

**PERBANDINGAN MODEL SETAR DAN LSTAR DALAM
MEMPREDIKSI DATA HARGA BENSIN KONVENSIONAL REGULER**

(Skripsi)

Oleh

ANASTASYA A. M. SIDABALOK



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

ABSTRACT

COMPARASION OF SETAR AND LSTAR MODELS IN PREDICTING REGULAR CONVENTIONAL GASOLINE PRICE DATA

By

Anastasya A. M. Sidabalok

Forecasting involves predicting what may happen in the future. An essential part of this process is examining time series data, especially when it shows nonlinear characteristics. This study concentrates on predicting the prices of standard regular gasoline in the United States, which consists of a time series affected by numerous economic and seasonal elements. It utilizes two nonlinear time series models: Self-Exciting Threshold Autoregressive (SETAR) and Logistic Smooth Transition Autoregressive (LSTAR). SETAR segments the data into distinct regimes based on a threshold variable, whereas LSTAR allows more gradual changes between regimes through a logistic function. Past research has indicated that both models effectively capture structural shifts in financial and economic time series. By assessing the forecasting performance of the SETAR and LSTAR models, this research seeks to identify which model better forecasts gasoline price fluctuations that demonstrate nonlinear behavior. The findings are anticipated to enhance understanding of energy market trends and aid in making better economic choices.

Keyword: time series, forecasting, SETAR, LSTAR, gasoline prices, nonlinear models.

ABSTRAK

PERBANDINGAN MODEL SETAR DAN LSTAR DALAM MEMPREDIKSI DATA HARGA BENSIN KONVENSIONAL REGULER

Oleh

Anastasya A. M. Sidabalok

Peramalan melibatkan prediksi tentang apa yang mungkin terjadi di masa depan. Bagian penting dari proses ini adalah memeriksa data deret waktu, terutama ketika data tersebut menunjukkan karakteristik nonlinear. Penelitian ini berkonsentrasi pada prediksi harga bensin reguler standar di Amerika Serikat, yang terdiri dari deret waktu yang dipengaruhi oleh berbagai elemen ekonomi dan musiman. Penelitian ini menggunakan dua model deret waktu nonlinear: *Self-Exciting Threshold Autoregressive* (SETAR) dan *Logistic Smooth Transition Autoregressive* (LSTAR). SETAR membagi data ke dalam beberapa rezim yang berbeda berdasarkan variabel ambang batas, sedangkan LSTAR memungkinkan perubahan yang lebih bertahap antar rezim melalui fungsi logistik. Penelitian sebelumnya telah menunjukkan bahwa kedua model tersebut secara efektif menangkap pergeseran struktural dalam deret waktu keuangan dan ekonomi. Dengan menilai kinerja peramalan model SETAR dan LSTAR, penelitian ini berusaha mengidentifikasi model mana yang lebih baik dalam meramalkan fluktuasi harga bensin yang menunjukkan perilaku nonlinear. Temuan ini diharapkan dapat meningkatkan pemahaman tentang tren pasar energi dan membantu dalam membuat pilihan ekonomi yang lebih baik.

Kata-kata kunci: deret waktu, peramalan, SETAR, LSTAR, harga bensin, model nonlinear.

**PERBANDINGAN MODEL SETAR DAN LSTAR DALAM
MEMPREDIKSI DATA HARGA BENSIN KONVENSIONAL REGULER**

ANASTASYA A. M. SIDABALOK

Skripsi

Sebagai Salah Satu Syarat untuk Memperoleh Gelar
SARJANA MATEMATIKA

Pada

Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

Judul Skripsi : **PERBANDINGAN MODEL SETAR DAN
LSTAR DALAM MEMPREDIKSI DATA
HARGA BENSIN KONVENSIONAL
REGULER**

Nama Mahasiswa : **Anastasya A. M. Sidabalok**

Nomor Pokok Mahasiswa : **2157031012**

Program Studi : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**

MENYETUJUI

1. **Komisi Pembimbing**


Dr. Subian Saidi, S.Si., M.Si.
NIP 198008212008121001


Dr. Bernadhita H. S. U., S.Si., M.Sc.
NIP 199206302023212034

2. **Ketua Jurusan Matematika**


Dr. Aang Nurvaman, S.Si., M.Si.
NIP 197403162005011001

MENGESAHKAN

1. Tim Penguji

Ketua

: Dr. Subian Saidi, S.Si., M.Si.

Seckertaris

: Dr. Bernadhita H. S. U., S.Si., M.Sc.

Penguji

Bukan Pembimbing : Prof. Ir. Netti Herawati, M.Sc., Ph.D.

2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

Dr. Eng. Heri Satria, S.Si., M.Si.

NIP-197110012005011002

Tanggal Lulus Ujian Skripsi: 01 Juli 2025

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : Anastasya A. M. Sidabalok
Nomor Pokok Mahasiswa : 2157031012
Jurusan : Matematika
Judul Skripsi : PERBANDINGAN MODEL SETAR DAN
LSTAR DALAM MEMPREDIKSI DATA
HARGA BENSIN KONVENSIONAL
REGULER

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri. Apabila kemudian hari terbukti bahwa skripsi ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 01 Juli 2025

Penulis,



Anastasya A. M. Sidabalok
NPM. 2157031012

RIWAYAT HIDUP

Penulis bernama lengkap Anastasya Anggraeni Manuela Sidabalok, lahir di Bandar Lampung pada tanggal 15 April 2004, sebagai anak pertama dari pasangan Bapak Anggiat Sidabalok dan Ibu Vrawati Pandiangan. Penulis memiliki tiga adik bernama Valentine Hillery Sidabalok, Ratu Gisella Sidabalok, dan Artha Jovanka Sidabalok.

Penulis menempuh pendidikan jenjang taman kanak-kanak di TK Bhakti Putra pada tahun 2008-2009, pendidikan dasar di SD Negeri 1 Suka Bhakti pada tahun 2009-2015, pendidikan menengah di SMP Negeri 2 Banjar Agung pada tahun 2015-2018, dan pendidikan menengah atas di SMA Yos Sudarso Metro pada tahun 2018-2021.

Pada tahun 2021 penulis terdaftar sebagai mahasiswa di Program Studi S1 Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung. Selama menjadi mahasiswa, penulis aktif dalam organisasi kampus, di antaranya menjadi anggota Hubungan Eksternal Badan Eksekutif Mahasiswa Fakultas MIPA (BEM FMIPA) Universitas Lampung periode 2023, menjadi Koordinator divisi Doa dan Pemerhati Persekutuan Oikumene Mahasiswa MIPA (POM MIPA) pada tahun 2023.

Pada awal semester VI, penulis melaksanakan kegiatan Kerja Praktik (KP) di Badan Pendapatan Daerah (BAPENDA) Provinsi Lampung. Kegiatan ini memberikan wawasan nyata mengenai penerapan ilmu yang diperoleh di bangku kuliah ke dalam dunia kerja. Penulis juga mengikuti program Kuliah Kerja Nyata (KKN) yang

dilaksanakan di Desa Trisnomulyo, Kecamatan Batang Hari Nuban, Kabupaten Lampung Timur selama 40 hari sebagai bentuk pengabdian kepada masyarakat.

KATA INSPIRASI

“Segala perkara dapat kutanggung di dalam Dia yang memberi kekuatan kepadaku.”

(Filipi 4:13)

“Sebab Aku ini mengetahui rancangan-rancangan apa yang ada pada-Ku mengenai kamu, demikianlah firman Tuhan, yaitu rancangan damai sejahtera dan bukan rancangan kecelakaan, untuk memberikan kepadamu hari depan yang penuh harapan.”

(Yeremia 29:11)

"Saat Tuhan Yesus yang pegang kendali, langkahmu menjadi ringan dan hidupmu akan selalu diberkati."

(Anastasya A. M. Sidabalok)

PERSEMBAHAN

Dengan mengucapkan puji syukur kepada Tuhan Yesus Kristus atas berkat dan kasih karunia-Nya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya. Dengan rasa syukur dan bahagia, saya persembahkan rasa terimakasih saya kepada:

Kedua Orangtuaku Bapak Anggiat Sidabalok dan Ibu Verawati Pandiangan

Terima kasih karena selalu memberi dukungan, semangat, doa, dan kasih sayang kepada penulis. Kalian adalah alasan terbesarku untuk terus melangkah.

Dosen Pembimbing dan Pembahas

Terima kasih kepada dosen pembimbing dan pembahas yang membantu jalannya skripsi ini, memberikan ilmu serta arahan kepada penulis.

Sahabat-sahabatku

Terima kasih selalu ada disaat suka dan duka, telah memberikan motivasi, pengalaman baik, doa dan selalu mendukung dalam segala hal.

Almamater Tercinta

Universitas Lampung

SANWACANA

Puji dan syukur penulis panjatkan kepada Tuhan Yesus Kristus atas berkat dan kasih karunia-Nya sehingga penulis dapat menyelesaikan skripsi ini yang berjudul “Perbandingan Model SETAR dan LSTAR dalam Memprediksi Data Harga Bensin Konvensional Reguler” dengan baik dan lancar serta tepat pada waktu yang telah ditentukan.

