERSERO)**

SKRIPSI

**Diajukan Kepada
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
untuk Memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Matematika (S.Mat)**

**Oleh
Mely Rahmatillah
NIM. 220601110085**

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG
2026**

**ESTIMASI GAUSS-NEWTON DALAM MODEL
LOGISTIC SMOOTH TRANSITION AUTOREGRESSIVE
PADA DATA HARGA SAHAM
PT TELKOM INDONESIA (PERSERO)**

SKRIPSI

**Oleh
Mely Rahmatillah
NIM. 220601110085**

Telah Diperiksa dan Disetujui untuk Diuji
Malang, 16 April 2026

Dosen Pembimbing I


Abdul Aziz, M.Si
NIP. 19760318 200604 1 002

Dosen Pembimbing II


Mohammad Nafie Jauhari, M.Si
NIPPPK. 19870218 202321 1 018

Mengetahui,
Ketua Program Studi Matematika


Dr. Fachrur Rozi, M.Si
NIP. 19800527 200801 1 012

**ESTIMASI GAUSS-NEWTON DALAM MODEL
LOGISTIC SMOOTH TRANSITION AUTOREGRESSIVE
PADA DATA HARGA SAHAM
PT TELKOM INDONESIA (PERSERO)**

SKRIPSI


Oleh
Mely Rahmatillah
NIM. 220601110085

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima sebagai Salah Satu Persyaratan
untuk Memperoleh Gelar Sarjana Matematika (S.Mat)
Tanggal 25 Mei 2026

Ketua Penguji : Prof. Dr. Sri Harini, M.Si


.....

Anggota Penguji 1 : Dr. Fachrur Rozi, M.Si


.....

Anggota Penguji 2 : Abdul Aziz, M.Si


.....

Anggota Penguji 3 : Mohammad Nafie Jauhari, M.Si


.....

Mengetahui,
Ketua Program Studi Matematika



Dr. Fachrur Rozi, M.Si
NIM. 119800527 200801 1 012

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Mely Rahmatillah
NIM : 220601110085
Program Studi : Matematika
Fakultas : Sains dan Teknologi
Judul Skripsi : Estimasi *Gauss-Newton* dalam Model *Logistic Smooth Transition Autoregressive* pada Data Harga Saham PT Telkom Indonesia (Persero)

Menyatakan dengan sebenarnya bahwa skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambilan data, tulisan atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka. Apabila di kemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 25 Mei 2026

Yang membuat pernyataan,



Mely Rahmatillah

NIM. 220601110085

MOTO

”Allah has perfect timing; never early, never late. It takes a little patience and a lot of faith. But it’s always worth the wait”

PERSEMBAHAN

Skripsi ini penulis persembahkan kepada:

Kedua orang tua hebat, yakni bapak dan Ibu tercinta, yang tak pernah lelah mendoakan dalam diam, menguatkan tanpa diminta, dan berkorban tanpa berharap balasan. Setiap langkah yang penulis tempuh hingga saat ini tidak lepas dari kasih sayang, kepercayaan, dan ketulusan yang begitu besar. Kakak-kakak serta seluruh keluarga besar, yang selalu menjadi tempat pulang, sumber semangat, dan penguat di setiap keadaan. Dan untuk diri sendiri, terima kasih karena telah bertahan sejauh ini, melewati lelah dan ragu namun tetap memilih untuk bangkit dan melangkah hingga akhirnya sampai pada titik ini, titik dimana penulis bisa seperti yang lain.

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Alhamdulillah, puji syukur kami panjatkan kehadirat Allah SWT atas segala rahmat, karunia, dan hidayah-Nya, sehingga penulis dapat menyusun skripsi ini dengan judul "*Estimasi Gauss Newton dalam Model Logistic Smooth Transition Autoregressive pada Data Harga Saham PT Telkom Indonesia (Persero)*". Sholawat serta salam semoga senantiasa terlimpahkan kepada junjungan kita Nabi Muhammad SAW, beserta keluarga, para sahabat, dan seluruh umat manusia yang selalu istiqamah menjalankan ajarannya.

Dalam proses penyusunan proposal ini, penulis mendapatkan banyak dukungan, bimbingan, arahan dan masukan dari berbagai pihak. Oleh karena itu, dengan segala kerendahan hati, penulis menyampaikan rasa hormat dan terima kasih yang sebesar-besarnya kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si, selaku Rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Agus Mulyono, M.Kes, selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Dr. Fachrur Rozi, M.Si, selaku Ketua Program Studi Matematika Universitas Islam Negeri Maulana Malik Ibrahim serta sebagai Anggota Penguji I dalam ujian skripsi yang telah memberikan arahan, saran, dan ilmu yang bermanfaat bagi peneliti.
4. Abdul Aziz, M.Si, selaku Dosen Pembimbing I yang telah memberikan berbagai bimbingan, ilmu pengetahuan, arahan dan motivasi kepada penulis.
5. Mohammad Nafie Jauhari, M.Si, selaku Dosen Pembimbing II yang telah memberikan berbagai bimbingan, ilmu pengetahuan, arahan dan motivasi kepada penulis.
6. Prof. Dr. Hj. Sri Harini, selaku Ketua Penguji dalam ujian skripsi yang telah memberikan arahan, masukan, saran, dan ilmu yang bermaaat bagi penulis.

7. Juhari, M.Si selaku Dosen Wali selama masa perkuliahan yang telah memberikan semangat dan motivasi kepada penulis dalam menjalani perkuliahan.
8. Seluruh Dosen Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
9. Rekan seperjuangan dalam penelitian yang saling menyemangati serta banyak membantu penulis.
10. Seluruh teman-teman mahasiswa angkatan 2022 yang telah memberikan bantuan dan dukungan kepada penulis.

Semoga Allah SWT memberikan balasan yang terbaik atas kebaikan serta keikhlasan yang diberikan kepada penulis. Pada akhirnya penulis berharap semoga penelitian ini dapat memberikan manfaat bukan hanya bagi penulis melainkan kepada pembaca untuk menambah wawasan dan ilmu pengetahuan serta penulis berharap akan adanya saran dan kritik terhadap penelitian ini.

Wassalamu'alaikum Warahmatullahi Wabarakatuh

Malang, 25 Mei 2026

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	vi
PERNYATAAN KEASLIAN TULISAN	v
MOTO	vi
PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xiii
DAFTAR SIMBOL	xiv
DAFTAR LAMPIRAN	xvi
ABSTRAK	xvii
ABSTRACT	xviii
مستخلص البحث	xix
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	6
1.3 Tujuan Penelitian	6
1.4 Manfaat Penelitian	7
1.5 Batasan Masalah	8
1.6 Definisi Istilah	8
BAB II KAJIAN TEORI	10
2.1 Teori Pendukung	10
2.1.1 <i>Time Series</i>	10
2.1.2 Fungsi Transisi	12
2.1.3 Pembagian Data	13
2.1.4 Uji Asumsi	13
2.1.5 Pembentukan Model <i>Autoregressive</i>	20
2.1.6 Estimasi <i>Gauss-Newton</i>	22
2.1.7 Transformasi Data	27
2.1.8 Evaluasi Model	27
2.1.9 Saham	28
2.2 Kajian Intergrasi dengan Al-Qur'an	29
2.3 Kajian Topik dengan Teori Pendukung	30
BAB III METODE PENELITIAN	32
3.1 Jenis Penelitian	32
3.2 Data dan Sumber Data	32
3.3 Teknik Analisis Data	32
3.4 Diagram Alir	36
BAB IV HASIL DAN PEMBAHASAN	39
4.1 Statistik Deskripsi Data	39
4.2 Uji Stasioner	40
4.3 Identifikasi Model ARIMA	42

4.4	Estimasi Parameter <i>Autoregressive</i>	44
4.5	Uji Linieritas <i>Langrange Multiple</i>	44
4.6	Identifikasi Model STAR	46
4.7	Estimasi <i>Gauss-Newton</i>	48
4.8	Uji Asumsi Residual.....	56
4.8.1	Uji Autokorelasi Residual.....	56
4.8.2	Uji Heteroskedastisitas Residual	57
4.8.3	Uji Normalitas Residual	58
4.9	Prediksi dan Transformasi.....	59
4.10	Evaluasi Model.....	61
4.11	Kajian Integrasi Penelitian dalam Islam.....	62
BAB V PENUTUP		65
5.1	Kesimpulan.....	65
5.2	Saran.....	66
DAFTAR PUSTAKA.....		67
LAMPIRAN.....		71
RIWAYAT HIDUP.....		99

DAFTAR TABEL

Tabel 2.1	Tingkat Akurasi Nilai MAPE	28
Tabel 4.1	Banyak Observasi.....	39
Tabel 4.2	Uji Stasioneritas	41
Tabel 4.3	Uji Stasioneritas pada Differencing Orde Pertama	42
Tabel 4.4	Estimasi Parameter	44
Tabel 4.5	Uji Linieritas Model AR(2)	46
Tabel 4.6	Estimasi Model Regresi Bantu	48
Tabel 4.7	Nilai SSE	54
Tabel 4.8	Estimasi Model LSTAR(2,1).....	55
Tabel 4.9	Hasil Uji Autokorelasi Residual	57
Tabel 4.10	Hasil Uji Heteroskedastisitas Residual	58
Tabel 4.11	Hasil Uji Normalitas Residual.....	59

DAFTAR GAMBAR

Gambar 3.1 Diagram Alir Penelitian.....	36
Gambar 4.1 Plot Pergerakan Harga Saham PT TELKOM.....	39
Gambar 4.2 Plot Data <i>Training</i>	42
Gambar 4.3 Plot Data <i>Testing</i>	43
Gambar 4.4 Grafik Perbandingan Harga Saham pada Data <i>Testing</i>	61
Gambar 4.5 Grafik <i>Error</i> pada Data <i>Testing</i>	62

DAFTAR SIMBOL

Y_t	: Nilai aktul pada waktu ke- t
X_{t-i}	: Harga saham pada <i>lag</i> i
t	: Periode waktu harga saham
X_t	: Nilai aktual harga saham pada waktu ke- t
φ_0	: Konstan (<i>intercept</i>) model <i>autoregressive</i>
φ_i	: Parameter model <i>autoregressive</i> , pada lag ke- i
p	: Orde pada model <i>autoregressive</i>
ε_t	: <i>Error</i> ke- t
$G(s_t; \gamma; c)$	: Fungsi transisi dengan nilai $[0,1]$
s_t	: Harga saham <i>lag</i> d ($1 \leq d \leq p$)
γ	: Parameter pemulusan
c	: <i>Threshold</i>
d	: Orde <i>differencing</i>
φ_{10}	: Konstan <i>autoregressive</i> rezim pertama
φ_{20}	: Konstan <i>autoregressive</i> rezim kedua
φ_{1i}	: Parameter <i>autoregressive</i> rezim pertama pada lag ke- i
φ_{2i}	: Parameter <i>autoregressive</i> rezim kedua pada lag ke- i
$\hat{\Phi}$	: Estimator Φ
$se(\hat{\Phi})$	: Standar residual dari estimator parameter $\hat{\Phi}$
n	: ukuran sampel
SSE_0	: Jumlah kuadrat residual model $AR(p)$
β_{00}	: Konstanta regresi bantu
$\beta_{1i}, \beta_{2i}, \beta_{3i}$	: Parameter regresi bantu
e_t	: Residual regresi bantu
$\hat{\beta}_{ji}$	: Estimator koefisien
$se(\hat{\beta}_{ji})$	: <i>standard error</i> dari koefisien regresi $\hat{\beta}_{ji}$
N	: Jumlah residual model

w	: Jumlah lag maksimum
SSR	: Jumlah kuadrat dari model regresi kuadrat residual
R^2	: Koefisien determinasi regresi residual
SST	: Jumlah kuadrat total dari kuadrat residual terhadap rata-rata
D	: Nilai statistik uji Kolmogorov Smirnov
$s(x)$	: Fungsi distribusi kumulatif dari data residual
f	: Fungsi model LSTAR
θ	: Vektor parameter LSTAR dengan estimasi <i>Gauss-Newton</i>
$\hat{\theta}$	: Parameter optimal hasil estimasi
J	: Matriks Jacobian
$M(\theta)$	: Jumlah kuadrat residual (<i>error</i>)
r	: Residual
$\hat{Y}_t$	: Prediksi harga saham

DAFTAR LAMPIRAN

Lampiran 1.	Data Harga Saham PT Telkom Indonesia (Persero) (Y_t)	71
Lampiran 2.	Data Harga Saham PT Telkom Indonesia (Persero) pada <i>Differencing</i> Orde Pertama (X_t).....	74
Lampiran 3.	Nilai AIC pada Masing-Masing Model ARIMA	77
Lampiran 4.	Residual Model <i>Autoregressive</i> (2) (ε_t)	78
Lampiran 5.	Residual Regresi Bantu dengan Variabel Transisi (e_t).....	80
Lampiran 6.	Tabel <i>Chi Square</i>	82
Lampiran 7.	Hasil <i>Grid Seacrh</i>	83
Lampiran 8.	Hasil Prediksi Harga Saham <i>Differencing</i> Orde Pertama pada Data <i>Testing</i> PT Telkom Indonesia (Persero) ($\hat{X}_t$)	84
Lampiran 9.	Perbandingan Data Aktual (Y_t) dan Data Prediksi ($\hat{Y}_t$) Harga Saham PT Telkom Indonesia (Persero) pada Data <i>Testing</i>	85
Lampiran 10.	Nilai <i>error</i> Model LSTAR(2,1) pada Data <i>Testing</i> Harga Saham PT Telkom Indonesia (Persero)	86
Lampiran 11.	Syntax Model LSTAR dengan Estimasi <i>Gauss-Newton</i>	87

ABSTRAK

Rahmatillah, Mely. 2026. **Estimasi *Gauss-Newton* dalam Model *Logistic Smooth Transition Autoregressive* pada Data Harga Saham PT Telkom Indonesia (PERSERO)**. Skripsi. Program Studi Matematika Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
Pembimbing: (I) Abdul Aziz, M.Si. (II) Mohammad Nafie Jauhari, M.Si.

Kata Kunci: *Time Series* Nonlinier, LSTAR, *Gauss-Newton*, Saham.

Pergerakan harga saham bersifat fluktuatif dan tidak selalu dapat direpresentasikan dengan model linier, sehingga diperlukan pendekatan nonlinier. Salah satu model *time series* nonlinier yang sering digunakan adalah model *Smooth Transition Autoregressive* (STAR). Model STAR berdasarkan fungsi transisi dibagi menjadi dua, yaitu *logistic* dan *exponential*. Penelitian ini bertujuan untuk memperoleh model *Logistic Smooth Transition Autoregressive* (LSTAR) serta mengukur tingkat akurasi model dalam memprediksi harga saham PT Telkom Indonesia (Persero). Data yang digunakan adalah data harga penutupan saham mingguan selama periode 6 Januari 2019 hingga 26 April 2026. Estimasi model LSTAR dilakukan menggunakan algoritma *Gauss-Newton*, yaitu metode iteratif berbasis pendekatan turunan untuk menyelesaikan masalah nonlinier. Hasil penelitian menunjukkan bahwa model yang diperoleh adalah LSTAR(2,1) dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 0,71%, yang menunjukkan tingkat akurasi model sangat baik.

ABSTRACT

Rahmatillah, Mely. 2026. **Gauss-Newton Estimation in the Logistic Smooth Transition Autoregressive Model for PT Telkom Indonesia (Persero) Stock Price Data.** Undergraduate Thesis. Mathematics Study Program, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
Advisors: (I) Abdul Aziz, M.Si. (II) Mohammad Nafie Jauhari, M.Si.

Keywords: Nonlinier Time Series, LSTAR, Gauss-Newton, Stock.

The movement of stock prices is fluctuative and cannot always be represented by a linear model, thus a nonlinear approach is required. One of the nonlinear time series models commonly used is the Smooth Transition Autoregressive (STAR) model. Based on the transition function, the STAR model is divided into two types: logistic and exponential. This study aims to obtain a Logistic Smooth Transition Autoregressive (LSTAR) model and to measure the accuracy level of the model in predicting the stock price of PT Telkom Indonesia (Persero). The data used consist of weekly closing stock prices from January 6, 2019 to April 26, 2026. The estimation of the LSTAR model is carried out using the Gauss-Newton algorithm, an iterative method based on derivative approaches to solve nonlinear problems. The results show that the obtained model is LSTAR(2,1) with a Mean Absolute Percentage Error (MAPE) value of 0,71%, indicating a very high level of accuracy.

مستخلص البحث

رحمة الله، ميلي. ٢٠٢٦. تقدير غاوس-نيوتن في نموذج الانحدار الذاتي ذو الانتقال السلس اللوجستي *Logistic Smooth Transition Autoregressive* على بيانات أسعار أسهم شركة تلكوم إندونيسيا (Persero). الحث العلي (بكالوريوس). قسم الرياضيات، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانغ.

المشرف (١): عبد العزيز، الماجستير في العلوي. (٢): محمد نافع جوهر ي ، الماجستير في العلوي.

الكلمات الأساسية: السلاسل الزمنية غير الخطية، *LSTAR*، غاوس-نيوتن، الأسهم.

تتسم تحركات أسعار الأسهم بالتقلب، ولا يمكن دائماً تمثيلها باستخدام نماذج خطية، لذلك يتطلب الأمر استخدام منهجيات غير خطية. ومن بين نماذج السلاسل الزمنية غير الخطية الشائعة الاستخدام نموذج الانحدار الذاتي ذو الانتقال السلس *Smooth Transition Autoregressive*. وينقسم هذا النموذج بناءً على دالة الانتقال إلى نوعين، وهما اللوجستي والأسّي. تهدف هدفت الدراسة إلى الحصول على نموذج الانحدار الذاتي ذو الانتقال السلس اللوجستي (*LSTAR*)، وكذلك قياس مستوى دقة النموذج في التنبؤ بأسعار أسهم شركة تلكوم إندونيسيا (Persero). تم استخدام بيانات أسعار الإغلاق الأسبوعية للأسهم خلال الفترة من ٦ يناير ٢٠١٩ حتى ٢٦ أبريل ٢٠٢٦. وتم تقدير النموذج باستخدام خوارزمية غاوس-نيوتن، وهي طريقة تكرارية تعتمد على تقريب المشتقات لحل المشكلات غير الخطية. وأظهرت نتائج الدراسة أن النموذج المتحصل عليه هو نموذج الانحدار الذاتي ذو الانتقال السلس اللوجستي من الرتبة (٢،١)، حيث بلغت قيمة متوسط نسبة الخطأ المطلق (*MAPE*) ٠,٧١٪، مما يدل على أن مستوى دقة النموذج مرتفع جداً.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Analisis deret waktu (*time series*) merupakan salah satu metode statistik yang banyak digunakan untuk mempelajari hubungan antar variabel dalam data runtut waktu. Brandt (2014) mendefinisikan *time series* sebagai rangkaian pengamatan suatu variabel yang dicatat pada interval waktu. Melalui analisis, dapat diidentifikasi suatu pola yang kemudian digunakan untuk membangun model dan melakukan peramalan yang dapat digunakan dalam berbagai bidang, seperti ekonomi, industri, bisnis, pertanian, maupun sosial.

Dalam penelitian Ning dkk. (2022), model *time series* diklasifikasikan ke dalam dua kelompok, yakni model linier dan model nonlinier. Ada beberapa metode yang digunakan untuk melakukan peramalan dalam model linier, yakni *time series regression*, *exponential smoothing*, dan *Autoregressive Integrated Moving Average* (ARIMA). Metode deret waktu linier, seperti ARIMA memang sering digunakan dan diperoleh hasil yang cukup optimal jika data yang digunakan menunjukkan sifat linier. Namun, ketika data mengandung *noise* atau memperlihatkan fluktuasi yang ekstrem, performa model deret waktu linier menjadi kurang efektif (Putri dkk., 2017). Hal ini menunjukkan bahwa ada sejumlah fenomena yang tidak dapat digambarkan secara tepat jika hanya menggunakan pendekatan linier, sehingga dilakukan pendekatan nonlinier (Ruey S & Rong, 2019).

Model *Threshold Autogressive* (TAR) diperkenalkan oleh Tong (1983) sebagai salah satu bentuk awal dari model *time series* nonlinier. Model ini

memungkinkan perubahan dinamika sistem ketika suatu variabel melewati nilai ambang (*Thresold*) tertentu, sehingga hubungan antar variabel dapat berbeda di setiap rezim. Namun, perubahan antar rezim pada model TAR terjadi secara tiba-tiba, sehingga dalam beberapa kasus kurang mampu menggambarkan proses transisi yang berlangsung secara bertahap. Dalam penelitian Respati dkk. (2018), rezim dikategorikan menjadi rezim *bearish* dan *bullish*. Rezim *bullish* merupakan kondisi dimana pasar saham mengalami kecenderungan naik dan rezim *bearish* merupakan kondisi dimana pasar saham mengalami kecenderungan menurun. Untuk mengatasi keterbatasan tersebut, dikembangkan model *Smooth Transition Autoregressive* (STAR) yang termasuk ke dalam model *time series* nonlinier dan merupakan perluasan dari model *autoregressive* (AR). Model tersebut mampu memfasilitasi transisi yang berlangsung secara halus antar fase dalam satu kerangka model (Dijk dkk., 2002). Terasvirta (1994) mengelompokkan STAR menjadi 2 bagian berdasarkan fungsi transisinya, yakni *Logistic Smooth Transition Autoregressive* (LSTAR) dan *Exponential Smooth Transition Autoregressive* (ESTAR).

Salah satu bentuk yang paling umum dan banyak digunakan dari model STAR adalah yang menggunakan fungsi logistik untuk mengatur kelancaran transisi antar rezim. Model LSTAR cocok untuk memodelkan data keuangan karena sifatnya yang dapat menggambarkan perubahan perilaku pasar secara bertahap, bukan secara tiba-tiba (Taurinna dkk., 2024). Misalnya, dalam harga saham, transisi rezim dari kondisi *bearish* ke *bullish* biasanya tidak terjadi secara tiba-tiba, melainkan melalui perubahan bertahap yang dipengaruhi oleh berbagai faktor internal dan eksternal (Oelschläger & Adam, 2020). (G. M. Van & Kruger, 2013)

menyatakan bahwa LSTAR lebih efektif dibanding model linier konvensional dalam mengakomodasi dinamika nonlinier dalam data saham, terutama yang mengalami *switching* atau perubahan karakteristik statistik dari waktu ke waktu.

Pemodelan LSTAR juga telah diterapkan pada saham-saham perusahaan besar di Indonesia. Sebagai contoh, Odelia dkk. (2020) menerapkan model LSTAR pada saham PT Bank Mandiri dan memperoleh hasil bahwa model LSTAR (1,1) mampu menangkap dinamika nonlinier harga saham lebih baik dibandingkan model linier, dengan nilai sMAPE yang rendah dan signifikan yaitu mendapatkan nilai 5,12%. Penelitian yang dilakukan oleh Mohd dkk. (2015), menunjukkan bahwa model LSTAR memiliki nilai RMSE lebih rendah dari pada model ESTAR dan AR dalam memprediksi pengembalian saham MAS (Malaysia Airlines). Hal ini menunjukkan bahwa model LSTAR dapat diandalkan dalam menganalisis dan memprediksi harga saham yang berfluktuasi dalam berbagai kondisi pasar (Ghasemzadeh dkk., 2019).

Untuk mengestimasi parameter dalam model LSTAR dibutuhkan metode estimasi nonlinier yang efisien. Salah satu metode yang dapat digunakan adalah algoritma *Gauss-Newton*, yang merupakan metode optimasi numerik berbasis pendekatan kuadrat terkecil (*least squares*) untuk fungsi nonlinier. *Gauss-Newton* bekerja dengan membangun aproksimasi linier lokal dari fungsi nonlinier menggunakan deret Taylor, lalu menyempurnakan estimasi parameter melalui iterasi hingga konvergen pada nilai optimum .

Dalam beberapa penelitian terkini, metode *Gauss-Newton* terbukti efektif dalam mengestimasi parameter. Misalnya, penelitian oleh Zhou (2024) menunjukkan bahwa pendekatan *Gauss-Newton* mampu meminimalkan *error*

prediksi secara signifikan dalam model regresi nonlinear yang diterapkan pada harga saham, dibandingkan metode-metode estimasi lainnya. Sementara itu, penelitian oleh Saputro dkk. (2022) membuktikan bahwa penerapan *Gauss-Newton* dalam estimasi parameter LSTAR mampu menghasilkan parameter transisi yang stabil dan akurat, serta menunjukkan konvergensi cepat pada kasus simulasi dan data riil. Penelitian lainnya yang dilakukan oleh Kresnawati dkk. (2018) menyatakan bahwa model LSTAR menggunakan metode *Nonlinier Least Square* (NLS) dengan algoritma *Gauss-Newton* berhasil diterapkan untuk memprediksi indeks harga saham gabungan, dengan tingkat akurasi MAPE sebesar 2,93%, yang mencerminkan kemampuannya dalam mengidentifikasi dinamika pasar yang kompleks secara efektif.

Investasi dapat dipahami sebagai upaya penanaman modal dalam bentuk dana maupun aset dengan tujuan memperoleh keuntungan di masa mendatang. Salah satu bentuk investasi adalah saham, di mana harga saham cenderung menunjukkan pola fluktuatif dari waktu ke waktu (Manurung, 2021). Saham berfungsi sebagai tanda kepemilikan seseorang atas sebagian perusahaan dan dikategorikan sebagai salah satu jenis investasi di pasar modal (Kurniawati dkk., 2024).

