

**PENERAPAN METODE *SEASONAL AUTOREGRESSIVE
INTEGRATED MOVING AVERAGE WITH EXOGENOUS
VARIABLES* PADA PERAMALAN PRODUKSI PADI
DI JAWA BARAT**

SKRIPSI

**OLEH
JEEM SHABIGH BADAR RAMADANI
NIM. 220601110083**



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

**PENERAPAN METODE *SEASONAL AUTOREGRESSIVE
INTEGRATED MOVING AVERAGE WITH EXOGENOUS
VARIABLES* PADA PERAMALAN PRODUKSI PADI
DI JAWA BARAT**

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
Jeem Shabigh Badar Ramadani
NIM. 220601110083**

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

**PENERAPAN METODE *SEASONAL AUTOREGRESSIVE
INTEGRATED MOVING AVERAGE WITH EXOGENOUS
VARIABLES* PADA PERAMALAN PRODUKSI PADI
DI JAWA BARAT**

SKRIPSI

Oleh
Jeem Shabigh Badar Ramadani
NIM. 220601110083

Telah Disetujui untuk Diuji

Malang, 25 Mei 2026

Dosen Pembimbing I

Prof. Dr. H. Sri Harini, M.Si.
NIP. 19731014 200112 2 002

Dosen Pembimbing II

Dr. Mohammad Jamhuri, M.Si.
NIP. 19810502 200501 1 004

Mengetahui,
Ketua Program Studi Matematika

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

**PENERAPAN METODE *SEASONAL AUTOREGRESSIVE
INTEGRATED MOVING AVERAGE WITH EXOGENOUS
VARIABLES* PADA PERAMALAN PRODUKSI PADI
DI JAWA BARAT**

SKRIPSI

**Oleh
Jeem Shabigh Badar Ramadani
NIM. 220601110083**

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


Tanggal 17 Juni 2026

Ketua Penguji : Dr. Fachrur Rozi, M.Si.

Anggota Penguji 1 : Abdul Aziz, M.Si.

Anggota Penguji 2 : Prof. Dr. Hj. Sri Harini, M.Si.

Anggota Penguji 3 : Dr. Mohammad Jamhuri, M.Si.



Mengetahui,
Ketua Program Studi Matematika



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

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Jeem Shabigh Badar Ramadan

NIM : 220601110083

Program Studi : Matematika

Fakultas : Sains dan Teknologi

Judul Skripsi : Penerapan Metode *Seasonal Autoregressive Integrated Moving Average with Exogenous Variables* pada Peramalan Produksi Padi di Provinsi Jawa Barat

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 kutipan 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, 17 Juni 2026

Yang membuat pernyataan,



Jeem Shabigh Badar Ramadan

NIM. 220601110083

MOTO

“Rasa senang kadang menipu, Rasa susah kadang mendidik. Maka jangan cepat menilai hidup hanya dari rasa”

(Mbah moen)

"Maka nikmat Tuhanmu yang manakah yang kamu berdua dustakan?"

(QS. Surah Ar-Rahman)

PERSEMBAHAN

Dengan penuh rasa syukur kepada Allah SWT atas segala rahmat, karunia, kesehatan, dan kemudahan yang diberikan sehingga penulis dapat menyelesaikan skripsi ini. Shalawat serta salam senantiasa tercurah kepada Nabi Muhammad SAW sebagai teladan bagi umat manusia.

Karya ini penulis persembahkan kepada kedua orang tua tercinta, Bapak Ahmad Djudiono dan Ibu Umu Aslamah, yang senantiasa memberikan kasih sayang, doa, dukungan, serta pengorbanan yang tiada henti. Terima kasih atas segala perjuangan, kerja keras, kesabaran, dan ketulusan yang telah diberikan dalam mendidik, membimbing, serta memenuhi kebutuhan penulis sejak kecil hingga dapat menempuh dan menyelesaikan skripsi ini. Setiap doa yang dipanjatkan, nasihat yang diberikan, dan pengorbanan yang dilakukan menjadi sumber kekuatan dan motivasi bagi penulis dalam menghadapi berbagai tantangan selama menempuh pendidikan. Semoga Allah SWT senantiasa melimpahkan kesehatan, kebahagiaan, keberkahan, serta membalas segala kebaikan dan pengorbanan Bapak dan Ibu dengan pahala yang berlipat ganda

KATA PENGANTAR

Assalamu 'alaikum Warahmatullahi Wabarakatuh

Puji syukur penulis panjatkan ke hadirat Allah SWT atas limpahan rahmat, taufik, dan hidayah-Nya sehingga penulis dapat menyelesaikan penyusunan skripsi ini dengan baik. Shalawat dan salam semoga senantiasa tercurah kepada Nabi Muhammad SAW beserta keluarga, sahabat, dan para pengikut beliau hingga akhir zaman.

Penyusunan skripsi ini tidak terlepas dari bantuan, dukungan, doa, serta kontribusi berbagai pihak. Oleh karena itu, dengan penuh rasa hormat penulis menyampaikan penghargaan dan ucapan terima kasih yang sebesar-besarnya kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si., CHARM., CRMP., 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 Malang dan selaku Ketua Penguji yang telah memberikan ilmu, arahan, kritik, dan saran dalam menyelesaikan skripsi ini.
4. Prof. Dr. Hj. Sri Harini, M.Si., selaku Dosen Pembimbing I yang senantiasa memberikan berbagai pengetahuan, motivasi, arahan, nasihat, serta dukungan selama proses penyusunan skripsi ini.
5. Dr. Mohammad Jamhuri, M.Si., selaku Dosen Pembimbing II yang senantiasa memberikan berbagai pengetahuan, motivasi, arahan, nasihat, serta dukungan selama proses penyusunan skripsi ini.
6. Abdul Aziz, M.Si., selaku Anggota Penguji 1 yang telah memberikan ilmu, arahan, kritik, dan saran dalam menyelesaikan skripsi ini.
7. Seluruh Dosen Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
8. Seluruh keluarga yang senantiasa memberikan dukungan berupa doanya, moral dan material.

9. Rekan-rekan serta seluruh teman seperjuangan angkatan 2022 Kebersamaan selama menempuh masa perkuliahan telah menjadi sumber kebahagiaan dan kekuatan dalam menghadapi berbagai tantangan.

Penulis menyadari bahwa skripsi ini masih jauh dari sempurna. Namun, dengan penuh ketulusan, karya ini dipersembahkan sebagai wujud rasa terima kasih dan penghargaan kepada semua pihak yang telah memberikan sumbangsih, dukungan, serta motivasi kepada penulis.

Wassalamu'alaikum warahmatullahi wabarakatuh.

Malang, 17 Juni 2026

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN.....	iii
HALAMAN PENGESAHAN.....	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTO	vi
PERSEMBAHAN.....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	x
DAFTAR TABEL.....	xii
DAFTAR GAMBAR.....	xiii
DAFTAR SIMBOL	xiv
DAFTAR LAMPIRAN	xv
ABSTRAK	xvi
ABSTRACT	xvii
مستخلص البحث.....	xviii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	7
1.3 Tujuan Penelitian	7
1.4 Manfaat penelitian	7
1.5 Batasan Masalah	8
BAB II KAJIAN TEORI	9
2.1 <i>Time Series</i>	9
2.2 Stasioneritas	10
2.2.1 Stasioner dalam Variansi	11
2.2.2 Stasioner dalam Rata-rata	12
2.3 Standardisasi Data.....	14
2.4 Model <i>Time Series</i> Stasioner	15
2.4.1 Model <i>Autoregressive</i>	15
2.4.2 Model <i>Moving Average</i>	16
2.4.3 Model <i>Autoregressive Moving Average</i>	17
2.5 Model <i>Time Series</i> Nonstasioner	18
2.5.1 Model <i>Autoregressive Integrated Moving Average</i>	18
2.5.2 Model <i>Seasonal Autoregressive Integrated Moving Average</i>	19
2.5.3 Model <i>Seasonal Autoregressive Integrated Moving Average with Exogenous Variable</i>	20
2.6 Identifikasi Model.....	22
2.6.1 <i>Autocorrelation Function</i>	22
2.6.2 <i>Partial Autocorrelation Function</i>	25
2.6.3 Pemilihan Model Awal	26
2.6.4 Pemilihan Model Terbaik	28
2.7 Uji Signifikansi	29
2.8 Residual <i>White Noise</i>	29
2.9 Metode <i>Maximum Likelihood Estimation</i>	30

2.10 Kelayakan Model	32
2.11 Produksi Padi	32
2.12 Luas Panen	33
2.13 Curah Hujan	34
2.14 Suhu Udara.....	36
2.15 Lamanya Penyinaran Matahari	37
2.16 Kelembaban Udara.....	39
2.17 <i>Ocean Niño Indeks</i>	40
2.18 Kajian Integrasi Topik dengan Al-Qur'an dan Hadis	41
2.19 Kajian Integrasi Topik dengan Teori Pendukung	43
BAB III METODE PENELITIAN	46
3.1 Jenis Penelitian.....	46
3.2 Data dan Sumber Data	46
3.3 Variabel Penelitian.....	46
3.4 Teknik Analisis Data.....	47
3.5 Diagram Alir (<i>Flowchart</i>).....	50
BAB IV HASIL DAN PEMBAHASAN.....	52
4.1 Identifikasi Data.....	52
4.1.1 Stasioneritas terhadap Varians.....	54
4.1.2 Stasioneritas terhadap <i>Mean</i>	57
4.1.3 Pembagian Data	60
4.2 Identifikasi Model SARIMA	61
4.2.2 Identifikasi Model Sementara	61
4.2.3 Estimasi dan Uji Signifikansi Parameter Model	68
4.2.4 Uji Asumsi Residual <i>White Noise</i>	72
4.2.5 Pemilihan Model SARIMA Terbaik.....	73
4.3 Identifikasi Model SARIMAX	74
4.3.1 Analisis Variabel Eksogen.....	74
4.3.2 Uji Stasioner Variabel Eksogen.....	76
4.3.3 Estimasi dan Uji Signifikansi Parameter Model	78
4.3.4 Akurasi Peramalan	83
4.3.5 Uji Asumsi Residual <i>White Noise</i>	85
4.3.6 Peramalan Jumlah Produksi Padi.....	86
4.4 Integrasi Islam.....	90
BAB V PENUTUP.....	91
5.1 Kesimpulan	91
5.2 Saran	92
DAFTAR PUSTAKA	93
LAMPIRAN.....	97

DAFTAR TABEL

Tabel 2.1	Nilai λ dan Transformasi.....	12
Tabel 2.2	Kriteria Nilai MAPE.....	32
Tabel 4.1	Deskriptif Data pada Variabel Eksogen	53
Tabel 4.2	Uji <i>Augmented Dickey-Fuller</i>	58
Tabel 4.3	Uji <i>Augmented Dickey-Fuller</i> setelah <i>Differencing 1</i>	58
Tabel 4.4	Uji <i>Augmented Dickey-Fuller</i> setelah <i>Differencing</i> Musiman.....	60
Tabel 4.5	Nilai Koefisien ACF	62
Tabel 4.6	Nilai Koefisien PACF	64
Tabel 4.7	Nilai Estimasi dan Uji Signifikansi Parameter Model Awal	69
Tabel 4.8	Nilai AIC Model SARIMA.....	71
Tabel 4.9	Uji <i>Ljung-Box Test</i>	72
Tabel 4.10	Uji Korelasi Pearson	75
Tabel 4.11	Uji <i>Variance Inflation Factor</i> (VIF)	76
Tabel 4.12	Uji Stasioneritas terhadap Variabel Eksogen.....	77
Tabel 4.13	Hasil Uji Stasioneritas Variabel Eksogen Setelah <i>Differencing</i>	77
Tabel 4.14	Nilai Estimasi dan Uji Signifikansi Parameter Model SARIMAX.....	78
Tabel 4.15	Nilai Uji Signifikansi Variabel X_1, X_2, X_4 dan X_6	79
Tabel 4.16	Nilai AIC Model SARIMAX	79
Tabel 4.17	Hasil Prediksi SARIMAX (0,1,2)(0,1,1) ₁₂ terhadap Data Aktual....	84
Tabel 4.18	Uji <i>Ljung-Box Test</i> SARIMAX.....	85
Tabel 4.19	Peramalan Produksi Padi di Jawa Barat 2025.....	88

DAFTAR GAMBAR

Gambar 3.1	Diagram Alir	51
Gambar 4.1	Plot Data Produksi Padi Januari 2018-Desember 2024	52
Gambar 4.2	<i>Plot Box-Cox</i> Data.....	55
Gambar 4.3	Transformasi <i>Box-Cox</i> Pertama	55
Gambar 4.4	Transformasi <i>Box-Cox</i> Kedua	56
Gambar 4.5	Plot Data Stasioner terhadap Varians.....	57
Gambar 4.6	Plot Data Stasioner terhadap <i>mean</i>	59
Gambar 4.7	Plot ACF Data <i>Differencing</i> Nonmusiman	63
Gambar 4.8	Plot PACF Data <i>Differencing</i> Nonmusiman	65
Gambar 4.9	Plot ACF Data <i>Differencing</i> Musiman.....	66
Gambar 4.10	Plot PACF Data <i>Differencing</i> Musiman	67
Gambar 4.11	Grafik Hasil Prediksi terhadap Data Aktual.....	84
Gambar 4.12	Grafik Peramalan Produksi Padi di Jawa Barat Tahun 2025	88

DAFTAR SIMBOL

Beberapa simbol yang digunakan dalam penelitian ini memiliki arti sebagai berikut:

Z_t	: Nilai variabel deret waktu pada periode ke- t
Z	: Matriks variabel dependen ukuran $n \times 1$
μ	: Rata-rata (<i>mean</i>) proses
ε_t	: Nilai <i>error</i> (<i>white noise</i>) pada periode ke- t
ε	: Matriks residual ukuran $n \times 1$
B	: Operator <i>backward</i> $BZ_t = Z_{t-1}$
φ_p	: Parameter <i>Autoregressive</i> (AR) orde ke- p
φ_i	: Koefisien AR lag ke- i , $i = 1, 2, \dots, p$
θ_q	: Parameter <i>Moving Average</i> (MA) orde ke- q
θ_i	: Koefisien MA lag ke- i , $i = 1, 2, \dots, q$
Φ_P	: Parameter AR musiman orde ke- P
Θ_Q	: Parameter MA musiman orde ke- Q
s	: Panjang periode musiman
d	: Derajat <i>differencing</i> non-musiman
D	: Derajat <i>differencing</i> musiman
X_t	: Variabel eksogen pada periode ke- t
X	: Matriks variabel independen ukuran $n \times k$
β	: Koefisien regresi variabel eksogen
γ_k	: Kovarian lag ke- k
ρ_k	: Autokorelasi lag ke- k
p	: Orde model AR
q	: Orde model MA
P	: Orde AR musiman
Q	: Orde MA musiman

DAFTAR LAMPIRAN

Lampiran 1. Data Bulanan Tahun 2018-2024.....	97
Lampiran 2. Hasil Standardisasi	99
Lampiran 3. Hasil Transformasi	101
Lampiran 4. Hasil <i>differencing</i> non musiman.....	102
Lampiran 5. Hasil <i>differencing</i> musiman.....	103
Lampiran 6. Rata-rata historis.....	104

ABSTRAK

Ramadani, Jeem Shabigh Badar. 2026. **Penerapan Metode *Seasonal Autoregressive Integrated Moving Average With Exogenous Variables* pada Peramalan Produksi Padi di Jawa Barat**. Skripsi. Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang
Pembimbing: (I) Prof. Dr. Hj. Sri Harini, M.Si. (II) Dr. Mohammad Jamhuri, M.Si.

Kata Kunci : Produksi padi, Peramalan, *Seasonal Autoregressive Integrated Moving Average with Exogenous Variable* (SARIMAX), Variabel eksogen, Deret waktu.

Peramalan merupakan suatu metode yang digunakan untuk memperkirakan nilai suatu variabel pada masa mendatang berdasarkan pola data historis yang dimiliki. Produksi padi merupakan salah satu komoditas strategis yang perlu diperkirakan secara akurat guna mendukung perencanaan dan pengambilan kebijakan di sektor pertanian. Penelitian ini bertujuan untuk meramalkan produksi padi di Provinsi Jawa Barat menggunakan metode *Seasonal Autoregressive Integrated Moving Average with Exogenous Variable* (SARIMAX) dengan mempertimbangkan faktor-faktor yang diduga memengaruhi produksi padi, yaitu luas panen, curah hujan, suhu udara, kelembapan udara, lama penyinaran matahari, dan *Oceanic Niño Index* (ONI). Hasil seleksi variabel menunjukkan bahwa luas panen, curah hujan, suhu udara, lama penyinaran matahari, dan ONI memenuhi kriteria sebagai variabel eksogen. Berdasarkan hasil analisis, diperoleh model SARIMAX $(0,1,2)(0,1,1)_{12}$ dengan variabel eksogen luas panen, curah hujan, lama penyinaran matahari, dan ONI. Hasil estimasi menunjukkan bahwa luas panen dan curah hujan berpengaruh positif terhadap produksi padi, sedangkan lama penyinaran matahari dan ONI berpengaruh negatif terhadap produksi padi. Model yang diperoleh menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 12,62%, yang menunjukkan bahwa model memiliki tingkat akurasi peramalan yang baik. Dengan demikian, model SARIMAX $(0,1,2)(0,1,1)_{12}$ dapat digunakan untuk meramalkan produksi padi di Provinsi Jawa Barat dan diharapkan dapat menjadi salah satu dasar dalam mendukung perencanaan produksi padi pada periode mendatang.