Dalam proses penyusunan skripsi ini, banyak pihak yang telah membantu memberikan bimbingan, dukungan, arahan, motivasi serta saran sehingga skripsi ini dapat terselesaikan. Oleh karena itu, dalam kesempatan ini penulis mengucapkan terima kasih kepada:

1. Bapak Dr. Subian Saidi, S.Si., M.Si. selaku Pembimbing I yang telah memberi arahan, bimbingan, saran kepada penulis sehingga dapat menyelesaikan skripsi ini.
2. Ibu Dr. Bernadhita Herindri Samodera Utami, S.Si., M.Sc. selaku Pembimbing II yang telah banyak meluangkan waktunya untuk memberikan arahan, bimbingan, dukungan, motivasi dan saran kepada penulis sehingga dapat menyelesaikan skripsi ini.
3. Ibu Prof. Ir. Netti Herawati, M.Sc., Ph.D. selaku Pembahas yang telah bersedia memberikan kritik dan saran serta evaluasi kepada penulis sehingga dapat menjadi lebih baik lagi.
4. Seluruh dosen, staff, dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

5. Kedua orangtuaku, Bapak Anggiat Sidabalok dan Ibu Verawati Pandiangan yang selalu memberikan semangat, dukungan, kasih sayang, doa dan motivasi kepada penulis sehingga dapat menyelesaikan skripsi ini.
6. Adik-adikku, Valentine Hillery Sidabalok, Ratu Gisella Sidabalok, dan Artha Jovanka Sidabalok yang selalu memberi dukungan, dan doa kepada penulis.
7. Kepada nenek, paman, bibi, dan tante yang selalu memberikan dukungan, doa serta motivasi kepada penulis.
8. Teman-temanku, Maya, Dita, Vedisya, Adinda, Meiliana, Sherina, Rahma, Nabila, Sari, Nafiri, Tiara, Elisa, Novel, Joe, Firman dan David terima kasih selalu membantu penulis, memberikan motivasi, dukungan serta semangat kepada penulis selama proses penyusunan skripsi ini.

Semoga skripsi ini dapat bermanfaat bagi kita semua. Penulis menyadari bahwa skripsi ini masih jauh dari sempurna, sehingga penulis mengharapkan kritik dan saran yang membangun untuk menjadikan skripsi ini lebih baik lagi.

Bandar Lampung, 01 Juli 2025
Penulis,

Anastasya A. M. Sidabalok

DAFTAR ISI

Halaman

DAFTAR TABEL	iii
--------------------	-----

DAFTAR GAMBAR	iv
---------------------	----

I. PENDAHULUAN.....	1
---------------------	---

1.1 Latar Belakang dan Masalah	1
1.2 Tujuan Penelitian.....	4
1.3 Manfaat Penelitian.....	4

II. TINJAUAN PUSTAKA	5
----------------------------	---

2.1 Data Deret Waktu	5
2.2 Stasioneritas	5
2.3 Transformasi <i>Box-Cox</i>	6
2.4 Uji <i>Augmented Dicky Fuller</i> (ADF).....	6
2.5 Pembeda (<i>Differencing</i>).....	7
2.6 Fungsi Autokorelasi dan Fungsi Autokorelasi Parsial.....	8
2.6.1 Fungsi Autokorelasi (ACF).....	8
2.6.2 Fungsi Autokorelasi Parsial (PACF).....	9
2.7 Model Deret Waktu	11
2.7.1 Model <i>Autoregressive</i> (AR)	12
2.7.2 Model <i>Moving Average</i> (MA).....	12
2.7.3 Model <i>Autoregressive Average Moving Average</i> (ARMA) .	13
2.8 Identifikasi Model	13
2.9 Estimasi Parameter	14
2.9.1 Uji Signifikansi Parameter.....	16
2.10 <i>Akaike's Information Criterion</i> (AIC)	16
2.11 Pemeriksaan Diagnostik	17
2.11.1 Uji <i>White Noise</i>	17
2.11.2 Uji Normalitas.....	18
2.11.3 Uji Heteroskedastisitas.....	19
2.12 Uji Nonlinearitas	20
2.13 Model <i>Threshold Autoregressive</i> (TAR)	21

2.14	Model <i>Self Exciting Threshold Autoregressive</i> (SETAR)	21
2.15	Estimasi Parameter Model SETAR	22
2.16	Model <i>Smooth Transition Autoregressive</i> (STAR).....	25
2.17	Model <i>Logistic Smooth Transition Autoregressive</i> (LSTAR).....	25
2.18	Estimasi Parameter LSTAR.....	26
2.19	<i>Mean Absolute Percentage Error</i> (MAPE)	27
2.20	Peramalan	28
III.	METODOLOGI PENELITIAN	29
3.1	Waktu dan Tempat Penelitian	29
3.2	Data Penelitian	29
3.3	Metode Penelitian.....	29
IV.	HASIL DAN PEMBAHASAN	31
4.1	Deskriptif Data Deret Waktu	31
4.2	Identifikasi Plot Data Pengamatan	31
4.3	Pemeriksaan Kestasioneran Data	32
4.4	Uji Nonlinearitas	35
4.5	Pemodelan SETAR.....	36
4.5.1	Identifikasi Model SETAR	37
4.5.2	Estimasi dan Uji Signifikansi Parameter Model SETAR	39
4.6	Pemodelan LSTAR.....	40
4.6.1	Identifikasi Model <i>Box-Jenkins</i>	41
4.6.2	Estimasi Parameter Model <i>Box-Jenkins</i>	42
4.6.3	Pemeriksaan Diagnostik	43
4.6.3.1	Uji <i>White Noise</i>	43
4.6.3.2	Uji Normalitas.....	44
4.6.3.3	Uji Heteroskedastisitas.....	45
4.6.4	Estimasi Parameter Model LSTAR.....	46
4.7	Perbandingan Model	47
4.8	Peramalan	48
V.	KESIMPULAN.....	51
	DAFTAR PUSTAKA.....	53

DAFTAR TABEL

Tabel	Halaman
1. Identifikasi Model dengan Pola ACF dan PACF	14
2. Kriteria Nilai MAPE	27
3. Statistik Deskriptif Data Harga Bensin Konvensional Reguler	31
4. Transformasi Box-Cox	33
5. Uji <i>Augmented Dickey Fuller</i> (ADF)	33
6. Uji <i>Augmented Dickey Fuller</i> (ADF) <i>Differencing</i> Satu Kali	34
7. Hasil Uji Nonlinearitas	36
8. Nilai <i>Embedding Dimension</i> dan Jarak Waktu	37
9. Hasil Uji Nonlinearitas vs <i>Threshold</i>	38
10. Nilai AIC Model 2- <i>Regime</i> SETAR	38
11. Hasil Estimasi Parameter Model SETAR	39
12. Model Dugaan (<i>Box-Jenkins</i>)	42
13. Hasil Uji <i>Ljung-Box</i>	44
14. Hasil Uji Normalitas	44
15. Hasil Uji Heteroskedastisitas	45
16. Estimasi Parameter Model LSTAR	46
17. Perbandingan Model SETAR dan LSTAR	48
18. Hasil Peramalan Data Harga Bensin Konvensional Reguler 10 Periode ke- depan	49

DAFTAR GAMBAR

Gambar	Halaman
1. Data Harga Bensin Konvensional Reguler	32
2. Data Harga Bensin Konvensional Reguler <i>Differencing</i> Satu Kali	35
3. Plot ACF Data Harga Bensin Konvensional Reguler	41
4. Plot PACF Data Harga Bensin Konvensional Reguler	41
5. Hasil Peramalan Data Harga Bensin Konvensional Reguler 10 Periode ke- depan	50

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Peramalan adalah suatu proses yang bertujuan untuk memprediksi kejadian-kejadian yang akan terjadi di masa depan. Peramalan penting untuk memahami perkembangan yang mungkin terjadi, sehingga dapat menentukan kapan suatu kejadian akan muncul atau kapan kebutuhan baru akan muncul. Dengan demikian, peramalan memungkinkan untuk merumuskan kebijakan atau tindakan yang diperlukan sebagai persiapan. Peranan peramalan dalam pengambilan keputusan sangatlah signifikan (Nasution, 2011). Menurut Heizer & Render (2006), tujuan serta fungsi peramalan adalah untuk menilai kebijakan yang diterapkan perusahaan, baik di masa kini maupun masa lalu, serta menganalisis kemungkinan dampak di masa mendatang. Salah satu metode yang digunakan dalam peramalan adalah analisis deret waktu, atau yang dikenal sebagai *time series*. Analisis ini melibatkan pengumpulan serangkaian pengamatan terhadap suatu variabel yang diambil secara berkala atau berurutan, disusun berdasarkan periode waktu tertentu dengan interval yang tetap, seperti tahunan, triwulanan, bulanan, atau harian. Penting untuk memastikan bahwa interval waktu tersebut konsisten (Wei, 2006).

Menurut *Federal Reserve Economic Data* (FRED), bensin konvensional reguler adalah jenis bahan bakar bensin dengan angka oktan rendah (sekitar 87) yang paling banyak digunakan oleh kendaraan di Amerika Serikat karena harganya lebih terjangkau. Bensin ini tidak memiliki formula khusus untuk pengurangan emisi dan berbeda dari bensin *reformulated* yang dirancang untuk daerah dengan standar lingkungan ketat. Harga bensin konvensional reguler di Amerika Serikat

mengalami fluktuasi yang dipengaruhi oleh berbagai faktor, seperti harga minyak mentah global, biaya distribusi, pajak, serta permintaan musiman. Pergerakan harga bensin ini membentuk data deret waktu yang dianalisis secara luas dalam studi ekonomi dan keuangan, terutama karena dampaknya terhadap inflasi, daya beli masyarakat, serta strategi bisnis sektor transportasi dan logistik. Selain itu, karena bensin konvensional reguler tidak memiliki formula khusus untuk pengurangan emisi, penggunaannya juga berkaitan dengan regulasi lingkungan di beberapa wilayah. Analisis dan prediksi harga bensin menjadi penting untuk memahami tren pasar energi, mengelola dampak ekonomi, serta merancang kebijakan yang lebih efektif dalam menjaga stabilitas harga dan ketersediaan bahan bakar bagi masyarakat.