PT Telekomunikasi Indonesia (Persero) merupakan salah satu BUMN yang bergerak di bidang telekomunikasi sekaligus menjadi emiten terbesar dan paling likuid di Bursa Efek Indonesia (IDX, 2024). Saat ini, tercatat saham Telkom sebesar 52,09% dimiliki oleh Pemerintah Republik Indonesia, sedangkan sisanya, yaitu 47,91% dimiliki oleh publik dan diperjualbelikan di bursa efek Indonesia (PT Telkom Indonesia, 2025). Penelitian mengenai prediksi harga saham Telkom telah dilakukan oleh Faisal (2021), menggunakan metode ARIMA. Namun ARIMA

dianggap lebih cocok untuk jangka pendek karena keterbatasannya dalam menangkap pola secara bertahap. Mihrani (2015), menyatakan bahwa harga saham PT Telkom terus meningkat setiap tahunnya. Berdasarkan teori permintaan dan penawaran, kondisi tersebut mengindikasikan bahwa saham ini diminati banyak investor.

Untuk mendasari pentingnya perencanaan dan kehati-hatian dalam mengambil keputusan ekonomi serta dalam memperhitungkan masa depan, firman Allah dalam Al-Qur'an surat Al-Hasyr ayat 18, yang artinya (Kementrian Agama RI, 2025):

“Wahai orang-orang yang beriman, bertakwalah kepada Allah dan hendaklah setiap orang memperhatikan apa yang telah diperbuatnya untuk hari esok (akhirat). Bertakwalah kepada Allah. Sesungguhnya Allah Mahateliti terhadap apa yang kamu kerjakan.” (QS. Al-Hayr:18)

Ayat ini mengajarkan bahwa setiap manusia hendaknya memiliki pandangan yang visioner, yakni berpikir dan bertindak dengan mempertimbangkan masa depan secara matang. Selain itu, ayat ini juga mendorong setiap individu untuk melakukan introspeksi terhadap perbuatannya di masa lalu, dan memperhitungkan akibat dari setiap tindakan. Nilai ini menjadi dasar penting dalam praktik ekonomi Islam, terutama dalam melakukan perencanaan, evaluasi, dan estimasi agar setiap keputusan membawa kemaslahatan dan terhindar dari kerugian maupun ketidakadilan.

Berdasarkan penelitian Odelia dkk. (2020), diperoleh tingkat akurasi yang sangat baik pada penerapan model LSTAR terhadap harga saham PT Bank Mandiri Tbk. Selain itu penelitian Kresnawati dkk. (2018), menunjukkan bahwa algoritma *Gauss-Newton* menghasilkan estimasi parameter yang baik pada model nonlinier. Mengacu pada kedua penelitian tersebut, penelitian ini akan dilakukan dengan

mengaplikasikan model LSTAR menggunakan estimasi NLS dengan algoritma *Gauss-Newton* pada data harga saham PT Telkom Indonesia. Diharapkan penelitian ini mampu menghasilkan prediksi yang lebih akurat, serta memberikan manfaat bagi investor dalam mengambil keputusan pembelian saham.

1.2 Rumusan Masalah

Berdasarkan latar belakang masalah diatas, maka rumusan masalah dalam penelitian ini adalah sebagai berikut

1. Bagaimana model harga saham menggunakan *Logistic Smooth Transition Autoregressive* (LSTAR) dengan estimasi *Gauss-Newton* pada PT Telkom Indonesia?
2. Bagaimana tingkat akurasi model *Logistic Smooth Transition Autoregressive* (LSTAR) dengan estimasi *Gauss-Newton* dalam memodelkan harga saham PT Telkom Indonesia?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah diatas, maka di dapatkan tujuan dari penelitian ini adalah sebagai berikut

1. Menganalisis model harga saham menggunakan *Logistic Smooth Transition Autoregressive* (LSTAR) dengan estimasi *Gauss-Newton* pada PT Telkom Indonesia.
2. Menganalisis tingkat akurasi model *Logistic Smooth Transition Autoregressive* (LSTAR) dengan estimasi *Gauss-Newton* dalam memodelkan harga saham PT Telkom Indonesia.

1.4 Manfaat Penelitian

Adapun manfaat yang diharapkan peneliti dalam penelitian ini adalah sebagai berikut:

1. Bagi Mahasiswa

Penelitian ini diharapkan dapat menjadi sumber pembelajaran dan referensi yang bermanfaat dalam memahami konsep prediksi harga saham serta penerapan model *Logistic Smooth Transition Autoregressive* (LSTAR) dengan metode estimasi *Gauss-Newton* dalam analisis data keuangan.

2. Program Studi

Sebagai referensi dalam pengembangan penelitian-penelitian selanjutnya di bidang statistika dan ekonomi.

3. Bagi Investor Saham

Penelitian ini dapat membantu pengambilan keputusan para investor dalam membeli dan menjual saham PT Telkom Indonesia secara lebih akurat sehingga meminimalkan resiko dan memaksimalkan keuntungan berdasarkan pergerakan harga saham yang telah diprediksi.

4. Bagi PT Telkom Indonesia

Penelitian mengenai harga saham PT Telkom bermanfaat untuk memberikan gambaran nyata tentang kinerja saham. Hasil penelitian ini dapat membantu manajemen dalam mengevaluasi strategi bisnis, memperbaiki komunikasi dengan investor, serta menjaga kepercayaan publik.

1.5 Batasan Masalah

Adapun batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Data yang digunakan adalah harga penutupan (*close price*) mingguan saham PT Telkom Indonesia dari periode 6 Januari 2019 hingga 26 April 2026.
2. Model LSTAR hanya menggunakan data harga saham dan tidak dipengaruhi oleh variabel eksternal.
3. Perhitungan tingkat akurasi yang digunakan yakni *Mean Absolute Percentage Error* (MAPE).

1.6 Definisi Istilah

Adapun beberapa definisi istilah yang digunakan dalam penelitian ini adalah:

<i>Time Series</i>	: Data hasil pengamatan yang diperoleh secara berurutan menurut urutan waktu dengan selang waktu yang tetap antarobservasinya.
<i>Autoregressive</i>	: Model deret waktu yang menjelaskan bahwa nilai pada periode sekarang dipengaruhi oleh nilai pada periode sebelumnya.
<i>Smooth Transition Autoregressive</i>	: Model perluasan dari <i>Autoregressive</i> (AR) yang memungkinkan terjadinya perubahan rezim secara bertahap melalui penggunaan fungsi transisi.
<i>Logistic Smooth Transition Autoregressive</i>	: Model khusus dari STAR dengan fungsi transisi <i>logistic</i> .

- Exponential Smooth* : Model khusus dari STAR dengan fungsi transisi *exponential*.
- Transition Autoregressive*
- Nonlinier Least Square* : Metode estimasi parameter pada model nonlinier dengan meminimalkan jumlah kuadrat *error*.
- Gauss-Newton* : Metode estimasi parameter dengan meminimalkan jumlah kuadrat galat melalui pendekatan linierisasi.
- Rezim : Kondisi atau keadaan (*noise*) dalam pergerakan pasar saham.

BAB II

KAJIAN TEORI

2.1 Teori Pendukung

2.1.1 *Time Series*

Time series merupakan suatu rangkaian pengamatan terhadap suatu variabel yang dilakukan berdasarkan urutan waktu (Box dkk., 2019). Data *time series* dapat diartikan sebagai kumpulan data hasil observasi suatu variabel yang dicatat secara berurutan sesuai dengan periode waktu tertentu, misalnya harian, mingguan, bulanan, tahunan, dan seterusnya. Melalui analisis data historis, dapat diidentifikasi pola-pola yang terdapat didalamnya. Model *time series* telah banyak digunakan pada bidang ekonometri (Kirchgässner & Wolters, 2010). Bianchesi dkk. (2022), menyebutkan bahwa secara umum model *time series* dikelompokkan menjadi dua, yakni model *time series* linier dan model *time series* nonlinier.

1. *Time Series* Model Linier

Time series linier merupakan *time series* yang terbentuk dari kombinasi linier nilai-nilai sebelumnya dari suatu *time series*. Model *autoregressive* merupakan salah satu bentuk dasar dari model *time series* linier. Model *autoregressive* menjelaskan kondisi di mana nilai saat ini pada data deret waktu yang dipengaruhi oleh nilai sebelumnya ditambah dengan gangguan acak. Berdasarkan Dijk (1999) bentuk umum model *autoregressive* dengan orde p sebagai berikut:

$$X_t = \varphi_0 + \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \cdots + \varphi_p X_{t-p} + \varepsilon_t \quad (2.1)$$

di mana:

X_t : Harga saham pada waktu ke- t

φ_0 : Konstanta model

φ_i : Parameter *autoregressive* orde ke- i , $i = 1, 2, \dots, p$

X_{t-i} : Harga saham pada lag ke- i

p : Orde *autoregressive*

ε_t : *Error* pada waktu ke- t

t : Periode observasi

2. Time Series Model Nonlinier

Pratama dkk. (2022) menjelaskan bahwa model STAR merupakan pengembangan dari model *autoregressive* untuk data deret waktu nonlinier yang dikenalkan oleh Terasvirta (1992). Model STAR secara umum dalam Djik (1999) dinyatakan dalam bentuk:

$$\begin{aligned} X_t = & (\varphi_{10} + \varphi_{11}X_{t-1} + \dots + \varphi_{1p}X_{t-p})(1 - G(s_t; \gamma, c)) \\ & + (\varphi_{20} + \varphi_{21}X_{t-1} + \dots + \varphi_{2p}X_{t-p})G(s_t; \gamma, c) + \varepsilon_t \end{aligned} \quad (2.2)$$

di mana:

φ_{10} : Konstanta AR rezim pertama

φ_{20} : Konstanta AR rezim kedua

φ_{1i} : Parameter AR rezim pertama pada *lag* ke- i

φ_{2i} : Parameter AR rezim kedua pada *lag* ke- i

$s_t = X_{t-d}$: Variabel transisi mengikuti besar orde p pada model AR dengan $1 \leq d \leq p$,

$G(s_t; \gamma, c)$: Fungsi transisi dengan nilai $[0, 1]$

- c : Nilai parameter lokasi (*threshold*),
 γ : Parameter pemulusan (*smoothing*), dan
 ε_t : Residual model STAR pada periode ke- t

2.1.2 Fungsi Transisi

Model STAR dapat diklasifikasikan menjadi dua berdasarkan fungsi transisinya, yakni *Logistic Smooth Transition Autoregressive* (LSTAR) serta *Exponential Smooth Transition Autoregressive* (ESTAR).

1. Fungsi Transisi Logistik pada Model LSTAR

LSTAR merupakan salah satu bentuk khusus dari STAR yang menggunakan fungsi transisi logistik. Bentuk umum dari fungsi transisi logistik dalam Dijk (1999) yaitu:

$$G(s_t; \gamma, c) = \frac{1}{1 + \exp(-\gamma(s_t - c))}, \gamma > 0 \quad (2.3)$$

Berdasarkan (2.2) dan (2.3) bentuk model LSTAR dapat dituliskan sebagai berikut:

$$X_t = (\varphi_{10} + \varphi_{11}X_{t-1} + \dots + \varphi_{1p}X_{t-p}) \left(1 - \left(\frac{1}{1 + e^{(-\gamma(s_t - c))}} \right) \right) + (\varphi_{20} + \varphi_{21}X_{t-1} + \dots + \varphi_{2p}X_{t-p}) \left(\frac{1}{1 + e^{(-\gamma(s_t - c))}} \right) + \varepsilon_t \quad (2.4)$$

2. Fungsi Transisi Eksponensial pada Model ESTAR

ESTAR merupakan salah satu bentuk khusus dari STAR yang menggunakan fungsi transisi eksponensial. Bentuk umum dari fungsi transisi eksponensial dalam Dijk (1999) yaitu:

$$G(s_t; \gamma, c) = 1 - \exp(-\gamma(s_t - c)), \gamma > 0 \quad (2.5)$$

Dari persamaan (2.2) dan (2.5) dapat diperoleh model ESTAR berikut:

$$X_t = (\varphi_{10} + \varphi_{11}X_{t-1} + \dots + \varphi_{1p}X_{t-p}) \exp(-\gamma(s_t - c)) + \\ (\varphi_{20} + \varphi_{21}X_{t-1} + \dots + \varphi_{2p}X_{t-p})(1 - \exp(s_t - c)) + \varepsilon_t \quad (2.6)$$

2.1.3 Pembagian Data

Pembagian data (*data splitting*) merupakan salah satu tahapan penting dalam proses pengembangan model prediksi karena digunakan untuk menilai kemampuan model dalam mempelajari pola dari data historis serta mengevaluasi kinerja model terhadap data yang belum pernah digunakan sebelumnya. Secara umum, dataset dibagi menjadi dua bagian utama, yaitu data *training* dan data *testing*. Data *training* digunakan untuk membangun dan mengestimasi parameter model, sedangkan data *testing* digunakan untuk menguji kemampuan model dalam melakukan prediksi pada data baru sehingga dapat mengukur tingkat generalisasi model. Dalam praktiknya, proporsi pembagian data dapat bervariasi, misalnya 90%:10%, 80%:20%, atau 70%:30%, tergantung pada jumlah data yang tersedia dan kebutuhan analisis. Namun, pada analisis *time series*, proses pembagian data tidak dilakukan secara acak karena observasi memiliki keterkaitan antar waktu (Medar & Rajpurohit, 2017).

2.1.4 Uji Asumsi

Setelah model LSTAR selesai diestimasi, dilakukan pengujian asumsi klasik untuk memastikan bahwa model yang dihasilkan layak digunakan. Asumsi-asumsi yang perlu diuji adalah sebagai berikut:

1. Stasioneritas

Menurut Odelia dkk. (2020) data runtun waktu memiliki syarat bahwa data harus dalam keadaan stasioner, yaitu tidak adanya perubahan kecendrungan dalam rata-rata (*mean*) dan perubahan varian. Stasioner data dalam varian dapat dilakukan dengan menggunakan transformasi Box-Cox plot. Jika nilai *rounded value* (λ) bernilai satu maka data stasioner dalam varian tetapi jika nilai *rounded value* kurang dari satu maka perlu dilakukan proses transformasi. Stasioneritas dalam *mean* dengan menggunakan uji akar unit, yaitu uji *Augmented Dickey* (ADF), seperti berikut:

$H_0 : \Phi = 1$, terdapat akar unit atau data tidak stasioner.

$H_1 : \Phi < 1$, tidak terdapat akar unit atau data stasioner.

Statistik Uji pada ADF *test* dituliskan sebagai berikut (Herranz, 2017):

$$ADF = t_{ratio} = \frac{\hat{\Phi} - 1}{se(\hat{\Phi})} \quad (2.7)$$

$$se(\hat{\Phi}) = \sqrt{\frac{1 - \hat{\Phi}^2}{n}} \quad (2.8)$$

di mana:

$\hat{\Phi}$: Estimator dari Φ

$se(\hat{\Phi})$: Standar residual dari Φ

n : Ukuran sampel

Adapun kriteria pengambilan keputusan yaitu tolak H_0 jika $t_{statistik} > t_{tabel}$ atau $p - value < \alpha$, artinya data stasioner. Ketika data tidak memenuhi sifat stasioner, dilakukan proses *differencing* untuk mengatasi

adanya tren maupun komponen non-stasioner lainnya. Rumus dari *differencing* dapat dituliskan sebagai berikut (Box dkk., 2019).

$$X_t = Y_t - Y_{t-d} \quad (2.9)$$

2. Normalitas

Ghazali dalam Aditiya dkk. (2023) menjelaskan bahwa tujuan dari uji normalitas adalah untuk menilai apakah dalam model regresi residual mengikuti distribusi normal. Uji normalitas dilakukan menggunakan uji *Kolmogorov Smirnov* dengan hipotesis sebagai berikut:

$H_0 : D = 0$ (Residual mengikuti distribusi normal)

$H_1 : D > 0$ (Residual tidak mengikuti distribusi normal)

Dengan statistik uji (Stephens, 2016):

$$D = \sup |F_n(x) - F_0(x)| \quad (2.10)$$

di mana:

D : Nilai statistik uji Kolmogorov Smirnov

$S(x)$: Fungsi distribusi kumulatif dari data residual

$F_0(x)$: Fungsi distribusi kumulatif dari distribusi normal teoritis

Adapun kriteria keputusan, jika nilai $D_{hitung} > D_{(N;\alpha)}$ atau $p\text{-value} < \alpha = 0,05$ maka tolak H_0 , artinya residual tidak mengikuti distribusi normal. Jika $D_{hitung} < D_{(1-\alpha)}$ atau $p\text{-value} > \alpha$, maka gagal tolak H_0 , artinya residual berdistribusi normal.

3. Autokorelasi

Uji autokorelasi residual dilakukan untuk mengetahui apakah residual bersifat acak atau tidak. Uji autokorelasi residual dapat dilakukan dengan

pendekatan *white noise* menggunakan *Ljung-Box* dengan hipotesis sebagai berikut (Odelia dkk., 2020).

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0 \text{ (tidak ada autokorelasi)}$$

$$H_1 : \text{Terdapat } \exists \rho_k \neq 0 \text{ dengan } k = 1, 2, \dots, h \text{ (terdapat autokorelasi)}$$

Dengan uji statistik sebagai berikut:

$$Q_k = T(T+2) \sum_{k=1}^h \frac{r_k^2}{T-k} \quad (2.11)$$

di mana:

$$Q_k : \text{Statistik uji } Ljung\text{-}Box$$

$$T : \text{Jumlah observasi}$$

$$r_k : \text{ACF residual pada lag ke-}k$$

$$h : \text{Banyaknya lag yang diuji}$$

Kriteria pengambilan keputusan yaitu jika nilai $Q_{hitung} > \chi_{(h,\alpha)}^2$ atau $p\text{-value} < \alpha$, maka tolak H_0 . Artinya terdapat autokorelasi.

4. Heteroskedastisitas

Uji heteroskedastisitas merupakan hal yang penting dilakukan untuk validitas model. Uji ini dilakukan untuk mengetahui apakah residual memiliki varian yang konstan (homoskedastisitas) atau tidak (heteroskedastisitas). Uji heteroskedastisitas dilakukan menggunakan uji *Lagrange Multiplier* (LM) dengan hipotesis sebagai berikut (Odelia dkk., 2020):

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_k = 0 \text{ (tidak ada heteroskedastisitas)}$$

$$H_1 : \exists \mu_m \neq 0 \text{ dengan } m = 1, 2, \dots, k \text{ (ada heteroskedastisitas)}$$

Dengan statistik uji:

$$LM = TR^2 = T \left(\frac{SSR}{SST} \right) = T \left(\frac{\sum_{t=1}^n (\hat{\eta}_t^2 - \bar{\eta}_t^2)^2}{\sum_{t=1}^n (\eta_t^2 - \bar{\eta}_t^2)^2} \right) \quad (2.12)$$

di mana:

R^2 : Koefisien determinasi dari regresi kuadrat residual

SSR : Jumlah kuadrat regresi dari regresi kuadrat residual LSTAR

SST : Jumlah kuadrat total dari regresi kuadrat residual LSTAR

T : Jumlah residual setelah pembentukan lag pada model AR

Kriteria pengambilan keputusan adalah tolak H_0 jika nilai $LM > \chi^2_{(m;\alpha)}$

atau $p\text{-value} < \alpha$, menunjukkan residual mengandung heteroskedastisitas.

5. Linieritas

Dalam pemodelan deret waktu, langkah yang penting dilakukan selanjutnya adalah uji linieritas untuk memastikan apakah data benar-benar mengikuti pola linier atau justru menunjukkan adanya indikasi nonlinier. Metode uji yang sering digunakan adalah *Langrange Multiple* (LM) dengan menggunakan pendekatan ekspansi Taylor hingga orde ketiga, berikut disajikan langkah-langkah dalam melakukan pengujian linieritas yang dikembangkan oleh Terasvirta (1994). Dalam uji ini, digunakan hipotesis sebagai berikut:

a. Hitung jumlah kuadrat residual dari model $AR(p)$

Jumlah kuadrat residual (*sum of squared errors*) dari model $AR(p)$

dihitung menggunakan rumus:

$$SSE_0 = \sum_{t=1}^n \hat{\varepsilon}_t^2 \quad (2.13)$$

di mana:

SSE_0 : Jumlah kuadrat residual dari model $AR(p)$

$\hat{\varepsilon}_t$: Residual dari estimasi model $AR(p)$

b. Bangun regresi bantuan (*auxiliary regression*)

Residual model $AR(p)$ diregresikan terhadap komponen hasil ekspansi taylor orde ketiga dari fungsi transisi, sehingga bentuk regresi bantuan adalah sebagai berikut:

$$\begin{aligned} \hat{\varepsilon}_t = & \beta_{00} + \sum_{i=1}^p \beta_{0i} X_{t-i} + \sum_{i=1}^p \beta_{1i} X_{t-i} s_t + \sum_{i=1}^p \beta_{2i} X_{t-i} s_t^2 \\ & + \sum_{i=1}^p \beta_{3i} X_{t-i} s_t^3 + e_t \end{aligned} \quad (2.14)$$

di mana:

β_{00} : konstanta regresi bantu

$\beta_{0i}, \beta_{1i}, \beta_{2i}, \beta_{3i}$: Parameter regresi bantu

e_t : Residual dari regresi bantu

Selanjutnya hitung jumlah residual kuadrat dari regresi bantu (SSE_1):

$$SSE_1 = \sum_{t=1}^n \hat{e}_t^2 \quad (2.15)$$

c. Uji Linieritas

Hipotesisi yang digunakan dalam pengujian ini adalah:

H_0 : $\beta_{1i} = \beta_{2i} = \beta_{3i} = 0$ (model linier)

H_1 : $\exists \beta_{ji} \neq 0$ (model nonlinier), $j = 1, 2, 3$ dan $i = 1, 2, \dots, p$

Uji dilakukan menggunakan taraf signifikansi $\alpha = 5\% = 0,05$ dengan menggunakan statistik uji LM sebagai berikut:

$$LM = nR^2 \quad (2.16)$$

$$\text{dengan } R^2 = \frac{(SSE_0 - SSE_1)}{SSE_0}$$

Kriteria pengambilan keputusan yaitu tolak H_0 apabila nilai LM > $\chi^2_{(3p;\alpha)}$ atau $p\text{-value} < \alpha = 0,05$ yang berarti terdapat hubungan nonlinier dalam data *time series*.

6. Identifikasi Model STAR

Penentuan bentuk fungsi transisi dilakukan melalui serangkaian pengujian menggunakan model regresi bantu pada persamaan (2.28). Pengujian ini bertujuan untuk mengidentifikasi bentuk nonlinier yang paling sesuai, yaitu apakah model mengikuti spesifikasi *Logistic Smooth Transition Autoregressive* (LSTAR) atau *Exponential Smooth Transition Autoregressive* (ESTAR). Proses identifikasi dilakukan dengan menguji hipotesis nol secara bertahap berdasarkan model regresi bantu berikut:

a. Hipotesis tahap pertama:

$$H_0 \quad : \quad \beta_{3i} = 0, \forall i = 1, 2, \dots, p$$

$$H_1 \quad : \quad \exists \beta_{3i} \neq 0$$

Jika H_0 ditolak, maka model mengikuti fungsi transisi *logistic* (LSTAR) sehingga proses pengujian tidak perlu dilanjutkan. Sebaliknya, jika H_0 gagal ditolak, maka pengujian dilanjutkan pada tahap berikutnya dengan menguji hipotesis tahap kedua.

b. Hipotesis tahap kedua

$$H_0 \quad : \quad \beta_{2i} = 0 \mid \beta_{3i} = 0$$

$$H_1 \quad : \quad \beta_{2i} \neq 0 \mid \beta_{3i} = 0$$

Jika H_0 ditolak, maka model mengikuti fungsi transisi *exponential* (ESTAR) dan pengujian dihentikan. Sebaliknya, jika H_0 gagal ditolak,

maka pengujian dilanjutkan pada tahap berikutnya dengan menguji hipotesis tahap ketiga.

c. Hipotesis tahap ketiga

$$H_0 : \beta_{1i} = 0 \mid \beta_{3i} = \beta_{2i} = 0$$

$$H_1 : \beta_{1i} \neq 0 \mid \beta_{3i} = \beta_{2i} = 0$$

Jika H_0 ditolak, maka model mengikuti fungsi transisi *logistic* (LSTAR).

Uji dilakukan menggunakan taraf signifikansi $\alpha = 0,05$ dengan menggunakan statistik uji:

$$t_{hitung} = \frac{\hat{\beta}_{ji}}{se(\hat{\beta}_{ji})} \quad (2.17)$$

di mana:

$\hat{\beta}_{ji}$: Estimator koefisien dari $\hat{\beta}_{ji}$

$se(\hat{\beta}_{ji})$: *Standard error* dari koefisien regresi $\hat{\beta}_{ji}$

Kriteria pengambilan keputusan yaitu tolak H_0 apabila nilai $|t_{hitung}| > t_{(v-u-1; \alpha/2)}$ atau $p\text{-value} < \alpha = 0,05$. Dimana $u = 1 + 3p$ merupakan jumlah parameter regresi bantu.