ABSTRACT

Ramadani, Jeem Shabigh Badar. 2026. **Application of the Seasonal Autoregressive Integrated Moving Average with Exogenous Variables Method for Forecasting Rice Production in West Java**. Undergraduate Thesis. Mathematics Program, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim Malang.

Advisors: (I) Prof. Dr. Hj. Sri Harini, M.Si. (II) Dr. Mohammad Jamhuri, M.Si.

Keywords: Rice production, Forecasting, Seasonal Autoregressive Integrated Moving Average with Exogenous Variables (SARIMAX), Exogenous variables, Time series.

Forecasting is a method used to estimate the future values of a variable based on its historical patterns. Rice production is one of the strategic agricultural commodities that needs to be accurately forecasted to support planning and decision-making in the agricultural sector. This study aims to forecast rice production in West Java Province using the Seasonal Autoregressive Integrated Moving Average with Exogenous Variables (SARIMAX) method by considering factors that are assumed to influence rice production, namely harvested area, rainfall, air temperature, humidity, sunshine duration, and the Oceanic Niño Index (ONI). The results of variable selection indicate that harvested area, rainfall, air temperature, sunshine duration, and ONI met the criteria as exogenous variables. Based on the analysis, the SARIMAX (0,1,2)(0,1,1)₁₂ model was obtained with harvested area, rainfall, sunshine duration, and ONI as exogenous variables. The estimation results show that harvested area and rainfall have a positive effect on rice production, while sunshine duration and ONI have a negative effect on rice production. The resulting model achieved a Mean Absolute Percentage Error (MAPE) value of 12.62%, indicating good forecasting accuracy. Therefore, the SARIMAX (0,1,2)(0,1,1)₁₂ model can be used to forecast rice production in West Java Province and is expected to serve as a reference for supporting rice production planning in future periods.

مستخلص البحث

رمضاني، جيم شايع بدر. ٢٠٢٦. تطبيق نموذج الانحدار الذاتي المتكامل والمتوسطات المتحركة الموسمي مع المتغيرات الخارجية في التنبؤ بإنتاج الأرز في جاوي الغربية. البحث العلوم. قسم الرياضيات، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج.

المشرف : (١) الأستاذة الدكتورة الحاجة سري هاريني، الماجستير. في العلوم: (٢) الدكتور محمد جمهوري، الماجستير في العلوم.

الكلمات الأساسية: إنتاج الأرز، التنبؤ، نموذج الانحدار الذاتي المتكامل والمتوسطات المتحركة الموسمي مع المتغيرات الخارجية ساريماكس، المتغيرات الخارجية، السلاسل الزمنية.

عُدَّ التنبؤ أحد الأساليب المستخدمة لتقدير قيم المتغيرات في المستقبل اعتمادًا على الأنماط التاريخية للبيانات. وعُدَّ إنتاج الأرز من السلع الزراعية الاستراتيجية التي تتطلب تقديرات دقيقة لدعم التخطيط واتخاذ القرارات في القطاع الزراعي. هدفت هذه الدراسة إلى التنبؤ بإنتاج الأرز في إقليم جاوة الغربية باستخدام نموذج الانحدار الذاتي التكاملي والمتوسطات المتحركة الموسمي مع المتغيرات الخارجية، وذلك من خلال مراعاة العوامل التي يُفترض أن تؤثر في إنتاج الأرز، وهي المساحة المحصودة، وهطول الأمطار، ودرجة حرارة الهواء، والرطوبة، ومدة سطوع الشمس، ومؤشر النينو المحيطي. وأظهرت نتائج اختبار المتغيرات أن المساحة المحصودة، وهطول الأمطار، ودرجة حرارة الهواء، ومدة سطوع الشمس، ومؤشر النينو المحيطي استوفت معايير استخدامها كمتغيرات خارجية. وبناءً على نتائج التحليل، تم الحصول على النموذج $(0,1,2)(0,1,1)$ باستخدام المساحة المحصودة، وهطول الأمطار، ومدة سطوع الشمس، ومؤشر النينو المحيطي كمتغيرات خارجية. وأظهرت نتائج التقدير أن المساحة المحصودة وهطول الأمطار لهما تأثير إيجابي على إنتاج الأرز، في حين أن مدة سطوع الشمس ومؤشر النينو المحيطي لهما تأثير سلبي على إنتاج الأرز. وقد حقق النموذج قيمةً متوسط النسبة المئوية للخطأ المطلق بلغت 12.62%، مما يدل على أن النموذج يتمتع بدقة جيدة في التنبؤ. واستخدم هذا النموذج للتنبؤ بإنتاج الأرز في إقليم جاوي الغربية، ومن المتوقع أن يُسهم في دعم تخطيط إنتاج الأرز خلال الفترات المستقبلية.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Analisis deret waktu (*time series analysis*) merupakan metode statistik yang digunakan untuk memahami pola dan tren dalam data yang dikumpulkan secara berurutan berdasarkan waktu. Metode ini dapat diterapkan pada data univariat, yaitu data dengan satu variabel, maupun multivariat, yaitu data dengan lebih dari satu variabel yang saling berinteraksi. Tujuan utama dari analisis deret waktu adalah untuk mengidentifikasi pola-pola penting dalam data, seperti tren jangka panjang, fluktuasi musiman, siklus, dan komponen acak (*noise*), sehingga dapat digunakan untuk peramalan (*forecasting*) dan pengambilan keputusan yang lebih tepat (Vannieuwenhoven dkk., 2024).

Salah satu pendekatan yang efektif dalam analisis dan peramalan deret waktu adalah metode *Seasonal Autoregressive Integrated Moving Average with Exogenous Variables* (SARIMAX). Model ini merupakan pengembangan dari SARIMA, dengan penambahan variabel eksogen sebagai faktor penjelas tambahan yang berpotensi memengaruhi dinamika variabel utama (Contreras-Reyes & Palma, 2023). Dengan adanya variabel eksogen, nilai variabel dependen Z_t tidak hanya dipengaruhi oleh perilaku historisnya, tetapi juga oleh variabel independen lain yang terjadi pada periode yang sama. SARIMAX mampu menangkap pola musiman, tren jangka panjang, serta efek eksternal yang signifikan, sehingga meningkatkan akurasi hasil peramalan (Zhang dkk., 2022).

Proses pembentukan model SARIMAX meliputi identifikasi orde ARIMA, penerapan *differencing* musiman, pemilihan variabel eksogen yang relevan,

estimasi parameter, dan uji diagnostik untuk memastikan keandalan model (Hyndman & Athanasopoulos, 2023). Keunggulan model ini menjadikannya sangat relevan untuk diterapkan pada deret waktu yang dipengaruhi oleh faktor lingkungan, sosial-ekonomi, maupun kebijakan. Dalam konteks sektor pertanian, pendekatan SARIMAX sangat berguna untuk memprediksi produksi dan ketersediaan komoditas pangan strategis seperti padi.

Padi (*Oryza sativa* L.) merupakan komoditas pangan strategis yang memiliki peranan sangat penting bagi masyarakat Indonesia, khususnya di Provinsi Jawa Barat. Sebagai makanan pokok utama yang sulit digantikan, beras menjadi sumber karbohidrat utama bagi sebagian besar penduduk, sehingga ketersediaan padi sangat menentukan ketahanan pangan daerah. Jawa Barat, sebagai salah satu lumbung padi nasional, memiliki tingkat konsumsi beras yang tinggi dan ketergantungan besar terhadap hasil produksi lokal. Oleh karena itu, peningkatan produktivitas dan stabilitas produksi padi menjadi prioritas dalam pembangunan pertanian. Upaya peningkatan produktivitas ini sejalan dengan prinsip ajaran Islam dalam QS. Ar-Ra'd ayat 11 (Kemenag, 2022) yang menyatakan:

لَهُ مُعَقِّبَاتٌ مِّنْ بَيْنِ يَدَيْهِ وَمِنْ خَلْفِهِ يَحْفَظُونَهُ، مِّنْ أَمْرِ اللَّهِ إِنَّ اللَّهَ لَا يُعَيِّرُ مَا بِقَوْمٍ حَتَّىٰ يُعَيِّرُوا مَا بِأَنفُسِهِمْ ۚ وَإِذَا أَرَادَ اللَّهُ بِقَوْمٍ سُوءًا فَلَا مَرَدَّ لَهُ ۚ وَمَا لَهُمْ مِّنْ دُونِهِ مِنِّ وَّالٍ

“Baginya (manusia) ada (malaikat-malaikat) yang menyertainya secara bergiliran dari depan dan belakangnya yang menjaganya atas perintah Allah. Sesungguhnya Allah tidak mengubah keadaan suatu kaum hingga mereka mengubah apa yang ada pada diri mereka. Apabila Allah menghendaki keburukan terhadap suatu kaum, tidak ada yang dapat menolaknya, dan sekali-kali tidak ada pelindung bagi mereka selain Dia.” (QS. Ar-Ra'd ayat 11)

Ayat ini menjadi dasar bahwa ikhtiar manusia melalui optimasi strategi pertanian dan pemanfaatan ilmu pengetahuan merupakan bagian dari proses perubahan menuju keberlanjutan pangan.

Produksi padi dipengaruhi oleh faktor-faktor eksternal dengan dinamika yang kompleks. Curah hujan merupakan faktor dominan dalam keberhasilan sistem irigasi sawah, tetapi sifatnya yang fluktuatif menjadi tantangan dalam proses budidaya (Adib Azka & Trilaksono, 2025). Fenomena perubahan iklim global seperti *El Niño* dapat memperburuk kondisi tersebut melalui penurunan curah hujan dan peningkatan suhu udara yang berdampak langsung pada penurunan hasil panen (Yuniasih dkk., 2023). Selain itu, faktor lain seperti kelembaban udara, intensitas radiasi matahari, serta luas lahan tanam juga berperan dalam menentukan tingkat produktivitas padi.

Dalam perspektif Islam, variabilitas iklim sebagai penyebab perubahan pola produksi pertanian merupakan bagian dari sistem keseimbangan alam yang telah Allah tetapkan. Hal ini sejalan dengan firman Allah SWT dalam QS. Qaf ayat 9 (Kemenag, 2022):

وَنَزَّلْنَا مِنَ السَّمَاءِ مَاءً مُّبَارَكًا فَأَنْبَتْنَا بِهِ جَنَّاتٍ وَحَبَّ الْحَصِيدِ

“Dan Kami turunkan dari langit air yang diberkahi, lalu Kami tumbuhkan dengannya kebun-kebun dan biji-bijian yang dapat dipanen.” (QS. Qaf ayat 9)

Ayat tersebut menegaskan bahwa hujan sebagai sumber utama irigasi dan pertumbuhan tanaman merupakan bentuk karunia. Melalui pemahaman ini, penelitian terkait prediksi produksi padi berbasis faktor iklim menjadi penting agar pengelolaan pertanian dapat dilakukan secara lebih adaptif terhadap perubahan lingkungan.

Provinsi Jawa Barat merupakan salah satu lumbung padi nasional dengan tingkat produksi yang konsisten tinggi serta karakteristik agro-iklim yang beragam. Keberagaman tersebut muncul akibat kondisi topografi Jawa Barat yang bervariasi, mulai dari dataran rendah di bagian utara hingga kawasan pegunungan di bagian

tengah dan selatan. Variasi fisiografis di Jawa Barat menyebabkan perbedaan distribusi curah hujan dan karakteristik iklim wilayahnya, sehingga menjadi representatif untuk mengkaji pengaruh variabel iklim dan karakteristik lahan terhadap produksi padi (Juswadi dkk., 2020). Kondisi ini membuat produksi padi di Jawa Barat lebih sensitif terhadap perubahan iklim dibandingkan wilayah dengan karakter iklim yang lebih seragam. Penelitian klimatologi terbaru menunjukkan bahwa variasi topografi di wilayah Jawa Barat memengaruhi distribusi curah hujan musiman, di mana daerah dengan elevasi lebih tinggi cenderung menerima curah hujan lebih besar dibandingkan dataran rendah, sehingga memengaruhi dinamika iklim lokal serta pola pertanian di wilayah tersebut (Hermawan, 2024). Dengan demikian, karakteristik iklim yang beragam serta dinamika produksi padinya menjadikan Provinsi Jawa Barat sebagai lokasi yang tepat untuk menguji efektivitas model SARIMAX, khususnya dalam memanfaatkan variabel eksogen iklim untuk menganalisis dan memproyeksikan perubahan produksi pertanian secara lebih akurat.

Beberapa penelitian menunjukkan bahwa metode SARIMAX efektif digunakan dalam peramalan data deret waktu. Ahanda dkk. (2025) melakukan penelitian dengan menerapkan model SARIMAX untuk meramalkan luas es laut di kawasan Arktik menggunakan data bulanan periode 1979–2020. Studi ini membandingkan performa SARIMA dan SARIMAX dengan memasukkan anomali suhu global sebagai variabel eksogen. Berdasarkan hasil uji akurasi, model SARIMAX menunjukkan kinerja prediksi *out-of-sample* yang lebih baik, ditunjukkan oleh nilai MAPE yang lebih rendah pada seluruh interval pengujian, yaitu 11,90% untuk data uji 1979–1993, 11,61% untuk 1979–2003, dan 3,92%

untuk 1979–2013. Sebaliknya, model SARIMA menghasilkan MAPE yang lebih tinggi, sehingga kurang optimal dalam prediksi jangka ke depan. Temuan ini menegaskan bahwa penambahan variabel eksogen berupa anomali suhu mampu meningkatkan kemampuan model dalam menangkap dinamika musiman dan tren penurunan luas es laut di Arktik.

Penelitian oleh Nasirudin dan Dzikrullah (2023) menerapkan model SARIMAX untuk meramalkan harga cabai merah nasional menggunakan data time series harga bulanan serta memasukkan variabel eksogen seperti curah hujan, inflasi, dan data tren pencarian (*Google Trends*) sebagai faktor eksternal. Analisis komparatif antara model SARIMA dan SARIMAX menunjukkan bahwa model SARIMAX memberikan performa prediksi lebih unggul, dibuktikan oleh nilai MAPE yang lebih rendah yaitu 6,899 % untuk model SARIMAX dibandingkan 7,630% untuk model SARIMA, sehingga menunjukkan peningkatan akurasi prediksi ketika variabel eksogen dimasukkan. Temuan ini menegaskan bahwa penggabungan faktor-faktor eksternal yang relevan selain pola historis mampu memperkaya informasi deret waktu dan meningkatkan ketepatan peramalan harga komoditas hortikultura yang cenderung volatil, seperti cabai merah di Indonesia.

Syahna dkk. (2024) juga melakukan penelitian dengan menerapkan model SARIMAX untuk meramalkan harga gabah (*rice futures*) menggunakan data historis periode 2020–2024 yang diperoleh dari Investing.com. Penelitian ini mengintegrasikan variabel eksogen berupa suhu, harga pupuk, dan tingkat produksi untuk meningkatkan akurasi prediksi dibandingkan jika hanya mengandalkan pola historis. Hasil evaluasi menunjukkan bahwa model SARIMAX memiliki kinerja prediksi yang sangat baik pada seluruh kategori harga pembukaan, penutupan,

tertinggi, dan terendah. dengan nilai MAPE yang berada di bawah ambang 2%. Kategori harga penutupan menunjukkan performa terbaik, ditandai dengan MAPE 1,354%, MSE 299.629,64, dan RMSE 547,38. Sementara itu, kategori harga tertinggi memiliki MAPE terbesar, yaitu 2,007%, namun tetap dalam batas akurasi yang dapat diterima. Temuan ini menegaskan bahwa penambahan variabel eksogen mampu meningkatkan kemampuan model dalam menangkap pola musiman dan dinamika pasar, sehingga SARIMAX menjadi model yang efektif untuk memprediksi harga gabah dan mendukung pengambilan keputusan dalam sektor pertanian.