Model SETAR (*Self Exciting Threshold Autoregressive*) adalah model deret waktu nonlinear yang termasuk dalam kategori *Threshold Autoregressive* (TAR). Dalam model ini, nilai *lag* deret waktu digunakan sebagai variabel ambang (*threshold*) atau variabel endogen, yang membagi data menjadi beberapa rezim berdasarkan kondisi nilai *threshold*. Setiap rezim memiliki model AR yang berbeda. Pendekatan ini efektif untuk menangkap perilaku deret waktu yang berubah-ubah sesuai kondisi data masa lalu (Katabba & Estefsni, 2023).

Menurut Terasvirta & Granger (1993), metode STAR (*Smooth Transition Autoregressive*) yaitu alternatif dari sebuah pemodelan nonlinear dimana menggunakan uji nonlinearitas dalam bentuk kelompok uji *Lagrange Multiplier* (LM). Tipe metode STAR menggunakan fungsi transisi yang berbasis fungsi logistik yang dikenal sebagai *Logistic Smooth Transition Autoregressive* (LSTAR).

Berdasarkan penelitian sebelumnya terhadap model LSTAR yang dilakukan oleh Odelia, *et al.* (2020) dengan judul 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) menghasilkan bahwa nilai MAPE cukup kecil, yaitu 5,12. Hal ini mengindikasikan bahwa peramalan menggunakan model LSTAR (1,1) sangat efektif, dengan prediksi tertinggi tercatat pada tanggal 23 Desember 2019 yaitu sebesar 7678,687. Dalam penelitian terhadap model SETAR oleh Putri & Irhamah (2016) dengan judul Peramalan *Return Saham Bank Central Asia Menggunakan Self Exciting Threshold Autoregressive-Genetic Algorithm* memberikan hasil yang optimal. Hasil terbaik terlihat dari nilai AIC *in-sample* dan MSE *out-sample* yang paling kecil, dengan *threshold* yang digunakan sebesar 0,0136 dan *delay* sebesar 3. Selain itu, nilai peramalan tertinggi dari penelitian ini tercatat pada 16 November 2015, yaitu sebesar 0,0024.

Analisis harga bensin konvensional reguler menggunakan model SETAR dan model LSTAR bertujuan untuk memahami pola dan dinamika nonlinear yang mungkin terjadi dalam data historis harga bensin. Kedua model ini memungkinkan identifikasi adanya perubahan rezim dalam deret waktu, yaitu kondisi ketika pola perilaku data berubah secara signifikan akibat pengaruh nilai masa lalu dari variabel itu sendiri. Model SETAR membagi data ke dalam beberapa rezim secara diskrit berdasarkan nilai ambang tertentu, sedangkan model LSTAR memungkinkan transisi yang lebih halus antar rezim dengan menggunakan fungsi logistik sebagai mekanisme peralihannya.

Dengan demikian, penelitian ini akan mengeksplorasi kemampuan model SETAR dan LSTAR dalam menangkap perubahan struktural maupun fluktuasi harga bensin yang tidak mengikuti pola linear atau musiman yang jelas. Perbandingan kinerja kedua model ini juga dilakukan untuk mengetahui mana yang lebih akurat dalam melakukan peramalan harga bensin konvensional reguler berdasarkan karakteristik data yang bersifat nonlinear.

1.2 Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut.

1. Menganalisis model *Self Exciting Threshold Autoregressive* (SETAR) dan model *Logistic Smoothing Transition Autoregressive* (LSTAR) yang sesuai pada data harga bensin konvensional reguler,
2. Melakukan perbandingan model *Self Exciting Threshold Autoregressive* (SETAR) dan model *Logistic Smoothing Transition Autoregressive* (LSTAR) pada data harga bensin konvensional reguler untuk memperoleh model dengan akurasi terbaik,
3. Memprediksi data harga bensin konvensional reguler pada periode selanjutnya dengan menggunakan model peramalan terbaik.

1.3 Manfaat Penelitian

Hasil dari penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Mampu membandingkan model *Self Exciting Threshold Autoregressive* (SETAR) dan model *Logistic Smoothing Transition Autoregressive* (LSTAR) dalam analisis data harga bensin konvensional reguler,
2. Memperoleh hasil peramalan dengan model yang terbaik pada data harga bensin konvensional reguler.

II. TINJAUAN PUSTAKA

2.1 Data Deret Waktu

Menurut Wei (2006), data deret waktu merupakan sekumpulan pengamatan terhadap suatu variabel yang diambil dan dicatat secara berurutan dari waktu ke waktu dengan interval yang tetap. Studi yang berfokus pada data deret waktu, yang dikenal sebagai analisis deret waktu (*time series analysis*), bertujuan untuk memahami data melalui analisis dari sekumpulan pengamatan dengan interval yang konsisten. Setelah data deret waktu dikumpulkan dan dianalisis, akan terlihat adanya pola-pola yang muncul. Pola-pola ini dapat dibagi menjadi tiga kategori yaitu tren (*trend*), siklus (*cycle*), dan pola musiman (*seasonal*) (Al'afi, *et al.*, 2020).

2.2 Stasioneritas

Menurut Wei (2006), stasioner merujuk pada keadaan dimana data tetap stabil tanpa mengalami perubahan yang signifikan, baik dalam hal rata-rata maupun variansinya, yang harus tetap konsisten sepanjang waktu. Terdapat dua jenis stasioneritas, yaitu:

a. Stasioner dalam *mean* (rata-rata)

Stasioner dalam *mean* berarti fluktuasi yang terjadi berputar di sekitar nilai rata-rata yang stabil, tanpa dipengaruhi oleh waktu, serta variansi dari fluktuasi tersebut. Untuk menentukan apakah suatu data bersifat stasioner atau tidak, kita dapat melihat bentuk plotnya. Melalui plot ACF

(*Autocorrelation Function*), dapat terlihat bahwa nilai-nilai autokorelasi yang dihasilkan dari data stasioner cenderung menurun mendekati nol setelah *time lag* kedua atau ketiga.

b. Stasioner dalam varians (ragam)

Sebuah data deret waktu dikategorikan sebagai stasioner dalam varians jika fluktuasi yang terjadi dalam data tersebut tetap atau konstan seiring waktu, tanpa adanya perubahan yang signifikan. Untuk menganalisis hal ini secara visual, kita dapat menggunakan plot deret waktu yang memungkinkan kita untuk mengamati perubahan data dari waktu ke waktu.

2.3 Transformasi *Box-Cox*

Menurut Drapper & Smith (1992), transformasi *Box-Cox* adalah jenis transformasi pangkat yang diterapkan pada variabel tak bebas dengan syarat bahwa nilai variabel tersebut harus positif. Tujuan dari transformasi *Box-Cox* adalah untuk menstabilkan ragam dalam data yang dianalisis. Berikut ini merupakan *Box-Cox Transformation*:

$$Z_t = \frac{Z_t^\lambda - 1}{\lambda} \quad (2.1)$$

dengan,

Z_t = nilai data pada waktu ke- t

λ = parameter yang digunakan dalam transformasi *Box-Cox*

2.4 Uji *Augmented Dicky Fuller* (ADF)

Uji *Augmented Dicky Fuller* (ADF) dapat digunakan untuk menentukan kestasioneran dalam data (Gujarati & Porter, 2009). Adapun persamaan ADF adalah sebagai berikut:

$$\Delta Y_t = \phi Y_{t-1} \sum_{j=1}^{\rho-1} \alpha_j^* \Delta Y_{t-j} + \varepsilon_t. \quad (2.2)$$

dengan,

- ΔY_t = hasil *difference* data pada period ke- t
- ϕ = koefisien *autoregressive*
- α_j^* = suatu konstanta
- ρ = panjang *lag* yang digunakan
- ε_t = residual pada waktu ke- t

Penggunaan koefisien ϕ dalam *t-statistic* memungkinkan untuk melakukan pengujian menggunakan ADF. Berikut adalah hipotesis yang digunakan dalam pengujian tersebut.

$H_0 : \phi = 0$ (data deret waktu tidak stasioner)

$H_1 : \phi < 0$ (data deret waktu stasioner)

dengan kriteria uji, tolak H_0 jika $p\text{-value} < \alpha$ yang menunjukkan bahwa data deret waktu bersifat stasioner dan terima H_0 jika $p\text{-value} > \alpha$ yang menunjukkan bahwa data deret waktu tidak bersifat stasioner.

2.5 Pembeda (*Differencing*)

Menurut Hanke, *et al.* (2003), jika data tidak menunjukkan karakteristik stasioner pada rata-ratanya, maka dapat diubah menjadi deret stasioner menggunakan metode *differencing*. Metode ini mencakup penggantian deret asli dengan deret selisih. Jumlah *differencing* yang diperlukan untuk mencapai sifat stasioner dinyatakan dengan notasi d . Adapun bentuk *differencing* pertama ($d=1$) adalah sebagai berikut:

$$W_t = X_t - X_{t-1}. \quad (2.3)$$

Sementara itu, untuk bentuk *differencing* kedua ($d=2$), dimana W_t^* merupakan definisi *differencing* pertama dari t adalah sebagai berikut:

$$\begin{aligned} W_t &= W_t^* - W_{t-1}^* \\ &= (X_t - X_{t-1}) - (X_{t-1} - X_{t-2}) \end{aligned} \quad (2.4)$$

dengan,

X_t = pengamatan yang dilakukan pada periode waktu ke- t

W_t = data hasil *differencing* yang diperoleh pada periode waktu ke- t

2.6 Fungsi Autokorelasi dan Fungsi Autokorelasi Parsial

Dalam proses identifikasi model untuk data yang akan diprediksi dalam analisis deret waktu, dapat menggunakan fungsi autokorelasi (ACF) serta fungsi autokorelasi parsial (PACF). ACF mengukur hubungan antara nilai saat ini dengan nilai masa lalu pada berbagai *lag* dan berguna untuk mengidentifikasi komponen *moving average* (MA), sedangkan PACF mengukur hubungan langsung antara nilai saat ini dan lag tertentu dengan menghilangkan pengaruh lag di antaranya, sehingga berguna untuk mengidentifikasi komponen *autoregressive* (AR).