2.1.5 Pembentukan Model *Autoregressive*

Proses pembentukan model *autoregressive* (p) dilakukan melalui beberapa tahapan sebagai berikut:

1. Identifikasi Model *Autoregressive* (p)

Tahap identifikasi model dilakukan dengan memanfaatkan fungsi `auto.arima` yang tersedia dalam *package forecast* pada bahasa pemrograman R. Penggunaan fungsi ini bertujuan untuk mempermudah penentuan model

ARIMA yang paling sesuai dengan data pengamatan. Fungsi `auto.arima` secara otomatis memilih model ARIMA terbaik dengan menggunakan variasi algoritma Hyndman-Khandakar, yang mencakup pengujian unit *root test* untuk mengetahui kestasioneran data serta pemilihan model berdasarkan nilai *Akaike Information Criterion* (AIC) terkecil. Persamaan AIC dinyatakan sebagai berikut (Hyndman, 2008):

$$AIC = n \ln \hat{\sigma}_\varepsilon^2 + 2x \quad (2.18)$$

dengan $\hat{\sigma}_\varepsilon^2 = \sum_{t=1}^n e_t^2$ dan $x = p + 1$

di mana:

n : Jumlah observasi

x : Jumlah parameter dalam model

2. Estimasi Model *Autoregressive* (p)

Tahap estimasi parameter merupakan proses untuk menentukan nilai parameter pada model AR sehingga model tersebut mampu menggambarkan pola data secara optimal dan mendekati kondisi sebenarnya. Parameter model *autoregressive* orde p pada persamaan (2.1) untuk n observasi dapat ditulis dalam bentuk matriks berikut:

$$\mathbf{Z} = \mathbf{X}\boldsymbol{\varphi} + \boldsymbol{\varepsilon} \quad (2.19)$$

$$\text{dengan } \mathbf{Z} = \begin{bmatrix} X_{p+1} \\ X_{p+2} \\ \vdots \\ X_n \end{bmatrix}, \mathbf{X} = \begin{bmatrix} 1 & X_p & X_{p-1} & \cdots & X_1 \\ 1 & X_{p+1} & X_p & \cdots & X_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{n-1} & X_{n-2} & \cdots & X_{n-p} \end{bmatrix}, \boldsymbol{\varphi} = \begin{bmatrix} \varphi_0 \\ \varphi_1 \\ \vdots \\ \varphi_p \end{bmatrix}, \text{ dan } \boldsymbol{\varepsilon} = \begin{bmatrix} \varepsilon_{p+1} \\ \varepsilon_{p+2} \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

estimator parameter $\boldsymbol{\varphi}$ menggunakan metode OLS dapat dinyatakan sebagai berikut (Aziz, 2010):

$$\hat{\boldsymbol{\varphi}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Z} \quad (2.20)$$

2.1.6 Estimasi *Gauss-Newton*

Menurut Saleh (2010), metode *Gauss-Newton* merupakan salah satu algoritma numerik yang digunakan untuk menyelesaikan masalah *Nonlinear Least Square* (NLS). Metode ini bekerja dengan melakukan pendekatan linier terhadap fungsi nonlinier melalui ekspansi deret Taylor orde pertama, kemudian menyelesaikannya secara iteratif hingga mencapai konvergensi.

Dalam model *Logistic Smooth Transition Autoregressive* (LSTAR), parameter diestimasi dengan meminimumkan fungsi objektif *Nonlinear Least Square* sebagai berikut:

$$\hat{\boldsymbol{\theta}} = \operatorname{argmin} M(\boldsymbol{\theta}) \quad (2.21)$$

dengan fungsi objektif:

$$M(\boldsymbol{\theta}) = \sum_{t=1}^n \left(X_t - f(X_{t-1}, \dots, X_{t-p}, \boldsymbol{\theta}) \right)^2 \quad (2.22)$$

di mana:

X_t : Nilai aktual harga saham pada waktu ke- t

f : Fungsi model LSTAR

$\hat{\boldsymbol{\theta}}$: Parameter optimal hasil estimasi

$\boldsymbol{\theta}$: Vektor parameter model

$M(\boldsymbol{\theta})$: Jumlah kuadrat residual

dan fungsi $f(X_{t-1}, \dots, X_{t-p}, \boldsymbol{\theta})$ pada model LSTAR dapat dituliskan sebagai:

$$f(X_{t-1}, \dots, X_{t-p}, \boldsymbol{\theta}) = (\varphi_{10} + \varphi_{11}X_{t-1} + \dots + \varphi_{1p}X_{t-p}) \left(1 - \left(\frac{1}{1 + e^{(-\gamma(s_t - c))}}\right)\right) + (\varphi_{20} + \varphi_{21}X_{t-1} + \dots + \varphi_{2p}X_{t-p}) \left(\frac{1}{1 + e^{(-\gamma(s_t - c))}}\right) \quad (2.23)$$

Parameter yang akan diestimasi dalam model LSTAR adalah $\boldsymbol{\theta} = (\boldsymbol{\varphi}_1, \boldsymbol{\varphi}_2, \gamma, c)$.

Estimasi parameter dilakukan menggunakan metode *Gauss-Newton*, yaitu suatu metode iteratif yang bertujuan meminimumkan fungsi objektif *Nonlinear Least Square* (NLS) melalui pendekatan linier berdasarkan turunan pertama fungsi model yang direpresentasikan dalam matriks Jacobian. Adapun prosedur estimasi parameter menggunakan metode *Gauss-Newton* untuk meminimumkan fungsi NLS adalah sebagai berikut:

1. Menentukan Nilai Awal Parameter $\boldsymbol{\theta}^{(0)}$

Langkah pertama dalam metode *Gauss-Newton* adalah menentukan nilai awal parameter. Tebakan awal parameter dinyatakan sebagai berikut:

- a. Parameter linier $(\boldsymbol{\varphi}_1, \boldsymbol{\varphi}_2 = (0,95)\boldsymbol{\varphi}_1)$ diperoleh dari hasil estimasi awal. Nilai 0,95 dipilih untuk menghasilkan perbedaan yang relatif kecil antara rezim 1 dan rezim 2, namun tetap menjaga kestabilan model serta menghindari kondisi divergen.
- b. Parameter pemulusan transisi γ dipilih dari *grid search*.
- c. Parameter ambang (*threshold*) c ditentukan sebagai median dari variabel transisi.

2. Menghitung Nilai Prediksi Model

Berdasarkan parameter awal $\boldsymbol{\theta}^{(0)}$, nilai prediksi model LSTAR dihitung sebagai berikut:

Langkah 1: Hitung fungsi transisi G_t

$$G(s_t; \gamma, c) = \frac{1}{1 + e^{(-\gamma(s_t - c))}} \quad (2.24)$$

Langkah 2: Hitung rezim

$$\vartheta_i = \varphi_{i0} + \sum_{j=1}^p \varphi_{ij} X_{t-j} \quad (2.25)$$

di mana:

- i : Rezim ke- i
- φ_{i0} : Konstanta pada rezim ke- i
- φ_{ij} : Parameter *autoregressive* ke- j pada rezim ke- i
- X_{t-j} : Nilai lag ke- j
- p : Orde *autoregressive*

Langkah 3: Hitung prediksi model

$$\hat{X}_t = (\varphi_{10} + \varphi_{11}X_{t-1} + \varphi_{12}X_{t-2})(1 - G_t) + \varphi_{10} + \varphi_{11}X_{t-1} + \varphi_{12}X_{t-2}(G_t) \quad (2.26)$$

3. Menghitung Residual

Residual diperoleh dari selisih antara nilai aktual dan nilai prediksi model, yaitu:

$$r_t = X_t - \hat{X}_t \quad (2.27)$$

4. Membentuk Matriks Jacobian

Langkah berikutnya adalah membentuk matriks Jacobian, yang berisi turunan parsial residual terhadap setiap parameter. Elemen matriks Jacobian dinyatakan sebagai:

$$J(\theta) = \frac{\partial \hat{X}_t(\theta)}{\partial \theta} \quad (2.28)$$

Turunan dilakukan terhadap setiap parameter yakni parameter linier, parameter nonlinier, γ , dan parameter *threshold* c . Berikut merupakan turunan parsial terhadap setiap parameter:

a. Parameter φ_1

$$\frac{\partial \hat{X}_t}{\partial \varphi_{10}} = (1 - G_t) \quad (2.29)$$

$$\frac{\partial \hat{X}_t}{\partial \varphi_{11}} = X_{t-1}(1 - G_t) \quad (2.30)$$

$$\frac{\partial \hat{X}_t}{\partial \varphi_{12}} = X_{t-2}(1 - G_t) \quad (2.31)$$

b. Parameter φ_2

$$\frac{\partial \hat{X}_t}{\partial \varphi_{20}} = G_t \quad (2.32)$$

$$\frac{\partial \hat{X}_t}{\partial \varphi_{21}} = X_{t-1}G_t \quad (2.33)$$

$$\frac{\partial \hat{X}_t}{\partial \varphi_{22}} = X_{t-2}G_t \quad (2.34)$$

c. Parameter γ

$$\frac{\partial \hat{X}_t}{\partial \gamma} = (\varphi_1 - \varphi_2)G_1(1 - G_1)(s_{t-1} - c) \quad (2.35)$$

d. Parameter c

$$\frac{\partial \hat{X}_t}{\partial c} = -(\varphi_1 - \varphi_2)G_1(1 - G_1) \quad (2.36)$$

5. Menghitung Koreksi dan Memperbarui Parameter

Perubahan parameter pada setiap iterasi dihitung menggunakan metode *Gauss-Newton* berdasarkan matriks Jacobian dan vektor residual. Karena matriks $\mathbf{J}^T \mathbf{J}$ bersifat singular, digunakan *pseudoinverse* untuk memperoleh solusi. Koreksi parameter dihitung dengan persamaan sebagai berikut:

$$\Delta\theta = (J^T J)^+ J^T r = \frac{1}{JJ^T} (J^T r) \quad (2.37)$$

di mana:

- $\Delta\theta$: Vektor koreksi parameter
- J : Matriks Jacobian
- J^T : Transpose dari matriks Jacobian
- $(J^T J)^+$: *Pseudoinverse* dari matriks $J^T J$
- r : Vektor residual
- $J^T r$: Hasil perkalian transpose Jacobian dengan vektor residual

Parameter diperbarui secara iteratif dengan persamaan:

$$\theta^{(k+1)} = \theta^{(0)} + \Delta\theta \quad (2.38)$$

6. Konvergensi

Salah satu kriteria konvergensi dalam algoritma *Gauss–Newton* ditentukan berdasarkan perubahan nilai fungsi objektif (SSE). Iterasi dihentikan ketika selisih nilai SSE antar iterasi memenuhi kondisi:

$$|SSE^{(t)} - SSE^{(t-1)}| < \epsilon \quad (2.39)$$

dengan nilai toleransi yang ditetapkan sebesar $\epsilon = 10^{-5}$. Kondisi ini menunjukkan bahwa perubahan nilai fungsi objektif antar iterasi sudah sangat kecil atau mendekati nol, sehingga proses iterasi dianggap telah mencapai keadaan stabil. Pada tahap ini, pembaruan parameter pada iterasi berikutnya tidak lagi memberikan perubahan yang signifikan terhadap nilai fungsi objektif. Dengan demikian, parameter yang diperoleh pada saat konvergensi dapat dianggap sebagai solusi optimum lokal dari permasalahan *Nonlinear Least Squares* (NLS).

2.1.7 Transformasi Data

Dalam analisis deret waktu, transformasi data sering dilakukan untuk memenuhi asumsi stasioneritas yang diperlukan oleh berbagai metode pemodelan. Salah satu transformasi yang umum digunakan adalah *differencing*, yaitu proses menghitung selisih antara suatu nilai observasi dengan nilai sebelumnya untuk menghilangkan tren atau ketidakstasioneran pada data. Namun, hasil prediksi yang diperoleh dari model yang dibangun menggunakan data yang telah *didifferencing* berada pada skala transformasi, sehingga tidak langsung merepresentasikan nilai sebenarnya dari variabel yang diamati. Oleh karena itu, hasil prediksi tersebut perlu dikembalikan ke skala aslinya melalui proses *inverse differencing* agar dapat diinterpretasikan secara tepat pada data asli. Proses ini dilakukan dengan menambahkan kembali nilai sebelumnya pada hasil prediksi dari data yang telah *didifferencing* sehingga menghasilkan nilai prediksi pada skala awal data. Berikut merupakan bentuk dari *inverse differencing* (Sekar dkk., 2020):

$$Y_t = Y_{t-1} + X_t \quad (2.40)$$

2.1.8 Evaluasi Model

Evaluasi bertujuan untuk mengetahui akurasi peramalan. Ukuran yang akan digunakan untuk evaluasi dalam penelitian ini adalah *Mean Absolute Percentage Error* (MAPE). MAPE merupakan ukuran kesalahan prediksi dalam bentuk persentase rata-rata kesalahan absolut. MAPE sering digunakan dalam praktik karena lebih mudah dimengerti. Selain itu MAPE tidak bergantung pada satuan

data, sehingga dapat digunakan pada data apapun. Secara umum, rumus MAPE dituliskan sebagai berikut (Adhikari dkk., 2013):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\% \quad (2.41)$$

di mana:

y_t : Nilai aktual pada waktu ke- t

$\hat{y}_t$: Nilai prediksi pada waktu ke- t

n : Jumlah data observasi

Nilai MAPE yang rendah menunjukkan bahwa model peramalan yang digunakan memiliki tingkat akurasi yang tinggi. MAPE memiliki tingkat signifikansi sebagai berikut (Chang dkk., 2007).

Tabel 2.1 Tingkat Akurasi Nilai MAPE

Nilai MAPE (%)	Akurasi Model
$MAPE < 10\%$	Sangat Akurat (<i>Highly Accurate</i>)
$10\% < MAPE \leq 20\%$	Akurat (<i>Good Forecasting</i>)
$20\% < MAPE \leq 50\%$	Cukup Akurat (<i>Reasonable Forecasting</i>)
$MAPE > 50\%$	Tidak Akurat (<i>Inaccurate Forecasting</i>)

2.1.9 Saham

Saham merupakan dokumen yang dimiliki seseorang berupa surat berharga bukti kepemilikan atau penyertaan modal pada sebuah perusahaan. Pada masa lalu, saham berbentuk fisik berupa dokumen. Namun, seiring berkembangnya teknologi, sistem jual beli saham kini dapat dilakukan secara *online* melalui aplikasi, sehingga saham yang diperdagangkan tidak lagi

berbentuk secara fisik. Sama halnya dengan harga barang lainnya, harga saham juga bersifat fluktuatif, yang artinya dapat naik dan turun (Priyadi dkk., 2021).

2.2 Kajian Intergrasi dengan Al-Qur'an

Dalam penelitian ini, penerapan metode ilmiah merupakan bentuk pemanfaatan akal dan ilmu pengetahuan yang dikaruniakan oleh Allah SWT kepada manusia sebagai sarana untuk memperoleh kebenaran dan memahami ciptaan-Nya secara bijak, rasional, dan sistematis. Hal ini sesuai dengan firman Allah SWT dalam Al-Qur'an QS. Al-Baqarah ayat 269, dalam (Kementrian Agama RI, 2025) yang artinya:

“Dia (Allah) menganugerahkan hikmah kepada siapa yang Dia kehendaki. Barangsiapa yang dianugerahi hikmah, maka sungguh ia telah dianugerahi kebaikan yang banyak. Tidak ada yang dapat mengambil pelajaran (darinya), kecuali ulul albab (orang-orang yang berakal).” (QS. Al-Baqarah:269)

Menurut Tafsir Fi Zhilalil-Qur'an, ayat ini menegaskan bahwa ilmu dan kebijaksanaan merupakan anugerah dari Allah SWT yang harus dimanfaatkan dengan penuh tanggung jawab. Dalam konteks penelitian, penggunaan metode ilmiah mencerminkan bentuk hikmah yakni kemampuan manusia menggunakan akal dan pengetahuan secara bijak untuk mencari kebenaran serta menghasilkan manfaat bagi sesama. Sebagaimana disebutkan dalam ayat tersebut, mereka yang mampu mengambil pelajaran dan menautkan ilmu dengan nilai-nilai ketuhanan hakikatnya sedang menjalani proses berpikir sistematis dan rasional dalam metode penelitian mencerminkan penggunaan akal yang sehat (ulul albab) (Aljawwi, 2024).

Untuk mendasari pentingnya investasi dan kepemilikan saham yang sesuai dengan prinsip syariah sebagai bagian dari pengelolaan harta yang amanah, hal ini

sejalan dengan firman Allah dalam Al-Qur'an surat An-Nisa ayat 29, sebagaimana tercantum dalam terbitan resmi (Kementrian Agama RI, 2025) yang artinya:

“Wahai orang-orang yang beriman, janganlah kamu memakan harta sesamamu dengan cara yang batil (tidak benar), kecuali berupa perniagaan atas dasar suka sama suka di antara kamu. Janganlah kamu membunuh dirimu. Sesungguhnya Allah adalah Maha Penyayang kepadamu.” (QS. An-Nisa:29)

Menurut Tafsir Al-Munir, Ayat ini menjelaskan menjaga harta dengan cara yang benar dan adil. Orang-orang yang beriman diajarkan untuk tidak mengambil atau memakan harta orang lain dengan jalan yang batil, melainkan melalui perniagaan yang didasari kerelaan kedua belah pihak. Tafsir ini mengajarkan bahwa dalam setiap transaksi, termasuk dalam perdagangan atau investasi seperti saham, diperlukan sikap hati-hati, kejujuran, dan tanggung jawab agar terhindar dari praktik yang merugikan diri sendiri maupun orang lain, sehingga keputusan yang diambil benar-benar sesuai dengan tuntunan syariah (Abdul Malik, 2019).

2.3 Kajian Topik dengan Teori Pendukung

Penelitian ini didasarkan pada beberapa penelitian terdahulu yang memiliki keterkaitan dengan pemodelan deret waktu nonlinier menggunakan model Smooth Transition Autoregressive (STAR), khususnya Logistic Smooth Transition Autoregressive (LSTAR). Misalnya pada penelitian yang dilakukan oleh Odelia dkk. (2020) menunjukkan bahwa penerapan model LSTAR(1,1) pada data harga saham mingguan PT Bank Mandiri (Persero) Tbk periode 1 Januari 2019 hingga 30 Desember 2019 mampu menghasilkan nilai *Symmetric Mean Absolute Percentage Error* (SMAPE) sebesar 5,12%. Nilai tersebut menunjukkan bahwa model LSTAR memiliki tingkat akurasi yang cukup baik dalam memprediksi pergerakan harga

saham yang bersifat nonlinier. Selain itu pada penelitian Kresnawati dkk. (2018) menunjukkan keberhasilan model LSTAR dalam memodelkan data keuangan. Pada penelitian tersebut, parameter model diestimasi menggunakan metode *Nonlinear Least Square* (NLS) dengan algoritma *Gauss–Newton*. Hasil penelitian menunjukkan bahwa model yang diperoleh mampu memberikan tingkat akurasi peramalan yang tinggi dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 2,93% pada data Indeks Harga Saham Gabungan (IHSG). Temuan ini mengindikasikan bahwa kombinasi model LSTAR dan metode estimasi NLS dengan algoritma *Gauss–Newton* efektif dalam menangani karakteristik nonlinier yang sering muncul pada data pasar modal.

Berdasarkan penelitian-penelitian tersebut, algoritma *Gauss–Newton* dipilih dalam penelitian ini untuk mengoptimalkan parameter model LSTAR melalui pendekatan *Nonlinear Least Square* (NLS). Pemilihan algoritma tersebut didasarkan pada kemampuannya dalam menyelesaikan permasalahan optimasi nonlinier secara iteratif dengan meminimumkan jumlah kuadrat residual, sehingga diharapkan dapat menghasilkan estimasi parameter yang optimal dan meningkatkan akurasi model dalam memprediksi harga saham PT Telkom Indonesia (Persero).

BAB III

METODE PENELITIAN

3.1 Jenis Penelitian

Penelitian ini menggunakan pendekatan kuantitatif karena data yang dianalisis berupa angka yang dapat diolah secara statistik. Data yang digunakan dalam penelitian adalah harga penutupan saham PT Telkom sebagai objek utama analisis. Pemilihan data tersebut didasarkan pada tujuan penelitian, yaitu untuk melakukan prediksi harga saham.

3.2 Data dan Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder berbentuk deret waktu (*time series*), yaitu data harga penutupan mingguan saham PT Telkom Indonesia selama periode 6 Januari 2019 hingga 26 April 2026, yang diperoleh secara daring melalui situs investing.com.

3.3 Teknik Analisis Data

Tahapan yang dilakukan dalam penelitian ini adalah:

1. Deskripsi Data

Menampilkan grafik pergerakan harga saham PT Telkom Indonesia (Persero) untuk melihat pola dan karakteristik data secara visual.

2. Uji Stasioneritas Data

Sebelum membangun model, dilakukan pengujian terhadap stasioneritas data untuk memastikan bahwa data bersifat stasioner menggunakan uji *Augmented*

Dickey-Fuller (ADF) pada persamaan (2.7). Jika data tidak stasioner dilakukan *differencing* sampai memenuhi asumsi stasioner menggunakan persamaan (2.9).

3. Pembagian Data

Data dibagi menjadi dua yaitu, data *training* sebesar 80% yang digunakan untuk pembentukan model dan data *testing* sebesar 20% digunakan untuk menghitung nilai kesalahan prediksi.

4. Identifikasi model ARIMA

Identifikasi model dilakukan dengan menggunakan kombinasi dari beberapa model dengan kriteria nilai AIC terkecil.

5. Estimasi Parameter Model AR

Model AR diestimasi menggunakan metode *Least Squares* sesuai dengan persamaan (2.19)

6. Uji Linearitas

Uji linieritas dilakukan dengan menghitung jumlah kuadrat residual dari model $AR(p)$ menggunakan persamaan (2.13). Residual tersebut kemudian digunakan untuk membentuk regresi bantu dan dihitung kembali jumlah kuadrat residualnya menggunakan persamaan (2.15). Selanjutnya, pengujian linieritas dilakukan dengan menggunakan statistik uji Lagrange Multiplier pada persamaan (2.16). Jika hasil pengujian menunjukkan hubungan linier, maka analisis kembali menggunakan model linier. Namun, apabila hubungan yang terbentuk bersifat nonlinier, maka analisis dilanjutkan ke tahap uji fungsi transisi.

7. Uji Transisi

Uji fungsi transisi dilakukan menggunakan statistik uji pada persamaan (2.3) berdasarkan parameter regresi bantu yang diperoleh dari hasil uji linieritas. Jika hasil pengujian menunjukkan bahwa fungsi transisi yang terbentuk adalah *exponential*, maka analisis kembali pada model sebelumnya. Namun, apabila fungsi transisi yang diperoleh adalah *logistic*, maka proses analisis dilanjutkan dengan pembentukan model LSTAR(p, l).

8. Pembentukan Model LSTAR

Tahap selanjutnya setelah pengujian fungsi transisi adalah menyusun model LSTAR(p, l) berdasarkan persamaan (2.4).

9. Estimasi model LSTAR dengan algoritma *Gauss-Newton*

- a. Inisialisasi parameter, menetapkan nilai awal untuk parameter $(\varphi_1, \varphi_2, \gamma, c)$ sebagai tebakan awal.
- b. Menghitung nilai prediksi model dengan langkah-langkah berikut: menghitung fungsi transisi G_t sesuai dengan persamaan (2.24), menghitung rezim pada persamaan (2.25) dan selanjutnya menghitung prediksi model sesuai dengan persamaan (2.24)
- c. Menghitung residual menggunakan persamaan (2.27)
- d. Menghitung matriks Jacobian menggunakan persamaan (2.28)
- e. Menghitung koreksi menggunakan persamaan (2.37) dan memperbarui parameter sesuai dengan persamaan (2.38)
- f. Menjalankan algoritma *Gauss-Newton* hingga konvergen dan mendapatkan estimasi parameter.

10. Uji Asumsi Residual

Setelah diperoleh model LSTAR, kemudian dilakukan uji normalitas residual pada persamaan (2.10), asumsi autokorelasi pada persamaan (2.11) dan homoskedastisitas pada persamaan (2.12). Uji autokorelasi dilakukan dengan uji *Ljung-Box*, sedangkan uji heteroskedastisitas dilakukan dengan *ARCH-LM*.

11. Transformasi Data


Transformasi data dilakukan dengan mengembalikan nilai prediksi dan data *testing* ke skala semula melalui proses *inverse differencing* berdasarkan persamaan (2.40).


12. Evaluasi Kinerja Model


Model yang telah dibangun kemudian dievaluasi menggunakan data uji (*testing set*) untuk mengukur tingkat akurasi prediksi. Evaluasi dilakukan dengan menggunakan *Mean Absolute Percentage Error* (MAPE) menggunakan persamaan (2.41).

3.4 Diagram Alir

Berikut ini diagram alir Estimasi *Gauss-Newton* pada Model *Logostic Smooth Transition Autoregressive* (LSTAR) dalam Prediksi Harga Saham PT Telkom Indonesia (PERSERO).







Gambar 3.1 Diagram Alir Penelitian

BAB IV

HASIL DAN PEMBAHASAN


4.1 Statistik Deskripsi Data

Statistik deskriptif digunakan untuk memberikan gambaran umum mengenai karakteristik data penelitian. Data yang dianalisis merupakan data harga penutupan saham mingguan (pada hari jumat) PT Telkom Indonesia (Persero) Tbk yang diperdagangkan di Bursa Efek Indonesia (BEI) dengan kode saham TLKM. Data tersebut diambil dari periode 6 Januari 2019 hingga 26 April 2026 kecuali pada hari jumat pada hari libur.

Tabel 4.1 Banyak Observasi

Variabel	Banyak Observasi
Harga Saham TLKM (Y)	378

Berdasarkan Tabel 4.1, data harga penutupan saham mingguan PT Telkom Indonesia (Persero) dalam satuan ribu rupiah selama periode 6 Januari 2019 hingga 26 April 2026 disajikan pada Gambar 4.1, data selengkapnya disajikan pada Lampiran 1.