Berdasarkan penelitian-penelitian tersebut, dapat disimpulkan bahwa metode *Seasonal Autoregressive Integrated Moving Average with Exogenous Variables* (SARIMAX) relevan untuk dipakai dalam meramalkan berbagai jenis data deret waktu yang dipengaruhi faktor musiman serta variabel eksternal seperti pada produksi padi di Jawa Barat. Oleh karena itu, penelitian ini dimaksudkan untuk menganalisis dan meramalkan produksi padi di Provinsi Jawa Barat dengan mempertimbangkan pengaruh faktor musiman serta variabel eksogen yang berkaitan dengan kondisi iklim dan karakteristik lahan.

Adapun tujuan penelitian ini adalah untuk membangun model peramalan yang optimal dengan menggunakan metode SARIMAX serta melibatkan variabel eksogen berupa luas lahan, curah hujan, suhu udara, lamanya penyinaran matahari, kelembaban udara, serta *Oceanic Niño Index* (ONI). Selain itu, penelitian ini juga bertujuan untuk mengevaluasi tingkat akurasi model yang dihasilkan sehingga dapat memberikan prediksi produksi padi yang akurat dan bermanfaat sebagai dasar pengambilan keputusan di sektor pertanian.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, rumusan masalah dalam penelitian ini adalah:

1. Bagaimana tingkat keakuratan metode *Seasonal Autoregressive Integrated Moving Average with Exogenous Variables* (SARIMAX) dalam meramalkan produksi padi di Provinsi Jawa Barat berdasarkan nilai MAPE?
2. Bagaimana hasil peramalan jumlah produksi padi di Provinsi Jawa Barat untuk periode Januari-Desember 2025 menggunakan metode *Seasonal Autoregressive Integrated Moving Average with Exogenous Variables* (SARIMAX)?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah diuraikan, tujuan penelitian ini adalah:

1. Menganalisis tingkat keakuratan metode *Seasonal Autoregressive Integrated Moving Average with Exogenous Variables* (SARIMAX) dalam meramalkan produksi padi di Provinsi Jawa Barat berdasarkan nilai MAPE
2. Menganalisis hasil peramalan jumlah produksi padi di Provinsi Jawa Barat untuk periode Januari-Desember 2025 menggunakan metode *Seasonal Autoregressive Integrated Moving Average with Exogenous Variables* (SARIMAX)

1.4 Manfaat penelitian

Berdasarkan tujuan penelitian yang telah dikemukakan, manfaat yang dapat diperoleh dari penulisan skripsi ini adalah sebagai berikut:

1. Bagi peneliti, penelitian ini memberikan kontribusi dalam memperkaya pengetahuan dan pemahaman akademis mengenai penerapan metode SARIMAX dalam melakukan peramalan produksi padi, sekaligus sebagai sarana untuk meningkatkan kompetensi analisis data.
2. Bagi pembaca, hasil penelitian ini diharapkan dapat menjadi referensi ilmiah maupun bahan literatur yang relevan untuk mendukung pengembangan penelitian serupa, baik dengan menggunakan metode SARIMAX maupun metode peramalan alternatif lainnya.
3. Bagi pemerintah, penelitian ini diharapkan dapat memberikan informasi yang bersifat aplikatif terkait proyeksi peningkatan maupun penurunan produksi padi, sehingga dapat dimanfaatkan sebagai salah satu pertimbangan dalam penyusunan kebijakan ketahanan pangan.

1.5 Batasan Masalah

Adapun batasan masalah dari penelitian ini adalah sebagai berikut:

1. Data yang digunakan adalah data time series produksi padi Jawa Barat pada bulan Januari 2018 sampai bulan Desember 2024.
2. Tingkat akurasi model diukur dengan menggunakan nilai *Mean Absolute Percentage Error* (MAPE).
3. Variabel eksogen yang digunakan dalam penelitian ini meliputi luas lahan, curah hujan, suhu udara, lamanya penyinaran matahari, kelembaban udara, serta *Oceanic Niño Index* (ONI). Pemilihan variabel-variabel tersebut didasarkan pada keterkaitannya dengan faktor-faktor yang memengaruhi produksi padi, baik dari aspek agronomis maupun kondisi iklim

BAB II

KAJIAN TEORI

2.1 *Time Series*

Deret waktu merupakan rangkaian observasi terhadap suatu variabel yang dicatat secara berurutan berdasarkan waktu kejadian, dengan interval waktu yang tetap. Menurut Wei (2006), deret waktu mencerminkan dinamika suatu fenomena yang diamati dari waktu ke waktu, sehingga memungkinkan analisis terhadap perubahan dan pola yang terjadi dalam jangka waktu tertentu.

Analisis deret waktu adalah salah satu metode statistik yang digunakan untuk memprediksi struktur probabilistik dari suatu keadaan di masa mendatang, yang bertujuan mendukung proses pengambilan keputusan (Aswi & Sukarna, 2006). Pendekatan ini didasarkan pada asumsi bahwa nilai pengamatan saat ini (Z_t) dipengaruhi oleh satu atau lebih nilai pengamatan sebelumnya (Z_{t-1}), dengan t sebagai indeks waktu. Tujuan utama dari analisis deret waktu meliputi pemahaman terhadap mekanisme yang mendasari suatu fenomena, peramalan nilai di masa depan, serta optimalisasi sistem pengendalian.

Cryer (2008) menekankan bahwa data deret waktu dapat dikumpulkan dalam berbagai interval seperti harian, mingguan, bulanan, tahunan, atau periode waktu lainnya yang konsisten. Melalui analisis terhadap pola dalam data tersebut, dapat ditentukan metode yang paling sesuai untuk pengolahan dan peramalan data. Makridakis dkk. (1999) mengklasifikasikan pola dalam data deret waktu ke dalam empat kategori utama, yaitu:

1. Pola Horizontal (*Stasionary*) Pola ini ditandai dengan fluktuasi data di sekitar nilai rata-rata yang relatif konstan. Data dengan pola ini disebut stasioner,

contohnya penjualan produk yang tidak menunjukkan tren kenaikan atau penurunan dalam periode tertentu.

2. Pola Musiman (*Seasonal*) Pola musiman muncul ketika data dipengaruhi oleh faktor musiman yang berulang secara periodik, seperti penjualan es krim yang meningkat saat musim panas atau bahan bakar pemanas yang meningkat saat musim dingin.
3. Pola Siklis (*Cyclical*) Pola ini mencerminkan fluktuasi jangka panjang yang berkaitan dengan siklus ekonomi, seperti penjualan mobil atau baja yang dipengaruhi oleh kondisi bisnis makro.
4. Pola Tren (*Trend*) Pola tren menunjukkan adanya kecenderungan kenaikan atau penurunan nilai pengamatan dalam jangka panjang. Data dengan pola ini disebut nonstasioner, contohnya produk domestik bruto (GNP) atau indikator ekonomi lainnya yang mengalami perubahan seiring waktu.

2.2 Stasioneritas

Salah satu konsep fundamental dalam analisis deret waktu adalah stasioneritas, yaitu kondisi di mana data menunjukkan fluktuasi yang konsisten di sekitar nilai rata-rata yang tetap, serta memiliki variansi yang tidak berubah sepanjang waktu. Menurut Makridakis dkk. (1999), data dikatakan stasioner apabila karakteristik statistiknya, seperti rata-rata dan variansi, tidak bergantung pada waktu dan tetap konstan dalam jangka panjang.

Penentuan apakah suatu data bersifat stasioner sangat krusial dalam proses analisis deret waktu, karena mempengaruhi kelayakan penggunaan model peramalan tertentu. Dalam hal ini, terdapat dua syarat utama yang harus dipenuhi

agar data dapat dikategorikan sebagai stasioner, yaitu: Stasioner dalam Rata-rata dan Stasioner dalam Variansi.

2.2.1 Stasioner dalam Variansi

Dalam analisis deret waktu, stasioneritas merupakan syarat penting yang harus dipenuhi sebelum dilakukan pemodelan. Salah satu bentuk stasioneritas adalah stasioneritas dalam variansi, yaitu kondisi di mana data menunjukkan fluktuasi dengan tingkat variansi yang konstan sepanjang waktu. Apabila nilai λ yang didapatkan $\lambda \neq 1$ maka perlu dilakukan transformasi Z_t dengan λ sebagai parameter proses transformasinya untuk menstabilkan variansi agar analisis dapat dilakukan secara lebih akurat.

Salah satu metode yang umum digunakan untuk menangani ketidakstasioneran dalam variansi adalah transformasi Box-Cox. Metode ini diperkenalkan oleh Box dan Cox tahun 1964 sebagai pendekatan transformasi pangkat terhadap variabel respon, dengan menggunakan parameter tunggal yang disebut λ . Transformasi ini bertujuan untuk mengubah distribusi data agar lebih mendekati normal dan memiliki variansi yang stabil. Secara matematis, transformasi Box-Cox dinyatakan sebagai berikut (Wei, 2006):

$$T(Z_t) = \begin{cases} \frac{Z_t^{(\lambda)} - 1}{\lambda}, & \lambda \neq 0 \\ \ln Z_t, & \lambda = 0 \end{cases} \quad (2.1)$$

Beberapa penggunaan nilai λ dengan bentuk transformasinya dapat dilihat pada tabel berikut:

Tabel 2.1 Nilai λ dan Transformasi

Nilai Lambda (λ)	Transformasi
-2	$\frac{1}{Z_t^2}$
-1	$\frac{1}{Z_t}$
-0.5	$\frac{1}{\sqrt{Z_t}}$
0	$\ln Z_t$
0.5	$\sqrt{Z_t}$
1	Z_t
2	Z_t^2

2.2.2 Stasioner dalam Rata-rata

Dalam analisis deret waktu, stasioneritas dalam rata-rata merujuk pada kondisi di mana data berfluktuasi secara konsisten di sekitar nilai tengah yang konstan sepanjang waktu. Secara visual, hal ini dapat diamati melalui diagram deret waktu yang menunjukkan pola fluktuasi sejajar dengan sumbu waktu (Makridakis dkk., 1999). Ketika data tidak memenuhi syarat ini, maka diperlukan proses transformasi untuk menjadikannya stasioner, salah satunya melalui teknik *differencing*.

Differencing merupakan metode yang digunakan untuk menghilangkan tren dalam data deret waktu dengan cara menghitung selisih antara nilai pengamatan saat ini dan nilai pengamatan pada periode sebelumnya. Notasi yang digunakan dalam proses ini adalah operator *back shift* atau *shift* mundur (B), yang dinyatakan sebagai:

$$BZ_t = Z_{t-1} \quad (2.2)$$

di mana:

B : Operator *Backshift*

Z_t : Nilai pengamatan pada waktu ke- t

Z_{t-1} : Nilai pengamatan pada waktu ke- $(t - 1)$

Operator B berfungsi untuk menggeser data satu periode ke belakang. Z_t adalah nilai pengamatan pada waktu ke- t , dan Z_{t-1} adalah nilai pengamatan pada waktu ke- $(t - 1)$ (Makridakis dkk., 1999). Proses *differencing* orde pertama dilakukan dengan menghitung selisih antara nilai pengamatan saat ini dan nilai sebelumnya, yang dirumuskan sebagai:

$$\begin{aligned}\Delta Z_t &= Z_t - Z_{t-1} \\ &= Z_t - BZ_t \\ &= (1 - B)Z_t\end{aligned}\tag{2.3}$$

Untuk menghilangkan tren yang lebih kompleks, dapat dilakukan *differencing* pada orde kedua, yaitu dengan menghitung selisih dari hasil *differencing* orde pertama:

$$\Delta^2 Z_t = (1 - B)^2 Z_t\tag{2.4}$$

Secara umum, proses *differencing* untuk orde ke- d dapat dinyatakan sebagai:

$$\Delta^d Z_t = (1 - B)^d Z_t\tag{2.5}$$

Kesetasioneran suatu data secara pasti dapat dilihat dengan menggunakan uji statistic, yaitu uji *unit root*. Salah satu pendekatan statistik yang digunakan untuk menguji keberadaan akar unit (*unit root*) dalam data adalah uji *Augmented Dickey-Fuller* (ADF). Uji ini bertujuan untuk menentukan apakah suatu deret waktu bersifat stasioner atau tidak, dengan menguji hipotesis nol bahwa data memiliki akar unit (nonstasioner) melawan hipotesis alternatif bahwa data bersifat stasioner. ADF merupakan pengembangan dari uji Dickey-Fuller klasik, yang menambahkan komponen lag dari variabel dependen untuk mengatasi

kemungkinan adanya autokorelasi dalam residual. Bentuk umum dari persamaan uji ADF dapat dinyatakan sebagai berikut (Enders, 2015):

$$\Delta Z_t = \beta_0 + \beta_1 Z_{t-1} + \sum_{i=1}^p \gamma_i \Delta Z_{t-i} + e_t \quad (2.6)$$

di mana:

ΔZ_t : Perubahan nilai deret waktu pada periode ke- t

β_0 : Konstanta

β_1 : Koefisien regresi terhadap nilai lag dari deret waktu

γ_i : Koefisien dari lag *differencing*

p : Jumlah lag yang digunakan

e_t : Komponen *error* yang diasumsikan bersifat *white noise*

Dalam uji ADF, hipotesis yang diuji adalah sebagai berikut:

Hipotesis nol (H_0): Data memiliki *unit root* (tidak stasioner)

Hipotesis alternatif (H_1): Data tidak memiliki *unit root* (stasioner)

Kriteria pengambilan keputusan dalam uji ADF dapat dilakukan melalui dua pendekatan: Berdasarkan nilai p: Tolak H_0 jika nilai *p-value* < tingkat signifikansi (α) atau Berdasarkan statistik uji: Tolak H_0 jika nilai absolut dari statistik uji ($|t|$) lebih besar dari nilai kritis MacKinnon.

2.3 Standardisasi Data

Standarisasi data merupakan proses mengubah nilai-nilai dalam suatu kumpulan data ke dalam skala yang seragam sehingga setiap variabel dapat dibandingkan secara lebih objektif. Tujuan utama standardisasi adalah mempermudah interpretasi dan analisis statistik, terutama ketika variabel memiliki satuan atau rentang nilai yang berbeda. Salah satu metode yang umum digunakan

adalah *z-score*. Metode ini mengukur posisi suatu observasi terhadap rata-rata data dalam satuan simpangan baku. Dengan mengubah data ke dalam bentuk *z-score*, setiap variabel akan memiliki skala yang sama sehingga memudahkan proses analisis, interpretasi, serta perbandingan antarvariabel. Rumus standardisasi menggunakan metode *z-score* ditunjukkan sebagai berikut:

$$X_i^* = \frac{X_i - \bar{X}}{\sigma} \quad (2.7)$$

dengan:

X_i^* : Nilai data ke- i setelah standardisasi, $i = 1, 2, \dots, n$

X_i : Nilai data asli ke- i

$\bar{X}$: Rata-rata seluruh data

σ : Simpangan baku seluruh data.

2.4 Model *Time Series* Stasioner

2.4.1 Model *Autoregressive*

Model *Autoregressive* (AR) merupakan salah satu komponen utama dalam analisis deret waktu, di mana nilai pengamatan saat ini dipengaruhi oleh nilai-nilai pengamatan pada periode sebelumnya Makridakis dkk. (1999). Secara umum, model AR orde- p dapat dinyatakan dalam bentuk (Aswi dan Sukarna, 2006):

$$\dot{Z}_t = Z_t - \mu$$

dengan

Z_t : Nilai pengamatan pada waktu ke- t

μ : Rata-rata proses

$\dot{Z}_t$: Deviasi nilai pengamatan terhadap rata-rata

$$\phi_p(B)\dot{Z}_t = e_t \quad (2.8)$$

Atau

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + e_t \quad (2.9)$$

karena $\dot{Z}_t = Z_t - \mu$ dan $\mu = \phi_0$ maka persamaan 2.8 dapat ditulis dalam bentuk sebagai berikut:

$$\begin{aligned} \dot{Z}_t &= \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + e_t \\ Z_t - \mu &= \phi_1 (Z_{t-1} - \mu) + \phi_2 (Z_{t-2} - \mu) + \dots + \phi_p (Z_{t-p} - \mu) + e_t \\ &= \phi_1 Z_{t-1} - \phi_1 \mu + \phi_2 Z_{t-2} - \phi_2 \mu + \dots + \phi_p Z_{t-p} - \phi_p \mu + e_t \\ Z_t &= \mu - \phi_1 \mu - \phi_2 \mu - \dots - \phi_p \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + e_t \\ &= \mu(1 - \phi_1 - \phi_2 - \dots - \phi_p) + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + e_t \\ &= \mu(1 - (\phi_1 + \phi_2 + \dots + \phi_p)) + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + e_t \\ &= \phi_0 + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + e_t \end{aligned} \quad (2.10)$$

dimana

Z_t : Nilai pengamatan pada waktu ke- t

e_t : Suatu proses *white noise* atau galat pada waktu ke- t

ϕ_0 : Konstanta rata-rata

ϕ_i : Koefisien AR ke- i , $i=1,2,3,\dots,p$

p : Orde koefisien AR

2.4.2 Model *Moving Average*

Metode *Moving Average* (MA), atau dalam bahasa Indonesia dikenal sebagai metode rata-rata bergerak, merupakan pendekatan statistik yang digunakan untuk melakukan peramalan berdasarkan nilai rata-rata dari data aktual pada periode sebelumnya. Teknik ini bertujuan untuk mengidentifikasi pola dalam deret waktu dan mereduksi fluktuasi acak, sehingga dapat memberikan estimasi yang lebih stabil terhadap nilai masa depan.