2.6.1 Fungsi Autokorelasi (ACF)

Menurut Wei (2006), dalam proses stasioner dalam data deret waktu (X_t) diperoleh $E(X_t) = \mu$ dan ragam $Var(X_t) = E(X_t - \mu)^2 = \sigma^2$ yang bersifat konstan. Selain itu, kovarian $Cov(X_t, X_{t+k})$ hanya bergantung pada selisih waktu $|t - (t + k)|$. Dengan demikian, kovarian antara X_t dan X_{t+k} dapat dinyatakan sebagai berikut:

$$\begin{aligned} \gamma_k &= Cov(X_t, X_{t+k}) = E[(X_t - \mu)(X_{t+k} - \mu)] \\ \gamma_0 &= \sqrt{Var(X_t)Var(X_{t+k})} = \sqrt{E(X_t - \mu)^2} \sqrt{E(X_{t+k} - \mu)^2} \end{aligned}$$

dan korelasi antara X_t dan X_{t-1} sebagai berikut:

$$\rho_k = \frac{Cov(X_t, X_{t+k})}{\sqrt{Var(X_t)Var(X_{t+k})}} = \frac{E[(X_t - \mu)(X_{t+k} - \mu)]}{\sqrt{E(X_t - \mu)^2} \sqrt{E(X_{t+k} - \mu)^2}} = \frac{\gamma_k}{\gamma_0} \quad (2.5)$$

dengan $Var(X_t) = Var(X_{t+k}) = \gamma_0$. Fungsi dari k, γ_k disebut fungsi autokovarian dan ρ_k disebut sebagai fungsi autokorelasi (ACF). Kedua fungsi ini, γ_k dan ρ_k memiliki karakteristik sebagai berikut:

- 1) $\gamma_0 = Var(X_t); \rho_0 = 1$
- 2) $|\gamma_k| \leq \gamma_0; \rho_k \leq 1$
- 3) $\gamma_k = \gamma_{-k}$ dan $\rho_k = \rho_{-k}$ untuk semua k, γ_k dan ρ_k merupakan fungsi yang simetris pada $lag\ k = 0$. Karakteristik ini muncul dari selisih antara X_t dan X_{t+k} . Oleh karena itu, fungsi autokorelasi biasanya hanya ditampilkan untuk lag yang tidak negatif.

2.6.2 Fungsi Autokorelasi Parsial (PACF)

Menurut Rosadi (2011), fungsi autokorelasi parsial (PACF) pada $lag-k$ berfungsi untuk mengukur korelasi antara X_t dan X_{t+k} setelah menghilangkan ketergantungan linear yang mungkin timbul dari variabel antara $X_{t+1}, X_{t+2}, \dots, X_{t+k-1}$. PACF digunakan untuk mengevaluasi seberapa erat hubungan antara X_t dan X_{t+k} dengan menganggap pengaruh dari $lag\ 1, 2, 3, \dots$, dan seterusnya hingga $k - 1$ tidak relevan. Autokorelasi parsial dapat dinyatakan dengan notasi $corr(X_{t+1}, X_{t+2}, \dots, X_{t+k-1})$ (Makridakis, *et al.*, 1999). Apabila diasumsikan bahwa X_t adalah proses stasioner dengan $E(X_t) = 0$ maka X_{t+k} dapat didefinisikan dalam bentuk model linear:

$$X_{t+k} = \phi_{k1}X_{t+k-1} + \phi_{k2}X_{t+k-2} + \dots + \phi_{kk}X_t + \varepsilon_{t+k} \quad (2.6)$$

dengan,

ϕ_{ki} = parameter regresi ke- i

ε_{t+k} = nilai kesalahan yang tidak memiliki korelasi dengan X_{t+k-j} ,

dimana $j = 1, 2, \dots, k$

Untuk memperoleh nilai fungsi autokorelasi parsial, langkah awal yang harus dilakukan yaitu mengalikan Persamaan (2.6) dengan X_{t+k-j} pada kedua ruas sehingga didapatkan:

$$X_{t+k-j}X_{t+k} = \phi_{k1}X_{t+k-1}X_{t+k-j} + \phi_{k2}X_{t+k-2}X_{t+k-j} + \cdots + \phi_{kk}X_tX_{t+k-j} + \varepsilon_{t+k}X_{t+k-j}. \quad (2.7)$$

Selanjutnya, nilai harapan dari Persamaan (2.7) yaitu

$$E(X_{t+k-j}X_{t+k}) = \phi_{k1}E(X_{t+k-1}X_{t+k-j}) + \phi_{k2}E(X_{t+k-2}X_{t+k-j}) + \cdots + \phi_{kk}E(X_tX_{t+k-j}) + E(\varepsilon_{t+k}X_{t+k-j}).$$

Misalkan nilai $E(X_{t+k-j}X_{t+k}) = \gamma_j, j = 0, 1, \dots, k$ dan karena $E(\varepsilon_{t+k}X_{t+k-j}) = 0$, sehingga didapat

$$\gamma_j = \phi_{k1}\gamma_{j-1} + \phi_{k2}\gamma_{j-2} + \cdots + \phi_{kk}\gamma_{j-k}. \quad (2.8)$$

Persamaan (2.8) dibagi dengan γ_0

$$\frac{\gamma_j}{\gamma_0} = \phi_{k1} \frac{\gamma_{j-1}}{\gamma_0} + \phi_{k2} \frac{\gamma_{j-2}}{\gamma_0} + \cdots + \phi_{kk} \frac{\gamma_{j-k}}{\gamma_0}$$

diperoleh

$$\gamma_j = \phi_{k1}\gamma_{j-1} + \phi_{k2}\gamma_{j-2}\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \cdots + \phi_{kk}\rho_{j-k} \quad (2.9)$$

untuk $j = 1, 2, \dots, k$ diperoleh sistem persamaan sebagai berikut.

$$\begin{aligned} \rho_1 &= \phi_{k1}\rho_0 + \phi_{k2}\rho_1 + \cdots + \phi_{kk}\rho_{k-1} \\ \rho_2 &= \phi_{k1}\rho_1 + \phi_{k2}\rho_0 + \cdots + \phi_{kk}\rho_{k-2} \\ &\vdots \\ \rho_k &= \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \cdots + \phi_{kk}\rho_0. \end{aligned} \quad (2.10)$$

Jika dinyatakan dalam bentuk matriks, Persamaan (2.10) dapat menjadi

$$\begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_k \end{bmatrix} \begin{bmatrix} \phi_{11} \\ \phi_{22} \\ \vdots \\ \phi_{kk} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix}.$$

dengan menggunakan aturan Cramer diperoleh

$$A_k = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_k \end{bmatrix}.$$

Nilai autokorelasi parsial *lag k* yaitu

$$A_k = \frac{\begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_k \end{bmatrix}}{\begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 \end{bmatrix}}$$

Himpunan dari fungsi ϕ_{kk} yang dinyatakan sebagai $\{\phi_{kk}; k = 1, 2, \dots\}$, dikenal dengan fungsi autokorelasi parsial (PACF). Nilai dari fungsi ϕ_{kk} akan bernilai nol ketika $k > p$. Sifat ini digunakan untuk membantu dalam mengidentifikasi model *Autoregressive* (AR) dan *Moving Average* (MA).

2.7 Model Deret Waktu

Deret waktu memiliki berbagai macam model yang dapat digunakan untuk menganalisis pola historisnya. Salah satu pendekatan yang umum digunakan adalah model *Autoregressive* (AR), *Moving Average* (MA), dan *Autoregressive Moving Average* (ARMA) (Box & Jenkins, 1976), yang menjadi dasar dalam pengembangan model yang lebih kompleks.