Gambar 4.1 Plot Pergerakan Harga Saham PT TELKOM

Gambar 4.1 menunjukkan fluktuasi harga saham selama periode pengamatan, yaitu dari 6 Januari 2019 hingga 26 April 2026. Berdasarkan grafik tersebut, harga saham PT TELKOM mencapai titik tertinggi pada 10 April 2022 sebesar Rp4.620 per lembar saham. Kenaikan harga tersebut didorong oleh pertumbuhan laba bersih dan pendapatan pada kuartal I, yang selanjutnya membentuk persepsi positif investor terhadap prospek serta kinerja perusahaan. Sementara itu, harga saham terendah terjadi pada 16 Maret 2025 sebesar Rp2.130 per lembar saham. Penurunan tersebut dipengaruhi oleh sejumlah faktor, antara lain meningkatnya ketidakpastian terhadap kebijakan ekonomi, tingginya tekanan jual akibat *panic selling*, serta penurunan tajam Indeks Harga Saham Gabungan (IHSG) yang turut memberikan tekanan terhadap pergerakan harga saham.

4.2 Uji Stasioner

Uji stasioneritas dilakukan untuk memastikan apakah data yang digunakan memiliki rata-rata, varians, dan kovarians yang konstan sepanjang waktu. Pengujian stasioneritas pada penelitian ini menggunakan metode *Augmented Dickey-Fuller* (ADF) yang bertujuan untuk mendeteksi keberadaan akar unit dalam data. Keberadaan akar unit mengindikasikan bahwa data bersifat tidak stasioner karena menunjukkan adanya ketergantungan antarobservasi dari waktu ke waktu. Uji ADF dilakukan berdasarkan persamaan (2.7) dengan hipotesis sebagai berikut:

$H_0 : \Phi = 1$, terdapat akar unit atau data tidak stasioner.

$H_1 : \Phi < 1$, tidak terdapat akar unit atau data stasioner.

Kriteria pengambilan keputusan didasarkan pada nilai *p-value*. Apabila *p-value* < $\alpha = 0,05$, maka H_0 ditolak sehingga data dinyatakan stasioner. Sebaliknya, jika

$p\text{-value} > \alpha = 0,05$, maka H_0 gagal ditolak sehingga data dinyatakan tidak stasioner. Berikut disajikan hasil pengujian stasioneritas menggunakan uji ADF.

Tabel 4.2 Uji Stasioneritas

Variabel	ADF Statistik	Nilai Kritis 5%	$p\text{-value}$	Keputusan
Harga Saham PT Telkom (Y)	-2,137	-2,86887	0,519	Tidak Stasioner

Berdasarkan Tabel 4.2 diperoleh nilai ADF statistik sebesar $-2,137$ yang lebih besar dari nilai kritis sebesar $-2,86887$. Selain itu, $p\text{-value}$ sebesar $0,519$, yang lebih besar dibandingkan taraf signifikansi $\alpha = 0,05$. Hasil tersebut mengindikasikan bahwa H_0 gagal ditolak, sehingga data dinyatakan tidak stasioner. Oleh karena itu, diperlukan transformasi data untuk memenuhi asumsi stasioneritas. Transformasi yang diterapkan dalam penelitian ini adalah metode *differencing* sebagaimana dirumuskan pada persamaan (2.9). Pada penelitian ini digunakan *differencing* orde pertama ($d = 1$), sehingga diperoleh:

$$X_t = Y_t - Y_{t-1} \quad (4.1)$$

Berdasarkan persamaan (4.1) dan data harga saham PT Telkom pada Lampiran 1, diperoleh:

$$X_2 = Y_2 - Y_1 = 4.020 - 4.860 = 160 \quad (4.2)$$

Hasil lengkap *differencing* orde pertama disajikan pada Lampiran 2. Selanjutnya, data kembali diuji menggunakan uji ADF untuk memastikan bahwa data telah memenuhi sifat stasioner. Berikut disajikan hasil pengujian stasioneritas setelah dilakukan proses *differencing*.


Tabel 4.3 Uji Stasioneritas pada Differencing Orde Pertama


Variabel	ADF Statistik	Nilai Kritis 5%	<i>p-value</i>	Keputusan
<i>Differencing</i> Harga saham PT Telkom (<i>X</i>)	-6,681	-2,86887	0,01	Stasioner

Berdasarkan Tabel 4.3 setelah dilakukan *differencing* orde pertama diperoleh nilai ADF sebesar $-6,681$ yang lebih kecil dari nilai kritis yaitu sebesar $-2,86887$. Selain itu, nilai $p\text{-value} = 0,01$ yang lebih kecil dari taraf signifikansi $\alpha = 0,05$. Hasil tersebut menunjukkan bahwa H_0 ditolak, sehingga dapat disimpulkan bahwa data telah bersifat stasioner.

4.3 Identifikasi Model ARIMA

Setelah data dinyatakan stasioner, data hasil *differencing* kemudian dibagi menjadi dua bagian, yaitu data *training* sebesar 80% data *testing* sebesar 20%. Visualisasi plot data *training* dan *testing* disajikan sebagai berikut.

**Gambar 4.2** Plot Data *Training*



Gambar 4.3 Plot Data *Testing*

Berdasarkan Gambar 4.2 dan Gambar 4.3, dapat diamati bahwa pola pergerakan data pada periode *training* dan *testing* menunjukkan kecenderungan yang serupa. Data *training* terdiri dari 301 observasi yang mencakup periode 13 Januari 2019 hingga 3 November 2024, sedangkan data *testing* terdiri dari 76 observasi yang mencakup periode 10 November 2024 hingga 26 April 2026.

Proses identifikasi model dilakukan menggunakan data *training* yang telah *didifferencing* dengan bantuan fungsi `auto.arima` dari *package* R. Fungsi ini digunakan untuk menentukan model ARIMA (p, d, q) yang paling optimal berdasarkan nilai *Akaike Information Criterion* (AIC) terkecil. Berdasarkan hasil pengolahan data, diperoleh nilai AIC terkecil, yaitu sebesar 3.788,811 dengan model ARIMA(2,1,2), sedangkan nilai AIC untuk model ARIMA lainnya disajikan pada Lampiran 3. Berdasarkan persamaan (2.1), bentuk model AR(2) dapat dirumuskan sebagai berikut:

$$X_t = \varphi_0 + \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \varepsilon_t \quad (4.3)$$

4.4 Estimasi Parameter *Autoregressive*

Parameter model AR(2) pada persamaan (4.3) diestimasi menggunakan metode *Ordinary Least Squares* (OLS) menggunakan persamaan (2.20) , yaitu dengan meminimalkan jumlah kuadrat galat (*Sum of Squared Errors*). Metode ini bertujuan untuk memperoleh parameter yang mampu merepresentasikan hubungan antara variabel saat ini dengan nilai pada periode sebelumnya secara optimal.

Berdasarkan hasil estimasi menggunakan data *training* yang telah *didierencing*, diperoleh nilai parameter model AR(2) yang selanjutnya digunakan sebagai nilai awal (*initial value*) dalam pembentukan model nonlinier LSTAR.

Tabel 4.4 Estimasi Parameter

Parameter	Koefisien
φ_0	-4,739
φ_1	-0,163
φ_2	-0,089

Berdasarkan Tabel 4.4 estimasi parameter model AR(2) menghasilkan nilai koefisien φ_0 , φ_1 dan φ_2 masing-masing sebesar -4,739, -0,163 dan -0,089. Kemudian parameter yang diperoleh substitusikan ke dalam persamaan (4.3), sehingga diperoleh model AR(2) sebagai berikut:

$$X_t = -4,739 - 0,163X_{t-1} - 0,089X_{t-2} + \varepsilon_t \quad (4.4)$$

4.5 Uji Linieritas *Langrange Multiple*

Uji linieritas dilakukan terhadap residual dari model AR(2) untuk mengevaluasi apakah model tersebut telah mampu menjelaskan pola pergerakan data secara memadai atau masih memerlukan pendekatan nonlinier. Hasil uji

linieritas selengkapnya disajikan pada Lampiran 4. Adapun tahapan dalam pelaksanaan uji linieritas adalah sebagai berikut:

1. Hitung jumlah kuadrat residual (*sum of squared errors*) dari model AR(2)

$$\begin{aligned} SSE_0 &= \hat{\varepsilon}_1^2 + \hat{\varepsilon}_2^2 + \dots + \hat{\varepsilon}_{299}^2 \\ &= (-13,801)^2 + (-29,390)^2 + \dots + (-63,419)^2 \\ &= 5.065.766 \end{aligned} \quad (4.5)$$

2. Bangun regresi bantu (*auxiliary regression*) menggunakan residual AR(2) dapat dituliskan sebagai berikut:

$$\begin{aligned} \hat{\varepsilon}_t &= \beta_{00} + \sum_{i=1}^2 \beta_{0i} X_{t-i} + \sum_{i=1}^2 \beta_{1i} X_{t-i} s_t + \\ &\quad \sum_{i=1}^2 \beta_{2i} X_{t-i} s_t^2 + \sum_{i=1}^2 \beta_{3i} X_{t-i} s_t^3 + e_t \end{aligned} \quad (4.6)$$

Persamaan (4.6) merupakan regresi bantu untuk mengidentifikasi kandidat variabel transisi dalam model. Berdasarkan persamaan tersebut, variabel transisi yang diuji adalah X_{t-1} dan X_{t-2} . Parameter regresi bantu di estimasi menggunakan metode *Ordinary least square*. Selanjutnya, jumlah kuadrat residual dari regresi bantu akan dihitung menggunakan persamaan (2.15) sebagai berikut:

$$SSE_1 = \hat{e}_1^2 + \hat{e}_2^2 + \dots + \hat{e}_{299}^2 \quad (4.7)$$

Berdasarkan residual model regresi bantu dengan variabel transisi X_{t-1} yang disajikan pada Lampiran 4, diperoleh hasil sebagai berikut.

$$\begin{aligned} SSE_1 &= (-35,10)^2 + (-21,68)^2 + \dots + (-71,04)^2 \\ &= 4.832.435 \end{aligned} \quad (4.8)$$

Nilai variabel X_{t-2} dilakukan dengan cara perhitungan yang sama.

3. Uji linieritas pada penelitian ini menggunakan statistik uji *Lagrange Multiplier* (LM) pada persamaan (2.16) dengan hipotesis sebagai berikut :

$$H_0: \beta_{1i} = \beta_{2i} = \beta_{3i} = 0 \text{ (model linier)}$$

$$H_1: \exists \beta_{ji} \neq 0 \text{ (model nonlinier), } j = 1,2,3 \text{ dan } i = 1,2,\dots,p$$

Kriteria pengambilan keputusan didasarkan pada nilai *p-value*. Jika *p-value* $< \alpha = 0,05$, maka H_0 ditolak, sehingga model nonlinier diperlukan.

Berdasarkan uji LM, hasil perhitungan disajikan pada tabel berikut:

Tabel 4.5 Uji Linieritas Model AR(2)

Variabel Transisi (X_{t-l})	Statistik LM	$\chi^2_{(6,0,05)}$	<i>p-value</i>
X_{t-1}	13,772	12,592	0,032
X_{t-2}	9,388	12,592	0,152

Berdasarkan Tabel 4.5, diperoleh nilai *p-value* pada variabel transisi X_{t-1} sebesar $0,032 < \alpha = 0,05$ dan nilai $LM = 13,772 > \chi^2_{(6,0,05)} = 12,592$, sehingga H_0 ditolak yang mengindikasikan adanya hubungan nonlinier. Sementara itu, hasil *p-value* pada variabel transisi X_{t-2} sebesar $0,152 < \alpha = 0,05$ dan nilai $LM = 9,388 < \chi^2_{(6,0,05)} = 12,592$ yang menunjukkan terima H_0 . Berdasarkan hasil tersebut, variabel X_{t-1} merupakan variabel yang signifikan. Hasil ini menunjukkan bahwa model AR(2) belum sepenuhnya mampu merepresentasikan pola pergerakan data secara linier, sehingga diperlukan pendekan model nonlinier.

4.6 Identifikasi Model STAR

Setelah uji linieritas menunjukkan adanya indikasi hubungan yang bersifat nonlinier, tahap selanjutnya adalah melakukan identifikasi untuk menentukan

bentuk model nonlinier yang paling sesuai, yaitu apakah mengikuti fungsi *logistic* (LSTAR) atau *exponential* (ESTAR). Penentuan jenis fungsi transisi tersebut dilakukan dengan menguji signifikansi parameter pada model regresi bantu. Dengan menggunakan variabel transisi terpilih $s_t = X_{t-1}$, bentuk regresi bantu pada persamaan (4.6) dinyatakan sebagai berikut.

$$\begin{aligned} \hat{\varepsilon}_t = & \beta_{00} + \beta_{01}X_{t-1} + \beta_{02}X_{t-1} + \beta_{11}X_{t-1}^2 + \beta_{12}X_{t-1}X_{t-2} + \beta_{21}X_{t-1}^3 + \\ & \beta_{22}X_{t-1}^2X_{t-2} + \beta_{31}X_{t-1}^4 + \beta_{32}X_{t-1}^3X_{t-2} + e_t \end{aligned} \quad (4.9)$$

Statistik uji yang digunakan terdapat pada persamaan (2.10) dengan hipotesis sebagai berikut:

$$H_0 : \beta_{ij} = 0, \forall i = 1, 2 \text{ (model eksponensial)}$$

$$H_1 : \exists \beta_{ij} \neq 0 \text{ (model logistik)}$$

Kriteria pengambilan keputusan yaitu tolak H_0 apabila nilai $|t_{hitung}| > t_{(T-u; \alpha/2)}$ atau $p\text{-value} < \alpha = 0,05$ yang menunjukkan bahwa fungsi transisi yang sesuai adalah fungsi logistik (LSTAR). Sebaliknya, jika $|t_{hitung}| < t_{(T-u; \alpha/2)}$ dan $p\text{-value} > \alpha = 0,05$ maka gagal tolak H_0 dan pengujian dilanjutkan pada hipotesis berikutnya. Estimasi regresi bantu pada persamaan (4.9) dilakukan dengan menggunakan metode OLS karena model tersebut bersifat linier terhadap parameter β . Dengan variabel transisi $s_t = X_{t-1}$, hasil estimasi regresi bantu yang ditunjukkan pada Tabel 4.6.

Berdasarkan Tabel 4.6, parameter β_3 pada lag-1 yaitu β_{31} memiliki nilai $|t_{hitung}| = 2,372$ dan $p\text{-value} = 0,019$. Pada taraf signifikansi sebesar 0,05 dengan nilai $\alpha/2 = 0,025$ dan derajat kebebasan $df = T - u = 299 - 9 = 290$, diperoleh nilai kritis $t_{(290; 0,025)} \approx 1,968$. Hasil pengujian menunjukkan bahwa nilai $|t_{hitung}|$ lebih besar dari nilai kritis tersebut serta nilai $p\text{-value} < \alpha = 0,05$. Dengan demikian H_0

ditolak, yang berarti fungsi transisi logistik dipilih. Berdasarkan hasil tersebut, model yang digunakan adalah *Logistic Smooth Transition Autoregressive* (LSTAR) dengan orde $p = 2$ dan $l = 1$.

Tabel 4.6 Estimasi Model Regresi Bantu

Parameter	Koefisien	Std. Error	t_{hitung}	p -value
β_{00}	-3,088	1,001	-0,309	0,757
β_{01}	$-5,743 \times 10^{-2}$	$9,109 \times 10^{-2}$	-0,630	0,528
β_{02}	$3,352 \times 10^{-2}$	$7,414 \times 10^{-2}$	0,452	0,651
β_{11}	$9,156 \times 10^{-4}$	$6,476 \times 10^{-4}$	1,414	0,158
β_{12}	$-4,320 \times 10^{-4}$	$6,325 \times 10^{-4}$	-0,683	0,495
β_{21}	$9,307 \times 10^{-7}$	$1,180 \times 10^{-6}$	0,789	0,430
β_{22}	$-1,245 \times 10^{-6}$	$2,401 \times 10^{-6}$	-0,518	0,604
β_{31}	$-1,047 \times 10^{-8}$	$4,415 \times 10^{-9}$	-2,3721	0,019
β_{32}	$1,402 \times 10^{-8}$	$7,815 \times 10^{-9}$	1,793	0,074

Berdasarkan bentuk umum LSTAR pada persamaan (2.4), model LSTAR(2,1) dapat dituliskan sebagai berikut:

$$\begin{aligned}
 X_t = & (\varphi_{10} + \varphi_{11}X_{t-1} + \varphi_{12}X_{t-2}) \left(1 - \left(\frac{1}{1 + e^{(-\gamma(X_{t-1}-c))}} \right) \right) \\
 & + (\varphi_{20} + \varphi_{21}X_{t-1} + \varphi_{22}X_{t-2}) \left(\frac{1}{1 + e^{(-\gamma(X_{t-1}-c))}} \right) + \varepsilon_t
 \end{aligned} \tag{4.10}$$

4.7 Estimasi *Gauss-Newton*

Estimasi parameter pada model LSTAR(2,1) pada persamaan (4.10) dilakukan menggunakan metode *Nonlinear Least Squares* (NLS) dengan algoritma *Gauss-Newton*. Metode ini digunakan untuk memperoleh nilai parameter yang meminimumkan jumlah kuadrat residual antara nilai aktual dan nilai hasil estimasi model. Adapun tahapan algoritma *Gauss-Newton* adalah sebagai berikut:

1. Menentukan nilai parameter awal

Langkah pertama adalah menentukan nilai awal parameter. Tebakan awal parameter sebagai berikut:

$$\boldsymbol{\theta}^{(0)} = (\boldsymbol{\varphi}_1, \boldsymbol{\varphi}_2, \gamma, c) \quad (4.11)$$

dengan:

$\boldsymbol{\varphi}_1 = (\varphi_{10}, \varphi_{11}, \varphi_{12})$, merupakan parameter koefisien linier pada rezim pertama yang diperoleh berdasarkan hasil estimasi model AR(2) dengan masing-masing nilainya adalah $(-4,739; -0,163; -0,089)$.

$\boldsymbol{\varphi}_2 = (\varphi_{20}, \varphi_{21}, \varphi_{22})$, merupakan koefisien pada rezim kedua yang didapatkan dari proporsi kecil dari $\boldsymbol{\varphi}_1$, yaitu sebesar $(0,95)\boldsymbol{\varphi}_1$ dengan masing-masing nilainya adalah $(-4,502; -0,155; -0,085)$.

γ = Parameter pemuluan yang diperoleh dari metode *grid search* dengan nilai sebesar 6,6.

c = Parameter ambang batas ditentukan berdasarkan median variabel transisi yang digunakan dalam model, yaitu sebesar -10 . Sehingga diperoleh nilai awal parameter sebagai berikut:

$$\boldsymbol{\theta}^{(0)} = [-4,73; -0,163; -0,089; -4,502; -0,155; -0,085; 6,6; -10] \quad (4.12)$$

2. Menghitung nilai Prediksi Model

Nilai prediksi model dilakukan dengan langkah-langkah berikut:

Langkah 1: hitung fungsi transisi pada persamaan (2.24)

$$G_t = \frac{1}{1 + e^{-\gamma(X_{t-1} - c)}} \quad (4.13)$$

Diketahui nilai X_t dimulai pada observasi ke-3 adalah

$X_3 = -10$, dengan lag $X_2 = -140$ dan $X_1 = 160$ yang diperoleh dari data *differencing* orde pertama. Didapatkan hasil fungsi transisi logistik adalah sebagai berikut:

$$\begin{aligned} G_3 &= \frac{1}{1 + e^{-6,6(-140 - (-10))}} \\ &= \frac{1}{1 + e^{858}} \approx 0 \end{aligned} \quad (4.14)$$

Dalam model LSTAR, nilai $G \approx 0$ menunjukkan bahwa model sepenuhnya berada pada rezim 1 (*bearish*).

Langkah 2: Hitung rezim sesuai dengan persamaan (2.25)

Rezim 1:

$$\begin{aligned} \vartheta_1 &= \varphi_{10} + \varphi_{11} X_{t-1} + \varphi_{12} X_{t-2} \\ &= (-4,73 + (-0,163)(-140) + (-0,089)(160)) \\ &= -4,73 + 22,82 + 14,24 = 3,809 \end{aligned} \quad (4.15)$$

Rezim 2:

$$\begin{aligned} \vartheta_2 &= \varphi_{20} + \varphi_{21} X_{t-1} + \varphi_{22} X_{t-2} \\ &= (-4,502 - 0,155(-140) - 0,085(160)) \\ &= -4,502 + 21,7 - 13,6 = 3,598 \end{aligned} \quad (4.16)$$

Nilai prediksi model dihitung menggunakan persamaan (2.26)

$$\begin{aligned} \hat{X}_3 &= (3,809)(1 - 0) + 3,598(0) \\ &= 3,809 \end{aligned} \quad (4.17)$$

3. Menghitung residual menggunakan persamaan (2.27) dihitung dari selisih antara nilai aktual dan nilai estimasi model sebagai berikut:

$$\begin{aligned} r_3 &= X_3 - \hat{X}_3 \\ &= -10 - 3,809 = -13,809 \end{aligned} \quad (4.18)$$

Residual tersebut kemudian disusun dalam bentuk vektor residual yang akan digunakan dalam proses pembentukan matriks Jacobian.

4. Membentuk Matriks Jacobian

Langkah selanjutnya adalah membentuk matriks Jacobian yang berisi turunan parsial residual terhadap setiap parameter model. Turunan dilakukan terhadap seluruh parameter model yang terdiri dari parameter linier rezim pertama, parameter linier rezim kedua, parameter kemiringan transisi, dan parameter *threshold* pada persamaan dengan $t = 3$:

a. Parameter $\boldsymbol{\varphi}_1$:

$$\begin{aligned}\frac{\partial \hat{X}_3}{\partial \varphi_{10}} &= 1 - G_3 = 1 - 0 = 1 \\ \frac{\partial \hat{X}_3}{\partial \varphi_{11}} &= X_2 (1 - G_3) = -140(1) = -140 \\ \frac{\partial \hat{X}_3}{\partial \varphi_{12}} &= X_1 (1 - G_3) = 160(1) = 160\end{aligned}\tag{4.19}$$

b. Parameter $\boldsymbol{\varphi}_2$:

$$\begin{aligned}\frac{\partial \hat{X}_3}{\partial \varphi_{20}} &= G_3 = 0 \\ \frac{\partial \hat{X}_3}{\partial \varphi_{21}} &= X_{t-1} G_3 = -140(0) = 0 \\ \frac{\partial \hat{X}_3}{\partial \varphi_{22}} &= X_{t-2} G_3 = 160(0) = 0\end{aligned}\tag{4.20}$$

c. Parameter γ :

$$\begin{aligned}\frac{\partial \hat{X}_3}{\partial \gamma} &= (\varphi_1^{(0)} - \varphi_2^{(0)}) G_3 (1 - G_3) (X_2 - c) \\ &= (3,089 - 3,598)(1)(1 - 1)(-140 - 6) = 0\end{aligned}\tag{4.21}$$

d. Parameter c :

$$\begin{aligned}\frac{\partial \hat{X}_3}{\partial c} &= -(\varphi_1^{(0)} - \varphi_2^{(0)})G_3(1 - G_3) \\ &= -(3,089 - 3,598)(0)(1 - 0) = 0\end{aligned}\quad (4.22)$$

Bentuk matriks Jacobian untuk $t = 3$ adalah sebagai berikut:

$$J_3 = [1 \quad -140 \quad 160 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0] \quad (4.23)$$

5. Menghitung Koreksi Parameter

Perubahan parameter dihitung menggunakan persamaan (2.38)

$$\boldsymbol{\theta}^{(1)} = \boldsymbol{\theta}^{(0)} + (\mathbf{J}^T \mathbf{J})^+ \mathbf{J}^T \mathbf{r} \quad (4.24)$$

Langkah 1: Menentukan matriks Jacobian dan residual dari observasi ke-3 berdasarkan persamaan (4.23) dan (4.18)

Langkah 2: menghitung $\mathbf{J}^T \mathbf{J}$

$$\begin{aligned}\mathbf{J}^T \mathbf{J} &= \begin{bmatrix} 1 \\ -140 \\ 160 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \cdot [1 \quad -140 \quad 160 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0] \\ &= \begin{bmatrix} 1 & -140 & 160 & 0 & 0 & 0 & 0 & 0 \\ -140 & 19600 & -22400 & 0 & 0 & 0 & 0 & 0 \\ 160 & -22400 & 25600 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}\end{aligned}\quad (4.25)$$

Karena matriks bersifat singular maka digunakan *pseudoinverse* untuk menghitung koreksi parameter dengan nilai $\mathbf{J}\mathbf{J}^T$ sebagai berikut:

$$\mathbf{J}\mathbf{J}^T = 1^2 + (-140)^2 + 160^2 = 1 + 19600 + 25600 = 45201$$

Langkah 3: menghitung $J^T r$

$$J^T r = \begin{bmatrix} 1 \\ -140 \\ 160 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \cdot -13,809 = \begin{bmatrix} -13,809 \\ 1933,26 \\ -2209,44 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad (4.26)$$

Langkah 4: menghitung $\Delta \theta = \frac{1}{J J^T} (J^T r)$

$$\Delta \theta = \frac{1}{45201} \cdot \begin{bmatrix} -13,809 \\ 1933,26 \\ -2209,44 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} -0,000305 \\ 0,04277 \\ -0,04888 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad (4.27)$$

Langkah 5: memperbaharui parameter pada iterasi pertama

$$\theta^{(1)} = \theta^{(0)} + \Delta \theta \quad (4.28)$$

dengan nilai:

$$\theta^{(0)} = [-4,73; -0,163; -0,089; -4,502; -0,155; -0,085; 6,6; -10]$$

sehingga diperoleh pembaharuan iterasi pertama berikut:

$$\theta^{(1)} = [-4,730305; -0,20577; -0,13788; -4,502; -0,155; -0,085; 6,6; -10]$$

Berdasarkan hasil perhitungan, nilai parameter pada iterasi ke-1 hanya mengalami perubahan yang relatif kecil dibandingkan nilai awal. Kondisi ini mengindikasikan bahwa proses iterasi tidak memerlukan penyesuaian yang besar untuk mengurangi residual, sehingga nilai parameter awal sudah berada pada kondisi yang cukup stabil terhadap model.