Menurut Aswi dan Sukarna (2006), bentuk umum dari model MA non-musiman dengan orde- q , yang dilambangkan sebagai MA(q), dapat dinyatakan dalam bentuk:

$$\dot{Z}_t = \theta_q(B)e_t \quad (2.11)$$

atau secara eksplisit:

$$Z_t = \theta_0 + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \cdots + \theta_q e_{t-q} + e_t \quad (2.12)$$

Dengan asumsi bahwa $\dot{Z}_t = Z_t - \mu$ dan $\mu = \theta_0$ maka persamaan tersebut dapat dituliskan kembali sebagai:

$$\begin{aligned} Z_t - \mu &= e_t - \theta_1 e_{t-1} - \cdots - \theta_q e_{t-q} \\ Z_t &= \theta_0 + e_t - \theta_1 e_{t-1} - \cdots - \theta_q e_{t-q} \end{aligned} \quad (2.13)$$

Adapun komponen-komponen dalam model tersebut dijelaskan sebagai berikut:

Z_t : Nilai pengamatan pada waktu ke- t

Z_t : Komponen *white noise* atau galat acak pada waktu ke- t

θ_0 : Konstanta rata-rata dari proses

θ_i : Koefisien MA untuk lag ke- i , dengan $i = 1, 2, \dots, q$

q : Orde dari model MA, menunjukkan jumlah lag yang digunakan

B : Operator *backshift*

2.4.3 Model *Autoregressive Moving Average*

Model *Autoregressive Moving Average* (ARMA) merupakan hasil integrasi antara dua pendekatan dalam analisis deret waktu, yaitu model *Autoregressive* (AR) dan model *Moving Average* (MA). Penggabungan kedua metode ini bertujuan untuk memperoleh hasil peramalan yang lebih akurat dengan tingkat

kesalahan (*error*) yang lebih rendah dibandingkan jika masing-masing digunakan secara terpisah.

Menurut Aswi dan Sukarna (2006), bentuk umum dari model ARMA non-musiman dengan orde p untuk komponen AR dan orde q untuk komponen MA, yang dilambangkan sebagai ARMA(p,q), dapat dinyatakan dalam bentuk operator backshift sebagai berikut:

$$\phi_p(B)\dot{Z}_t = \theta_q(B)e_t \quad (2.14)$$

Atau secara eksplisit

$$\dot{Z}_t = \phi_1\dot{Z}_{t-1} + \dots + \phi_p\dot{Z}_{t-p} + e_t - \theta_1e_{t-1} - \dots - \theta_qe_{t-q} \quad (2.15)$$

Dengan asumsi bahwa $\dot{Z}_t = Z_t - \mu$ maka persamaan tersebut dapat dituliskan kembali sebagai:

$$\begin{aligned} \dot{Z}_t &= \phi_1\dot{Z}_{t-1} + \dots + \phi_p\dot{Z}_{t-p} + e_t - \theta_1e_{t-1} - \dots - \theta_qe_{t-q} \\ Z_t - \mu &= \phi_1(Z_{t-1} - \mu) + \dots + \phi_p(Z_{t-p} - \mu) + e_t - \theta_1e_{t-1} - \dots - \theta_qe_{t-q} \\ &= \phi_1Z_{t-1} - \phi_1\mu + \dots + \phi_pZ_{t-p} - \phi_p\mu + e_t - \theta_1e_{t-1} - \dots - \theta_qe_{t-q} \\ Z_t &= \mu - \phi_1\mu - \phi_p\mu + \phi_1Z_{t-1} + \dots + \phi_pZ_{t-p} + e_t - \theta_1e_{t-1} - \dots - \theta_qe_{t-q} \\ &= \mu(1 - \phi_1 - \dots - \phi_p) + \phi_1Z_{t-1} + \dots + \phi_pZ_{t-p} + e_t \\ &\quad - \theta_1e_{t-1} - \dots - \theta_qe_{t-q} \end{aligned} \quad (2.16)$$

dengan memisalkan $\mu(1 - \phi_1 - \dots - \phi_p) = \phi_0$, maka

$$Z_t = \phi_0 + \phi_1Z_{t-1} + \dots + \phi_pZ_{t-p} + e_t - \theta_1e_{t-1} - \dots - \theta_qe_{t-q} \quad (2.17)$$

2.5 Model *Time Series* Nonstasioner

2.5.1 Model *Autoregressive Integrated Moving Average*

Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan pengembangan dari model ARMA (p,q) yang dilengkapi dengan proses

pembedaan (*differencing*) sebanyak d kali untuk mengatasi masalah ketidakstasioneran dalam data deret waktu. Pembedaan ini bertujuan untuk menghilangkan tren atau pola musiman sehingga data menjadi stasioner sebelum dimodelkan lebih lanjut. Menurut Wei (2006), setelah proses pembedaan diterapkan, model ARIMA(p, d, q) dapat dinyatakan dalam bentuk operator *backshift* sebagai berikut:

$$\phi_p(B)(1 - B)^d Z_t = \theta_q(B)e_t \quad (2.18)$$

Persamaan tersebut dapat disederhanakan menjadi:

$$Z_t = \phi_0 + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (2.19)$$

2.5.2 Model Seasonal Autoregressive Integrated Moving Average

Model *Seasonal Autoregressive Integrated Moving Average* (SARIMA) merupakan bentuk perluasan dari model ARIMA yang secara khusus dirancang untuk menangani data deret waktu yang menunjukkan pola musiman. SARIMA menggabungkan komponen non-musiman dan musiman dalam satu kerangka model, sehingga mampu menangkap dinamika jangka pendek, tren, serta fluktuasi musiman secara simultan. Model SARIMA dinotasikan $SARIMA(p, d, q)(P, D, Q)s$ yang merupakan bentuk perluasan dari model ARIMA dengan penjelasan sebagai berikut (Cryer, 2008):

di mana:

- p : Orde dari proses *autoregressive* non-musiman (AR)
- d : Jumlah pembedaan non-musiman (I) yang diperlukan agar deret menjadi stasioner
- q : Orde dari proses *moving average* non-musiman (MA)
- P : Orde dari proses *autoregressive* musiman (SAR)

D : Jumlah pembedaan musiman (I_s) untuk mencapai kestasioneran musiman

Q : Orde dari proses *moving average* musiman (SMA)

s : Panjang siklus musiman (misalnya, $s=12$ untuk data bulanan)

Selanjutnya persamaan SARIMA $(p,d,q)(P,D,Q)_s$ secara umum dapat ditulis sebagai berikut:

$$\Phi_P(B^S) \phi_p(B) (1 - B)^d (1 - B^S)^D Z_t = \Theta_Q(B^S) \theta_q(B) e_t \quad (2.20)$$

dengan:

$$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$$

$$\Phi_P(B^S) = 1 - \Phi_1 B^S - \dots - \Phi_P B^{PS}$$

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$$

$$\Theta_Q(B^S) = 1 - \Theta_1 B^S - \dots - \Theta_Q B^{QS}$$

2.5.3 Model *Seasonal Autoregressive Integrated Moving Average with Exogenous Variable*

Model SARIMAX (*Seasonal Autoregressive Integrated Moving Average with Exogenous variables*) merupakan pengembangan dari model ARIMA dan SARIMA yang digunakan dalam analisis deret waktu. ARIMA sendiri hanya mengandalkan data masa lalu dari variabel target untuk melakukan peramalan, sementara SARIMA menambahkan komponen musiman untuk menangani pola berulang dalam periode tertentu. SARIMAX melangkah lebih jauh dengan mengintegrasikan variabel eksogen yaitu variabel luar yang secara teoritis atau empiris memiliki pengaruh terhadap variabel utama yang dianalisis. SARIMAX memungkinkan kita untuk memodelkan hubungan antara variabel target dengan satu atau lebih variabel eksternal, seperti suhu, curah hujan, inflasi, atau kebijakan

pemerintah, yang dapat memengaruhi perilaku deret waktu. Dengan demikian, SARIMAX menjadi alat yang lebih fleksibel dan akurat dalam peramalan, terutama ketika fenomena yang dianalisis dipengaruhi oleh faktor-faktor luar (Wei, 2006). Model SARIMAX dapat dituliskan sebagai:

$$(p, d, q)(P, D, Q)_s + X_t \quad (2.21)$$

di mana:

p, d, q : Parameter ARIMA non-musiman

P, D, Q : Parameter musiman

s : Periode musiman

X_t : Variabel eksogen pada waktu t

Secara umum, model SARIMAX dapat dinyatakan sebagai model regresi linier berganda dengan *error* runtun waktu, yaitu:

$$Z_t = \beta_0 + \beta_1 X_{1,t} + \beta_2 X_{2,t} + \dots + \beta_m X_{m,t} + \omega_t \quad (2.22)$$

di mana

Z_t : Variabel dependen,

$X_{n,t}$: Variabel eksogen ke- n pada saat t dengan $m=1,2,3,\dots,n$

ω_t : Residual pada waktu ke- t dari proses runtun waktu

β_0 : Konstanta model

β_i : Koefisien regresi variabel eksogen ke- i

Deret residual ω_t mengikuti proses SARIMA, sehingga dapat dinyatakan sebagai (Wei, 2006):

$$\omega_t = \frac{\theta_q(B) \theta_Q(B^s)}{\phi_p(B) \Phi_P(B^s) (1-B)^d (1-B^s)^D} e_t \quad (2.23)$$

Dengan mensubstitusikan Persamaan (2.23) ke dalam Persamaan (2.22), diperoleh bentuk umum model SARIMAX sebagai berikut:

$$Z_t = \beta_0 + \beta_1 X_{1,t} + \beta_2 X_{2,t} + \dots + \beta_m X_{m,t} + \frac{\theta_q(B) \theta_Q(B^S)}{\phi_p(B) \Phi_P(B^S) (1-B)^d (1-B^S)^D} e_t \quad (2.24)$$

$\phi_p(B)$: Komponen *autoregressive* orde-p

$\Phi_P(B^S)$: Komponen *autoregressive* musiman orde-P

$\theta_q(B)$: Komponen *moving average* orde-q

$\theta_Q(B^S)$: Komponen *moving average* musiman orde-Q

$(1-B)^d$: *Differencing* non-musiman orde-d

$(1-B^S)^D$: *Differencing* musiman orde-D

e_t : *Residual error* pada waktu ke-t

Persamaan di atas merupakan bentuk umum model SARIMAX yang mengombinasikan komponen musiman dan non-musiman pada deret waktu, dengan memasukkan pengaruh variabel eksogen (X_t) terhadap variabel dependen (Z_t). Model ini tidak hanya memanfaatkan pola historis yang terdapat pada data, tetapi juga mempertimbangkan pengaruh faktor eksternal yang relevan, sehingga mampu menjelaskan variasi data secara lebih komprehensif dan meningkatkan akurasi hasil peramalan.

2.6 Identifikasi Model

2.6.1 Autocorrelation Function

Autocorrelation Function (ACF) merupakan alat analisis statistik yang digunakan untuk mengukur tingkat hubungan antar nilai dalam deret waktu yang dipisahkan oleh lag tertentu. ACF sangat penting dalam identifikasi pola dan

struktur dari data deret waktu, terutama dalam proses stasioner, yaitu data yang memiliki karakteristik statistik konstan sepanjang waktu.

Menurut Wei (2006), ACF adalah representasi grafis dari koefisien autokorelasi pada berbagai lag, yang dihitung dari data deret waktu stasioner Z_t . Dalam proses stasioner, nilai ekspektasi dari data adalah konstan, yaitu: $E(Z_t) = \mu$ dan variansinya $Var(Z_t) = E(Z_t - \mu)^2 = \sigma^2 = y_0$. Selain itu, kovarians antara dua titik waktu Z_t dan Z_s hanya bergantung pada selisih waktu antara keduanya, yaitu $|t - s|$, bukan pada waktu absolutnya. Oleh karena itu, kovarians dan korelasi antara Z_t dan Z_{t-k} dapat dinyatakan sebagai fungsi dari lag k . Secara matematis, fungsi autokorelasi pada lag ke- k dirumuskan sebagai:

$$\rho_k = \frac{y_k}{y_0} \quad (2.25)$$

di mana:

y_k : Kovarians antara Z_t dan Z_{t-k}

y_0 : Variansi dari Z_t

ρ_k : Koefisien autokorelasi pada lag ke- k

Dalam analisis deret waktu, fungsi autokovarian (y_k) dan fungsi autokorelasi (ρ_k) merupakan ukuran statistik yang digunakan untuk menilai tingkat keterkaitan antara nilai pengamatan saat ini (Z_t) dan nilai pengamatan pada periode sebelumnya (Z_{t-k}), yang dipisahkan oleh lag k . Kedua fungsi ini membantu dalam memahami struktur internal dari proses stasioner dalam deret waktu.

Karena fungsi autokorelasi populasi tidak dapat dihitung secara langsung, maka dilakukan pendekatan melalui estimasi koefisien autokorelasi sampel, yang dinotasikan sebagai r_k . Koefisien ini dihitung berdasarkan data observasi dan

digunakan untuk mengidentifikasi pola serta menentukan orde dari komponen *Moving Average* (MA) dalam model SARIMA. Rumus estimasi koefisien autokorelasi pada lag ke- k adalah sebagai berikut (Aswi & Sukarna, 2006):

$$r_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t-k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (2.26)$$

dimana

r_k : Koefisien autokorelasi pada lag ke- k

Z : Rata-rata dari deret waktu

n : Jumlah observasi

Untuk menilai signifikansi dari koefisien autokorelasi tersebut, digunakan taksiran kesalahan baku (*standard error*) yang dirumuskan sebagai:

$$S_{r_k} = \sqrt{\frac{1 + 2 \sum_{j=1}^{k-1} r_j^2}{n}} \quad (2.27)$$

dimana

S_{r_k} : Standard error dari r_k

r_j : Koefisien autokorelasi pada lag ke- j

k : Lag yang diuji

n : Jumlah observasi

Selanjutnya, untuk menguji apakah r_k berbeda secara signifikan dari nol, digunakan statistik uji-t sebagai berikut:

$$t_{r_k} = \frac{r_k}{S_{r_k}} \quad (2.28)$$

Nilai t_{r_k} ini dibandingkan dengan nilai kritis distribusi t pada tingkat signifikansi tertentu. Jika nilai uji menunjukkan signifikansi, maka koefisien autokorelasi

dianggap berbeda dari nol, dan informasi ini digunakan untuk menentukan struktur dan orde dari model MA dalam pemodelan SARIMA.

Menurut Aswi dan Sukarna (2006), pola yang ditampilkan dalam diagram ACF dapat memberikan indikasi awal mengenai apakah data bersifat stasioner dalam rata-rata. Jika nilai autokorelasi menurun secara perlahan atau menunjukkan penurunan yang menyerupai garis linear, maka hal tersebut mengindikasikan bahwa data belum stasioner dalam rata-rata. Sebaliknya, jika nilai autokorelasi menurun secara cepat dan mendekati nol dalam beberapa lag awal, maka data cenderung stasioner.

2.6.2 *Partial Autocorrelation Function*

Fungsi autokorelasi parsial atau *Partial Autocorrelation Function* (PACF) merupakan suatu ukuran statistik yang menggambarkan besarnya hubungan antara nilai pengamatan pada waktu ke- t (Z_t) dengan nilai pengamatan pada waktu ke- $t - k$ (Z_{t-k}), dengan mengeliminasi pengaruh dari nilai-nilai pengamatan yang berada di antara keduanya, yaitu $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$. PACF digunakan untuk mengidentifikasi struktur internal dari proses stasioner dalam deret waktu, khususnya dalam menentukan orde komponen *Autoregressive* (AR) pada model SARIMA (Aswi dan Sukarna, 2006). Nilai PACF pada lag ke- k , yang dinotasikan sebagai ϕ_{kk} , secara matematis didefinisikan sebagai berikut:

$$\phi_{kk} = \text{corr}(Z_t, Z_{t-k} | Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}) \quad (2.29)$$

Untuk memperoleh nilai ϕ_{kk} , digunakan sistem persamaan Yule-Walker yang menyatakan hubungan antara koefisien autokorelasi penuh (ρ_k) dan koefisien autokorelasi parsial (ϕ_{kj}). Sistem ini dapat dituliskan sebagai:

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k}, \text{ untuk } j = 1, 2, \dots, k \quad (2.30)$$

Persamaan tersebut dapat disusun dalam bentuk matriks dan diselesaikan menggunakan metode Cramer, berturut-turut untuk $k=1,2,\dots,m$ diperoleh (Wei, 2006):

$$\begin{aligned}
 \phi_{11} &= \rho_1 \\
 \phi_{22} &= \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} \\
 \phi_{33} &= \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}} \\
 &\vdots \\
 \phi_{kk} &= \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_k \end{vmatrix}} \quad (2.31)
 \end{aligned}$$

Persamaan yang lebih efisien untuk menyelesaikan persamaan Yule-Walker, nilai ϕ_{kk} dapat dihitung secara rekursif menggunakan rumus Durbin-Levinson sebagai berikut:

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j} \quad (2.32)$$

dalam praktiknya, karena nilai ρ_k tidak dapat diperoleh secara langsung dari populasi, maka digunakan estimasi dari data sampel berupa koefisien autokorelasi sampel (r_k) sebagai pendekatan terhadap ρ_k .