2.7.1 Model *Autoregressive* (AR)

Model *Autoregressive* (AR) merupakan salah satu jenis model deret waktu yang digunakan untuk meramalkan nilai di masa depan dari suatu variabel dengan mempertimbangkan nilai-nilai masa lalu dari variabel tersebut. Dalam model ini, nilai saat ini (X_t) dijelaskan sebagai suatu kombinasi linear dari nilai-nilai sebelumnya. Model *autoregressive* dengan orde p dinyatakan sebagai $AR(p)$ dan dapat dijelaskan melalui persamaan berikut:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t \quad (2.11)$$

dengan,

X_t = nilai variabel dependen pada waktu ke- t

ϕ_p = parameter model AR, $i = 1, 2, \dots, p$

ε_t = nilai galat pada waktu ke- t

p = orde AR

2.7.2 Model *Moving Average* (MA)

Model *Moving Average* (MA) adalah salah satu jenis model deret waktu yang berfungsi untuk memprediksi nilai saat ini berdasarkan kombinasi linear dari kesalahan prediksi atau residual yang terjadi di masa lalu. Model *moving average* dengan orde q dinyatakan sebagai $MA(q)$ dan dapat dijelaskan melalui persamaan berikut:

$$X_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.12)$$

dengan,

X_t = nilai variabel pada waktu ke- t

θ_q = parameter model MA, $i = 1, 2, \dots, p$

ε_t = nilai galat pada waktu ke- t

p = orde MA

2.7.3 Model *Autoregressive Moving Average* (ARMA)

Model *Autoregressive Moving Average* (ARMA) merupakan kombinasi dari dua model, yaitu AR dan MA. Dalam model ini, nilai X_t tidak hanya dipengaruhi oleh nilai variabel itu sendiri, tetapi juga oleh residual dari variabel tersebut dari periode sebelumnya. Berikut adalah representasi dari model ARMA dengan parameter (p, q) :

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.13)$$

2.8 Identifikasi Model

Menurut Makridakis, *et al.* (1995), langkah awal dalam membangun model deret waktu adalah mengidentifikasi sifat data, apakah stasioner atau nonstasioner. Hal ini penting karena komponen AR dan MA dalam model ARMA hanya berlaku untuk data yang stasioner. Untuk mendeteksi stasioneritas, dapat digunakan plot ACF; data dikatakan stasioner jika autokorelasi menurun cepat menuju nol. Jika data tidak stasioner, maka perlu dilakukan proses pembedaan (*differencing*) untuk menghilangkan *trend*. Setelah data menjadi stasioner, pemilihan model dapat dilanjutkan dengan mengamati pola pada ACF dan PACF sesuai pedoman yang berlaku. Untuk memperjelas proses identifikasi dan pemilihan model berdasarkan pola ACF dan PACF, berikut disajikan tabel yang merangkum panduan umum dalam menentukan bentuk model deret waktu yang sesuai.

Tabel 1. Identifikasi Model dengan Pola ACF dan PACF

Model	Pola ACF	Pola PACF
AR (p)	Menurun secara bertahap hingga mendekati nol	Menurun drastis pada <i>lag</i> tertentu
MA (q)	Penurunan drastis pada <i>lag</i> tertentu	Menurun secara bertahap menuju nol
ARMA (p, q)	Menurun secara bertahap hingga mendekati nol	Menurun secara bertahap hingga mendekati nol

2.9 Estimasi Parameter Model

Setelah mengidentifikasi model sementara, langkah berikutnya adalah mengestimasi parameter dari model tersebut. Secara umum, terdapat beberapa metode yang dapat digunakan untuk memperkirakan parameter pada model ARMA (p, q), di antaranya adalah metode momen, metode kuadrat terkecil, metode kemungkinan maksimum, dan kuadrat terkecil tak bersyarat. Dalam hal ini, akan fokus dibahas metode kemungkinan maksimum (*maximum likelihood*). Misalkan untuk model AR(1), dengan bentuk

$$X_t = \phi X_{t-1} + \varepsilon_t. \quad (2.14)$$

Dengan mengasumsikan bahwa ε_t bersifat independen dan berdistribusi normal dengan rata-rata nol dan simpangan baku σ_ε . Fungsi densitas peluang ε_t dapat dinyatakan sebagai berikut:

$$(2\pi\sigma_\varepsilon^2)^{-\frac{1}{2}} \exp\left(-\frac{\varepsilon_t^2}{2\sigma_\varepsilon^2}\right), -\infty < \varepsilon_t < \infty. \quad (2.15)$$

Karena ε_t saling bebas, maka densitas peluang bersama $\varepsilon_2, \varepsilon_3, \dots, \varepsilon_n$ adalah

$$(2\pi\sigma_\varepsilon^2)^{-\frac{n-1}{2}} \exp\left(-\frac{1}{2\sigma_\varepsilon^2} \sum_{t=2}^n \varepsilon_t^2\right). \quad (2.16)$$

Misalkan

$$\begin{aligned} X_2 - \mu &= \phi(X_1 - \mu) + \varepsilon_2 \\ X_3 - \mu &= \phi(X_2 - \mu) + \varepsilon_2 \\ &\vdots \\ X_n - \mu &= \phi(X_{n-1} - \mu) + \varepsilon_n \end{aligned}$$

diperoleh

$$f(x_2, x_3, \dots, x_n | x_1) = (2\pi\sigma_\varepsilon^2)^{-\left(\frac{n-1}{2}\right)} \exp\left(-\frac{1}{2\sigma_\varepsilon^2} \sum_{t=2}^n [(x_t - \mu) - \phi(X_{t-1} - \mu)]^2\right). \quad (2.17)$$

Fungsi kemungkinan yang bersesuaian adalah

$$L(\phi, \mu, \sigma_\varepsilon^2) = (2\pi\sigma_\varepsilon^2)^{-\left(\frac{n}{2}\right)} (1 - \phi^2)^{\frac{1}{2}} \exp\left[-\frac{S(\phi, \mu)}{2\sigma_\varepsilon^2}\right] \quad (2.18)$$

dengan

$$S(\phi, \mu) = \sum_{t=2}^n [(x_t - \mu) - \phi(X_{t-1} - \mu)]^2 + (1 - \phi^2)(X_1 - \mu)^2 \quad (2.19)$$

Fungsi $S(\phi, \mu)$ disebut fungsi jumlah kuadrat tak bersyarat. Fungsi log kemungkinan (*log-likelihood*) dinotasikan

$$L(\phi, \mu, \sigma_\varepsilon^2) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma_\varepsilon^2) + \frac{1}{2} \log(1 - \phi^2) - \frac{1}{2\sigma_\varepsilon^2} S(\phi, \mu). \quad (2.20)$$

Dengan melakukan turunan dari persamaan log kemungkinan terhadap masing – masing parameter yaitu $\phi, \mu, \sigma_\varepsilon^2$ akan diperoleh nilai estimasi untuk setiap parameter. Salah satunya adalah

$$\widehat{\sigma_\varepsilon^2} = \frac{S(\hat{\phi}, \hat{\mu})}{n}. \quad (2.21)$$

Untuk nilai ϕ dan μ , $L(\phi, \mu, \sigma_\varepsilon^2)$ dapat dimaksimalkan secara analitik terhadap σ_ε^2 dan diperoleh

$$\widehat{\sigma}_{\varepsilon}^2 = \frac{S(\hat{\phi}), \hat{\mu}}{n} \quad (2.22)$$

2.9.1 Uji Signifikansi Parameter

Uji signifikansi parameter dilakukan setelah estimasi nilai-nilai parameter dari model yang telah ditentukan berhasil dilaksanakan. Tujuan dari uji ini adalah untuk menentukan apakah parameter tersebut dianggap signifikan atau tidak (Rosadi, 2011). Hipotesis yang digunakan uji signifikansi parameter adalah sebagai berikut:

$H_0: \phi_1 = 0$ (parameter tidak signifikan dalam model)

$H_1: \phi_1 \neq 0$ (parameter signifikan dalam model)

Taraf signifikansi $\alpha = 0.05$

dengan statistik uji:

$$t_{hitung} = \frac{\phi}{SE(\phi)} \cdot \quad (2.23)$$

Kriteria keputusan: H_0 ditolak jika $|t_{hitung}| > t_{\frac{\alpha}{2}}$, atau $p - value < \alpha$ yang artinya parameter signifikan dalam model.

2.10 Akaike's Information Criterion (AIC)

Kriteria *Akaike's Information Criterion* (AIC) pertama kali diperkenalkan oleh Akaike pada tahun 1974 sebagai alat untuk menentukan model yang paling sesuai dengan data yang ada. Metode ini menggunakan pendekatan *Maximum Likelihood*. Bentuk persamaan AIC adalah sebagai berikut:

$$AIC = -2 \log L + 2p \quad (2.24)$$

dengan,

$\log L$ = *log-likelihood* dalam suatu model

p = jumlah parameter yang terdapat dalam model

Nilai AIC digunakan untuk menentukan model *autoregressive* yang paling sesuai, dimana model dengan nilai AIC terendah dianggap sebagai model terbaik dalam memprediksi nilai y secara simultan (Gujarati & Porter, 2009).

2.11 Pemeriksaan Diagnostik

Menurut Nachrowi (2006), pemeriksaan diagnostik dapat dilakukan dengan cara mengamati apakah residual dari model yang diestimasi menunjukkan karakteristik *white noise* serta memenuhi asumsi normalitas dan heteroskedastisitas. Hal ini penting karena residual yang memenuhi ketiga kriteria tersebut menandakan bahwa model sudah mampu merepresentasikan data dengan baik tanpa meninggalkan pola tersisa atau kesalahan sistematis.

2.11.1 Uji *White Noise*

Jika suatu data terdiri dari variabel acak yang tidak saling berkorelasi satu sama lain, maka disebut sebagai proses *white noise*. Untuk menguji keberadaan *white noise* dapat digunakan uji autokorelasi residual dalam analisis kesalahan. Salah satu metode yang umum digunakan dalam hal ini adalah uji *Ljung Box* (Wei, 2006). Hipotesis yang digunakan dalam pengujian *white noise* adalah sebagai berikut:

$H_0: \rho_k = 0$ (tidak terdapat autokorelasi antar residual)

$H_1: \rho_k \neq 0$ (terdapat autokorelasi antar residual)

Taraf signifikansi: $\alpha = 0.05$

dengan statistik uji:

$$Q_{LB} = n(n+2) \sum_{k=1}^K \frac{\widehat{\rho_k^2}}{n-k} \quad (2.25)$$

dengan,

n = banyaknya data

k = selisih *lag*

K = banyaknya *lag* yang diuji

$\widehat{\rho_k^2}$ = koefisien autokorelasi pada periode ke- k

Kriteria keputusan: tolak H_0 jika $Q_{LB} > \chi^2_{(\alpha, (K-p-q))}$ atau $p - value < \alpha$ yang artinya terdapat autokorelasi antar residual. Tidak tolak H_0 jika $Q_{LB} < \chi^2_{(\alpha, (K-p-q))}$ atau $p - value > \alpha$ yang artinya tidak terdapat autokorelasi antar residual.