6. Mengecek konvergensi

Langkah selanjutnya adalah proses iterasi yang dilakukan secara berulang hingga nilai parameter yang diperoleh mencapai kondisi stabil (konvergen).

Dalam proses estimasi parameter menggunakan metode *Gauss-Newton*, fungsi objektif yang digunakan adalah *Sum of Squared Errors* (SSE) pada persamaan (2.39) dengan tujuan meminimalkan selisih nilai SSE. Dalam proses iterasi, penurunan nilai SSE pada setiap langkah menunjukkan bahwa fungsi objektif berhasil diminimalkan dan model semakin mendekati kondisi optimal. Perubahan nilai SSE pada setiap iterasi ditunjukkan sebagai berikut:

Tabel 4.7 Nilai SSE

Iterasi	SSE	Selisih Nilai
1	5.024.992,796347	-
2	5.009.116,577350	15876,218997
3	5.000.756,669709	8359,907641
4	5.000.756,669707	0,000002

Berdasarkan Tabel 4.7, nilai *Sum of Squared Errors* (SSE) menurun secara bertahap hingga mencapai nilai minimum sebesar 5.000.756,669707. Penurunan SSE pada iterasi awal cukup besar, kemudian semakin kecil pada iterasi berikutnya hingga mendekati nol. Pada iterasi ke-4, selisih nilai SSE sebesar 0,000002 lebih kecil dari batas toleransi konvergensi 10^{-5} . Pola penurunan selisih nilai SSE yang semakin kecil menunjukkan bahwa algoritma *Gauss-Newton* bekerja secara stabil dalam mendekati titik minimum fungsi objektif. Dengan terpenuhinya kriteria konvergensi tersebut, proses estimasi dinyatakan telah konvergen, sehingga parameter yang diperoleh pada iterasi ke-4 merupakan hasil estimasi akhir. Parameter hasil estimasi model LSTAR(2,1) yang diperoleh dari proses estimasi menggunakan metode *Gauss-Newton* secara iteratif ditunjukkan pada Tabel 4.8.

Berdasarkan Tabel 4.8, model LSTAR(2,1) menunjukkan adanya dua rezim yang menggambarkan kondisi pergerakan saham. Nilai konstanta model pada rezim

pertama yaitu sebesar $-12,283$ dengan koefisien lag $X_{t-1} = -0,159$ dan $X_{t-2} = -0,093$. Nilai konstanta yang negatif menunjukkan adanya kecenderungan penurunan pada perubahan harga saham. Selain itu, koefisien lag yang juga bernilai negatif semakin memperkuat arah penurunan tersebut, sehingga rezim pertama dapat diinterpretasikan sebagai kondisi pasar yang sedang melemah atau *bearish*. Sementara itu, rezim kedua memiliki nilai konstanta $33,399$ dengan koefisien lag $X_{t-1} = -0,211$ dan $X_{t-2} = 0,014$. Konstanta yang bernilai positif mencerminkan kecenderungan peningkatan dalam perubahan harga saham. Meskipun koefisien X_{t-1} bernilai negatif yang menunjukkan adanya koreksi dari periode sebelumnya, koefisien X_{t-2} yang positif mengindikasikan adanya pengaruh peningkatan dari dua periode sebelumnya. Oleh karena itu, rezim kedua dapat menggambarkan kondisi pasar yang cenderung menguat atau *bullish*.

Nilai parameter kecepatan transisi sebesar $\gamma = 6,591$ yang berarti bernilai positif menunjukkan bahwa perpindahan antar rezim berlangsung relatif cepat. Nilai ambang batas (*threshold*) sebesar $c = -11,529$ yang berfungsi sebagai nilai ambang batas dalam menentukan perpindahan. Ketika $X_{t-1} < -11,529$, model cenderung berada pada rezim pertama (*bearish*). Sebaliknya, jika $X_{t-1} > -11,529$, maka model akan lebih condong berada pada rezim kedua (*bullish*).

Tabel 4.8 Estimasi Model LSTAR(2,1)

Parameter	Koefisien
Rezim 1 (Rezim <i>Bearish</i>)	
φ_{10}	$-12,283$
φ_{11}	$-0,159$
φ_{12}	$-0,093$
Rezim 2 (Rezim <i>Bullish</i>)	
φ_{20}	$33,399$
φ_{21}	$-0,211$
φ_{22}	$0,014$
Parameter Transisi	
γ	$6,591$
c	$-11,529$

Hasil estimasi pada Tabel 4.8 disubstitusikan ke dalam model LSTAR(2,1) pada persamaan 4.10, sehingga diperoleh model LSTAR(2,1) sebagai berikut:

$$X_t = (-12,283 - 0,159X_{t-1} - 0,093X_{t-2}) \left(1 - \left(\frac{1}{1 + e^{(-6,591(X_{t-1} + 11,529))}} \right) \right) + (33,399 - 0,211X_{t-1} + 0,014X_{t-2}) \left(\frac{1}{1 + e^{(-6,591(X_{t-1} + 11,529))}} \right) + \varepsilon_t \quad (4.27)$$

4.8 Uji Asumsi Residual

Setelah model LSTAR(2,1) diperoleh, langkah selanjutnya adalah melakukan pengujian terhadap residual model. Pengujian ini dilakukan untuk memastikan bahwa model yang dihasilkan telah memenuhi asumsi-asumsi dalam analisis deret waktu (*time series*). Berikut beberapa pengujian yang dilakukan terhadap residual model LSTAR(2,1):

4.8.1 Uji Autokorelasi Residual

Uji autokorelasi dilakukan untuk mengetahui apakah residual model saling bebas atau masih memiliki korelasi pada beberapa lag waktu tertentu. Pengujian autokorelasi residual dilakukan menggunakan uji Ljung–Box sebagaimana ditunjukkan pada persamaan (2.11) dengan hipotesis sebagai berikut:

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_h = 0 \text{ (tidak ada autokorelasi)}$$

$$H_1 : \exists \rho_k \neq 0 \text{ dengan } k = 1, 2, \dots, h \text{ (terdapat autokorelasi)}$$

Kriteria pengambilan keputusan adalah tolak H_0 apabila nilai $p\text{-value} < \alpha$ yang menunjukkan bahwa residual model terdapat autokorelasi. Berikut disajikan hasil pengujian autokorelasi residual menggunakan uji Ljung–Box:

Tabel 4.9 Hasil Uji Autokorelasi Residual

Lag	Q_{hitung}	$\chi^2_{(df;0,05)}$	$p-value$
1	0,027	3,841	0,998
2	0,084	5,591	0,954
3	1,456	7,815	0,706
4	2,312	9,488	0,632
5	2,331	11,070	0,761
6	7,686	12,592	0,233
7	9,832	14,017	0,181
8	10,078	15,507	0,239
9	10,103	16,919	0,315
10	10,685	18,307	0,370
11	12,536	19,675	0,299
12	12,863	21,026	0,337
13	12,956	22,368	0,395
14	14,176	23,685	0,412
15	14,437	24,996	0,453
16	16,933	26,296	0,316
17	17,109	27,587	0,364
18	19,893	28,869	0,292

Berdasarkan Tabel 4.9, nilai Q_{hitung} pada lag 1 sampai 18 lebih kecil dari nilai $\chi^2_{(df;0,05)}$ dan semua nilai $p-value$ besar dari $\alpha = 0,05$. Hasil tersebut menunjukkan bahwa H_0 gagal ditolak, sehingga dapat disimpulkan bahwa residual model LSTAR(2,1) tidak mengandung autokorelasi.

4.8.2 Uji Heteroskedastisitas Residual

Uji heteroskedastisitas dilakukan untuk mengetahui apakah varians residual pada model bersifat konstan (homoskedastisitas). Pengujian ini dilakukan

menggunakan uji *Lagrange Multiplier* (LM) sebagaimana dinyatakan pada persamaan (2.12) dengan hipotesis pengujian sebagai berikut:

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_k = 0 \text{ (tidak ada heteroskedastisitas)}$$

$$H_1 : \exists \mu_m \neq 0 \text{ dengan } m = 1, 2, \dots, k \text{ (ada heteroskedastisitas)}$$

Kriteria pengambilan keputusan adalah tolak H_0 apabila nilai $p\text{-value} < \alpha$ yang menunjukkan bahwa residual bersifat heteroskedastis. Berikut disajikan hasil pengujian autokorelasi residual menggunakan uji LM:

Tabel 4.10 Hasil Uji Heteroskedastisitas Residual

LM	$\chi^2_{(18;0,05)}$	$p\text{-value}$
6,481	28,869	0,242

Berdasarkan Tabel 4.10, diperoleh nilai LM = 6,481 dan nilai $p\text{-value}$ = 0,242. Pada taraf signifikansi $\alpha = 0,05$ dengan jumlah lag maksimum yang diuji sebanyak $k = 18$ diperoleh nilai $\chi^2_{(18;0,05)} = 28,869$. Nilai LM lebih kecil dari $\chi^2_{(18;0,05)}$ dan nilai $p\text{-value}$ yang diperoleh lebih besar dari α . Hasil tersebut menunjukkan bahwa H_0 gagal ditolak, sehingga dapat disimpulkan bahwa residual dari model LSTAR(2,1) bersifat homogen (homoskedastis) atau tidak mengandung heteroskedastisitas.

4.8.3 Uji Normalitas Residual

Uji normalitas dilakukan untuk mengetahui apakah residual dari model berdistribusi normal. Pengujian normalitas residual ini dilakukan menggunakan uji Kolmogorov–Smirnov sebagaimana dinyatakan pada persamaan (2.10) dengan hipotesis sebagai berikut:

$$H_0 : \text{Residual mengikuti distribusi normal}$$

$$H_1 : \text{Residual tidak mengikuti distribusi normal}$$

Kriteria keputusan, jika nilai $D_{hitung} > D_{(N;\alpha)}$ atau nilai $p-value < \alpha$ maka tolak H_0 , artinya residual tidak mengikuti distribusi normal.

Tabel 4.11 Hasil Uji Normalitas Residual

D_{hitung}	$D_{(299;0,05)}$	$p-value$
0,0629	0,078	0,2027

Berdasarkan Tabel 4.11, diperoleh nilai $D_{hitung} = 0,0629$ dan $p-value = 0,2027$. Pada taraf signifikansi $\alpha = 0,05$ dan jumlah residual sebanyak 299, diperoleh nilai kritis $D_{(299;0,05)} = 0,078$. Karena nilai D_{hitung} lebih kecil dari nilai kritis $D_{(299;0,05)}$ dan nilai $p-value$ lebih besar dari α , maka H_0 gagal ditolak. Sehingga dapat disimpulkan bahwa residual model LSTAR(2,1) berdistribusi normal.

4.9 Prediksi dan Transformasi

Setelah seluruh pengujian asumsi residual terpenuhi, model LSTAR(2,1) kemudian digunakan untuk melakukan prediksi terhadap harga saham PT Telkom Indonesia (Persero). Model ini dibangun menggunakan data yang telah melalui proses *differencing* orde pertama, sehingga proses peramalan dilakukan berdasarkan data *differencing* yang ditampilkan pada Lampiran 2. Berikut merupakan hasil prediksi untuk observasi ke-303 yang diperoleh.

$$\begin{aligned}
 \hat{X}_{303} &= (-12,283 - 0,159(-30) - 0,093(-130)) \left(1 - \left(\frac{1}{1 + e^{(-6,591(-30 + 11,529))}} \right) \right) \\
 &\quad + (33,399 - 0,211(-30) + 0,014(-130)) \left(\frac{1}{1 + e^{(-6,591(-30 + 11,529))}} \right) \\
 &\approx 4,577
 \end{aligned} \tag{4.28}$$

Berdasarkan hasil tersebut, diketahui bahwa nilai prediksi *differencing* harga saham PT Telkom Indonesia (Persero) pada tanggal 10 November 2024. Dengan

menggunakan perhitungan yang sama, diperoleh nilai prediksi $\hat{X}_{304}$ sampai $\hat{X}_{378}$ yang selengkapnya disajikan pada lampiran 8.

Dalam tahap evaluasi model, data yang digunakan harus berada pada skala asli, sehingga data yang masih berada pada skala *differencing* perlu dikembalikan ke skala awal melalui proses *inverse differencing* sebagaimana ditunjukkan pada persamaan (2.40). Karena orde *differencing* yang digunakan adalah satu ($d = 1$), maka bentuk *inverse differencing* yang digunakan adalah sebagai berikut:

$$Y_t = X_t + Y_{t-1} \quad (4.29)$$

Data harga saham PT Telkom Indonesia (Persero) pada skala asli (Y_t) disajikan pada Lampiran 1, sedangkan data yang telah melalui proses *differencing* (X_t) disajikan pada Lampiran 2. Berikut ditampilkan proses *inverse differencing* yang dilakukan untuk mengembalikan data ke skala aslinya.

Inverse differencing data training:

$$\begin{aligned} Y_2 &= X_2 + Y_1 = 160 + 3.860 = 4.020 \\ &\vdots \end{aligned} \quad (4.30)$$

$$Y_{302} = X_{302} + Y_{301} = -30 + 2.780 = 2.750$$

Perhitungan dimulai dari $\hat{Y}_{305}$ karena model dengan $p = 2$ membutuhkan dua data sebelumnya sehingga *inverse differencing* data prediksi adalah sebagai berikut:

$$\hat{Y}_{305} = \hat{X}_{305} + Y_{304} = 23,97 + 2.800 = 2.827,97 \quad (4.31)$$

Hasil proses *inverse differencing* untuk data *testing* (Y_t) serta hasil data prediksi masing disajikan pada Lampiran 9.

4.10 Evaluasi Model

Tingkat akurasi model dinilai menggunakan *Mean Absolute Percentage Error* (MAPE) sebagaimana ditunjukkan pada persamaan (2.41). Menggunakan data *testing* yang sudah ditransformasi, hasil perhitungan nilai MAPE adalah sebagai berikut:

$$\begin{aligned}
 MAPE &= \left(\frac{1}{72} \left(\left| \frac{2.830 - 2.827,73}{2.830} \right| + \dots + \left| \frac{3.410 - 3.415,21}{3.410} \right| \right) \times 100\% \right) \\
 &= \left(\frac{1}{72} (0,00080 + \dots + (-0,0015)) \times 100\% \right) \\
 &= 0,71\%
 \end{aligned} \tag{4.32}$$

Berdasarkan persamaan (4.32), nilai MAPE diperoleh dari hasil perhitungan menggunakan data katual dan data hasil prediksi diperoleh nilai MAPE model LSTAR(2,1) sebesar 0,71%. Berdasarkan pada kriteria yang tercantum pada Tabel 2.1, nilai tersebut termasuk dalam kategori akurat dalam melakukan peramalan pada data harga saham PT Telkom Indonesia (Persero).


Grafik perbandingan antara data aktual dan hasil prediksi harga saham PT Telkom Indonesia (Persero) pada data *testing* disajikan pada gambar berikut.



Gambar 4.4 Grafik Perbandingan Harga Saham pada Data *Testing*

Gambar 4.4 menunjukkan bahwa model LSTAR(2,1) mampu mengikuti pola umum pergerakan harga saham pada data *testing*, terutama pada periode awal. Namun, seiring berjalannya waktu, hasil prediksi cenderung lebih halus dan tidak mampu menangkap fluktuasi tajam, khususnya saat terjadi kenaikan harga yang signifikan, sehingga nilai prediksi berada di bawah data aktual.

Grafik yang menunjukkan *error* hasil prediksi pada data testing ditampilkan pada gambar berikut.



Gambar 4.5 Error pada Data Testing

Gambar 4.5 menunjukkan bahwa *error* prediksi model LSTAR pada data *testing* awalnya berfluktuasi di sekitar nol, menandakan prediksi cukup mendekati nilai aktual. Namun, pada periode selanjutnya *error* cenderung meningkat dan didominasi nilai positif, yang menunjukkan bahwa model sering mengestimasi lebih rendah dari nilai aktual, terutama saat terjadi kenaikan harga yang signifikan.

4.11 Kajian Integrasi Penelitian dalam Islam

Hasil penelitian menunjukkan bahwa parameter model nonlinier pada pergerakan harga saham PT Telkom Indonesia (Persero) dapat diestimasi dengan baik menggunakan metode *Gauss-Newton*. Metode ini bekerja secara iteratif

dengan meminimalkan jumlah kuadrat galat (*sum of squared errors*), sehingga mampu menghasilkan estimasi parameter yang konvergen dan stabil. Proses iteratif tersebut memungkinkan model menyesuaikan diri terhadap pola data yang kompleks, khususnya dalam menangkap hubungan nonlinier yang tidak dapat dijelaskan oleh model linier konvensional. Dengan demikian, model LSTAR yang dihasilkan mampu merepresentasikan dinamika harga saham secara lebih fleksibel dan realistis.

Selain itu, penggunaan metode *Gauss-Newton* memberikan keunggulan dalam hal efisiensi komputasi dan ketepatan estimasi, karena memanfaatkan pendekatan turunan parsial (Jacobian) dalam proses optimasi. Hal ini membuat parameter yang diperoleh tidak hanya optimal secara matematis, tetapi juga memiliki interpretasi yang kuat dalam menggambarkan perubahan rezim pada pergerakan harga saham. Dengan adanya model yang lebih akurat dan stabil, investor dapat memperoleh informasi yang lebih jelas dan terukur sebagai dasar dalam pengambilan keputusan investasi, sehingga risiko kesalahan akibat ketidakpastian dapat diminimalkan.

Dalam perspektif Islam, aktivitas investasi diperbolehkan selama dilakukan secara transparan, adil, dan tidak mengandung unsur yang dilarang seperti riba, *gharar* (ketidakjelasan), dan manipulasi. Prinsip ini sejalan dengan firman Allah dalam Al-Qur'an surat Al-Baqarah ayat 282 yang menekankan pentingnya pencatatan dan kejelasan dalam setiap transaksi. Ayat tersebut mengandung pesan bahwa setiap aktivitas muamalah dilakukan secara sistematis, transparan, dan dapat dipertanggungjawabkan, sehingga meminimalkan perselisihan di kemudian hari.

Menurut tafsir Al-Misbah karya M. Quraish Shihab dalam Aljawwi (2024), Al-Qur'an surat Al-Baqarah ayat 282 tidak hanya mengatur pencatatan transaksi utang-piutang, tetapi juga memberikan prinsip umum bahwa seluruh aktivitas keuangan harus dilaksanakan secara teliti, jelas, dan dapat dipertanggungjawabkan. Hal ini menunjukkan bahwa Islam sangat menekankan pentingnya akurasi informasi dan transparansi dalam aktivitas ekonomi, termasuk dalam investasi di pasar modal.

Penggunaan metode *Gauss-Newton* dalam penelitian ini mencerminkan upaya untuk menerapkan prinsip-prinsip tersebut dalam analisis data keuangan. Dengan pendekatan yang berbasis data dan metode matematis yang jelas, hasil yang diperoleh menjadi lebih objektif, terukur, dan dapat diuji kebenarannya. Hal ini sejalan dengan nilai kejujuran (*shiddiq*) dan kehati-hatian (*ihtiyat*) dalam Islam, yang menuntut setiap individu untuk menghindari spekulasi berlebihan (*gharar*) dalam pengambilan keputusan.

Dengan demikian, penerapan model LSTAR yang diestimasi menggunakan metode *Gauss-Newton* tidak hanya memberikan kontribusi secara akademis dalam pemodelan data *time series* nonlinier, tetapi juga memiliki implikasi praktis dalam mendukung pengambilan keputusan investasi yang lebih rasional, transparan, dan sesuai dengan prinsip-prinsip syariah. Investor diharapkan dapat memanfaatkan informasi yang dihasilkan dari model ini untuk mengambil keputusan yang lebih bijak, bertanggung jawab, dan berlandaskan pada nilai-nilai etika dalam Islam.

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan rumusan masalah dan pembahasan, maka dapat diambil kesimpulan sebagai berikut:

1. Bentuk model LSTAR(2,1) harga saham PT Telkom Indonesia (Persero) dengan estimasi *Gauss-Newton* adalah:

$$X_t = (-12,283 - 0,159X_{t-1} - 0,093X_{t-2}) \left(1 - \left(\frac{1}{1 + e^{(-6,591(X_{t-1} + 11,529)}} \right) \right) + (33,399 - 0,211X_{t-1} + 0,014X_{t-2}) \left(\frac{1}{1 + e^{(-6,591(X_{t-1} + 11,529)}} \right) + \varepsilon_t$$

Model LSTAR(2,1) yang diperoleh menunjukkan adanya dua kondisi pasar (rezim), yaitu rezim pertama yang mencerminkan kondisi penurunan (*bearish*) dan rezim kedua yang menggambarkan kondisi kenaikan (*bullish*). Perubahan harga saham saat ini X_t dipengaruhi oleh nilai pada satu dan dua periode (mingguan) sebelumnya, yakni X_{t-1} dan X_{t-2} . Peralihan antar rezim tidak terjadi secara tiba-tiba, melainkan berlangsung secara halus melalui fungsi transisi logistik yang bergantung pada variabel transisi X_{t-1} . Dalam model ini didapatkan parameter pemuluan sebesar 6,591, yang menunjukkan kecepatan perubahan harga saham relatif cepat. Sementara itu, diperoleh nilai ambang batas (*threshold*) sebesar $-11,529$. Apabila nilai X_{t-1} berada di bawah nilai *threshold*, maka fungsi transisi akan mendekati nol sehingga model lebih didominasi oleh rezim pertama. Pada kondisi ini, dinamika sistem mengikuti persamaan, $-12,283 - 0,159X_{t-1} - 0,093X_{t-2}$

yang merepresentasikan kecenderungan penurunan. Sebaliknya, ketika X_{t-1} melebihi nilai *threshold*, fungsi transisi akan mendekati satu sehingga rezim kedua menjadi dominan. Pada kondisi ini, perilaku sistem mengikuti persamaan, $33,399 - 0,211x_{t-1} + 0,014x_{t-2}$ yang menunjukkan adanya kecenderungan peningkatan. Dengan demikian, model ini mampu menangkap perubahan dinamika secara nonlinier antara dua kondisi pasar, di mana peran nilai masa lalu, terutama satu periode sebelumnya menjadi faktor utama dalam menentukan rezim yang sedang berlangsung.

2. Nilai *Mean Absolute Percentage Error* (MAPE) sebesar 0,71% menunjukkan bahwa model LSTAR(2,1) memiliki tingkat akurasi yang sangat baik digunakan dalam memprediksi harga saham PT Telkom Indonesia (Persero).

5.2 Saran

Pada penelitian ini model nonlinear deret waktu yang digunakan untuk memodelkan harga saham PT Telkom Indonesia (Persero) adalah model *Logistic Smooth Transition Autoregressive* (LSTAR) dengan estimasi parameter menggunakan metode *Gauss–Newton*. Metode *Gauss–Newton* merupakan metode iteratif yang memerlukan penentuan nilai awal parameter yang tepat agar proses estimasi dapat mencapai konvergensi dengan baik. Oleh karena itu, pada penelitian selanjutnya disarankan untuk menggunakan metode optimasi lain seperti *Genetic Algorithm* (GA) atau *Simulated Annealing* (SA) untuk menentukan nilai awal parameter yang lebih optimal, sehingga proses estimasi parameter dapat menghasilkan model dengan kinerja prediksi yang lebih baik.