2.6.3 Pemilihan Model Awal

Menurut Wei (2006), pola pada *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) merupakan pedoman utama dalam mengidentifikasi ordo model ARIMA maupun SARIMA. Pola-pola berikut digunakan untuk menentukan keberadaan komponen AR, MA, maupun komponen musiman.

1. Jika ACF terputus (*cut off*) pada lag tertentu dan PACF menurun secara perlahan (*dies down*), maka model yang sesuai adalah komponen *moving average* non-musiman MA(q), dengan q ditentukan dari lag tempat ACF terputus.
2. Jika ACF terputus pada lag musiman, sedangkan PACF menurun secara perlahan, maka pola tersebut menunjukkan keberadaan komponen *moving average* musiman SMA(Q), dengan Q merupakan lag musiman tempat ACF terputus.
3. Jika ACF terputus pada lag musiman dan PACF terputus pada lag non-musiman, maka model dapat mengandung kombinasi komponen MA musiman dan AR non-musiman. Nilai q (non-musiman) dan Q (musiman) ditentukan berdasarkan lag tempat ACF dan PACF terputus.
4. Jika PACF terputus pada lag tertentu dan ACF menurun secara perlahan, maka model yang tepat adalah komponen *autoregressive* non-musiman AR(p), dengan p diambil dari lag PACF yang terputus.
5. Jika PACF terputus pada lag musiman, sementara ACF menurun secara perlahan, maka pola tersebut menunjukkan keberadaan komponen *autoregressive* musiman SAR(P), dengan P merupakan lag musiman tempat PACF terputus.

6. Jika PACF terputus pada lag musiman dan ACF terputus pada lag non-musiman, maka model dapat melibatkan kombinasi AR musiman dan MA non-musiman. Nilai p dan P ditentukan berdasarkan pola *cut off* pada PACF dan ACF.
7. Jika ACF dan PACF sama-sama menurun secara perlahan tanpa menunjukkan pola *cut off*, maka data cenderung mengikuti model campuran ARMA untuk komponen non-musiman atau model SARMA untuk komponen musiman.

2.6.4 Pemilihan Model Terbaik

Pemilihan model terbaik pada analisis deret waktu dapat dilakukan dengan menggunakan *Akaike Information Criterion* (AIC). AIC merupakan ukuran yang digunakan untuk menilai kualitas suatu model statistik berdasarkan keseimbangan antara tingkat kesesuaian model (*goodness of fit*) dan kompleksitas model. Konsep ini diperkenalkan oleh Akaike (1974), yang menyatakan bahwa suatu model tidak hanya harus mampu menyesuaikan diri dengan data, tetapi juga harus memiliki struktur yang sederhana agar tidak terjadi *overfitting*.

Secara matematis, AIC dirumuskan sebagai:

$$AIC = -2\ln(\hat{L}) + 2k \quad (2.33)$$

dengan $\hat{L}$ merupakan nilai *maximum likelihood* dari model, dan k adalah jumlah parameter yang diestimasi. Rumus tersebut menunjukkan bahwa AIC memberikan penalti terhadap model yang memiliki parameter terlalu banyak sehingga model yang kompleks tidak selalu dianggap lebih baik.

2.7 Uji Signifikansi

Uji signifikansi parameter digunakan untuk menentukan apakah suatu parameter dalam model layak dipertahankan atau tidak. Secara umum, misalkan θ adalah suatu parameter dalam model, $\hat{\theta}$ merupakan nilai estimasinya, dan $SE(\hat{\theta})$ adalah *standard error* dari estimasi tersebut.

$$t - \text{hitung} = \frac{\hat{\theta}}{SE(\hat{\theta})} \quad (2.34)$$

dengan hipotesa sebagai berikut:

$$H_0 : \hat{\theta} = 0 \text{ (Parameter tidak signifikan)}$$

$$H_1 : \hat{\theta} \neq 0 \text{ (Parameter signifikan)}$$

Suatu model dapat digunakan untuk tujuan peramalan apabila parameter-parameter yang menyusunnya signifikan. Parameter dikatakan signifikan apabila tolak H_0 yang mana apabila nilai $p - \text{value} < \alpha = 0,05$ atau nilai $|t - \text{hitung}| > t - \text{tabel}$.

2.8 Residual *White Noise*

Residual *white noise* merupakan deret waktu acak yang digunakan untuk menguji apakah residual dari suatu model memenuhi asumsi stasioneritas dan tidak memiliki pola sistematis yang tersisa. Menurut Wei (2006), Residual white noise adalah residual yang tidak memiliki autokorelasi signifikan, memiliki rata-rata mendekati nol, dan variansi relatif konstan. Normalitas dapat diuji sebagai asumsi tambahan. *White noise* menjadi indikator bahwa model telah menangkap seluruh pola dalam data, sehingga sisa galat (residual) bersifat acak dan tidak dapat diprediksi lebih lanjut.

Untuk menguji apakah residual memenuhi asumsi *white noise*, digunakan uji Ljung-Box, yang merupakan pengembangan dari uji Box-Pierce dengan koreksi terhadap ukuran sampel kecil. Menurut Makridakis dkk. (1999) uji Ljung-Box lebih akurat dalam praktik karena mempertimbangkan jumlah observasi dan jumlah lag yang diuji, sehingga dapat menilai apakah residual dari model deret waktu memenuhi asumsi *white noise* secara lebih andal

Hipotesis:

H_0 : Residual merupakan *white noise* (tidak ada autokorelasi signifikan)

H_1 : Residual bukan *white noise* (terdapat autokorelasi signifikan)

Statistik Uji:

$$Q = n(n+2) \sum_{k=1}^m \frac{\rho_k^2}{n-k} \quad (2.35)$$

dengan:

Q : Nilai statistik Ljung-Box

n : Jumlah observasi

ρ_k : Nilai autokorelasi pada lag ke- k

m : Jumlah lag maksimum yang diuji

Keputusan uji pada taraf signifikansi sebesar $\alpha = 0,05$ ditentukan dengan dua pendekatan. hipotesis nol (H_0) ditolak jika jika $p - value < \alpha$ atau jika $Q > \chi_{\alpha,df}^2$ dan hipotesis nol (H_0) diterima jika $p - value \geq \alpha$ atau jika $Q \leq \chi_{\alpha,df}^2$.

2.9 Metode Maximum Likelihood Estimation

Maximum Likelihood Estimation (MLE) merupakan salah satu metode yang umum digunakan untuk mengestimasi parameter model deret waktu, termasuk model SARIMA dan SARIMAX. Metode ini bekerja dengan menentukan nilai

parameter yang memaksimumkan fungsi likelihood berdasarkan data yang diamati (Box dkk., 2015). Misalkan terdapat deret waktu $(Z_1, Z_2, \dots, Z_n)$ yang mengikuti model SARIMA atau SARIMAX dengan parameter (θ) . Fungsi likelihood dapat dinyatakan sebagai:

$$L(\theta) = f(Z_1, Z_2, \dots, Z_n; \theta) \quad (2.36)$$

$f(Z_1, Z_2, \dots, Z_n; \theta)$ adalah fungsi densitas peluang bersama (*joint probability density function*) atau fungsi massa peluang bersama (*joint probability mass function*) dari seluruh data pengamatan $Z_1, Z_2, \dots, Z_n$ yang dinyatakan sebagai fungsi dari parameter model θ . Untuk mempermudah proses optimisasi, fungsi likelihood ditransformasikan ke dalam bentuk log-likelihood:

$$l(\theta) = \ln L(\theta) \quad (2.37)$$

Nilai parameter yang diestimasi diperoleh dengan memaksimumkan fungsi log-likelihood tersebut, yaitu:

$$\hat{\theta} = \arg \max_{\theta} l(\theta) \quad (2.38)$$

Pada penelitian ini, estimasi parameter model SARIMA dan SARIMAX dilakukan menggunakan metode *Maximum Likelihood Estimation* (MLE) yang tersedia pada perangkat lunak statistik. Parameter model dipilih berdasarkan nilai estimasi yang signifikan secara statistik dan memenuhi asumsi residual yang telah ditetapkan.

dengan:

θ : Vektor parameter model yang diestimasi

$L(\theta)$: Fungsi likelihood

$l(\theta)$: Fungsi log-likelihood

$\hat{\theta}$: Estimator parameter model

- Z_t : Nilai pengamatan pada waktu ke- t
 n : Banyaknya pengamatan
 f : Fungsi kepadatan peluang yang bergantung pada parameter θ
 $\arg \max_{\theta}$: Nilai parameter θ yang memaksimumkan fungsi log-likelihood

2.10 Kelayakan Model

Terdapat berbagai ukuran statistik yang digunakan untuk mengevaluasi kinerja suatu model, salah satunya yaitu *Mean Absolute Percentage Error* (MAPE). MAPE digunakan untuk mengukur tingkat akurasi hasil peramalan yang dinyatakan dalam rata-rata persentase absolut dari residual. Semakin kecil nilai MAPE yang diperoleh, maka semakin baik model dalam melakukan peramalan sehingga model tersebut layak digunakan untuk *forecasting* (Sungkawa & Megasari, 2023). rumus MAPE menurut Makridakis dkk. (1999),

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \times 100 \quad (2.39)$$

diketahui, n adalah banyaknya ramalan yang dilakukan, Z_t adalah data sebenarnya, dan $\hat{Z}_t$ adalah data hasil peramalan. Kriteria nilai MAPE sebagai berikut:

Tabel 2.2 Kriteria Nilai MAPE

Nilai MAPE	Keterangan
<10%	Ketepatan peramalan sangat baik
$10\% \leq x < 20\%$	Ketepatan peramalan baik
$20\% \leq x < 50\%$	Ketepatan peramalan cukup baik
$\geq 50\%$	Ketepatan peramalan buruk

2.11 Produksi Padi

Produksi merupakan kegiatan ekonomi yang bertujuan untuk menciptakan barang atau jasa guna memenuhi kebutuhan manusia. Dalam sektor pertanian, produksi menjadi inti dari aktivitas usaha tani, termasuk bagi petani padi yang

sangat bergantung pada hasil panen untuk keberlangsungan hidup dan ekonomi keluarga. Petani berharap hasil panen yang tinggi agar dapat memenuhi kebutuhan konsumsi dan mendukung keberlanjutan usaha, namun dalam praktiknya, tidak semua musim tanam memberikan hasil optimal. Banyak kendala yang menjadi hambatan, seperti perubahan pola iklim, terutama curah hujan yang tidak menentu dan suhu ekstrem serta meningkatnya intensitas hama dan penyakit, yang bersama-sama dapat menurunkan produktivitas padi secara signifikan (Wang dkk., 2021).

Indonesia dikenal sebagai negara agraris yang memiliki potensi besar dalam pengembangan tanaman padi. Sebagai komoditas pangan utama, padi memiliki peran penting dalam memenuhi kebutuhan konsumsi nasional sekaligus menjadi sumber pendapatan utama bagi sebagian besar petani. Keunggulan produksi padi di Indonesia didukung oleh kondisi agroklimat tropis yang umumnya sesuai, meliputi suhu yang relatif stabil, kelembaban udara yang tinggi, serta intensitas penyinaran matahari yang memadai untuk menunjang pertumbuhan tanaman padi. Namun demikian, stabilitas produktivitas padi tetap bergantung pada variabilitas iklim, di mana perubahan pola suhu dan curah hujan dapat memengaruhi performa pertumbuhan dan hasil panen secara signifikan (Ansari dkk., 2023).

Meskipun demikian, tantangan seperti perubahan iklim, keterbatasan lahan, dan fluktuasi harga tetap menjadi hambatan dalam mencapai hasil produksi yang stabil dan optimal. Oleh karena itu, diperlukan strategi yang adaptif dan berbasis data untuk meningkatkan produktivitas padi secara berkelanjutan.

2.12 Luas Panen

Luas panen merupakan salah satu komponen utama dalam sistem produksi pertanian karena menentukan kapasitas produksi dan potensi hasil panen yang dapat

dicapai. Semakin besar lahan yang dikelola, semakin besar pula jumlah komoditas pertanian yang dapat dihasilkan, dengan asumsi ketersediaan input produksi lain seperti benih, pupuk, tenaga kerja, dan teknologi berada pada tingkat yang memadai. Hubungan ini menggambarkan bahwa luas panen tidak hanya berfungsi sebagai ruang produksi, tetapi juga sebagai salah satu faktor penentu efisiensi usaha tani, khususnya pada komoditas yang memerlukan ruang tanam seperti padi.

Penelitian terbaru menunjukkan bahwa luas panen memiliki pengaruh signifikan terhadap peningkatan produksi padi di berbagai wilayah sentra pertanian Indonesia. Studi kuantitatif yang dilakukan Semiwati (2025) menemukan bahwa luas panen merupakan faktor yang secara konsisten berkontribusi positif terhadap peningkatan *output* usaha tani padi. Artinya, semakin luas panen sawah yang dimiliki petani, semakin tinggi potensi produksi yang dapat dicapai, sehingga berdampak langsung pada peningkatan pendapatan petani.

Temuan tersebut sejalan dengan studi lainnya yang menegaskan bahwa luas lahan menjadi variabel penentu skala ekonomi dalam usaha tani padi. Pengelolaan lahan dengan skala yang lebih besar memungkinkan penerapan teknologi produksi, penggunaan tenaga kerja yang lebih efisien, serta peningkatan kapasitas panen, sehingga hasil produksi menjadi lebih tinggi dibandingkan usaha tani berskala kecil (Dewi & Meydianawathi, 2025). Dengan demikian, luas panen berperan penting dalam menentukan tingkat produktivitas dan keberlanjutan pendapatan petani, terutama dalam sistem pertanian berbasis lahan seperti budidaya padi.

2.13 Curah Hujan

Curah hujan merupakan unsur penting dalam siklus hidrologi yang berperan dalam menjaga keseimbangan iklim serta ketersediaan air di permukaan bumi.

Secara meteorologis, curah hujan didefinisikan sebagai jumlah air hujan yang jatuh pada suatu wilayah dalam periode waktu tertentu dan diukur menggunakan satuan milimeter (Prasetyo & Kadir, 2023). Variabilitas curah hujan di wilayah tropis seperti Indonesia dipengaruhi oleh dinamika atmosfer, termasuk suhu udara, kelembapan, dan tekanan udara, serta fenomena iklim global seperti *El Niño–Southern Oscillation* (ENSO). Faktor lokal seperti perubahan penggunaan lahan dan topografi juga memiliki peranan penting dalam menentukan distribusi spasial curah hujan; misalnya, daerah pegunungan cenderung memiliki intensitas hujan lebih tinggi karena proses pengangkatan orografis (Santoso dkk., 2022).

Klasifikasi intensitas curah hujan secara umum dibedakan ke dalam enam kategori, yaitu tidak hujan (0 mm), sangat ringan (1–5 mm), ringan (5–20 mm), sedang (20–50 mm), lebat (50–100 mm), dan sangat lebat (>100 mm). Sementara berdasarkan intensitas per jam, hujan ringan berada pada kisaran 1–5 mm/jam, sedang 5–10 mm/jam, lebat 10–20 mm/jam, dan sangat lebat melebihi 20 mm/jam (Aditya dkk., 2021).

Dalam bidang pertanian, curah hujan merupakan faktor ekologis yang sangat berpengaruh terhadap produktivitas tanaman pangan, khususnya padi yang sangat bergantung pada ketersediaan air selama siklus pertumbuhannya. Air hujan berperan penting mulai dari fase vegetatif hingga fase pengisian bulir. Sejumlah penelitian membuktikan adanya hubungan signifikan antara variabilitas curah hujan dan produksi padi. Santoso dkk. (2022) menunjukkan bahwa pola curah hujan yang sesuai kebutuhan fisiologis tanaman mampu meningkatkan produksi, sedangkan curah hujan berlebih maupun distribusi yang tidak merata dapat menyebabkan

genangan atau kekeringan yang berdampak pada penurunan hasil panen (Aditya dkk., 2021).