2.11.2 Uji Normalitas

Kenormalitasan dalam data dapat dianalisis melalui uji normalitas Kolmogorov-Smirnov (Santoso, 2015). Uji ini berfungsi untuk mengukur kesesuaian (*goodness of fit*) antara distribusi sampel yang ada dengan distribusi lain. Selain itu, uji Kolmogorov-Smirnov juga digunakan untuk membandingkan data dalam sampel dengan distribusi normal yang memiliki nilai rata rata dan standar deviasi yang serupa (Siregar, 2015). Dalam pengujian ini, hipotesis yang diajukan adalah sebagai berikut:

H_0 : residual pada data berdistribusi normal

H_1 : residual pada data tidak berdistribusi normal

Taraf signifikansi: $\alpha = 0.05$

Statistik uji:

$$D = KS = \max |F_0(X) - S_n(X)| \quad (2.26)$$

dengan,

$F_0(X)$ = fungsi distribusi kumulatif pembanding

$S_n(X)$ = fungsi distribusi kumulatif observasi

Kriteria keputusan: tolak H_0 jika $D_{hitung} > D_{(1-\alpha)}$ atau $p - value < \alpha$ yang artinya residual pada data tidak berdistribusi normal. Tidak tolak H_0 jika $D_{hitung} < D_{(1-\alpha)}$ atau $p - value > \alpha$ yang artinya residual pada data berdistribusi normal.

2.11.3 Uji Heteroskedastisitas

Pengujian heteroskedastisitas dilakukan dengan menggunakan model *Autoregressive Conditional Heteroscedasticity* (ARCH). Model ini memiliki karakteristik dengan nilai tengah nol, variabel yang tidak berkorelasi, serta variansi bersyarat yang bervariasi seiring berjalannya waktu. Sementara itu, variansi tidak bersyarat tetap konstan (Nainggolan, 2009). Dalam pengujian ini, hipotesis yang diajukan adalah sebagai berikut:

H_0 : tidak terdapat heteroskedastisitas

H_1 : terdapat heteroskedastisitas

Statistik uji:

$$\chi^2 = nR^2 \quad (2.27)$$

dimana, $R^2 = \frac{\sum_{i=1}^T (\hat{X}_i - \bar{X})^2}{\sum_{i=1}^T (X_i - \bar{X})^2}$

dengan,

n = jumlah pengamatan

R^2 = koefisien determinasi

χ^2 = distribusi *chi-square*

Kriteria keputusan: tolak H_0 jika $\chi^2_{statistik} > \chi^2_{(\alpha,r)}$ atau $p - value < \alpha$ yang artinya terdapat heteroskedastisitas. Tidak tolak H_0 jika $\chi^2_{statistik} < \chi^2_{(\alpha,r)}$ atau $p - value > \alpha$ yang artinya tidak terdapat heteroskedastisitas.

2.12 Uji Nonlinearitas

Untuk menguji apakah data mengandung sifat nonlinear, digunakan pengujian nonlinearitas dengan menggunakan uji Terasvirta. Uji Terasvirta merupakan bagian dari kelompok uji *Lagrange Multiplier* (LM) yang menggunakan pendekatan ekspansi Taylor (Terasvirta, *et al.*, 1993). Hipotesis yang digunakan dalam pengujian ini adalah sebagai berikut.

$H_0: f(x)$ merupakan fungsi linear dalam model linear

$H_1: f(x)$ merupakan fungsi nonlinear dalam model nonlinear

Statistik uji:

$$F = \frac{\frac{SSR_0 - SSR}{m}}{\frac{SSR}{N-p-1-m}} \quad (2.28)$$

dengan:

SSR_0 = jumlah kuadrat residual dari regresi, baik menggunakan model linear maupun nonlinear yang menghasilkan residual ε_t

SSR = jumlah kuadrat residual dari regresi ε_t dengan model linear maupun nonlinear dan m

p = jumlah variabel prediktor awal

m = jumlah variabel prediktor dalam bentuk kuadratik dan kubik

N = jumlah data yang digunakan

Kriteria keputusan: tolak H_0 jika $F_{hitung} > F_{(m,(N-p-1-m))}$ atau $p - value < \alpha$ yang artinya $f(x)$ adalah fungsi nonlinear dalam model nonlinear, sedangkan tidak tolak H_0 jika $F_{hitung} < F_{(m,(N-p-1-m))}$ atau $p - value > \alpha$ yang artinya $f(x)$ adalah fungsi linear dalam model linear.

2.13 Model *Threshold Autoregressive* (TAR)

Salah satu model deret waktu yang bersifat nonlinear adalah model *Threshold Autoregressive* (TAR). Model TAR dibangun oleh berbagai faktor nonlinear yang sering muncul dalam penerapannya, seperti adanya asimetri pada data. Faktor ini mencerminkan pola pergerakan data yang menunjukkan fluktuasi naik dan turun dalam suatu proses. Berikut adalah penjelasan lebih lanjut mengenai model TAR.

$$Z_t = \phi_0 + \sum_{n=1}^p \phi_n Z_{t-n} + \varepsilon_t \text{ jika } s_{t-k} \in R \quad (2.29)$$

dengan,

- Z_t = data deret waktu ke- t ($t = 1, 2, \dots, T$)
- Z_{t-n} = data pada periode $t-n$
- ϕ_0 = konstanta
- ϕ_n = koefisien *autoregressive*
- ε_t = *error* pada saat ke- t
- s_{t-k} = *state determing variable*
- R = nilai *threshold*

Model TAR terdiri dari dua variasi yaitu *Self Exciting Threshold Autoregressive* (SETAR) dan *Smooth Transition Autoregressive* (STAR). Kedua variasi ini berbeda dalam metode transisi dan dalam cara mereka mendefinisikan *regime* (Katabba & Estefnsni, 2023).

2.14 Model *Self Exciting Threshold Autoregressive* (SETAR)

Menurut Terasvirta (1994), model SETAR merupakan salah satu jenis model deret waktu nonlinear yang termasuk dalam kategori model TAR. Model ini memanfaatkan nilai *lag* dari deret waktunya sendiri atau variabel endogen. Proses penentuan model SETAR melibatkan jumlah *regime* (m), orde *Autoregressive* (p),

parameter *delay* dan variabel *threshold* Persamaan umum untuk model SETAR dapat dituliskan sebagai berikut:

$$Z_t = \phi_{0,j} + \sum_{n=1}^{p_j} \phi_{n,j} Z_{t-n} + \varepsilon_t \text{ jika } Z_{t-d} \in R_j \quad (2.30)$$

dengan,

- Z_t = data deret waktu ke- t ($t = 1, 2, \dots, T$)
- Z_{t-n} = data pada periode $t-n$
- $\phi_{0,j}$ = konstanta pada *regime* ke- j ($j = 1, 2, \dots, m$)
- $\phi_{n,j}$ = koefisien *autoregressive* ke- i pada *regime* ke- j
- ε_t = residual pada *regime* ke- j
- R_j = nilai *threshold* pada *regime* ke- j
- d = parameter *delay*

Model *j-regime* SETAR $(d, p_1, \dots, p_j)$ didefinisikan sebagai berikut.

$$Z_t = \begin{cases} \phi_{0,1} + \sum_{n=1}^{p_1} \phi_{n,1} Z_{t-n} + \varepsilon_t, & \text{jika } Z_{t-d} \leq r_1 \\ \phi_{0,2} + \sum_{n=1}^{p_2} \phi_{n,2} Z_{t-n} + \varepsilon_t, & \text{jika } r_1 < Z_{t-d} \leq r_2 \\ \vdots \\ \phi_{0,j} + \sum_{n=1}^{p_j} \phi_{n,j} Z_{t-n} + \varepsilon_t, & \text{jika } r_{j-1} < Z_{t-d} \end{cases} \quad (2.31)$$

dengan,

- j = nomor *regime* dalam model
- d = panjang *delay* variabel *threshold*
- p_j = orde *autoregressive* pada *regime* ke- j dalam model
- r_j = nilai *threshold* pada *regime* ke- j

2.15 Estimasi Parameter Model SETAR

Menurut Chan (2004), jika model SETAR pada persamaan (2.31) memiliki nilai $p_1 = \dots = p_j$, maka model tersebut akan bertransformasi menjadi model linear

AR. Dalam hal ini, nilai p dipilih berdasarkan PACF dari Y_t sedangkan nilai d dipilih untuk memberikan nilai statistik uji- F yang signifikan. Nilai AIC digunakan untuk menentukan orde $(p_j \leq p)$ AR dari setiap *regime*.