DAFTAR PUSTAKA

- Abdul Malik. (2019). Fiqih Ekonomi Qur'ani An-Nisa 29 (Representasi Qur'an bagi Ekonomi Keumatan). *Pustaka Pranala*, 7.
- Adhikari, R., & Agrawal, R. K. (2013). An Introductory Study on Time Series Modeling and Forecasting. *arXiv preprint arXiv:1302.6613*
- Aditiya, N. Y., Evani, E. S., & Maghfiroh, S. (2023). Konsep uji asumsi klasik pada regresi linier berganda. *Jurnal Riset Akuntansi Soedirman*, 2(2), 102–110.
- Aljawwi, M. (2024). *Tafsir Fi Zhilalil-Qur'an Surah Al-Baqarah*. Gema Insani.
- Aziz, A. (2010). *Ekonometrika: Teori & praktik eksperimen dengan MATLAB*. Malang: Universitas Islam Negeri Malang.
- Bianchesi, N. M. P., da Matta, C. E., Streitenberger, S. C., Romão, E. L., Balestrassi, P. P., & Costa, A. F. B. (2022). A nonlinear time-series prediction methodology based on neural networks and tracking signals. *Production*, 32. <https://doi.org/10.1590/0103-6513.20220064>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2019). Time Series Analysis Forecasting and Control. In Canada: *Simultaneously* (Vol. 11, No. 1).
- Brandt, S. (2014). Time series analysis. In Data analysis (pp. 331–340). *Springer International Publishing*. <https://doi.org/10.1007/978-3-319-03762-213>
- Chang, P. C., Wang, Y. W., & Liu, C. H. (2007). The development of a weighted evolving fuzzy neural network for PCB sales forecasting. *Expert Systems with Applications*, 32(1), 86–96. <https://doi.org/10.1016/j.eswa.2005.11.021>
- Dijk, D. van, Teräsvirta, T., & Franses, P. H. (2002). Smooth Transition Autoregressive Models — A Survey of Recent Developments. *Econometric Reviews*, 21(1), 1–47. <https://doi.org/10.1081/ETC-120008723>
- Faisal, A. (2021). Prediksi Saham Telkom dengan Metode ARIMA. *Jurnal Bisnis, Logistik Dan Supply Chain (BLOGCHAIN)*, 1(2), 45–50. <https://doi.org/10.55122/blogchain.v1i2.298>
- Ghasemzadeh, P., Kalbkhani, H., Sartipi, S., & Shayesteh, M. G. (2019). Classification of sleep stages based on LSTAR model. *Applied Soft Computing*, 75, 523–536. <https://doi.org/10.1016/j.asoc.2018.11.007>
- Herranz, E. (2017). Unit root tests. *WIREs Computational Statistics*, 9(3). <https://doi.org/10.1002/wics.1396>
- Hyndman, R. J., & Khandakar, Y. (2008). Automatic time series forecasting: The forecast package for R. *Journal of Statistical Software*, 27(3), 1–22. <https://doi.org/10.18637/jss.v027.i03>
- Indonesia Stock Exchange. (2024). Data emiten dan saham PT Telekomunikasi Indonesia Tbk. <https://www.idx.co.id>

- Kamalov, F., & Sulieman, H. (2021). Time series signal recovery methods: Comparative study. *2021 International Symposium on Networks, Computers and Communications, ISNCC 2021*, (1), 1–5. <https://doi.org/10.1109/ISNCC52172.2021.9615669>
- Kementrian Agama RI. (2025). *Qur'an Kemenag*. <https://Quran.Kemenag.Go.Id>.
- Kirchgässner, G., & Wolters, J. (2010). *Introduction to Modern Time Series Analysis*. Springer.
- Kresnawati, G., Warsito, B., Hoyyi, A., Statistika, D., Sains, F., & Matematika, D. (2018a). Peramalan Indeks Harga Saham Gabungan Dengan Metode Logistic Smooth Transition Autoregressive (LSTAR). *Jurnal Gaussian*, 7(1), 84–95. <https://ejournal3.undip.ac.id/index.php/gaussian/>
- Kurniawati, A., Tista, J. D., Sapitra, A. S., & Fares, F. Z. (2024). Pengaruh Pengetahuan Dasar Investasi dan Peran Tata Kelola Perusahaan Terhadap Kinerja Pasar Modal Dalam. *Jurnal Akuntansi, Keuangan, Perpajakan Dan Tata Kelola Perusahaan*, 2(2), 606–619. <https://doi.org/10.70248/jakpt.v2i2.946>
- M Saleh. (2010). Penaksiran Parameter Regresi Nonlinier dengan Algoritma Gauss-Newton dan Tafsiran Geometris Least Squares. *Jurnal Matematika, Statistika dan Komputasi*, 7(1), 39–48.
- Manurung, A. H. (2021). Investing and Protection of Investor in Stock Market. *Indonesian Journal of International Law*, 7(1). <https://doi.org/10.17304/ijil.vol7.1.228>
- Medar, R., & Rajpurohit, V. (2017). Impact of Training and Testing Data Splits on Accuracy of Time Series Forecasting in Machine Learning. *2017 International Conference on Computing, Communication, Control and Automation (ICCUBEA)*, 1–6. <https://doi.org/10.1109/ICCUBEA.2017.8463779>
- Mihrani. (2015). Analisis Faktor-Faktor yang Mempengaruhi Harga Saham PT.Telkom Tbk di Bursa Efek Jakarta. *Jurnal Ilmiah (Politeknik Pertanian Negeri Pangkep)*.
- Mohd, N., Rohani, S., Yusof, F., Kane, L., & Ibrahim. (2015). Nonlinear Smooth Transition Autoregressive (STAR)-Type Modelling and Forecasting on Malaysia Airlines (MAS) Stock Returns. *Jurnal Teknologi*, 74(11). <https://doi.org/10.11113/jt.v74.4883>
- Ning, Y., Kazemi, H., & Tahmasebi, P. (2022). A comparative machine learning study for time series oil production forecasting: ARIMA, LSTM, and Prophet. *Computers & Geosciences*, 164, 105126. <https://doi.org/10.1016/j.cageo.2022.105126>
- Odelia, M., Asih, D., Maruddani, I., & Yasin, H. (2020a). Peramalan Harga Saham Dengan Metode Logistic Smooth Transition Autoregressive (LSTAR) (Studi Kasus pada Harga Saham Mingguan PT. Bank Mandiri Tbk Periode 03 Januari

- 2011 sampai 24 Desember 2018). *JURNAL GAUSSIAN*, 9(4), 391–401. <https://ejournal3.undip.ac.id/index.php/gaussian/>
- Oelschläger, L., & Adam, T. (2020). Detecting bearish and bullish markets in financial time series using hierarchical hidden Markov models. *Statistical Modelling*, 23(2), 107–126. <https://doi.org/10.1177/1471082X211034048>
- Pratama, I., Sumarjaya, I. W., & Suciptawati, N. (2022). Peramalan Harga Bitcoin dengan Metode Smooth Transition Autoregressive (STAR). *E-Jurnal Matematika*, null, null. <https://doi.org/10.24843/mtk.2022.v11.i02.p367>
- Priyadi, I. H., Wijaya, R., Ready, A., Naedi, A., Safriyanto, S., Salimah, S., Aslinnoroniyah, S., Riwana, A., Cahyani, A., Murda, H., Harum, N., Ningsih, M., Indawati, I., Putri, D., Dwi, A., Agustin, P., Aisatus, N., Nur, S., & Sholehah, A. (2021). *Investasi Itu Mudah Cara Cerdas Menuju Financial Freedom*.
- PT Telkom Indonesia. (2025). *Sekilas tentang Telkom Indonesia*. https://www.telkom.co.id/sites/profil-telkom/id_ID/page/profil-dan-riwayat-singkat-22.
- Putri, G. A. M. A., Hendayanti, N. P. N., & Nurhidayati, M. (2017). Pemodelan Data Deret Waktu dengan Autoregressive Integrated Moving Average dan Logistic Smoothing Transition Autoregressive. *Jurnal Varian*, 1(1), 54. <https://doi.org/10.30812/varian.v1i1.50>
- Respati, P., Purwanto, B., & Irwanto, A. K. (2018). Estimasi Bullish dan Bearish dengan Model Perpindahan Markov dan Risiko Sistematis (beta) dengan Model Penilaian Modal Sharpe dalam Investasi Saham di Bursa Efek Indonesia, Tahun 2011 - 2016. *Jurnal Manajemen Dan Organisasi*, 8(3), 221–235. <https://doi.org/10.29244/jmo.v8i3.22471>
- Ruey S, T., & Rong, C. (2019). *Nonlinear Time Series Analysis*. John Wiley & Sons.
- Saputro, D. R. S., Pratiwi, N. B. I., & Kusumawati, R. (2022). Logistic smooth transition autoregressive model parameter estimation using Gauss Newton. *AIP Conference Proceedings*, 2479. <https://doi.org/10.1063/5.0100105>
- Sekar Seruni, D., Tanzil Furqon, M., & Cahya Wihandika, R. (2020). Sistem Prediksi Pertumbuhan Jumlah Penduduk Kota Malang Menggunakan Metode K-Nearest Neighbor Regression. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 4(4), 1075–1082.
- Stephens, M. A. (2016). Kolmogorov – Smirnov Tests of Fit. In *Wiley StatsRef: Statistics Reference Online* (pp. 1–10). Wiley. <https://doi.org/10.1002/9781118445112.stat01632.pub2>
- Taurinna K, C., Herawati, N., & Sutrisno, A. (2024).). *International Journal of Multidisciplinary Research and Analysis Logistic Smooth Transition Autoregressive (LSTAR) and Exponential Smooth Transition Autoregressive (ESTAR) Methods in Predicting the Exchange Rate of Farmers in Lampung*

- Province, Indonesi.* 07(07), 3209–3215. <https://doi.org/10.47191/ijmra/v7-i07-18>
- Terasvirta, T. (1994). Specification, Estimation, and Evaluation of Smooth Transition Autoregressive Models. In *Source: Journal of the American Statistical Association* (Vol. 89, Number 425).
- Tong, H. (1983). Threshold models in time series analysis. In *Statistics and Its Interface* (Vol. 4).
- van Dijk, D. (1999). Smooth Transition Models: Extensions and Outlier Robust Inference. *Tinbergen Institute Discussion Paper*.
- Van, G. M., & Kruger, R. (2013). The Performance of Linear Versus Non-Linear Models in Forecasting Returns on the Johannesburg Stock Exchange. In *International Business & Economics Research Journal-August* (Vol. 12, Number 8).
- Zhou, Q. (2024). Stock Price Forecasting Based on the Gauss-Newton Method. *Frontiers in Business, Economics and Management*, 17(3), 25–29. <https://doi.org/10.54097/7g8xrc36>

LAMPIRAN

Lampiran 1. Data Harga Saham PT Telkom Indonesia (Persero) (Y_t)

No	Tanggal	Y_t	No	Tanggal	Y_t	No	Tanggal	Y_t
1	06/01/2019	3.860	42	20/10/2019	4.080	83	02/08/2020	3.030
2	13/01/2019	4.020	43	27/10/2019	4.110	84	09/08/2020	3.000
3	20/01/2019	3.880	44	03/11/2019	4.080	85	16/08/2020	2.960
4	27/01/2019	3.870	45	10/11/2019	4.050	86	23/08/2020	2.860
5	03/02/2019	3.850	46	17/11/2019	3.930	87	30/08/2020	2.810
6	10/02/2019	3.790	47	24/11/2019	4.100	88	06/09/2020	2.890
7	17/02/2019	3.840	48	01/12/2019	3.990	89	13/09/2020	2.690
8	24/02/2019	3.910	49	08/12/2019	4.020	90	20/09/2020	2.680
9	03/03/2019	3.740	50	15/12/2019	3.990	91	27/09/2020	2.730
10	10/03/2019	3.740	51	22/12/2019	3.980	92	04/10/2020	2.750
11	17/03/2019	3.820	52	29/12/2019	3.980	93	11/10/2020	2.630
12	24/03/2019	3.950	53	05/01/2020	3.810	94	18/10/2020	2.620
13	31/03/2019	4.050	54	12/01/2020	3.920	95	25/10/2020	2.830
14	07/04/2019	3.830	55	19/01/2020	3.800	96	01/11/2020	2.990
15	14/04/2019	3.860	56	26/01/2020	3.790	97	08/11/2020	3.220
16	21/04/2019	3.910	57	02/02/2020	3.640	98	15/11/2020	3.460
17	28/04/2019	3.820	58	09/02/2020	3.690	99	22/11/2020	3.250
18	05/05/2019	3.790	59	16/02/2020	3.490	100	29/11/2020	3.280
19	12/05/2019	3.510	60	23/02/2020	3.750	101	06/12/2020	3.510
20	19/05/2019	3.750	61	01/03/2020	3.390	102	13/12/2020	3.320
21	26/05/2019	3.900	62	08/03/2020	2.880	103	20/12/2020	3.310
22	02/06/2019	3.990	63	15/03/2020	3.090	104	27/12/2020	3.570
23	09/06/2019	4.040	64	22/03/2020	3.200	105	03/01/2021	3.480
24	16/06/2019	4.140	65	29/03/2020	3.120	106	10/01/2021	3.390
25	23/06/2019	4.280	66	05/04/2020	3.230	107	17/01/2021	3.110
26	30/06/2019	4.180	67	12/04/2020	3.090	108	24/01/2021	3.290
27	07/07/2019	4.270	68	19/04/2020	3.500	109	31/01/2021	3.190
28	14/07/2019	4.160	69	26/04/2020	3.190	110	07/02/2021	3.210
29	21/07/2019	4.280	70	03/05/2020	3.100	111	14/02/2021	3.490
30	28/07/2019	4.260	71	10/05/2020	3.180	112	21/02/2021	3.320
31	04/08/2019	4.280	72	17/05/2020	3.150	113	28/02/2021	3.450
32	11/08/2019	4.380	73	24/05/2020	3.230	114	07/03/2021	3.440
33	18/08/2019	4.450	74	31/05/2020	3.030	115	14/03/2021	3.490
34	25/08/2019	4.210	75	07/06/2020	3.280	116	21/03/2021	3.390
35	01/09/2019	4.160	76	14/06/2020	3.190	117	28/03/2021	3.360
36	08/09/2019	4.290	77	21/06/2020	3.120	118	04/04/2021	3.360
37	15/09/2019	4.310	78	28/06/2020	3.110	119	11/04/2021	3.310
38	22/09/2019	4.190	79	05/07/2020	3.060	120	18/04/2021	3.200
39	29/09/2019	4.170	80	12/07/2020	3.020	121	25/04/2021	3.190
40	06/10/2019	4.190	81	19/07/2020	3.050	122	02/05/2021	3.180
41	13/10/2019	4.280	82	26/07/2020	2.980	123	09/05/2021	3.270

No	Tanggal	Y_t	No	Tanggal	Y_t	No	Tanggal	Y_t
124	16/05/2021	3.270	169	27/03/2022	4.580	214	05/02/2023	4.040
125	23/05/2021	3.500	170	03/04/2022	4.680	215	12/02/2023	3.900
126	30/05/2021	3.470	171	10/04/2022	4.620	216	19/02/2023	4.010
127	06/06/2021	3.350	172	17/04/2022	4.620	217	26/02/2023	4.050
128	13/06/2021	3.250	173	24/04/2022	4.260	218	05/03/2023	4.070
129	20/06/2021	3.070	174	01/05/2022	4.170	219	12/03/2023	4.060
130	27/06/2021	3.160	175	08/05/2022	4.300	220	19/03/2023	4.250
131	04/07/2021	3.170	176	15/05/2022	4.310	221	26/03/2023	4.340
132	11/07/2021	3.170	177	22/05/2022	4.020	222	02/04/2023	4.270
133	18/07/2021	3.240	178	29/05/2022	4.120	223	09/04/2023	4.250
134	25/07/2021	3.320	179	05/06/2022	4.150	224	16/04/2023	4.170
135	01/08/2021	3.300	180	12/06/2022	4.020	225	23/04/2023	3.980
136	08/08/2021	3.400	181	19/06/2022	4.010	226	30/04/2023	4.020
137	15/08/2021	3.320	182	26/06/2022	4.150	227	07/05/2023	4.130
138	22/08/2021	3.390	183	03/07/2022	4.230	228	14/05/2023	4.040
139	29/08/2021	3.330	184	10/07/2022	4.230	229	21/05/2023	4.150
140	05/09/2021	3.530	185	17/07/2022	4.650	230	28/05/2023	3.970
141	12/09/2021	3.560	186	24/07/2022	4.550	231	04/06/2023	3.950
142	19/09/2021	3.660	187	31/07/2022	4.600	232	11/06/2023	4.000
143	26/09/2021	3.800	188	07/08/2022	4.490	233	18/06/2023	3.960
144	03/10/2021	3.810	189	14/08/2022	4.600	234	25/06/2023	3.930
145	10/10/2021	3.870	190	21/08/2022	4.600	235	02/07/2023	3.860
146	17/10/2021	3.800	191	28/08/2022	4.410	236	09/07/2023	3.720
147	24/10/2021	3.770	192	04/09/2022	4.380	237	16/07/2023	3.690
148	31/10/2021	3.600	193	11/09/2022	4.460	238	23/07/2023	3.810
149	07/11/2021	3.900	194	18/09/2022	4.350	239	30/07/2023	3.760
150	14/11/2021	4.010	195	25/09/2022	4.290	240	06/08/2023	3.720
151	21/11/2021	4.070	196	02/10/2022	4.360	241	13/08/2023	3.720
152	28/11/2021	4.150	197	09/10/2022	4.450	242	20/08/2023	3.690
153	05/12/2021	4.100	198	16/10/2022	4.210	243	27/08/2023	3.720
154	12/12/2021	4.110	199	23/10/2022	4.150	244	03/09/2023	3.860
155	19/12/2021	4.040	200	30/10/2022	4.010	245	10/09/2023	3.750
156	26/12/2021	4.170	201	06/11/2022	4.030	246	17/09/2023	3.780
157	02/01/2022	4.190	202	13/11/2022	4.000	247	24/09/2023	3.850
158	09/01/2022	4.330	203	20/11/2022	3.650	248	01/10/2023	3.700
159	16/01/2022	4.260	204	27/11/2022	3.680	249	08/10/2023	3.500
160	23/01/2022	4.230	205	04/12/2022	3.780	250	15/10/2023	3.570
161	30/01/2022	4.450	206	11/12/2022	3.750	251	22/10/2023	3.550
162	06/02/2022	4.400	207	18/12/2022	3.710	252	29/10/2023	3.550
163	13/02/2022	4.340	208	25/12/2022	3.780	253	05/11/2023	3.620
164	20/02/2022	4.400	209	01/01/2023	3.870	254	12/11/2023	3.830
165	27/02/2022	4.590	210	08/01/2023	3.960	255	19/11/2023	3.940
166	06/03/2022	4.540	211	15/01/2023	3.880	256	26/11/2023	3.980
167	13/03/2022	4.520	212	22/01/2023	3.800	257	03/12/2023	3.960
168	20/03/2022	4.580	213	29/01/2023	3.760	258	10/12/2023	3.950

No	Tanggal	Y_t	No	Tanggal	Y_t	No	Tanggal	Y_t
259	17/12/2023	3.890	299	22/09/2024	3.100	339	29/06/2025	2.980
260	24/12/2023	4.010	300	29/09/2024	2.910	340	06/07/2025	2.940
261	31/12/2023	3.940	301	06/10/2024	2.780	341	13/07/2025	3.310
262	07/01/2024	3.980	302	13/10/2024	2.750	342	20/07/2025	3.240
263	14/01/2024	3.990	303	20/10/2024	2.540	343	27/07/2025	3.130
264	21/01/2024	3.980	304	27/10/2024	2.750	344	03/08/2025	3.150
265	28/01/2024	4.160	305	03/11/2024	2.710	345	10/08/2025	3.100
266	04/02/2024	4.100	306	10/11/2024	2.760	346	17/08/2025	3.230
267	11/02/2024	3.920	307	17/11/2024	2.790	347	24/08/2025	3.110
268	18/02/2024	3.860	308	24/11/2024	2.550	348	31/08/2025	3.070
269	25/02/2024	3.970	309	01/12/2024	2.750	349	07/09/2025	3.040
270	03/03/2024	3.900	310	08/12/2024	2.750	350	14/09/2025	2.880
271	10/03/2024	3.470	311	15/12/2024	2.680	351	21/09/2025	3.290
272	17/03/2024	3.430	312	22/12/2024	2.660	352	28/09/2025	3.210
273	24/03/2024	3.150	313	29/12/2024	2.690	353	05/10/2025	3.470
274	31/03/2024	3.030	314	05/01/2025	2.660	354	12/10/2025	3.550
275	07/04/2024	3.160	315	12/01/2025	2.590	355	19/10/2025	3.500
276	14/04/2024	3.080	316	19/01/2025	2.530	356	26/10/2025	3.510
277	21/04/2024	2.990	317	26/01/2025	2.650	357	02/11/2025	3.700
278	28/04/2024	2.940	318	02/02/2025	2.350	358	09/11/2025	3.550
279	05/05/2024	2.900	319	09/02/2025	2.410	359	16/11/2025	3.410
280	12/05/2024	3.050	320	16/02/2025	2.420	360	23/11/2025	3.460
281	19/05/2024	2.720	321	23/02/2025	2.310	361	30/11/2025	3.470
282	26/05/2024	2.950	322	02/03/2025	2.410	362	07/12/2025	3.450
283	02/06/2024	3.130	323	09/03/2025	2.330	363	14/12/2025	3.660
284	09/06/2024	3.020	324	16/03/2025	2.550	364	21/12/2025	3.770
285	16/06/2024	3.220	325	23/03/2025	2.600	365	28/12/2025	3.600
286	23/06/2024	3.140	326	30/03/2025	2.680	366	01/02/2026	3.380
287	30/06/2024	3.100	327	06/04/2025	2.600	367	08/02/2026	3.450
288	07/07/2024	2.850	328	13/04/2025	2.740	368	15/02/2026	3.480
289	14/07/2024	2.830	329	20/04/2025	2.690	369	22/02/2026	3.540
290	21/07/2024	2.960	330	27/04/2025	2.820	370	01/03/2026	3.190
291	28/07/2024	2.950	331	04/05/2025	2.840	371	08/03/2026	2.970
292	04/08/2024	3.060	332	11/05/2025	2.740	372	15/03/2026	3.050
293	11/08/2024	3.040	333	18/05/2025	2.640	373	22/03/2026	3.050
294	18/08/2024	3.110	334	25/05/2025	2.710	374	29/03/2026	3.130
295	25/08/2024	3.150	335	01/06/2025	2.630	375	05/04/2026	3.210
296	01/09/2024	3.050	336	08/06/2025	2.730	376	12/04/2026	3.100
297	08/09/2024	2.880	337	15/06/2025	2.770	377	19/04/2026	2.810
298	15/09/2024	2.940	338	22/06/2025	2.820	378	26/04/2026	2.810

Lampiran 2. Data Harga Saham PT Telkom Indonesia (Persero) pada *Differencing* Orde Pertama (X_t)

No	Tanggal	X_t	No	Tanggal	X_t	No	Tanggal	X_t
1	06/01/2019	*	44	10/11/2019	-30	87	06/09/2020	-50
2	13/01/2019	160	45	17/11/2019	-30	88	13/09/2020	80
3	20/01/2019	-140	46	24/11/2019	-120	89	20/09/2020	-200
4	27/01/2019	-10	47	01/12/2019	170	90	27/09/2020	-10
5	03/02/2019	-20	48	08/12/2019	-110	91	04/10/2020	50
6	10/02/2019	-60	49	15/12/2019	30	92	11/10/2020	20
7	17/02/2019	50	50	22/12/2019	-30	93	18/10/2020	-120
8	24/02/2019	70	51	29/12/2019	-10	94	25/10/2020	-10
9	03/03/2019	-170	52	05/01/2020	0	95	01/11/2020	210
10	10/03/2019	0	53	12/01/2020	-170	96	08/11/2020	160
11	17/03/2019	80	54	19/01/2020	110	97	15/11/2020	230
12	24/03/2019	130	55	26/01/2020	-120	98	22/11/2020	240
13	31/03/2019	100	56	02/02/2020	-10	99	29/11/2020	-210
14	07/04/2019	-220	57	09/02/2020	-150	100	06/12/2020	30
15	14/04/2019	30	58	16/02/2020	50	101	13/12/2020	230
16	21/04/2019	50	59	23/02/2020	-200	102	20/12/2020	-190
17	28/04/2019	-90	60	01/03/2020	260	103	27/12/2020	-10
18	05/05/2019	-30	61	08/03/2020	-360	104	03/01/2021	260
19	12/05/2019	-280	62	15/03/2020	-510	105	10/01/2021	-90
20	19/05/2019	240	63	22/03/2020	210	106	17/01/2021	-90
21	26/05/2019	150	64	29/03/2020	110	107	24/01/2021	-280
22	09/06/2019	90	65	05/04/2020	-80	108	31/01/2021	180
23	16/06/2019	50	66	12/04/2020	110	109	07/02/2021	-100
24	23/06/2019	100	67	19/04/2020	-140	110	14/02/2021	20
25	30/06/2019	140	68	26/04/2020	410	111	21/02/2021	280
26	07/07/2019	-100	69	03/05/2020	-310	112	28/02/2021	-170
27	14/07/2019	90	70	10/05/2020	-90	113	07/03/2021	130
28	21/07/2019	-110	71	17/05/2020	80	114	14/03/2021	-10
29	28/07/2019	120	72	24/05/2020	-30	115	21/03/2021	50
30	04/08/2019	-20	73	31/05/2020	80	116	28/03/2021	-100
31	11/08/2019	20	74	07/06/2020	-200	117	04/04/2021	-30
32	18/08/2019	100	75	14/06/2020	250	118	11/04/2021	0
33	25/08/2019	70	76	21/06/2020	-90	119	18/04/2021	-50
34	01/09/2019	-240	77	28/06/2020	-70	120	25/04/2021	-110
35	08/09/2019	-50	78	05/07/2020	-10	121	02/05/2021	-10
36	15/09/2019	130	79	12/07/2020	-50	122	09/05/2021	-10
37	22/09/2019	20	80	19/07/2020	-40	123	16/05/2021	90
38	29/09/2019	-120	81	26/07/2020	30	124	23/05/2021	0
39	06/10/2019	-20	82	02/08/2020	-70	125	30/05/2021	230
40	13/10/2019	20	83	09/08/2020	50	126	06/06/2021	-30
41	20/10/2019	90	84	16/08/2020	-30	127	13/06/2021	-120
42	27/10/2019	-200	85	23/08/2020	-40	128	20/06/2021	-100
43	03/11/2019	30	86	30/08/2020	-100	129	27/06/2021	-180