2.14 Suhu Udara

Suhu udara merupakan salah satu parameter utama dalam klimatologi yang berfungsi sebagai indikator tingkat energi termal di atmosfer. Secara ilmiah, suhu udara didefinisikan sebagai ukuran panas atau dinginnya udara yang ditentukan oleh energi kinetik rata-rata molekul gas di atmosfer. Makin tinggi energi kinetik molekul tersebut, makin tinggi pula nilai suhu yang terukur (*World Meteorological Organization*, 2023). Suhu udara umumnya dinyatakan dalam satuan derajat Celsius ($^{\circ}\text{C}$) atau Kelvin (K) dan diukur menggunakan instrumen meteorologi seperti termometer digital maupun sensor otomatis berbasis *Internet of Things* (IoT) pada sistem klimatologi modern.

Variasi suhu udara dipengaruhi oleh sejumlah faktor klimatologis dan geografis, antara lain radiasi matahari, ketinggian tempat, tutupan lahan, kondisi atmosfer, serta kedekatan wilayah dengan badan air. Radiasi matahari berfungsi sebagai sumber energi utama dalam sistem iklim sehingga wilayah dengan intensitas radiasi tinggi cenderung memiliki suhu udara lebih panas. Faktor topografi juga memiliki peran penting: wilayah pada elevasi tinggi menunjukkan suhu lebih rendah akibat menurunnya tekanan udara dan kemampuan atmosfer menahan panas. Selain itu, penggunaan lahan, seperti kawasan urban, area pertanian, dan hutan, menentukan kapasitas permukaan dalam menyerap dan melepaskan energi panas, yang kemudian membentuk pola suhu spesifik suatu wilayah (Ruminta dkk., 2024).

Dalam sektor pertanian, suhu udara memiliki peran penting dalam menentukan keberhasilan proses fisiologis tanaman, termasuk padi. Suhu memengaruhi fotosintesis, respirasi, pembungaan, dan pengisian biji. Studi empiris menunjukkan bahwa padi memiliki rentang optimal suhu antara 22°C hingga 30°C untuk pertumbuhan dan produksi. Suhu yang melampaui batas optimal, terutama pada fase pembungaan, dapat menyebabkan peningkatan sterilisasi spikelet, penurunan pengisian bulir, dan penurunan hasil panen. Penelitian terbaru menunjukkan bahwa kenaikan suhu rata-rata hingga +3°C dapat mempercepat pertumbuhan vegetatif namun berdampak negatif pada hasil akhir dengan menurunkan indeks kesehatan tanaman dan produktivitas (Oh dkk., 2023).

Selain faktor berdiri sendiri, suhu udara berinteraksi dengan komponen iklim lain seperti curah hujan, kelembapan udara, dan intensitas radiasi matahari dalam membentuk kondisi agroklimat suatu wilayah. Kombinasi suhu tinggi dan curah hujan rendah dapat menyebabkan cekaman kekeringan, sedangkan suhu tinggi dengan kelembapan udara tinggi dapat meningkatkan risiko penyakit tanaman, terutama pada tanaman padi di wilayah tropis yang rentan terhadap perubahan iklim (Purwaningrum dkk., 2025). Oleh karena itu, pemahaman mengenai dinamika suhu udara diperlukan dalam pengambilan keputusan pertanian berbasis iklim, terutama dalam menghadapi variabilitas iklim dan perubahan iklim global yang semakin meningkat.

2.15 Lamanya Penyinaran Matahari

Lama penyinaran matahari merupakan salah satu unsur iklim yang menggambarkan durasi ketika sinar matahari mencapai permukaan bumi tanpa terhalang oleh awan atau objek lainnya dalam periode tertentu. Nilainya umumnya

dinyatakan dalam satuan jam per hari dan diukur menggunakan instrumen seperti *sunshine recorder* atau sensor berbasis otomatis dalam jaringan stasiun meteorologi modern. Lama penyinaran matahari sangat dipengaruhi oleh posisi matahari, rotasi dan revolusi bumi, serta kondisi atmosfer termasuk tingkat tutupan awan (*World Meteorological Organization*, 2023).

Dalam ilmu klimatologi, lama penyinaran matahari menjadi indikator penting besarnya radiasi matahari yang diterima permukaan bumi karena terdapat hubungan positif antara durasi penyinaran dengan nilai radiasi global. Teknologi penginderaan jauh juga memungkinkan estimasi durasi penyinaran matahari dalam cakupan spasial yang lebih luas, terutama pada wilayah dengan keterbatasan stasiun cuaca. Dataset satelit seperti *Sunshine Duration Climate Data Record* telah digunakan untuk memetakan variasi penyinaran matahari secara harian maupun musiman di berbagai wilayah (Kothe dkk., 2024).

Dalam sektor pertanian, lama penyinaran matahari memiliki peran penting terhadap proses fisiologis tanaman, terutama dalam fotosintesis, pembentukan malai, serta pengisian bulir. Penelitian terbaru menunjukkan bahwa peningkatan durasi penyinaran berkontribusi pada meningkatnya indeks luas daun, efisiensi penyerapan energi cahaya, serta produktivitas tanaman pangan termasuk padi. Sebaliknya, rendahnya durasi penyinaran akibat tingginya tutupan awan, terutama pada musim hujan, dapat menurunkan efisiensi fotosintesis dan menyebabkan penurunan hasil panen (Song dkk., 2023). Dengan demikian, pemantauan durasi penyinaran matahari menjadi penting dalam manajemen agroklimat dan adaptasi pertanian terhadap variabilitas iklim.

2.16 Kelembaban Udara

Kelembapan udara merupakan salah satu unsur iklim utama yang menunjukkan jumlah uap air yang terkandung di atmosfer pada waktu dan lokasi tertentu. Secara meteorologis, kelembapan dapat dinyatakan dalam berbagai bentuk, seperti kelembapan spesifik, kelembapan absolut, tekanan uap air, dan kelembapan relatif. Di antara bentuk tersebut, kelembapan relatif paling umum digunakan karena menggambarkan perbandingan antara jumlah uap air yang ada dengan kapasitas maksimum udara pada suhu tertentu, yang dinyatakan dalam persen (%). Perubahan nilai kelembapan udara sangat dipengaruhi oleh suhu, ketersediaan sumber uap air, tekanan atmosfer, serta kondisi meteorologis seperti tutupan awan dan pola angin (*World Meteorological Organization*, 2023).

Secara fisik, terdapat hubungan langsung antara suhu udara dan kemampuan atmosfer menampung uap air, di mana peningkatan suhu akan meningkatkan kapasitas udara menyimpan kandungan uap. Oleh karena itu, wilayah bersuhu tinggi namun minim sumber uap air cenderung memiliki kelembapan relatif rendah, sedangkan wilayah bersuhu rendah dapat menunjukkan kelembapan relatif tinggi meskipun kandungan uap air absolutnya rendah. Faktor-faktor lingkungan seperti keberadaan badan air, tutupan vegetasi, dan tipe penggunaan lahan juga memengaruhi distribusi kelembapan udara secara spasial (Zhang dkk., 2024).

Dalam konteks pertanian, kelembapan udara berperan penting dalam mengatur proses fisiologis tanaman melalui mekanisme transpirasi, respirasi, dan laju fotosintesis. Pada tanaman padi, kelembapan udara yang stabil dalam kisaran optimal mendukung pertumbuhan vegetatif dan perkembangan malai, terutama pada fase pembungaan hingga pengisian bulir. Penelitian mutakhir menunjukkan

bahwa kelembapan terlalu tinggi dapat meningkatkan risiko penyakit tanaman akibat meningkatnya kelembapan permukaan daun, sementara kelembapan terlalu rendah dapat mempercepat transpirasi dan menyebabkan cekaman air yang dapat menurunkan hasil panen (Rahmawati dkk., 2023). Dengan demikian, keberadaan kelembapan udara sebagai variabel agroklimat menjadi penting dalam pengelolaan lingkungan produksi padi, terutama pada wilayah tropis yang memiliki variabilitas musim yang tinggi.

2.17 *Ocean Niño Indeks*

Ocean Niño Index (ONI) merupakan indikator utama yang digunakan untuk mengukur intensitas fenomena *El Niño–Southern Oscillation* (ENSO) melalui pemantauan anomali suhu permukaan laut (Sea Surface Temperature, SST) di wilayah Niño 3.4 (5° LU– 5° LS dan 120° – 170° BB). Nilai ONI dihitung berdasarkan rata-rata anomali SST dalam periode rolling tiga bulan dan dibandingkan dengan nilai normal klimatologis jangka panjang. Nilai ONI positif menunjukkan kondisi El Niño, sedangkan nilai negatif menunjukkan kondisi La Niña (NOAA, 2025).

Variasi ONI memiliki implikasi penting terhadap dinamika iklim global, termasuk sistem monsun di Indonesia. Penelitian Deshafa dkk. (2025) menunjukkan bahwa kondisi *El Niño* cenderung melemahkan sirkulasi Walker sehingga mengurangi pembentukan awan dan presipitasi di sebagian besar wilayah Indonesia. Sebaliknya, fase *La Niña* memperkuat suplai uap air dan meningkatkan curah hujan, terutama pada puncak musim hujan. Dampak variabilitas ini sangat signifikan pada sektor yang bergantung pada stabilitas iklim, seperti sumber daya

air, perikanan, serta pertanian, termasuk padi yang sensitif terhadap ketersediaan air dan pola musim tanam.

Dalam bidang pertanian padi, fluktuasi ONI berpengaruh langsung terhadap ketersediaan air irigasi, kelembapan tanah, serta stabilitas musim tanam. Penelitian Novita Dharma dkk. (2024) menunjukkan bahwa fase *El Niño* moderat hingga kuat berpotensi menyebabkan defisit air irigasi dan peningkatan frekuensi gagal panen di wilayah sentra produksi padi. Sebaliknya, fase *La Niña* dapat meningkatkan produktivitas, namun juga meningkatkan risiko banjir, genangan, dan penyakit tanaman.

Dengan demikian, ONI merupakan variabel osean-atmosfer penting yang tidak hanya menggambarkan dinamika ENSO secara global, tetapi juga memberikan dasar ilmiah bagi perencanaan mitigasi risiko iklim di sektor pertanian. Pemantauan ONI secara berkala dapat mendukung pengambilan keputusan berbasis iklim, terutama pada wilayah tropis maritim seperti Indonesia yang sangat sensitif terhadap variabilitas ENSO.

2.18 Kajian Integrasi Topik dengan Al-Qur'an dan Hadis

Dalam Al-Qur'an, Allah telah menyebutkan berbagai tanda kekuasaan-Nya melalui tumbuh-tumbuhan yang bermanfaat bagi manusia. Salah satunya terdapat dalam surah Abasa ayat 24–32, di mana Allah menegaskan bahwa Dialah yang menyediakan makanan bagi manusia melalui proses tumbuhnya tanaman, termasuk biji-bijian seperti padi. Allah berfirman pada surat Abasa ayat 24–32:

فَلْيَنْظُرِ الْإِنْسَانُ إِلَى طَعَامِهِ ۚ أَنَّا صَبَبْنَا الْمَاءَ صَبًّا ثُمَّ شَقَقْنَا الْأَرْضَ شَقَاقًا فَنُتَبِتُ فِيهَا حَبًّا وَنَعْبَأُ وَقْضِبًا وَزَيْتُونًا وَنَخْلًا وَحَدَاقٍ غُلْبًا وَفَاكِهَةً وَأَبًّا مَتَاعًا لَّكُمْ وَلِأَنْعَامِكُمْ

Artinya : “Maka hendaklah manusia memperhatikan makanannya. Sesungguhnya Kami yang mencurahkan air melimpah, kemudian Kami belah bumi dengan sebaik-baiknya, lalu Kami tumbuhkan biji-bijian, anggur dan sayur-

sayuran, zaitun dan kurma, kebun-kebun yang rindang, serta buah-buahan dan rerumputan—sebagai bahan makanan bagi kamu dan ternakmu.” (Q.S. Abasa: 24–32)

Ayat ini menjelaskan bahwa Allah telah menyediakan berbagai jenis tanaman yang berasal dari biji-bijian, termasuk padi yang menjadi sumber pokok makanan banyak bangsa, termasuk Indonesia. Padi, sebagaimana tanaman lain yang disebut dalam ayat tersebut, tumbuh melalui proses panjang yang seluruhnya berada dalam kekuasaan Allah, mulai dari turunnya hujan, terbukanya tanah, hingga tumbuhnya butiran-butiran kehidupan dari biji kecil yang sebelumnya tampak tak berdaya.

Dari ayat ini dapat dipahami bahwa padi merupakan salah satu bentuk karunia Allah yang sangat besar, karena dari biji yang sederhana, Allah menumbuhkan hasil yang menjadi makanan pokok bagi umat manusia. Hal ini menunjukkan bahwa padi bukan sekadar tanaman pertanian, tetapi juga bagian dari tanda kebesaran-Nya dan rezeki yang telah diatur untuk manusia dan hewan.

Dalil lain yang berkaitan dengan tumbuhnya tanaman dan nikmat pangan dijelaskan dalam QS. Al-Baqarah ayat 22 (Kemenag, 2022) yang berbunyi:

الَّذِي جَعَلَ لَكُمُ الْأَرْضَ فِرَاشًا وَالسَّمَاءَ بِنَاءً وَأَنْزَلَ مِنَ السَّمَاءِ مَاءً فَأَخْرَجَ بِهِ مِنَ الثَّمَرَاتِ رِزْقًا لَّكُمْ ۖ فَلَا تَجْعَلُوا لِلَّهِ أَندَادًا وَأَنْتُمْ تَعْلَمُونَ

Artinya: “Dialah yang menjadikan bumi sebagai hamparan bagimu dan langit sebagai atap, dan Dia menurunkan air dari langit, lalu dengan itu Dia mengeluarkan berbagai buah-buahan sebagai rezeki untukmu. Oleh karena itu, janganlah kamu mengadakan tandingan-tandingan bagi Allah, padahal kamu mengetahui.”. (Q.S. Al-Baqarah: 22)

Ayat ini menegaskan bahwa setiap hasil pertanian, termasuk padi, merupakan bagian dari rezeki yang Allah keluarkan dari bumi melalui air hujan. Maka manusia diperintahkan untuk mensyukuri setiap makanan yang Allah sediakan. Selain ayat Al-Qur'an, Rasulullah Saw juga menegaskan kemuliaan pekerjaan yang berkaitan dengan tanaman dan pertanian dalam sebuah hadis:

فَلَا يَغْرِسُ الْمُسْلِمُ غَرْسًا فَيَأْكُلُ مِنْهُ إِنْسَانٌ وَلَا دَابَّةٌ وَلَا طَيْرٌ إِلَّا كَانَ لَهُ صَدَقَةٌ إِلَى يَوْمِ الْقِيَامَةِ

Artinya “Tidaklah seorang muslim menanam tanaman atau menabur benih, lalu hasil dari tanaman itu dimakan oleh burung, manusia, atau hewan, kecuali menjadi sedekah baginya.” (H.R. Muslim, no. 1553a).

Hadis ini menjelaskan bahwa menanam padi adalah amal ibadah, karena padi memberikan manfaat luas bagi banyak makhluk hidup. Setiap butir padi yang dimakan orang lain menjadi amal sedekah bagi petaninya. Bahkan, ketika seorang petani telah meninggal, namun sawahnya masih menghasilkan dan memberi makan orang lain, pahala itu tetap mengalir sebagai amal jariyah.

Dengan demikian, padi adalah nikmat Allah yang menunjukkan kekuasaan-Nya dalam memberikan rezeki, serta menjadi jalan bagi manusia untuk mendapatkan pahala melalui usaha bercocok tanam. Padi bukan sekadar komoditas pertanian, tetapi bagian dari tanda-tanda kekuasaan Allah yang seharusnya disyukuri dan dikelola dengan bijaksana.

2.19 Kajian Integrasi Topik dengan Teori Pendukung

Sektor pertanian, khususnya subsektor tanaman pangan, memegang peran yang sangat penting dalam perekonomian Indonesia karena memberikan kontribusi terhadap PDB, menjaga ketahanan pangan nasional, serta menyediakan lapangan kerja bagi sebagian besar masyarakat pedesaan. Komoditas padi menjadi pusat perhatian karena merupakan sumber pangan pokok masyarakat, sehingga peningkatan produksinya menjadi prioritas utama dalam pembangunan pertanian. Untuk mencapai tujuan tersebut, diperlukan analisis mendalam mengenai faktor-faktor iklim seperti curah hujan, suhu udara, kelembapan, dan lama penyinaran matahari serta karakteristik lahan, karena variabilitas iklim terbukti berpengaruh signifikan terhadap hasil produksi padi. Oleh sebab itu, metode peramalan yang

tepat sangat dibutuhkan guna mengantisipasi perubahan kondisi iklim di masa depan.