Metode *Permutation Entropy* (PE) diterapkan untuk mengukur kompleksitas dalam deret waktu dengan cara membandingkan nilai-nilai di sekitarnya. Dalam hal ini, deret waktu dipetakan untuk menggambarkan hubungan antara nilai saat ini dengan nilai lainnya dalam rentang tertentu (Nuhad, 2014). Pemetaan deret waktu dilakukan dengan mengtransformasikan deret waktu $Y, t = 1, 2, \dots$ ke dalam ruang berdimensi m , sehingga menghasilkan:

$$Y_t = [Y_t, Y_{t-\tau}, \dots, Y_{t+m\tau}]$$

dengan:

$m = \text{embedding dimension}$ (jumlah sampel yang terdapat dalam setiap motif)

$\tau = \text{jarak waktu}$ (jumlah sampel yang memisahkan setiap bagian dalam motif)

Likelihood ratio digunakan untuk melakukan pengujian nonlinearitas pada *threshold* dengan menggunakan statistik uji sebagai berikut:

$$F_{01} = n \left(\frac{SSR_0 - SSR_1}{SSR_1} \right) \quad (2.32)$$

dengan,

n = jumlah sampel

SSR_0 = jumlah kuadrat regresi berdasarkan hipotesis nol

SSR_1 = jumlah kuadrat regresi yang berasal dari hipotesis alternatif .

Pada Persamaan (2.32) terdapat tiga hipotesis yang digunakan, yaitu sebagai berikut:

1. H_0 : model AR (1 *regime*)

H_1 : model SETAR dengan 1 *threshold* (2 *regime*)

2. H_0 : model AR (1 *regime*)
 H_1 : model SETAR dengan 2 *threshold* (3 *regime*)
3. H_0 : model SETAR dengan 1 *threshold* (2 *regime*)
 H_1 : model SETAR dengan 2 *threshold* (3 *regime*)

Pengujian untuk hipotesis pertama dan kedua dilakukan sebagai uji linearitas, sedangkan pengujian hipotesis ketiga berfungsi sebagai uji spesifikasi model. Distribusi F_{01} diestimasi menggunakan metode *bootstrap*, mengingat distribusi tersebut tidak bersifat standar akibat adanya parameter *threshold*. Proses *bootstrap* dilakukan dengan pengambilan sampel ulang dari residual di bawah hipotesis nol, selanjutnya memprediksi parameter *threshold*, dan menghitung statistik uji F_{01} . Keputusan untuk menolak H_0 jika *p-value bootstrap* dari statistik uji $F_{01} < \alpha(0.05)$ (Larsen, 2012).

Pada Persamaan (2.31) model 2 *regime* SETAR memiliki parameter $\phi_{i,j}$, $i = 0, \dots, p, j = 1, 2, r$ dan σ_a^2 yang digunakan dalam estimasi metode *Conditional Least Square*. Dengan asumsi bahwa a_t mengikuti distribusi normal, hasil estimasi yang diperoleh akan sebanding dengan estimasi *maximum likelihood*. Untuk menentukan orde AR dari masing-masing *regime*, dilakukan dengan mempertimbangkan nilai AIC. Untuk menghitung AIC pada model 2 *regime* SETAR (d, p_1, p_2), dilakukan penjumlahan AIC dari model AR pada kedua *regime* tersebut. Persamaan AIC dinyatakan sebagai berikut:

$$AIC(p_1, p_2) = n_1 \ln \widehat{\sigma_2^2} + \ln \widehat{\sigma_2^2} + 2(p_1 + 1) + 2(p_2 + 1) \quad (2.33)$$

dengan:

- n_j = banyaknya pengamatan pada *regime* ke- j
- $\widehat{\sigma_2^2}$ = varians dari residual dalam *regime* ke- j
- j = 1, 2

2.16 Model *Smooth Transition Autoregressive* (STAR)

Menurut Azzam (2007), model STAR merupakan suatu pendekatan dalam analisis data deret waktu yang bersifat nonlinear. Model ini dianggap sebagai pengembangan dari model AR yang memunculkan dua daerah berbeda, dimana nilai parameter antara kedua daerah tersebut dihaluskan melalui proses pemulusan transisi. Model STAR dapat dinyatakan dalam bentuk (p, d) sebagai berikut:

$$X_t = \phi'_1 Y_t (1 - G(S_t; \gamma; c)) + \phi'_2 Y_t G(S_t; \gamma; c) + \varepsilon_t \quad (2.34)$$

dengan,

X_t	= variabel yang diamati pada waktu ke- t
Y_t	= vektor <i>lag</i> pada waktu ke- t , ($Y_t = [1, X_{t-1}, \dots, X_{t-p}]$)
ϕ'_1	= parameter model AR yang menunjukkan <i>regime</i> 1
$G(S_t; \gamma; c)$	= fungsi transisi
S_t	= variabel transisi
γ	= parameter <i>smooth</i>
ε_t	= nilai residu pada waktu ke- t dari model STAR (p, q)

2.17 Model *Logistic Smooth Transition Autoregressive* (LSTAR)

Menurut Terasvirta (1994), model LSTAR adalah salah satu jenis model STAR yang dirancang untuk mengatasi nonlinearitas dalam data deret waktu. Model LSTAR mengintegrasikan elemen dari model *autoregressive* linear dengan komponen transisi nonlinear yang diwakili oleh fungsi logistik. Dengan demikian, model ini memungkinkan adanya transisi yang halus antara dua keadaan yang berbeda berdasarkan nilai dari variabel transisi. Fungsi transisi logistik didefinisikan sebagai berikut:

$$G(S_t; \gamma; c) = \frac{1}{1 + \exp(-\gamma(S_t - c))}, \gamma > 0 \quad (2.35)$$

dimana $S_t = X_{t-1}$ dengan yaitu parameter *delay* l yang merupakan bilangan bulat positif dengan $l > 0$. Parameter c dikenal sebagai *threshold* sedangkan γ menunjukkan tingkat kecepatan serta perhalusan transisi. Model LSTAR dalam bentuk sederhana dapat dituliskan sebagai berikut:

$$X_t = \phi'_1 Y_t \left(1 - \left(\frac{1}{1 + \exp(-\gamma(S_t - c))} \right) \right) + \phi'_2 Y_t \left(\frac{1}{1 + \exp(-\gamma(S_t - c))} \right) + \varepsilon_t$$

jika dijabarkan sebagai berikut:

$$\begin{aligned} X_t = & \left(\phi'_{1,0} + \sum_{j=1}^p \phi'_{1,j} X_{t-1} \right) \left(1 - \left(\frac{1}{1 + \exp(-\gamma(S_t - c))} \right) \right) + \\ & \left(\phi'_{2,0} + \sum_{j=1}^p \phi'_{2,j} X_{t-1} \right) \left(\frac{1}{1 + \exp(-\gamma(S_t - c))} \right) + \varepsilon_t. \end{aligned} \quad (2.36)$$

Model LSTAR memungkinkan data untuk berpindah dari satu kondisi ke kondisi lainnya secara halus, yang menjadikannya berguna dalam menganalisis data.

2.18 Estimasi Parameter Model LSTAR

Menurut Dijk (1999), metode *Nonlinear Least Squares* (NLS) merupakan pendekatan yang digunakan untuk mengestimasi parameter dalam model nonlinear. Proses estimasi parameter ini dilakukan dengan cara meminimalkan jumlah kuadrat residu, yang merupakan selisih antara nilai yang diobservasi dan nilai yang diprediksi oleh model. Jumlah kuadrat residu didefinisikan sebagai berikut:

$$\hat{\theta} = \arg \min Q_T(\theta) = \arg \min \sum_{t=1}^T (X_t - F(Y_t, \theta))^2 \quad (2.37)$$

dengan

$$F(Y_t, \theta) = \phi'_1 Y_t (1 - G(S_t; \gamma; c)) + \phi'_2 Y_t G(S_t; \gamma; c) \quad (2.38)$$

Fungsi objek NLS dapat disederhanakan hanya dengan mempertimbangkan γ dan c karena estimasi dari ϕ'_1 dan ϕ'_2 dapat dilakukan menggunakan metode kuadrat terkecil setelah nilai γ dan c telah ditentukan.

2.19 Mean Absolute Percentage Error (MAPE)

Menurut Gujarti dan Porter (2009) *Mean Absolute Percentage Error* (MAPE) merujuk pada persentase kesalahan rata-rata yang dihitung secara mutlak.

$$MAPE = \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{|y_t|} \times 100\% \quad (2.39)$$

dengan,

y_i = data aktual pada periode ke- t

$\hat{y}_t$ = nilai peramalan pada periode ke- t

n = jumlah data yang tersedia.

Terdapat 4 kategori nilai MAPE yang dapat diinterpretasikan seperti pada tabel berikut.

Tabel 2. Kriteria Nilai MAPE

Nilai MAPE	Kriteria
$MAPE < 10\%$	Kemampuan model peramalan sangat baik
$10\% \leq MAPE < 20\%$	Kemampuan model peramalan baik
$20\% \leq MAPE < 50\%$	Kemampuan model peramalan layak
$MAPE \geq 50\%$	Kemampuan model peramalan buruk

Dari Tabel 2, kriteria nilai MAPE maka dapat dijelaskan bahwa semakin kecil nilai MAPE, maka semakin kecil pula kesalahan pendugaan. Sebaliknya, jika nilai MAPE semakin besar maka kesalahan dalam hasil pendugaan juga akan semakin meningkat. Sebuah metode pendugaan dikatakan memiliki kemampuan peramalan yang sangat baik jika nilai MAPE-nya rendah.

2.20 Peramalan

Peramalan adalah suatu kegiatan yang bertujuan untuk memperkirakan apa yang akan terjadi di masa depan. Untuk memahami dan memprediksi perkembangan di waktu yang akan datang, peramalan sangat penting dalam menentukan kapan suatu peristiwa akan terjadi atau kapan suatu kebutuhan akan muncul. Hal ini memungkinkan kita untuk mempersiapkan kebijakan atau tindakan yang diperlukan. Dengan demikian, peramalan menjadi komponen krusial dalam proses pengambilan keputusan manajemen (Nasution, 2011). Heizer & Render (2006), mengungkapkan bahwa tujuan dan fungsi peramalan adalah untuk mengevaluasi kebijakan perusahaan yang ada saat ini maupun di masa lalu, serta untuk menganalisis dampaknya di masa depan.

III METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan pada semester ganjil tahun ajaran 2024/2025 bertempat di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung. Lokasi penelitian ini berada di Jalan Prof. Dr. Ir. Soemantri Brojonegoro, Gedong Meneng, Kecamatan Rajabasa, Kota Bandar Lampung, Lampung.

3.2 Data Penelitian

Data yang digunakan dalam penelitian ini adalah data deret waktu sekunder yang diambil dari *Federal Reserve Economic Data* (FRED). Sumber data ini dapat diakses melalui tautan <https://fred.stlouisfed.org/series/GASREGCOVW>. Dataset ini berisi harga bensin konvensional reguler mingguan untuk periode 16 Februari 2015 hingga 10 Februari 2025, dengan total observasi sebanyak 533 data.

3.3 Metode Penelitian

Penelitian ini dilakukan melalui kajian literatur secara sistematis dengan memanfaatkan berbagai sumber, baik dari buku maupun media lainnya, guna

mengumpulkan informasi yang mendukung penyusunan skripsi. Adapun langkah-langkah yang dilakukan adalah sebagai berikut:

1. Melakukan analisis deskriptif pada data,
2. Membuat plot data harga bensin konvensional reguler,
3. Melihat kestasioneritas data terkait varian menggunakan transformasi Box-Cox, serta terhadap rata-rata melalui uji *Augmented Dickey-Fuller*. Apabila data tidak stasioner pada varian, maka akan dilakukan transformasi, dan jika tidak stasioner pada rata-rata, data akan distasionerkan melalui teknik *differencing*,
4. Melakukan uji nonlinearitas,
5. Data dibagi menjadi dua bagian, yaitu 523 data digunakan sebagai data pelatihan dan 10 data digunakan sebagai data validasi.
6. Mengidentifikasi model SETAR dengan cara:
 - a. Menentukan *embedding dimension* (m), jarak waktu (τ) *delay* variabel *threshold* (d), *threshold* (r), banyaknya *regime* (j), dan orde AR (p).
 - b. Mengestimasi dan uji signifikansi parameter model SETAR dengan statistik uji t dan setiap parameter di dalam model harus signifikan,
7. Mengidentifikasi model LSTAR dengan cara:
 - a. Menentukan model *Box-Jenkins* dengan menganalisis plot ACF dan PACF,
 - b. Mengestimasi parameter model *Box-Jenkins* terbaik dilihat dari nilai probabilitasnya dari koefisien parameter dan dilihat model terbaik yang mempunyai nilai AIC terkecil,
 - c. Melakukan pemeriksaan uji diagnostik model *Box-Jenkins*,
 - d. Mengestimasi parameter model LSTAR terbaik dilihat dari nilai probabilitasnya dari koefisien parameter. Selain itu, model terbaik juga ditentukan berdasarkan nilai AIC terkecil,
8. Melakukan perbandingan keakuratan dari model SETAR dengan model LSTAR dilihat dari nilai AIC dan nilai MAPE terkecil,
9. Melakukan peramalan dengan menggunakan model yang telah dipilih terhadap data harga bensin konvensional reguler selama 10 periode mendatang dengan membandingkannya dengan 10 data validasi.

V. KESIMPULAN

Berdasarkan pembahasan pada penelitian ini, dapat disimpulkan sebagai berikut:

1. Hasil analisis untuk model SETAR dan LSTAR pada data harga bensin konvensional reguler yaitu sebagai berikut:

Untuk model SETAR(0,1,3)

$$Z_t = \begin{cases} 6.482699 + 0.777328z_{t-1} + \varepsilon_t, & Z_t \leq 27 \\ 16.922545 + 0.276478z_{t-1} - 0.205751z_{t-2} + 0.369436z_{t-3} + \varepsilon_t, & Z_t > 27 \end{cases}$$

Untuk model LSTAR(1,1)

$$X_t = (5.062159 + 0.745199X_{t-1}) \left(1 - \left(\frac{1}{1 + \exp(20.013021(X_{t-1} - 59.491659))} \right) \right) + (8.001653 - 0.481552X_{t-1}) \left(\frac{1}{1 + \exp(20.013021(X_{t-1} - 59.491659))} \right) + \varepsilon_t$$

2. Model SETAR dan LSTAR sama-sama mampu menangkap karakteristik nonlinear pada data harga bensin konvensional reguler. Namun, dari hasil perbandingan model LSTAR(1,1) memiliki nilai MAPE yang lebih rendah (11.72%) dibandingkan dengan model SETAR(0,1,3) (13.43%), yang menunjukkan bahwa model LSTAR(1,1) memberikan hasil peramalan yang lebih akurat. Meskipun nilai AIC pada model SETAR(0,1,3) lebih kecil (4017), dalam konteks peramalan, tingkat akurasi yang lebih tinggi lebih diutamakan. Oleh karena itu, model LSTAR(1,1) dipilih sebagai model terbaik untuk memprediksi harga bensin konvensional reguler.
3. Hasil peramalan pada 10 periode validasi menunjukkan bahwa nilai prediksi cukup mendekati data aktual, seperti pada periode ke-524 dengan data aktual sebesar \$3.021/gal dan hasil peramalan \$3.064/gal, serta periode ke-525 dengan data aktual \$2.997/gal dan hasil peramalan \$3.101/gal. Hal ini menunjukkan bahwa model LSTAR(1,1) memiliki kemampuan yang baik

dalam mengikuti pola pergerakan harga bensin konvensional reguler, sehingga layak digunakan untuk keperluan peramalan.

DAFTAR PUSTAKA

- Al'afi, A. M., Widiarti, W., Kurniasari, D., & Usman, M. 2020. Peramalan data time series seasonal menggunakan metode analisis spektral. *Jurnal Siger Matematika*. **1**(1):10-15.
- Azzam, I. 2007. The Effect of Model-Selection Uncertainty on Autoregressive Models Estimates. *International Research Journal of Finance and Economics*. **2**(11):79-92.
- Box, G. E. P. & Jenkins, G. L. 1976. *Time Series Analysis Forecasting and Control*. Holden Day, San Francisco.
- Chan, W. S., Wong, A. C. S., & Tong, H. 2004. Some Nonlinear Threshold Autoregressive Time Series Models for Actuarial Use. *North American Actuarial Journal*. **8**(4):37-61.
- Dijk, V. 1999. *Smooth Transition Models: Extensions and Outliers Robust Inference*. Tinberg Institute, Amsterdam.
- Federal Reserve Bank of St. Louis. 2015. Conventional gasoline prices: West Coast (PADD 5). <https://fred.stlouisfed.org/series/GASREGCOVW>. Diakses pada 19 Januari 2025.
- Gujarati, D. N. & Porter, D. C. 2009. *Basic Econometrics*. 5th Edition. McGraw Hill Irwin, New York.
- Hanke, J. E., Reitsch, A. G., & Wichern, D. W. 2003. *Peramalan Bisnis*. 7th Edition. PT Prenhallindo, Jakarta.

- Heizer, J. & Render, B. 2006. *Operations Mangement*. 7th Edition. Salemba Empat, Jakarta.
- Katabba, Y. I. & Estefani, K. 2023. Penerapan Model Self-Exciting Threshold Autoregressive (SETAR) Nonlinear dalam Memodelkan Data Harga Minyak Sawit (FCPOc1). *Mathematical Sciences and Applications Journal*. **4**(1):33-39.
- Nachrowi, N. D. & Usman, H. 2006. *Pendekatan Populer dan Praktis Ekonometrika untuk Analisis Ekonomi dan Keuangan*. Lembaga Penerbit Fakultas Ekonomi Universitas Indonesia, Jakarta.
- Nainggolan, N. 2009. *Model Time Series Heteroskedastik*. Unpad Press, Bandung.
- Nasution, S. 2011. *Metode Research (Penelitian Ilmiah)*. Bumi Aksara, Jakarta.
- Nuhad, F. 2014. Penerapan Model Nonlinear Self-Exciting Threshold Autoregressive (Setar) Untuk Pemodelan Data Inflasi Di Indonesia (Skripsi). Jurusan Matematika FMIPA UB, Malang.
- Makridakis, S., Whellwright, S. C., & McGee, V. E. 1999. *Metode dan Aplikasi Peramalan*. Erlangga, Jakarta.
- Odelia, M., Diasih, I. M., & Yasin, H. 2020. 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.
- 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):54-63.
- Rosadi, D. 2011. *Analisis Ekonometrika dan Runtun Waktu Terapan*. Kalimedia, Yogyakarta.
- Santoso, S. 2015. *Statistik NonParametrik*. PT Elex Media Komputindo, Jakarta.

Siregar, S. 2015. *Statistik Terapan untuk Perguruan Tinggi*. Prenadamedia Group, Jakarta.

Terasvirta, T. 1994. Specification, Estimation, and Evaluation of Smooth Transition Autoregressive Models. *Journal of the American Statistical Association*. **89**(425):208-218.

Terasvirta, T., Lin, C. F., & Granger, C. W. J. 1993. Power of the Neural Networks Linearity Test. *Journal of Time Series Analysis*. **14**(2):209-220.

Tsay, R. S. 2010. *Analysis of Financial Time Series*. 3th Edition. John Wiley & Sons, Kanada.

Wei, W. W. S. 2006. *Time Series Analysis : Univariate and Multivariate Methods*. Addison Wesley Publishing Company Inc., USA.