No	Tanggal	X_t	No	Tanggal	X_t	No	Tanggal	X_t
130	04/07/2021	90	175	22/05/2022	130	220	02/04/2023	190
131	11/07/2021	10	176	29/05/2022	10	221	09/04/2023	90
132	18/07/2021	0	177	05/06/2022	-290	222	16/04/2023	-70
133	25/07/2021	70	178	12/06/2022	100	223	23/04/2023	-20
134	01/08/2021	80	179	19/06/2022	30	224	30/04/2023	-80
135	08/08/2021	-20	180	26/06/2022	-130	225	07/05/2023	-190
136	15/08/2021	100	181	03/07/2022	-10	226	14/05/2023	40
137	22/08/2021	-80	182	10/07/2022	140	227	21/05/2023	110
138	29/08/2021	70	183	17/07/2022	80	228	28/05/2023	-90
139	05/09/2021	-60	184	24/07/2022	0	229	04/06/2023	110
140	12/09/2021	200	185	31/07/2022	420	230	11/06/2023	-180
141	19/09/2021	30	186	07/08/2022	-100	231	18/06/2023	-20
142	26/09/2021	100	187	14/08/2022	50	232	25/06/2023	50
143	03/10/2021	140	188	21/08/2022	-110	233	02/07/2023	-40
144	10/10/2021	10	189	28/08/2022	110	234	09/07/2023	-30
145	17/10/2021	60	190	04/09/2022	0	235	16/07/2023	-70
146	24/10/2021	-70	191	11/09/2022	-190	236	23/07/2023	-140
147	31/10/2021	-30	192	18/09/2022	-30	237	30/07/2023	-30
148	07/11/2021	-170	193	25/09/2022	80	238	06/08/2023	120
149	14/11/2021	300	194	02/10/2022	-110	239	13/08/2023	-50
150	21/11/2021	110	195	09/10/2022	-60	240	20/08/2023	-40
151	28/11/2021	60	196	16/10/2022	70	241	27/08/2023	0
152	05/12/2021	80	197	23/10/2022	90	242	03/09/2023	-30
153	12/12/2021	-50	198	30/10/2022	-240	243	10/09/2023	30
154	19/12/2021	10	199	06/11/2022	-60	244	17/09/2023	140
155	26/12/2021	-70	200	13/11/2022	-140	245	24/09/2023	-110
156	02/01/2022	130	201	20/11/2022	20	246	01/10/2023	30
157	09/01/2022	20	202	27/11/2022	-30	247	08/10/2023	70
158	16/01/2022	140	203	04/12/2022	-350	248	15/10/2023	-150
159	23/01/2022	-70	204	11/12/2022	30	249	22/10/2023	-200
160	30/01/2022	-30	205	18/12/2022	100	250	29/10/2023	70
161	06/02/2022	220	206	25/12/2022	-30	251	05/11/2023	-20
162	13/02/2022	-50	207	01/01/2023	-40	252	12/11/2023	0
163	20/02/2022	-60	208	08/01/2023	70	253	19/11/2023	70
164	27/02/2022	60	209	15/01/2023	90	254	26/11/2023	210
165	06/03/2022	190	210	22/01/2023	90	255	03/12/2023	110
166	13/03/2022	-50	211	29/01/2023	-80	256	10/12/2023	40
167	20/03/2022	-20	212	05/02/2023	-80	257	17/12/2023	-20
168	27/03/2022	60	213	12/02/2023	-40	258	24/12/2023	-10
169	03/04/2022	0	214	19/02/2023	280	259	31/12/2023	-60
170	10/04/2022	100	215	26/02/2023	-140	260	07/01/2024	120
171	17/04/2022	-60	216	05/03/2023	110	261	14/01/2024	-70
172	24/04/2022	0	217	12/03/2023	40	262	21/01/2024	40
173	08/05/2022	-360	218	19/03/2023	20	263	28/01/2024	10
174	15/05/2022	-90	219	26/03/2023	-10	264	04/02/2024	-10

No	Tanggal	X_t	No	Tanggal	X_t	No	Tanggal	X_t
265	11/02/2024	180	303	10/11/2024	-210	341	10/08/2025	370
266	18/02/2024	-60	304	17/11/2024	210	342	17/08/2025	-70
267	25/02/2024	-180	305	24/11/2024	-40	343	24/08/2025	-110
268	03/03/2024	-60	306	01/12/2024	50	344	31/08/2025	20
269	10/03/2024	110	307	08/12/2024	30	345	07/09/2025	-50
270	17/03/2024	-70	308	15/12/2024	-240	346	14/09/2025	130
271	24/03/2024	-430	309	22/12/2024	200	347	21/09/2025	-120
272	31/03/2024	-40	310	29/12/2024	0	348	28/09/2025	-40
273	14/04/2024	-280	311	05/01/2025	-70	349	05/10/2025	-30
274	21/04/2024	-120	312	12/01/2025	-20	350	12/10/2025	-160
275	28/04/2024	130	313	19/01/2025	30	351	19/10/2025	410
276	05/05/2024	-80	314	26/01/2025	-30	352	26/10/2025	-80
277	12/05/2024	-90	315	02/02/2025	-70	353	02/11/2025	260
278	19/05/2024	-50	316	09/02/2025	-60	354	09/11/2025	80
279	26/05/2024	-40	317	16/02/2025	120	355	16/11/2025	-50
280	02/06/2024	150	318	23/02/2025	-300	356	23/11/2025	10
281	09/06/2024	-330	319	02/03/2025	60	357	30/11/2025	190
282	16/06/2024	230	320	09/03/2025	10	358	07/12/2025	-150
283	23/06/2024	180	321	16/03/2025	-110	359	14/12/2025	-140
284	30/06/2024	-110	322	23/03/2025	100	360	21/12/2025	50
285	07/07/2024	200	323	06/04/2025	-80	361	28/12/2025	10
286	14/07/2024	-80	324	13/04/2025	220	362	04/01/2026	-20
287	21/07/2024	-40	325	20/04/2025	50	363	11/01/2026	210
288	28/07/2024	-250	326	27/04/2025	80	364	18/01/2026	110
289	04/08/2024	-20	327	04/05/2025	-80	365	25/01/2026	-170
290	11/08/2024	130	328	11/05/2025	140	366	01/02/2026	-220
291	18/08/2024	-10	329	18/05/2025	-50	367	08/02/2026	70
292	25/08/2024	110	330	25/05/2025	130	368	15/02/2026	30
293	01/09/2024	-20	331	01/06/2025	20	369	22/02/2026	60
294	08/09/2024	70	332	08/06/2025	-100	370	01/03/2026	-350
295	15/09/2024	40	333	15/06/2025	-100	371	08/03/2026	-220
296	22/09/2024	-100	334	22/06/2025	70	372	15/03/2026	80
297	29/09/2024	-170	335	29/06/2025	-80	373	22/03/2026	0
298	06/10/2024	60	336	06/07/2025	100	374	29/03/2026	80
299	13/10/2024	160	337	13/07/2025	40	375	05/04/2026	80
300	20/10/2024	-190	338	20/07/2025	50	376	12/04/2026	-110
301	27/10/2024	-130	339	27/07/2025	160	377	19/04/2026	-290
302	03/11/2024	-30	340	03/08/2025	-40	378	26/04/2026	0

Lampiran 3. Nilai AIC pada Masing-Masing Model ARIMA

No	Model	Nilai AIC	No	Model	Nilai AIC
1	ARIMA(0,1,0)	3.797,280	12	ARIMA(2,1,0)	3.791,977
2	ARIMA(0,1,1)	3.791,295	13	ARIMA(2,1,1)	3.790,041
3	ARIMA(0,1,2)	3.793,012	14	ARIMA(2,1,2)	3.788,811
4	ARIMA(0,1,3)	3.791,671	15	ARIMA(2,1,3)	<i>Inf</i>
5	ARIMA(0,1,4)	3.793,701	16	ARIMA(3,1,0)	3.793,005
6	ARIMA(0,1,5)	3.795,594	17	ARIMA(3,1,1)	3.794,253
7	ARIMA(1,1,0)	3.792,283	18	ARIMA(3,1,2)	3.790,635
8	ARIMA(1,1,1)	3.793,190	19	ARIMA(4,1,0)	3.793,685
9	ARIMA(1,1,2)	3.789,613	20	ARIMA(4,1,1)	3.795,652
10	ARIMA(1,1,3)	3.793,715	21	ARIMA(5,1,0)	3.795,216
11	ARIMA(1,1,4)	3.792,145			

Lampiran 4. Residual Model *Autoregressive* (2) (ε_t)

No	ε_t	No	ε_t	No	ε_t	No	ε_t	No	ε_t
1	-13,80	45	-88,26	89	32,00	133	108,62	177	-111,44
2	-29,39	46	31,98	90	-107,54	134	-60,74	178	-23,78
3	-59,41	47	-30,19	91	-23,04	135	70,62	179	131,50
4	43,17	48	-7,47	92	202,39	136	-50,99	180	106,67
5	77,53	49	0,43	93	198,08	137	201,21	181	30,28
6	-149,38	50	-166,15	94	279,57	138	61,99	182	431,88
7	-16,73	51	87,02	95	296,52	139	127,49	183	-26,79
8	69,56	52	-112,50	96	-145,60	140	163,72	184	75,93
9	147,78	53	-15,00	97	21,93	141	46,49	185	-106,04
10	133,08	54	-157,61	98	220,88	142	78,87	186	101,27
11	-187,35	55	29,39	99	-145,08	143	-54,59	187	12,85
12	7,80	56	-200,50	100	-15,70	144	-31,32	188	-175,44
13	39,99	57	236,60	101	246,15	145	-176,40	189	-56,24
14	-74,43	58	-330,73	102	-43,76	146	274,34	190	62,88
15	-35,47	59	-540,74	103	-76,72	147	148,47	191	-94,90
16	-288,19	60	99,45	104	-297,97	148	109,46	192	-66,05
17	196,41	61	103,44	105	131,05	149	104,34	193	55,14
18	168,87	62	-38,58	106	-90,91	150	-26,86	194	100,79
19	140,62	63	111,52	107	24,51	151	13,73	195	-214,34
20	82,80	64	-124,47	108	279,07	152	-68,09	196	-86,35
21	120,93	65	401,73	109	-117,82	153	124,22	197	-166,47
22	165,51	66	-250,92	110	132,02	154	39,68	198	-3,44
23	-63,51	67	-99,20	111	0,76	155	159,61	199	-34,50
24	90,93	68	42,39	112	64,72	156	-40,65	200	-348,37
25	-99,52	69	-20,25	113	-88,00	157	-24,17	201	-25,00
26	114,84	70	86,99	114	-37,10	158	213,60	202	78,38
27	-5,52	71	-184,90	115	-9,08	159	-12,07	203	-6,28
28	32,19	72	229,27	116	-47,94	160	-43,77	204	-31,22
29	106,21	73	-62,36	117	-113,41	161	50,49	205	65,54
30	92,83	74	-57,61	118	-27,66	162	199,16	206	102,58
31	-214,92	75	-24,71	119	-16,71	163	-8,93	207	115,66
32	-78,14	76	-53,14	120	92,22	164	-6,45	208	-52,55
33	105,16	77	-44,31	121	18,52	165	57,01	209	-80,27
34	41,47	78	23,75	122	242,77	166	12,74	210	-55,45
35	-100,39	79	-63,94	123	12,24	167	110,10	211	271,08
36	-33,04	80	46,00	124	-99,62	168	-38,96	212	-93,18
37	10,76	81	-23,36	125	-117,50	169	3,89	213	116,91
38	96,21	82	-35,69	126	-202,28	170	-360,62	214	50,17
39	-178,80	83	-104,46	127	56,46	171	-143,95	215	41,08
40	10,17	84	-65,14	128	13,34	172	87,92	216	1,57
41	-38,23	85	67,66	129	14,40	173	27,90	217	194,89
42	-27,47	86	-186,68	130	75,63	174	-272,02	218	124,82
43	-122,83	87	-30,73	131	96,15	175	58,35	219	-33,62
44	152,50	88	35,25	132	4,03	176	25,15	220	-18,64

No	ε_t	No	ε_t	No	ε_t	No	ε_t	No	ε_t
221	-84,77	237	-32,70	253	81,42	269	-111,62	285	-258,92
222	-200,09	238	-6,25	254	1,08	270	-320,17	286	-59,59
223	6,62	239	-28,83	255	-4,95	271	-164,48	287	109,16
224	104,30	240	29,85	256	-58,68	272	90,18	288	14,15
225	-63,76	241	146,95	257	114,06	273	-64,78	289	124,72
226	109,89	242	-79,76	258	-51,05	274	-86,70	290	1,78
227	-165,36	243	29,30	259	44,04	275	-67,08	291	81,30
228	-34,79	244	69,81	260	15,01	276	-51,45	292	54,37
229	35,41	245	-131,17	261	-0,06	277	143,75	293	-82,49
230	-28,89	246	-213,47	262	184,00	278	-304,38	294	-177,99
231	-27,32	247	28,74	263	-26,81	279	194,33	295	28,09
232	-73,72	248	-21,70	264	-168,97	280	192,77	296	159,34
233	-149,35	249	7,73	265	-89,96	281	-55,38	297	-153,82
234	-54,34	250	72,95	266	88,89	282	202,88	298	-141,95
235	107,35	251	226,15	267	-52,68	283	-52,47	299	-63,42
236	-28,37	252	155,23	268	-426,85	284	-30,45		

Lampiran 5. Residual Regresi Bantu dengan Variabel Transisi X_{t-1} (e_t)

No	e_t	No	e_t	No	e_t	No	e_t	No	e_t
1	-35,10	45	-98,54	89	35,72	133	106,88	177	-109,45
2	-21,69	46	12,40	90	-104,90	134	-61,11	178	-39,73
3	-57,42	47	-24,04	91	-37,11	135	58,87	179	138,83
4	40,89	48	-8,25	92	209,34	136	-48,28	180	101,19
5	81,79	49	3,98	93	184,78	137	194,26	181	32,31
6	-146,93	50	-162,73	94	273,58	138	49,82	182	432,29
7	-36,69	51	67,21	95	276,15	139	127,49	183	95,84
8	78,35	52	-115,65	96	-171,52	140	163,76	184	45,00
9	149,56	53	-32,97	97	16,08	141	42,43	185	-101,36
10	130,13	54	-150,66	98	229,01	142	78,37	186	87,37
11	-186,50	55	11,94	99	-160,40	143	-51,47	187	10,33
12	-3,53	56	-195,30	100	-30,69	144	-39,33	188	-176,04
13	48,32	57	217,88	101	255,73	145	-172,68	189	-77,08
14	-71,13	58	-326,42	102	-55,30	146	254,59	190	72,01
15	-46,21	59	-294,85	103	-98,40	147	175,04	191	-93,18
16	-283,56	60	-27,41	104	-301,41	148	111,20	192	-81,37
17	188,91	61	98,99	105	108,51	149	106,84	193	57,53
18	169,41	62	-37,77	106	-102,38	150	-24,98	194	103,47
19	136,76	63	99,23	107	5,63	151	7,82	195	-213,12
20	84,44	64	-126,68	108	285,39	152	-63,07	196	-90,63
21	123,60	65	381,99	109	-128,95	153	118,84	197	-157,33
22	165,70	66	-60,56	110	111,61	154	34,81	198	-17,90
23	-67,57	67	74,13	111	-5,41	155	160,29	199	-27,21
24	74,07	68	50,41	112	62,24	156	-45,74	200	-348,69
25	-99,19	69	-18,64	113	-84,28	157	-36,42	201	25,83
26	99,05	70	83,97	114	-49,45	158	217,32	202	89,29
27	-9,48	71	-183,18	115	-4,01	159	-25,22	203	-6,24
28	28,79	72	211,82	116	-43,85	160	-56,72	204	-35,15
29	110,57	73	-62,43	117	-115,30	161	49,77	205	66,39
30	92,78	74	-78,77	118	-36,83	162	202,71	206	105,21
31	-212,56	75	-24,80	119	-10,14	163	-20,87	207	116,88
32	-84,98	76	-48,08	120	95,02	164	-17,89	208	-51,23
33	115,33	77	-45,69	121	19,32	165	60,67	209	-91,49
34	36,85	78	25,56	122	242,85	166	16,03	210	-57,67
35	-99,71	79	-59,18	123	-1,92	167	111,17	211	274,32
36	-47,11	80	39,57	124	-109,39	168	-39,17	212	-96,95
37	17,33	81	-19,00	125	-129,42	169	-4,62	213	91,87
38	100,57	82	-37,36	126	-206,08	170	-355,52	214	47,34
39	-177,85	83	-103,61	127	34,89	171	-60,88	215	43,30
40	-6,87	84	-72,96	128	13,25	172	98,55	216	4,46
41	-30,29	85	70,79	129	15,36	173	22,77	217	196,56
42	-28,25	86	-185,00	130	78,39	174	-272,23	218	113,06
43	-120,91	87	-48,18	131	98,71	175	67,43	219	-31,78
44	140,58	88	45,22	132	5,94	176	22,59	220	-28,24

No	e_t	No	e_t	No	e_t	No	e_t	No	e_t
221	-80,28	237	-40,62	253	82,23	269	50,76	285	-255,68
222	-205,49	238	-4,44	254	3,30	270	-300,16	286	-78,84
223	-16,26	239	-24,40	255	-5,03	271	-174,49	287	121,13
224	111,06	240	30,42	256	-55,50	272	89,07	288	9,92
225	-64,72	241	151,52	257	111,27	273	-70,30	289	122,24
226	96,03	242	-84,72	258	-54,42	274	-100,04	290	0,30
227	-167,68	243	11,14	259	32,85	275	-71,04	291	78,31
228	-54,09	244	75,96	260	19,96	276	-48,82	292	56,96
229	44,47	245	-128,68	261	2,35	277	145,56	293	-79,66
230	-25,06	246	-232,76	262	186,05	278	-311,59	294	-189,84
231	-30,30	247	1,62	263	-37,51	279	305,88	295	8,49
232	-71,35	248	-18,75	264	-181,64	280	191,44	296	163,56
233	-152,61	249	6,40	265	-111,10	281	-65,40	297	-161,33
234	-68,48	250	76,71	266	94,92	282	182,82	298	-158,72
235	114,22	251	228,71	267	-54,69	283	-64,17	299	-71,04
236	-31,38	252	140,51	268	-437,51	284	-47,49		

Lampiran 6. Tabel *Chi Square*

dk	Tabel Signifikansi					
	50%	30%	20%	10%	5%	1%
1	0,455	1,074	1,642	2,706	3,841	6,635
2	0,139	2,408	3,219	3,605	5,591	9,21
3	2,366	3,665	4,642	6,251	7,815	11,341
4	3,357	4,878	5,989	7,779	9,488	13,277
5	4,351	6,064	7,289	9,236	11,070	15,086
6	5,348	7,231	8,558	10,645	12,592	16,812
7	6,346	8,383	9,803	12,017	14,017	18,475
8	7,344	9,524	11,03	13,362	15,507	20,09
9	8,343	10,656	12,242	14,684	16,919	21,666
10	9,342	11,781	13,442	15,987	18,307	23,209
11	10,341	12,899	14,631	17,275	19,675	24,725
12	11,34	14,011	15,812	18,549	21,026	26,217
13	12,34	15,119	16,985	19,812	22,368	27,688
14	13,339	16,22	18,151	21,064	23,685	29,141
15	14,339	17,322	19,311	22,307	24,996	30,578
16	15,338	18,418	20,465	23,542	26,296	32
17	16,338	19,511	21,615	24,769	27,587	33,409
18	17,338	20,601	22,76	26,028	28,869	34,805
19	18,338	21,689	23,9	27,271	30,144	36,191
20	19,337	22,775	25,038	28,514	31,41	37,566
21	20,337	23,858	26,171	29,615	32,671	38,932
22	21,337	24,939	27,301	30,813	33,924	40,289
23	22,337	26,018	28,429	32,007	35,172	41,638
24	23,337	27,096	29,553	33,196	36,415	42,98
25	24,337	28,172	30,675	34,382	37,652	44,314
26	25,336	29,246	31,795	35,563	38,885	45,642
27	26,336	30,319	32,912	36,741	40,113	46,963
28	27,336	31,391	34,027	37,916	41,337	48,278
29	28,336	32,461	35,139	39,087	42,557	49,588
30	29,336	33,53	36,25	40,256	43,775	50,892

Lampiran 7. Hasil Grid Search

No	γ	SSE	No	γ	SSE	No	γ	SSE
1	0,5	5.004.105	33	3,7	4.989.705	65	6,9	4.985.545
2	0,6	5.003.500	34	3,8	4.989.420	66	7	4.985.580
3	0,7	5.002.905	35	3,9	4.989.145	67	7,1	4.985.625
4	0,8	5.002.320	36	4	4.988.880	68	7,2	4.985.680
5	0,9	5.001.745	37	4,1	4.988.625	69	7,3	4.985.745
6	1	5.001.180	38	4,2	4.988.380	70	7,4	4.985.820
7	1,1	5.000.625	39	4,3	4.988.145	71	7,5	4.985.905
8	1,2	5.000.080	40	4,4	4.987.920	72	7,6	4.986.000
9	1,3	4.999.545	41	4,5	4.987.705	73	7,7	4.986.105
10	1,4	4.999.020	42	4,6	4.987.500	74	7,8	4.986.220
11	1,5	4.998.505	43	4,7	4.987.305	75	7,9	4.986.345
12	1,6	4.998.000	44	4,8	4.987.120	76	8	4.986.480
13	1,7	4.997.505	45	4,9	4.986.945	77	8,1	4.986.625
14	1,8	4.997.020	46	5	4.986.780	78	8,2	4.986.780
15	1,9	4.996.545	47	5,1	4.986.625	79	8,3	4.986.945
16	2	4.996.080	48	5,2	4.986.480	80	8,4	4.987.120
17	2,1	4.995.625	49	5,3	4.986.345	81	8,5	4.987.305
18	2,2	4.995.180	50	5,4	4.986.220	82	8,6	4.987.500
19	2,3	4.994.745	51	5,5	4.986.105	83	8,7	4.987.705
20	2,4	4.994.320	52	5,6	4.986.000	84	8,8	4.987.920
21	2,5	4.993.905	53	5,7	4.985.905	85	8,9	4.988.145
22	2,6	4.993.500	54	5,8	4.985.820	86	9	4.988.380
23	2,7	4.993.105	55	5,9	4.985.745	87	9,1	4.988.625
24	2,8	4.992.720	56	6	4.985.680	88	9,2	4.988.880
25	2,9	4.992.345	57	6,1	4.985.625	89	9,3	4.989.145
26	3	4.991.980	58	6,2	4.985.580	90	9,4	4.989.420
27	3,1	4.991.625	59	6,3	4.985.545	91	9,5	4.989.705
28	3,2	4.991.280	60	6,4	4.985.520	92	9,6	4.990.000
29	3,3	4.990.945	61	6,5	4.985.505	93	9,7	4.990.305
30	3,4	4.990.620	62	6,6	4.985.500	94	9,8	4.990.620
31	3,5	4.990.305	63	6,7	4.985.505	95	9,9	4.990.945
32	3,6	4.990.000	64	6,8	4.985.520	96	10	4.991.280

Lampiran 8. Hasil Prediksi Harga Saham *Differencing* Orde Pertama pada Data *Testing* PT Telkom Indonesia (Persero) ($\hat{X}_t$)

No	Periode	$\hat{X}_t$	No	Periode	$\hat{X}_t$	No	Periode	$\hat{X}_t$
303	10/11/2024	4,56	329	18/05/2025	2,73	354	09/11/2025	-22,58
304	17/11/2024	23,97	330	25/05/2025	-17,30	355	16/11/2025	20,23
305	24/11/2024	-13,88	331	01/06/2025	5,27	356	23/11/2025	-11,74
306	01/12/2024	-25,39	332	08/06/2025	31,03	357	30/11/2025	30,58
307	08/12/2024	22,28	333	15/06/2025	1,80	358	07/12/2025	-6,53
308	15/12/2024	27,78	334	22/06/2025	12,93	359	14/12/2025	-6,01
309	22/12/2024	23,18	335	29/06/2025	17,21	360	21/12/2025	23,95
310	29/12/2024	-12,20	336	06/07/2025	-6,03	361	28/12/2025	20,86
311	05/01/2025	36,25	337	13/07/2025	11,17	362	04/01/2026	32,00
312	12/01/2025	-1,13	338	20/07/2025	26,39	363	11/01/2026	-10,02
313	19/01/2025	-2,60	339	27/07/2025	23,42	364	18/01/2026	-11,18
314	26/01/2025	26,79	340	03/08/2025	0,36	365	25/01/2026	13,19
315	02/02/2025	-10,29	341	10/08/2025	-20,75	366	01/02/2026	4,60
316	09/02/2025	1,66	342	17/08/2025	-45,21	367	08/02/2026	38,55
317	16/02/2025	3,77	343	24/08/2025	-35,46	368	15/02/2026	15,50
318	23/02/2025	7,23	344	31/08/2025	11,74	369	22/02/2026	28,07
319	02/03/2025	24,39	345	07/09/2025	27,61	370	01/03/2026	21,17
320	09/03/2025	16,47	346	14/09/2025	-6,17	371	08/03/2026	37,93
321	16/03/2025	32,14	347	21/09/2025	5,27	372	15/03/2026	55,25
322	23/03/2025	4,32	348	28/09/2025	-5,22	373	22/03/2026	13,39
323	06/04/2025	10,74	349	05/10/2025	5,23	374	29/03/2026	34,54
324	13/04/2025	-8,81	350	12/10/2025	-3,79	375	05/04/2026	16,53
325	20/04/2025	-14,14	351	19/10/2025	16,00	376	12/04/2026	17,67
326	27/04/2025	25,99	352	26/10/2025	-55,35	377	19/04/2026	-2,17
327	04/05/2025	17,24	353	02/11/2025	-37,57	378	26/04/2026	44,14
328	11/05/2025	-6,96						

Lampiran 9. Perbandingan Data Aktual (Y_t) dan Data Prediksi ($\hat{Y}_t$) Harga Saham PT Telkom Indonesia (Persero) pada Data *Testing*