Pada tahap awal analisis, dilakukan pengolahan statistik deskriptif dan visualisasi data deret waktu untuk mengamati pola musiman, kecenderungan jangka panjang, dan fluktuasi tahunan pada variabel produksi padi serta variabel eksogen terkait. Selanjutnya, dilakukan uji stasioneritas untuk memastikan kestabilan data deret waktu. Pengujian ini biasanya dilakukan menggunakan *Augmented Dickey-Fuller* (ADF). Apabila data tidak stasioner pada level, dilakukan *differencing* hingga mencapai kestasioneran. Data yang telah stasioner kemudian digunakan untuk proses identifikasi model menggunakan kriteria informasi seperti *Akaike Information Criterion* (AIC)

Untuk memodelkan hubungan antara variabel iklim dan produksi padi, penelitian ini menggunakan pendekatan SARIMAX, yaitu pengembangan dari SARIMA yang memasukkan variabel eksogen. Model SARIMAX memungkinkan variabel eksogen seperti curah hujan, suhu, kelembapan, dan lama penyinaran matahari dijadikan sebagai faktor yang memengaruhi hasil produksi padi, sehingga menghasilkan estimasi yang lebih akurat dibandingkan model deret waktu univariat.

Setelah model teridentifikasi, dilakukan pengujian stabilitas model serta estimasi parameter. Validasi model dilakukan melalui uji autokorelasi residual, misalnya menggunakan uji Ljung–Box. Model yang memenuhi asumsi kemudian digunakan untuk analisis lebih lanjut, seperti peramalan produksi padi dan interpretasi pengaruh variabel iklim.

Hasil model kemudian dianalisis menggunakan *Mean Absolute Percentage Error* (MAPE) untuk mengevaluasi tingkat akurasi peramalan dengan membandingkan nilai prediksi dan data *testing*. Setelah diperoleh model dengan nilai MAPE terbaik, model tersebut kemudian digunakan untuk melakukan peramalan nilai produksi padi pada periode mendatang.

Hasil prediksi ini diharapkan dapat memberikan gambaran mengenai kondisi produksi padi di tahun-tahun selanjutnya sehingga dapat digunakan sebagai dasar perencanaan kebijakan, mitigasi risiko iklim, serta pengelolaan sumber daya pertanian secara lebih optimal dan berkelanjutan.

BAB III

METODE PENELITIAN

3.1 Jenis Penelitian

Penelitian ini merupakan penelitian yang bersifat kuantitatif karena data yang digunakan berupa angka. Penelitian kuantitatif adalah jenis penelitian yang mengolah informasi serta data melalui pendekatan statistik. Dengan berdasarkan tujuan yang telah dipaparkan sebelumnya yaitu untuk melakukan peramalan produksi padi di Provinsi Jawa Barat.

3.2 Data dan Sumber Data

Penelitian ini menggunakan data sekunder yang diperoleh dari beberapa website resmi instansi terkait, yaitu Badan Pusat Statistik (BPS) (www.bps.go.id), Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) (www.bmkg.go.id), serta *National Oceanic and Atmospheric Administration* (NOAA) (www.noaa.gov). dalam bentuk data bulanan Produksi padi, luas panen, curah hujan, suhu udara, *Oceanic Niño Index*, Kelembaban udara, dan lamanya penyinaran matahari dari bulan Januari 2018 sampai Desember 2024 dikumpulkan dalam format Excel kemudian diolah lebih lanjut menggunakan perangkat lunak statistik. Adapun data tersebut terlampir pada Lampiran 1.

3.3 Variabel Penelitian

Variabel dalam penelitian ini merupakan komponen yang menjadi objek pengamatan. Pada penelitian ini, variabel yang digunakan meliputi variabel dependen dan variabel eksogen. Adapun variabel-variabel yang antara lain;

Z : Produksi Padi (Ton)

X_1 : Luas panen (Ha)

- X_2 : Curah hujan (mm)
 X_3 : Suhu udara ($^{\circ}\text{C}$)
 X_4 : Lamanya penyinaran matahari (jam)
 X_5 : Kelembaban udara (%)
 X_6 : *Oceanic Niño Index* (ONI)

3.4 Teknik Analisis Data

Langkah analisis dalam penelitian yang dilakukan untuk mendapatkan model SARIMAX pada produksi Padi di Jawa Barat adalah sebagai berikut:

1. Identifikasi Data

Tahap awal penelitian dilakukan dengan mengidentifikasi karakteristik data produksi padi di Provinsi Jawa Barat. Analisis ini meliputi pemeriksaan pola data secara visual melalui grafik deret waktu untuk melihat adanya tren, pola musiman, serta fluktuasi data.

2. Mengidentifikasi stasioneritas data dalam varians dan mean.

Mengidentifikasi kestasioneran data dalam varians dan *mean* dengan melakukan transformasi Box-Cox menggunakan persamaan (2.1) pada data yang belum stasioner dalam varians, dan melakukan *differencing* dengan menggunakan persamaan (2.5) pada data yang belum stasioner terhadap *mean*.

3. Pembagian data

Membagi data menjadi dua yakni data *training* yang merupakan data produksi padi mulai bulan Januari 2018 sampai dengan Desember 2023 dan data *testing* yaitu data produksi padi mulai bulan Januari 2024 sampai dengan Desember 2024.

4. Melakukan identifikasi model SARIMA

Setelah data stasioner, dilakukan identifikasi model awal SARIMA sesuai persamaan umum SARIMA pada Persamaan (2.20) dengan menentukan ordo $(p,d,q)(P,D,Q)s$ berdasarkan analisis grafik Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF).

5. Estimasi Parameter SARIMA

Model SARIMA yang diperoleh selanjutnya diestimasi parameternya menggunakan metode *Maximum Likelihood Estimation* (MLE) sesuai Persamaan (2.35). Selanjutnya, pemilihan model terbaik dilakukan berdasarkan uji signifikansi parameter dan nilai *Akaike Information Criterion* (AIC) sesuai Persamaan (2.32). Model dengan parameter yang signifikan serta memiliki nilai AIC terkecil dipilih sebagai model yang paling optimal.

6. Melakukan uji asumsi residual *white noise*:

Melakukan uji asumsi residual *white noise* menggunakan uji Ljung-Box Pierce.

7. Penentuan model SARIMA terbaik

Model SARIMA terbaik ditentukan berdasarkan hasil evaluasi AIC dan uji asumsi residual *white noise* yang telah dilakukan.

8. Pembentukan Model SARIMAX

Sebelum ke model dilakukan uji korelasi dan stasioneritas variabel eksogen selanjutnya dibentuk model SARIMAX dengan menambahkan variabel eksogen yang diduga memengaruhi variabel dependen dengan menggunakan Persamaan (2.24).

9. Estimasi Parameter dan Uji Diagnostik SARIMAX

Model SARIMAX yang terbentuk kemudian diestimasi parameternya menggunakan metode *Maximum Likelihood Estimation* (MLE) sesuai Persamaan (2.35).


10. Evaluasi Model SARIMAX


Evaluasi model akan dilakukan dengan menggunakan MAPE dengan persamaan (2.38), dengan menghitung perbedaan antara data asli dengan data hasil peramalan. Selanjutnya dilakukan uji signifikansi parameter dan uji asumsi residual *white noise* untuk memastikan model telah memenuhi asumsi.

11. Menghitung Peramalan

Setelah mendapatkan model SARIMAX terbaik, pada tahap ini akan dilakukan peramalan pada data hasil produksi padi di Jawa Barat pada Januari 2025 sampai Desember 2025.

3.5 Diagram Alir (Flowchart)






Gambar 3.1 Diagram Alir

BAB IV

HASIL DAN PEMBAHASAN

4.1 Identifikasi Data

Data yang digunakan dalam penelitian ini merupakan data produksi padi di Provinsi Jawa Barat periode tahun 2018 hingga 2024 yang disajikan pada Lampiran I. Berdasarkan data tersebut, diperoleh plot deret waktu (*time series plot*) berikut:



Gambar 4.1 Plot Data Produksi Padi Januari 2018-Desember 2024

Berdasarkan Gambar 4.1, terlihat bahwa data produksi padi di Provinsi Jawa Barat memperlihatkan pola fluktuasi yang berulang secara periodik dari waktu ke waktu. Pola ini menunjukkan adanya komponen musiman, yang ditandai dengan kecenderungan kenaikan dan penurunan produksi yang terjadi pada bulan-bulan tertentu dan relatif konsisten setiap tahunnya.

Selama periode pengamatan Januari 2018 hingga Desember 2024, produksi padi mengalami variasi yang cukup besar. Hal ini terlihat dari adanya lonjakan produksi pada beberapa periode tertentu, yang kemudian diikuti oleh penurunan yang cukup tajam. Pola tersebut tidak bersifat acak sepenuhnya, melainkan

menunjukkan kecenderungan berulang yang mengindikasikan adanya pengaruh musiman dalam data.

Selain itu, pada plot juga tampak beberapa titik puncak (*peak*) dengan nilai produksi yang tinggi serta titik lembah (*trough*) dengan nilai yang rendah. Kemunculan pola puncak dan lembah yang berulang ini semakin memperkuat bahwa data memiliki komponen musiman, meskipun masih terdapat unsur acak (*random variation*) dalam pergerakannya.

Selain variabel produksi padi sebagai variabel dependen, penelitian ini juga menggunakan enam variabel eksogen yang diduga memengaruhi produksi padi di Provinsi Jawa Barat, yaitu luas panen, curah hujan, suhu udara rata-rata, lama penyinaran matahari, kelembapan udara rata-rata, dan indeks Niño. Statistik deskriptif masing-masing variabel disajikan pada Tabel 4.1.

Tabel 4.1 Deskriptif Data pada Variabel Eksogen

Variabel	Minimum	Maksimum	Mean	Std. Deviasi
Luas Lahan (ha)	25.607	299.445	133.316	61.909
Curah Hujan (mm)	0,0	1.068,0	250,2	193,4
Suhu Udara (°C)	23,884	29,550	26,081	1,103
Lama Penyinaran Matahari (jam)	6,648	9,738	7,968	0,939
Kelembapan Udara (%)	66,633	88,032	81,050	4,415
Indeks Niño	-1,300	2,000	-0,052	0,835

Berdasarkan Tabel 4.1, luas panen memiliki rata-rata sebesar 133.316 hektar dengan nilai minimum 25.607 hektar dan maksimum 299.445 hektar. Variabel curah hujan memiliki rata-rata sebesar 250,2 mm dengan rentang nilai antara 0 mm hingga 1.068 mm, yang menunjukkan adanya variasi curah hujan yang cukup tinggi selama periode pengamatan. Suhu udara rata-rata memiliki nilai rata-rata sebesar

26,081°C dengan standar deviasi sebesar 1,103°C, sedangkan kelembapan udara rata-rata memiliki nilai rata-rata sebesar 81,050%.

Lama penyinaran matahari memiliki rata-rata sebesar 7,968 jam per hari dengan nilai minimum 6,648 jam dan maksimum 9,738 jam. Sementara itu, indeks Niño memiliki rata-rata sebesar -0,052 dengan nilai minimum -1,300 dan maksimum 2,000 yang menunjukkan adanya variasi kondisi ENSO selama periode penelitian.


Secara umum, variabel eksogen yang digunakan memiliki karakteristik dan tingkat variasi yang berbeda-beda. Variabel luas panen dan curah hujan menunjukkan variasi yang relatif lebih besar dibandingkan variabel lainnya, sedangkan suhu udara, kelembapan udara, lama penyinaran matahari, dan indeks Niño cenderung lebih stabil selama periode pengamatan. Perbedaan skala dan satuan pengukuran antarvariabel tersebut menjadi salah satu alasan dilakukannya proses standardisasi Sebelum dilakukan analisis lebih lanjut, seluruh variabel eksogen distandardisasi menggunakan metode *z-score* dengan persamaan (2.33), Sebagai contoh, standardisasi pada variabel luas panen dilakukan sebagai berikut:

$$X_{1i}^* = \frac{X_{1i} - 133316}{61909}$$

Proses yang sama diterapkan pada variabel eksogen yang lainnya, sehingga diperoleh hasil dari standardisasi pada semua variabel eksogen pada Lampiran 2.


4.1.1 Stasioneritas terhadap Varians

Uji stasioneritas data diawali dengan pengujian stasioneritas terhadap varians menggunakan transformasi Box-Cox. Data dikatakan telah stasioner terhadap varians apabila nilai *rounded value* (λ) yang diperoleh sama dengan 1.




Gambar 4.2 *Plot Box-Cox Data*

Berdasarkan Gambar 4.2, nilai rounded value yang dihasilkan dari plot Box-Cox sebesar 0,50. Nilai tersebut menunjukkan bahwa data belum stasioner terhadap varians. Dengan demikian, perlu dilakukan transformasi Box-Cox sebagai langkah lanjutan.



Gambar 4.3 *Transformasi Box-Cox Pertama*

Berdasarkan Gambar 4.3, diperoleh nilai *rounded value* sebesar 0,50. Nilai tersebut menunjukkan bahwa data masih belum stasioner terhadap varians. Oleh karena itu, perlu dilakukan transformasi Box-Cox kembali hingga diperoleh nilai *rounded value* mendekati atau sama dengan 1.



Gambar 4.4 Transformasi *Box-Cox* Kedua

Gambar 4.4 menunjukkan bahwa nilai *rounded value* yang diperoleh setelah dilakukan transformasi sebanyak dua kali adalah 1. Nilai tersebut mengindikasikan bahwa data telah stasioner terhadap varians.

Berdasarkan plot Box-Cox, diperoleh nilai *rounded value* sebesar 0,50 yang menunjukkan bahwa varians data belum stabil. Oleh karena itu dilakukan transformasi pangkat sesuai rekomendasi Box-Cox. Karena transformasi dilakukan sebanyak dua kali pada nilai $\lambda = 0,50$, maka transformasi yang ekuivalen adalah transformasi pangkat $1/4$ atau akar pangkat empat, yaitu:

$$W_t = Z_t^{1/4} \quad (4.1)$$


di mana W_t merupakan data hasil transformasi dan Z_t merupakan data asli.

Berikut merupakan contoh transformasi yang dilakukan pada pengamatan ke-1. Contoh:

$$W_1 = 299729^{1/4} = 23,3982$$

hasil transformasi secara lengkap dapat dilihat pada Lampiran 3.

Berikut disajikan plot data setelah dilakukan transformasi Box-Cox. Plot tersebut digunakan untuk melihat pola data setelah transformasi serta memastikan bahwa *varians* data telah menjadi lebih stabil.



Gambar 4.5 Plot Data Stasioner terhadap Varians

Berdasarkan plot data hasil transformasi Box-Cox, terlihat bahwa fluktuasi data sudah relatif stabil dan tidak menunjukkan perubahan *varians* yang signifikan dari waktu ke waktu. Hal ini mengindikasikan bahwa data telah stasioner terhadap *varians*. Hasil tersebut juga didukung oleh nilai rounded value Box-Cox sebesar 1, yang menunjukkan bahwa transformasi yang dilakukan berhasil menstabilkan *varians* data.

4.1.2 Stasioneritas terhadap *Mean*

Pengujian stasioneritas terhadap rata-rata dilakukan menggunakan uji Augmented Dickey-Fuller (ADF). Uji ADF digunakan untuk mengetahui apakah data mengandung akar unit (*unit root*) yang mengindikasikan bahwa data belum stasioner terhadap rata-rata. Hipotesis yang digunakan dalam uji ADF adalah:

H_0 : Data memiliki *unit root* (tidak stasioner)

H_1 : Data tidak memiliki *unit root* (stasioner)

Kriteria pengambilan keputusan dalam uji ADF dapat dilakukan melalui dua pendekatan: Berdasarkan nilai p : Tolak H_0 jika nilai $p\text{-value} < \text{tingkat signifikansi } (\alpha)$ dengan α sebesar 0,05 atau Berdasarkan statistik uji: Tolak H_0 jika nilai absolut dari statistik uji ($|t|$) lebih besar dari nilai mutlak kritis MacKinnon.