No	Periode	Y_t	$\hat{Y}_t$	No	Periode	Y_t	$\hat{Y}_t$
1	17/11/2024	2.830	2.827,73	37	03/08/2025	2.550	2.509,48
2	24/11/2024	2.960	2.940,74	38	10/08/2025	2.600	2.576,15
3	01/12/2024	2.950	2.928,86	39	17/08/2025	2.680	2.678,57
4	08/12/2024	3.060	3.044,92	40	24/08/2025	2.600	2.595,84
5	15/12/2024	3.040	3.026,68	41	31/08/2025	2.740	2.726,03
6	22/12/2024	3.110	3.090,17	42	07/09/2025	2.690	2.689,16
7	29/12/2024	3.150	3.156,93	43	14/09/2025	2.820	2.795,83
8	05/01/2025	3.050	3.086,18	44	21/09/2025	2.840	2.849,47
9	12/01/2025	2.880	2.887,38	45	28/09/2025	2.740	2.764,71
10	19/01/2025	2.940	2.919,68	46	05/10/2025	2.640	2.636,85
11	26/01/2025	3.100	3.106,44	47	12/10/2025	2.710	2.709,84
12	02/02/2025	2.910	2.951,06	48	19/10/2025	2.630	2.619,39
13	09/02/2025	2.780	2.797,05	49	26/10/2025	2.730	2.706,36
14	16/02/2025	2.750	2.783,85	50	02/11/2025	2.770	2.752,34
15	23/02/2025	2.540	2.508,80	51	09/11/2025	2.820	2.800,15
16	02/03/2025	2.750	2.725,50	52	16/11/2025	2.980	2.961,85
17	09/03/2025	2.710	2.702,50	53	23/11/2025	2.940	2.824,75
18	16/03/2025	2.760	2.744,35	54	30/11/2025	3.310	3.270,09
19	23/03/2025	2.790	2.821,15	55	07/12/2025	3.240	3.262,54
20	06/04/2025	2.550	2.524,98	56	14/12/2025	3.130	3.136,31
21	13/04/2025	2.750	2.720,21	57	21/12/2025	3.150	3.151,27
22	20/04/2025	2.750	2.757,09	58	28/12/2025	3.100	3.099,16
23	27/04/2025	2.680	2.687,79	59	04/01/2026	3.230	3.228,77
24	04/05/2025	2.660	2.653,24	60	11/01/2026	3.110	3.127,42
25	11/05/2025	2.690	2.686,72	61	18/01/2026	3.070	3.075,62
26	18/05/2025	2.660	2.670,90	62	25/01/2026	3.040	3.065,65
27	25/05/2025	2.590	2.604,34	63	01/02/2026	2.880	2.751,48
28	01/06/2025	2.530	2.534,38	64	08/02/2026	3.290	3.246,65
29	08/06/2025	2.650	2.679,55	65	15/02/2026	3.210	3.148,87
30	15/06/2025	2.350	2.373,89	66	22/02/2026	3.470	3.419,48
31	22/06/2025	2.410	2.396,36	67	01/03/2026	3.550	3.543,65
32	29/06/2025	2.420	2.432,38	68	08/03/2026	3.500	3.500,33
33	06/07/2025	2.310	2.303,20	69	15/03/2026	3.510	3.477,82
34	13/07/2025	2.410	2.392,92	70	22/03/2026	3.700	3.696,07
35	20/07/2025	2.410	2.418,73	71	29/03/2026	3.550	3.587,62
36	27/07/2025	2.330	2.287,86	72	05/04/2026	3.410	3.415,21

Lampiran 10. Nilai *Error* Model LSTAR(2,1) pada Data *Testing* Harga Saham PT Telkom Indonesia (Persero)

No	Periode	Error	No	Periode	Error
1	17/11/2024	2,270	37	03/08/2025	40,523
2	24/11/2024	19,256	38	10/08/2025	23,846
3	01/12/2024	21,142	39	17/08/2025	1,432
4	08/12/2024	15,077	40	24/08/2025	4,160
5	15/12/2024	13,316	41	31/08/2025	13,970
6	22/12/2024	19,830	42	07/09/2025	0,841
7	29/12/2024	-6,927	43	14/09/2025	24,173
8	05/01/2025	-36,184	44	21/09/2025	-9,468
9	12/01/2025	-7,376	45	28/09/2025	-24,710
10	19/01/2025	20,322	46	05/10/2025	3,154
11	26/01/2025	-6,437	47	12/10/2025	0,161
12	02/02/2025	-41,059	48	19/10/2025	10,612
13	09/02/2025	-17,047	49	26/10/2025	23,641
14	16/02/2025	-33,849	50	02/11/2025	17,659
15	23/02/2025	31,198	51	09/11/2025	19,846
16	02/03/2025	24,501	52	16/11/2025	18,150
17	09/03/2025	7,497	53	23/11/2025	115,250
18	16/03/2025	15,651	54	30/11/2025	39,906
19	23/03/2025	-31,145	55	07/12/2025	-22,539
20	06/04/2025	25,022	56	14/12/2025	-6,311
21	13/04/2025	29,787	57	21/12/2025	-1,272
22	20/04/2025	-7,091	58	28/12/2025	0,841
23	27/04/2025	-7,787	59	04/01/2026	1,226
24	04/05/2025	6,760	60	11/01/2026	-17,416
25	11/05/2025	3,276	61	18/01/2026	-5,615
26	18/05/2025	-10,902	62	25/01/2026	-25,653
27	25/05/2025	-14,343	63	01/02/2026	128,523
28	01/06/2025	-4,382	64	08/02/2026	43,348
29	08/06/2025	-29,548	65	15/02/2026	61,126
30	15/06/2025	-23,889	66	22/02/2026	50,521
31	22/06/2025	13,643	67	01/03/2026	6,349
32	29/06/2025	-12,377	68	08/03/2026	-0,329
33	06/07/2025	6,801	69	15/03/2026	32,182
34	13/07/2025	17,085	70	22/03/2026	3,930
35	20/07/2025	-8,730	71	29/03/2026	-37,618
36	27/07/2025	42,137	72	05/04/2026	-5,205

Lampiran 11. Syntax Model LSTAR dengan Estimasi *Gauss-Newton*

```

library(readxl)
library(dplyr)
library(ggplot2)
library(forecast)
library(tseries)
library(scales)
library(tsDyn)
library(FinTS)
library(numDeriv)
#-----
# IMPORT DATA
#-----
tlkm <- read_excel("C:/Users/WINDOWS 10/Downloads/DATA TELKOM MINGGUAN
AKTUAL.xlsx")%>%
  rename(Y = `Terakhir`)%>%
  mutate(Tanggal = as.Date(Tanggal, format = "%d/%m/%Y"))
length(tlkm$Y)
head(tlkm)
#-----
# UJI STASIONERITAS AWAL
#-----
adf.test(tlkm$Y)
#---Differencing 1 kali---
differencing <- diff(tlkm$Y, differences = 1)
# Data frame setelah differencing
differencing_df <- data.frame(Tanggal = tlkm$Tanggal[-1], Diff_X = differencing)
differencing_df
#-----
#UJI STASIONERITAS SETELAH DIFFERENCING
#-----
adf.test(na.omit(differencing_df$Diff_X))
#-----
# PEMBAGIAN DATA
#-----
latih_rat <- 0.80
m <- nrow(differencing_df)
m_latih <- floor(latih_rat * m)
latih <- differencing_df[1:m_latih, ]
uji <- differencing_df[(m_latih + 1):m, ]
#-----
# DATA FRAME DATA LATIH
#-----

```

```

data_latih <- latihan %>%
  dplyr::select(Tanggal, Diff_X) %>%
  na.omit()
str(data_latih)
head(data_latih)
length(data_latih$Diff_X)
#-----
# IDENTIFIKASI MODEL AR (AIC)
#-----
model_arima = auto.arima(data_latih$Diff_X,
  trace = TRUE,
  stepwise = FALSE,
  approximation = FALSE)
summary(model_arima)
#-----
# ESTIMASI MODEL AR(2) (Least square)
#-----
Z <- as.numeric(data_latih$Diff_X)
n <- length(Z)
p <- 2
#Matrix lag
ar_mat <- embed(Z, p+1)
#Definisi eksplisit
Xt <- ar_mat[, 1]
X_lag1 <- ar_mat[, 2]
X_lag2 <- ar_mat[, 3]
#Data frame AR(2)
df_ar <- data.frame(Xt, X_lag1, X_lag2)
#Estimasi AR (2)
ar_model <- lm(Xt ~ X_lag1 + X_lag2, data = df_ar)
summary(ar_model)
#=====
#UJI Linieritas dan Uji Transisi
#=====
#Residual AR(2)
res_ar <- residuals(ar_model)
V <- length(res_ar)
SSEO <- sum(res_ar^2)
#Regresi bantu dan uji LM
max_delay <- p
LM_stat <- rep(NA, max_delay)
p_value <- rep(NA, max_delay)
for (l in 1:max_delay) {

```

```

st <- ar_mat[, 1+l]
st2 <- st^2
st3 <- st^3
aux_df <- data.frame(res_ar, X_lag1, X_lag2, st, st2, st3)
aux_model <- lm(res_ar ~ X_lag1+X_lag2+ X_lag1:st + X_lag2:st +
                X_lag1:st2 + X_lag2:st2 +
                X_lag1:st3 + X_lag2:st3,
                data = aux_df )
SSE1 <- sum(resid(aux_model)^2)
# Statistik LM
LM_stat[l] <- V * (SSE0- SSE1) / SSE0
df_lm <- 3 * p
p_value[l] <- 1- pchisq(LM_stat[l], df = df_lm)}
#hasil uji LM
hasil_lm <- data.frame(Delay = 1:max_delay, LM_stat = LM_stat,p_value = p_value)
print(hasil_lm)
#Delay terbaik
best_delay <- 1
#Estimasi regresi bantu dengan delay terbaik
st <- ar_mat[, 1 + best_delay]
st2 <- st^2
st3 <- st^3
aux_df_final <- data.frame(res_ar, X_lag1, X_lag2, st,st2,st3)
aux_model_final <- lm(
  res_ar ~ X_lag1 + X_lag2 +
  X_lag1:st + X_lag2:st +
  X_lag1:st2 + X_lag2:st2 +
  X_lag1:st3 + X_lag2:st3,
  data = aux_df_final)
summary(aux_model_final)
resid_SSEI <-resid(aux_model_final)
SSE1 <- sum(resid_SSEI^2)
# =====
# ESTIMASI MODEL LSTAR DENGAN NLS (Gauss-Newton)
# =====
p <- 2
X_train <- data_latih$Diff_X
ar_mat <- embed(X_train, p + 1)
d <- best_delay
y_star <- ar_mat[,1]
# pakai semua lag
Xreg <- cbind(1, ar_mat[, 2:(p+1)]) # tambah intercept
Xreg <- as.matrix(Xreg)

```

```

z_t <- ar_mat[, d+1]
# =====
# INISIALISASI PARAMETER
# =====
# Pemilihan Gamma dengan Grid Search
phi_start <- coef(ar_model)
beta_start <- phi_start * 0.95

# pakai model AR(2)
gamma_start <- 6.6
c_start <- median(z_t)
c_start
theta <- c(phi_start, beta_start, gamma_start, c_start)
k <- length(theta)
#=====
# PARAMETER GAUSS-NEWTON
# =====
max_iter <- 1000
tol_grad <- 1e-6
tol_param <- 1e-6
tol_obj <- 1e-6
# =====
# FUNGSI LSTAR
# =====
lstar_predict <- function(theta, Xreg, z) {
  k <- ncol(Xreg)
  phi <- theta[1:k]
  beta <- theta[(k+1):(2*k)]
  gamma <- theta[2*k + 1]
  cpar <- theta[2*k + 2]
  # fungsi transisi
  G <- 1 / (1 + exp(-gamma * (z - cpar)))
  G <- as.numeric(G)
  # bagian linear & nonlinear
  lin_part <- as.numeric(Xreg %*% phi)
  nonlin_part <- as.numeric(Xreg %*% beta)
  # samakan panjang
  G <- G[1:length(lin_part)]
  y_hat <- lin_part + nonlin_part * G
  return(y_hat)
}
#Residual
compute_residual <- function(y, yhat){

```

```

y- yhat
}
compute_sse <- function(res){
  sum(res^2)
}
compute_chisq <- function(res) {
  sum(res^2)
}
compute_jacobian <- function(theta, Xreg, z, y, p) {
  jacobian(
    func = function(th) as.numeric(y- lstar_predict(th, Xreg, z, p)),
    x = theta)
}
# =====
# ITERASI GAUSS-NEWTON
# =====
for(iter in 1:max_iter){

  y_hat <- lstar_predict(theta, Xreg, z_t)
  res <- compute_residual(y_star, y_hat)
  sse_old <- compute_sse(res)

  # Jacobian
  J <- jacobian(
    func = function(th) compute_residual(y_star, lstar_predict(th, Xreg, z_t)),
    x = theta
  )

  H <- t(J) %*% J
  g <- t(J) %*% res

  # update GN
  step <- tryCatch(
    solve(H, g),
    error = function(e) {
      cat("Singular matrix, pakai pseudo-inverse\n")
      MASS::ginv(H) %*% g
    }
  )

  theta_new <- theta- as.vector(step)

  # evaluasi

```

```

y_hat_new <- lstar_predict(theta_new, Xreg, z_t)
res_new <- compute_residual(y_star, y_hat_new)
sse_new <- compute_sse(res_new)

cat(sprintf("Iter %d | SSE: %.6f\n", iter, sse_new))

# update
if(abs(sse_old- sse_new) < tol_obj){
  cat("Konvergen pada iterasi:", iter, "\n")
  theta <- theta_new
  break
}

theta <- theta_new
}

# =====
# HASIL ESTIMASI
# =====
names(theta) <- c("phi0", "phi1", "phi2",
                 "beta0", "beta1", "beta2",
                 "gamma", "c")
theta
# =====
# PREDIKSI DATA TRAINING
# =====
lstar_predict_1step <- function(Xlag, theta, delay){
  # Parameter
  phi10 <- theta[1]
  phi11 <- theta[2]
  phi12 <- theta[3]
  phi20 <- theta[4]
  phi21 <- theta[5]
  phi22 <- theta[6]
  gamma <- theta[7]
  c <- theta[8]
  # Variabel transisi
  st <- Xlag[delay]
  # Fungsi transisi (logistik)
  G <- 1 / (1 + exp(-gamma * (st - c)))
  # Rezim 1
  reg1 <- phi10 + phi11 * Xlag[1] + phi12 * Xlag[2]
  # Rezim 2
  reg2 <- phi20 + phi21 * Xlag[1] + phi22 * Xlag[2]

```

```

# Prediksi LSTAR
yhat <- reg1 * (1 - G) + reg2 * G
return(yhat)
}
n_train <- length(data_latih$Diff_X)
pred_train <- rep(NA, n_train)
for(t in (p+1):n_train){
  Xlag <- c(
    data_latih$Diff_X[t-1],
    data_latih$Diff_X[t-2]
  )
  pred_train[t] <- lstar_predict_1step(
    Xlag,
    theta, # pakai parameter hasil estimasi
    best_delay # penting!
  )
}
hasilpred_train <- data.frame(
  Tanggal = data_latih$Tanggal,
  Aktual = data_latih$Diff_X,
  Prediksi = pred_train
)
head(hasilpred_train, 10)

# =====
# UJI AUTOKORELASI (LJUNG-BOX)
# =====
max_lag <- 18
alpha <- 0.05
res_lstar <- y_star - lstar_predict(theta, Xreg, z_t)
lb_table <- data.frame(Lag = 1:max_lag, Q_hitung = NA, p_value = NA)
for (k in 1:max_lag) {
  test <- Box.test(res_lstar, lag = k, type = "Ljung-Box")
  lb_table$Q_hitung[k] <- test$statistic
  lb_table$p_value[k] <- test$p.value}
lb_table
# =====
# UJI HOMOSKEDASTISITAS (UJI LM)
# =====
res2 <- res_lstar^2
lag <- 12
arch_data <- data.frame(res2 = res2)
for(i in 1:lag){

```

```

  arch_data[, paste0("lag", i)] <- dplyr::lag(res2, i)
}
arch_data <- na.omit(arch_data)
arch_model <- lm(res2 ~ ., data = arch_data)
summary(arch_model)
n <- nrow(arch_data)
R2 <- summary(arch_model)$r.squared
LM_stat <- n * R2
LM
p_value <- 1- pchisq(LM_stat, df = lag)
p_value
# =====
# UJI NORMALITAS
# =====
# Kolmogorov-Smirnov
ks_result <- ks.test(res_std, "pnorm")
print(ks_result)
#=====
# FUNGSI PREDIKSI LSTAR(2,1)
#=====
lstar_predict_1step <- function(Xlag, theta, best_delay) {
  phi0 <- theta[1]
  phi1 <- theta[2]
  phi2 <- theta[3]
  beta0 <- theta[4]
  beta1 <- theta[5]
  beta2 <- theta[6]
  gamma <- theta[7]
  cpar <- theta[8]
  # variabel transisi
  s_t <- Xlag[best_delay]
  # fungsi logistik
  G <- 1 / (1 + exp(-gamma * (s_t- cpar)))
  # bagian linear
  reg1 <- phi0 + phi1 * Xlag[1] + phi2 * Xlag[2]
  # bagian nonlinear
  reg2 <- beta0 + beta1 * Xlag[1] + beta2 * Xlag[2]
  pred <- reg1 * (1- G) + reg2 * G
  return(pred)}
#=====
# PREDIKSI OUT OF-SAMPLE
#=====
param <- theta

```

```

delay <- best_delay
p <- 2
pred_test <- numeric(nrow(uji))
for(i in 1:nrow(uji)){
  current_index <- m_latih + i
  # ambil lag dari data differencing
  Xlag <- rev(differencing_df$Diff_X[
    (current_index- p):(current_index- 1)
  ])
  pred_test[i] <- lstar_predict_1step(Xlag, param, delay)
}
hasil_prediksi <- data.frame(
  Tanggal = uji$Tanggal,
  Aktual = uji$Diff_X,
  Prediksi = pred_test
)
head(hasil_prediksi)
# =====
# INVERSE TRAINING
# =====
X_awal_train <- tlkm$Y[1]
inv_train <- X_awal_train + cumsum(data_latih$Diff_X)
inv_train
# =====
# INVERSE TESTING (AKTUAL)
# =====
X_awal_test <- tail(inv_train, 1)
inv_test <- X_awal_test + cumsum(uji$Diff_X)
# =====
# INVERSE PREDIKSI
# =====
X_awal_pred <- tail(inv_train, 1)
inv_pred <- numeric(length(hasil_prediksi$Prediksi))
for(i in 1:length(inv_pred)){
  if(i == 1){
    inv_pred[i] <- X_awal_pred + hasil_prediksi$Prediksi[i]
  } else {
    inv_pred[i] <- inv_test[i-1] + hasil_prediksi$Prediksi[i]
  }
}
# =====
# DATA LEVEL (AKTUAL & PREDIKSI)
# =====

```

```

hasil_level <- data.frame(
  Tanggal = uji$Tanggal,
  Aktual_Level = inv_test,
  Prediksi_Level = inv_pred
)
head(hasil_level)
print(hasil_level)
# =====
# ERROR DATA TESTING (SETELAH TRANSFORMASI)
# =====

error_test <- inv_test - inv_pred
hasil_error_test <- data.frame(
  Tanggal = uji$Tanggal,
  Aktual = inv_test,
  Prediksi = inv_pred,
  Error = error_test
)

head(hasil_error_test)
# =====
# HITUNG MAPE
# =====
MAPE <- mean(abs((hasil_plot$Aktual - hasil_plot$Prediksi) / hasil_plot$Aktual), na.rm =
TRUE) * 100
MAPE

# =====
# GRAFIK DATA TESTING
# =====
hasil_plot <- data.frame(
  Tanggal = uji$Tanggal[2:length(pred_asli)],
  Aktual = Y_test[1:(length(pred_asli)-1)],
  Prediksi = pred_asli[2:length(pred_asli)]
)

library(ggplot2)
ggplot(hasil_plot, aes(x = Tanggal)) +
  geom_line(aes(y = Aktual, color = "Aktual"), linewidth = 1.3) +
  geom_line(aes(y = Prediksi, color = "Prediksi"), linewidth = 1.3) +

  scale_color_manual(values = c(

```

```

"Aktual" = "midnightblue",
"Prediksi" = "firebrick1"
)) +

labs(
  title = "Perbandingan Harga Saham Aktual vs Prediksi\nData Testing",
  x = "Periode",
  y = "Harga Saham TLKM",
  color = "Keterangan"
) +

scale_x_date(date_breaks = "2 months", date_labels = "%d-%m-%Y") +

theme_minimal() +
theme(
  plot.title = element_text(hjust = 0.5, face = "bold", size = 16),

  axis.text.x = element_text(angle = 45, hjust = 1),

  legend.position = "right"
)

head(hasil_plot)

# =====
# GRAFIK ERROR DATA TESTING
# =====
# Menghitung error
hasil_plot$Error <- hasil_plot$Aktual- hasil_plot$Prediksi
# Menentukan batas sumbu Y agar memuat nilai negatif dan positif
batas_y <- max(abs(hasil_plot$Error), na.rm = TRUE)

ggplot(hasil_plot, aes(x = Tanggal, y = Error)) +
  geom_line(color = "gold", linewidth = 1.2) +
  geom_point(color = "darkgoldenrod3", size = 1.5) +

# Garis nol
geom_hline(
  yintercept = 0,
  linetype = "dashed",
  color = "gold",
  linewidth = 0.8
) +

```

```
labs(  
  title = "Error Prediksi Model LSTAR\nData Testing",  
  x = "Periode",  
  y = "Error"  
) +  
  
# Menampilkan nilai negatif dan positif pada sumbu Y  
scale_y_continuous(  
  limits = c(-batas_y, batas_y)  
) +  
  
scale_x_date(  
  date_breaks = "2 months",  
  date_labels = "%d-%m-%Y"  
) +  
  
theme_minimal() +  
theme(  
  plot.title = element_text(  
    hjust = 0.5,  
    face = "bold",  
    size = 16  
  ),  
  axis.text.x = element_text(  
    angle = 45,  
    hjust = 1  
  )  
)
```

RIWAYAT HIDUP



Mely Rahmatillah, lahir di Situbondo, 22 November 2001. Tinggal di Desa Peleyan, Kecamatan Panarukan, Kabupaten Situbondo, penulis merupakan anak ketiga dari tiga bersaudara. Anak bungsu dari pasangan Bapak Akhmad dan Ibu Nurul Aini. Penulis telah menempuh pendidikan formal mulai dari TK Al-Amin dan lulus pada tahun 2008. Kemudian penulis melanjutkan pendidikan dasar di SDN 5 Patokan dan lulus pada tahun 2014, dilanjutkan pendidikan menengah pertama di SMPN 1 Situbondo dan lulus pada tahun 2017. Setelah itu melanjutkan pendidikan menengah atas di SMAN 1 Situbondo dan lulus pada tahun 2020. Pada tahun 2022, penulis melanjutkan studi ke jenjang perguruan tinggi di Universitas Islam Negeri Maulana Malik Ibrahim Malang melalui jalur SBMPTN pada Program Studi Matematika, Fakultas Sains dan Teknologi.



KEMENTERIAN AGAMA RI
UNIVERSITAS ISLAM NEGERI
MAULANA MALIK IBRAHIM MALANG
FAKULTAS SAINS DAN TEKNOLOGI
Jl. Gajayana No.50 Dinoyo Malang Telp. / Fax. (0341)558933

BUKTI KONSULTASI SKRIPSI

Nama : Mely Rahmatillah
NIM : 210601110085
Fakultas / Jurusan : Sains dan Teknologi / Matematika
Judul Skripsi : Estimasi *Gauss-Newton* dalam Model *Logistic Smooth Transition Autoregressive* pada Data Harga Saham PT Telkom Indonesia (PERSERO)
Pembimbing I : Abdul Aziz, M.Si.
Pembimbing II : Mohammad Nafie Jauhari, M.Si.

No	Tanggal	Hal	Tanda Tangan
1.	11 Juli 2025	Pembahasan Topik	1.
2.	2 September 2025	Konsultasi Latar Belakang	2.
3.	12 September 2025	Konsultasi Bab I, II, dan III	3.
4.	22 September 2025	Revisi Kepenulisan	4.
5.	25 September 2025	Revisi Flowchart	5.
6.	29 September 2025	Konsultasi Kajian Agama Bab I dan II	6.
7.	6 Oktober 2025	Konsultasi Kajian Agama Bab I dan II	7.
8.	10 Oktober 2025	ACC Kajian Agama Bab I dan II	8.
9.	29 Oktober 2025	ACC Seminar Proposal	9.
10.	3 Desember 2025	Konsultasi Revisi Seminar Proposal	10.
11.	12 Februari 2026	Konsultasi Bab IV	11.
12.	12 Maret 2026	Revisi Bab IV dan V	12.
13.	13 Maret 2026	Konsultasi Kajian Agama Bab IV	13.
14.	26 Maret 2026	ACC Kajian Agama Bab IV	14.
15.	13 April 2026	ACC Bab IV dan V	15.



**KEMENTERIAN AGAMA RI
UNIVERSITAS ISLAM NEGERI
MAULANA MALIK IBRAHIM MALANG
FAKULTAS SAINS DAN TEKNOLOGI**

Jl. Gajayana No.50 Dinoyo Malang Telp. / Fax. (0341)558933

16.	16 April 2026	ACC Seminar Hasil	16.
17.	7 Mei 2026	Konsultasi Revisi Seminar Hasil	17.
18.	11 Mei 2026	Konsultasi Revisi Seminar Hasil	18.
19.	13 Mei 2026	ACC Sidang Skripsi	19.
20.	25 Mei 2026	ACC Keseluruhan	20.

Malang, 25 Mei 2026

Mengetahui,

Ketua Program Studi Matematika



Dr. Fachrur Rozi, M.Si

NIP. 19800527 200801 1 012