Tabel 4.2 Uji *Augmented Dickey-Fuller*

	t-Statistik	Prob.
<i>Augmented Dickey-Fuller test statistic</i>	-1,874402	0,3420
Test critical values		
1% level	-3,544063	
5% level	-2,910860	
10% level	-2,593090	


Hasil uji stasioner pada rata-rata menunjukkan bahwa data Produksi Padi memiliki nilai ADF Statistic sebesar -1,874402 dengan $p\text{-value}$ sebesar 0,3420, sehingga data belum bersifat stasioner karena $p\text{-value}$ melebihi tingkat signifikansi (0,05). Selain itu, berdasarkan perbandingan nilai absolut dari statistik uji dengan nilai kritis MacKinnon, diperoleh $|-1,874402| = 1,874402$, Nilai tersebut lebih kecil dibandingkan nilai absolut kritis MacKinnon pada taraf signifikansi 1%, 5%, dan 10%, yaitu $|-3,544063| = 3,544063$, $|-2,910860| = 2,910860$, dan $|-2,593090| = 2,593090$. Dengan demikian, H_0 gagal ditolak, sehingga data masih mengandung akar unit (*unit root*) dan belum stasioner terhadap rata-rata. maka dilakukan differencing sehingga menghasilkan data berikut:

Tabel 4.3 Uji *Augmented Dickey-Fuller* setelah *Differencing 1*

	t-Statistik	Prob.
<i>Augmented Dickey-Fuller test statistic</i>	-8,074488	0,000
Test critical values		
1% level	-3,544063	
5% level	-2,910860	
10% level	-2,593090	

Setelah dilakukan proses *differencing* sebanyak satu kali, diperoleh nilai ADF Statistic sebesar -8,074488 dan nilai $p\text{-value}$ sebesar 0,0000. Karena nilai $p\text{-value}$

value lebih kecil dari 0,05, Selain itu, berdasarkan perbandingan nilai absolut dari statistik uji dengan nilai kritis MacKinnon, diperoleh $|-8,074488| = 8,074488$, yang lebih besar daripada nilai kritis pada taraf signifikansi 1%, 5%, dan 10%, yaitu masing-masing sebesar 3,544063; 2,910860; dan 2,593090. $|-3,544063| = 3,544063$, $|-2,910860| = 2,910860$, dan $|-2,593090| = 2,593090$. Maka data dapat dinyatakan telah memenuhi asumsi stasioner terhadap rata-rata. Dengan demikian, keputusan yang diambil adalah tolak H_0 . Data hasil pengujian tersebut disajikan pada Lampiran 4. Berikut disajikan plot data setelah dilakukan *differencing* satu kali. Plot tersebut digunakan untuk melihat pola data setelah *differencing* serta memastikan bahwa *mean* data telah menjadi lebih stabil.



Gambar 4.6 Plot Data Stasioner terhadap *Mean*

Berdasarkan Gambar 4.6, data hasil differencing berfluktuasi di sekitar nilai nol dan tidak menunjukkan adanya pola tren yang sistematis. Namun, masih terlihat beberapa lonjakan yang muncul secara berulang pada periode tertentu sehingga terdapat indikasi adanya pengaruh musiman pada data. Oleh karena itu, selain dilakukan differencing nonmusiman, perlu dilakukan differencing musiman untuk menghilangkan komponen musiman yang masih tersisa. Selanjutnya, uji

Augmented Dickey-Fuller (ADF) dilakukan kembali pada data hasil differencing musiman untuk memastikan bahwa data telah stasioner terhadap rata-rata sebelum dilakukan identifikasi model SARIMA dan SARIMAX. Proses *differencing* musiman dilakukan dengan penggeseran data sebanyak 12 periode ke belakang dengan menerapkan persamaan (2.5), dan hasilnya dapat dilihat pada Lampiran 5.

Tabel 4.4 Uji *Augmented Dickey-Fuller* setelah *Differencing* Musiman

		t-Statistik	Prob.
<i>Augmented Dickey-Fuller test statistic</i>		-8,656157	0,000
Test critical values	1% level	-3,552666	
	5% level	-2,914517	
	10% level	-2,595033	

Berdasarkan hasil uji ADF setelah differencing musiman diperoleh nilai ADF Statistic sebesar -8,656157 dengan p-value sebesar 0,0000. Karena nilai *p-value* lebih kecil dari 0,05, maka H_0 ditolak. Selain itu, nilai absolut statistik uji sebesar 8,656157 lebih besar dibandingkan nilai kritis MacKinnon pada taraf signifikansi 1%, 5%, dan 10%, yaitu masing-masing sebesar 3,552666; 2,914517; dan 2,595033. Dengan demikian, data hasil *differencing* musiman tidak mengandung *unit root* dan telah stasioner terhadap rata-rata sehingga dapat digunakan pada tahap identifikasi model SARIMA dan SARIMAX.

4.1.3 Pembagian Data

Setelah data stasioner maka dilakukan pemisahan data menjadi dua bagian, yakni data *training* dan *testing*. Data *training* mencakup periode januari 2018 hingga desember 2023, yang digunakan untuk melatih model dan menguji kemampuannya dalam mempelajari pola historis. Sementara itu, data *testing* mencakup periode januari 2024 hingga desember 2024, yang digunakan untuk mengevaluasi kinerja model dalam melakukan prediksi.

4.2 Identifikasi Model SARIMA

4.2.2 Identifikasi Model Sementara

Apabila data telah memenuhi kondisi stasioner baik terhadap rata-rata maupun variansi, maka langkah selanjutnya adalah menentukan model sementara berdasarkan hasil identifikasi data. Identifikasi model sementara dilakukan dengan memperhatikan pola *cut off* dan *dies down* pada plot ACF dan PACF dari data yang telah stasioner. Berikut contoh perhitungan manual ACF menggunakan Persamaan (2.25) dengan data yang telah ditransformasi dan *differencing*. Adapun perhitungan nilai koefisien tersebut adalah sebagai berikut:

$$\begin{aligned}
 r_k &= \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t-k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \\
 &= \frac{(5,8119)(5,6323) + (5,6323)(-1,7789) + \dots + (-3,0870)(-2,2831)}{(5,8119)^2 + (5,6323)^2 + \dots + (-2,2831)^2} \\
 &= \frac{52,46}{441,98} \\
 &= 0,118691
 \end{aligned}$$

Sehingga diperoleh nilai ACF pada lag ke-1 sebesar:

$$r_k = 0,118691$$

Untuk nilai ACF selanjutnya bisa dilihat pada tabel 4.5 berikut:

Tabel 4.5 Nilai Koefisien ACF

Lag	ACF	T	LBQ	Lag	ACF	T	LBQ
1	0,118691	1,00	1,04	19	0,021252	0,11	65,11
2	-0,456017	-3,79	16,66	20	-0,022198	-0,12	65,16
3	-0,209290	-1,47	20,00	21	-0,212119	-1,12	69,83
4	0,162484	1,11	22,04	22	-0,117170	-0,61	71,28
5	0,000738	0,00	22,04	23	0,151355	0,78	73,75
6	-0,050220	-0,34	22,25	24	0,308128	1,57	84,22
7	-0,079127	-0,53	22,75	25	-0,005103	-0,03	84,23
8	0,068823	0,46	23,14	26	-0,070618	-0,35	84,80
9	-0,117528	-0,78	24,30	27	-0,033494	-0,16	84,93
10	-0,283253	-1,86	31,11	28	0,000100	0,00	84,93
11	0,008116	0,05	31,12	29	-0,107131	-0,53	86,35
12	0,514377	3,23	54,36	30	0,060518	0,30	86,81
13	0,234703	1,30	59,29	31	0,050964	0,25	87,15
14	-0,178084	-0,96	62,17	32	-0,030544	-0,15	87,27
15	-0,157907	-0,84	64,48	33	-0,159678	-0,78	90,75
16	-0,028673	-0,15	64,55	34	-0,104145	-0,50	92,27
17	-0,045351	-0,24	64,75	35	0,161449	0,78	96,02
18	0,056857	0,30	65,07	36	0,294815	1,41	108,89

Berdasarkan jumlah data training sebanyak 72 observasi, batas signifikansi 95% dihitung menggunakan


$$\text{Batas Signifikansi} = \pm \frac{1,96}{\sqrt{n}}$$

sehingga diperoleh

$$\pm \frac{1,96}{\sqrt{72}} = \pm \frac{1,96}{8,485} = \pm 0,231$$

dengan demikian, interval kepercayaan yang digunakan adalah $(-0,231; 0,231)$.

Terdapat beberapa lag yang berada di luar interval tersebut, yaitu lag ke-2, ke-10, ke-12, ke-13, ke-24, dan ke-36. Munculnya *spike* yang signifikan pada lag-lag musiman tersebut menunjukkan bahwa data masih mengandung pola musiman dengan periode 12 bulan. Oleh karena itu, diperlukan *differencing* musiman untuk menghilangkan pengaruh musiman pada data. Berikut plot ACF non-musiman berdasarkan Tabel 4.5



Gambar 4.7 Plot ACF Data *Differencing* Nonmusiman

Berdasarkan plot Autocorrelation Function (ACF) setelah dilakukan differencing nonmusiman orde satu, terlihat beberapa spike yang melewati batas signifikansi, terutama pada lag ke-2, lag ke-12, dan beberapa lag lainnya. Namun secara umum nilai autokorelasi tidak menunjukkan pemutusan (*cut off*) yang jelas pada lag tertentu, melainkan menurun secara bertahap (*dies down*). Selain itu, terdapat spike yang cukup signifikan pada lag ke-12 yang mengindikasikan adanya pola musiman dengan periode 12.

Setelah mendapatkan nilai ACF, berikut adalah contoh perhitungan manual PACF menggunakan Persamaan (2.31) dengan data yang telah ditransformasi. Adapun perhitungan nilai lag-1 adalah sebagai berikut:

$$\begin{aligned}\phi_{kk} &= r_k \\ &= 0,118691\end{aligned}$$

untuk perhitungan nilai lag-2 adalah

$$\begin{aligned}\phi_{kk} &= \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j} \\ \phi_{22} &= \frac{-0,4560 - (0,118691)(0,118691)}{1 - (0,118691)(0,118691)}\end{aligned}$$

$$\begin{aligned}
&= \frac{-0,4560 - 0,0141}{1 - 0,0141} \\
&= \frac{-0,4701}{0,9859} \\
&= -0,476821
\end{aligned}$$


Untuk nilai PACF selanjutnya bisa dilihat pada tabel 4.6 berikut:

Tabel 4.6 Nilai Koefisien PACF

Lag	PACF	T	Lag	PACF	T
1	0,118691	1,00	19	-0,065406	-0,55
2	-0,476821	-4,02	20	0,021239	0,18
3	-0,095520	-0,80	21	-0,201560	-1,70
4	-0,011697	-0,10	22	0,099637	0,84
5	-0,210752	-1,78	23	0,132898	1,12
6	0,028249	0,24	24	0,091688	0,77
7	-0,189830	-1,60	25	-0,088819	-0,75
8	0,053443	0,45	26	-0,025032	-0,21
9	-0,301469	-2,54	27	-0,152549	-1,29
10	-0,378815	-3,19	28	-0,043801	-0,37
11	-0,138722	-1,17	29	-0,029556	-0,25
12	0,181214	1,53	30	0,096081	0,81
13	0,102034	0,86	31	-0,003442	-0,03
14	0,157974	1,33	32	0,006576	0,06
15	0,156885	1,32	33	0,102167	0,86
16	-0,110977	-0,94	34	-0,072083	-0,61
17	-0,110308	-0,93	35	0,075931	0,64
18	0,001116	0,01	36	0,054604	0,46

Berdasarkan batas signifikansi 95% pada Tabel 4.6, diperoleh interval kepercayaan sebesar $(-0,231; 0,231)$. Terdapat beberapa lag yang berada di luar interval tersebut, yaitu lag ke-2, ke-9, dan ke-10. Namun, spike signifikan tersebut tidak membentuk pola cut off yang jelas karena masih terdapat beberapa lag yang melewati batas signifikansi setelah lag ke-2. Secara umum, nilai PACF cenderung menurun dan berfluktuasi di sekitar nol. Pola ini menunjukkan bahwa komponen non-musiman cenderung mengikuti model campuran ARIMA, sehingga identifikasi orde non-musiman perlu dilakukan dengan mempertimbangkan plot

ACF dan PACF secara bersama-sama. Berikut plot PACF non-musiman berdasarkan Tabel 4.6




Gambar 4.8 Plot PACF Data *Differencing* Nonmusiman

Berdasarkan plot *Partial Autocorrelation Function* (PACF) setelah dilakukan *differencing* nonmusiman orde satu, terlihat beberapa *spike* yang melewati batas signifikansi, terutama pada lag ke-2 serta beberapa lag lainnya. Namun, setelah lag-lag awal tersebut nilai PACF cenderung menurun dan sebagian besar berada di dalam batas signifikansi. Pola ini menunjukkan bahwa PACF tidak mengalami pemutusan (*cut off*) secara jelas pada lag tertentu, melainkan menurun secara bertahap (*dies down*).

Berdasarkan plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF), terlihat bahwa pada bagian non-musiman kedua plot tidak menunjukkan pola *cut off* yang jelas, melainkan menurun secara bertahap (*dies down*). Pola ini mengindikasikan bahwa komponen non-musiman mengikuti model campuran ARIMA, sehingga model yang dapat dipertimbangkan adalah ARIMA (0,1,1), ARIMA (1,1,1), ARIMA (0,1,2), dan ARIMA (1,1,2).


Meskipun data telah stasioner terhadap rata-rata setelah dilakukan *differencing* non-musiman orde satu, hasil plot ACF masih menunjukkan adanya spike yang signifikan pada lag musiman ke-12, ke-24, dan ke-36. Munculnya spike pada kelipatan lag 12 mengindikasikan bahwa data masih mengandung pola musiman dengan periode 12 bulan. Oleh karena itu, diperlukan *differencing* musiman orde satu ($D = 1$) untuk menghilangkan pengaruh musiman yang masih tersisa sehingga data menjadi stasioner baik pada komponen non-musiman maupun musiman. Setelah dilakukan *differencing* musiman, proses identifikasi model musiman dapat dilakukan melalui analisis plot ACF dan PACF hasil *differencing* musiman. Selanjutnya dilakukan proses *differencing* musiman untuk mengidentifikasi model musiman.



Gambar 4.9 Plot ACF Data *Differencing* Musiman

Berdasarkan plot ACF setelah *differencing* musiman, terlihat bahwa terdapat spike signifikan pada lag awal yang kemudian menurun dengan cepat, sehingga menunjukkan pola *cut off* pada lag 1. Hal ini mengindikasikan adanya komponen *Moving Average* orde rendah pada bagian non-musiman. Selain itu, tidak terlihat lagi spike signifikan pada lag musiman (lag 12, 24, dan seterusnya),

yang menunjukkan bahwa proses *differencing* musiman telah berhasil menghilangkan pola musiman pada data.



Gambar 4.10 Plot PACF Data *Differencing* Musiman

Sementara itu, plot PACF menunjukkan spike signifikan pada lag awal dan selanjutnya menurun secara bertahap (*dies down*), yang mengindikasikan kemungkinan adanya komponen *Autoregressive* orde rendah. Berdasarkan pola ACF dan PACF tersebut, komponen musiman yang dapat dipertimbangkan adalah model dengan orde rendah, yaitu $(0,1,1)_{12}$, $(1,1,0)_{12}$, dan $(0,1,2)_{12}$.

Identifikasi kandidat model SARIMA dilakukan berdasarkan pola ACF dan PACF dari data yang telah stasioner. Oleh karena itu, tidak seluruh kombinasi orde AR, MA, SAR, dan SMA diuji, melainkan hanya kombinasi yang sesuai dengan indikasi yang ditunjukkan oleh plot ACF dan PACF. Pembatasan tersebut dilakukan untuk menghindari pembentukan model yang terlalu banyak dan kurang relevan dengan karakteristik data. Selain itu, pemilihan kandidat model yang berada di sekitar orde yang teridentifikasi dari ACF dan PACF merupakan prosedur yang umum digunakan dalam metode Box-Jenkins. Dengan demikian, model-model yang diuji merupakan model yang secara teoritis memiliki peluang

lebih besar untuk menggambarkan pola data dibandingkan kombinasi orde lainnya.

Dengan demikian, berdasarkan identifikasi model untuk bagian non-musiman dan musiman, diperoleh beberapa model SARIMA sementara yang mungkin adalah sebagai berikut: SARIMA (0,1,1)(0,1,1)₁₂, SARIMA (1,1,1)(0,1,1)₁₂, SARIMA (0,1,1)(1,1,0)₁₂, SARIMA (1,1,1)(1,1,0)₁₂, SARIMA (0,1,2)(0,1,1)₁₂, SARIMA (1,1,2)(0,1,1)₁₂, SARIMA (0,1,1)(0,1,2)₁₂, dan SARIMA (1,1,1)(0,1,2)₁₂

4.2.3 Estimasi dan Uji Signifikansi Parameter Model

Estimasi parameter dilakukan untuk memperoleh nilai koefisien dari masing-masing komponen *autoregressive* (AR), *moving average* (MA), *seasonal autoregressive* (SAR), dan *seasonal moving average* (SMA) pada model. Selanjutnya, dilakukan uji signifikansi parameter untuk mengetahui apakah parameter yang dihasilkan berpengaruh secara signifikan dalam model atau tidak.

Suatu parameter dalam model SARIMA dikatakan signifikan apabila nilai $|t - \text{hitung}| > t - \text{tabel}$ atau dengan nilai *p-value* yang diperoleh lebih kecil dibandingkan dengan taraf signifikansi yang telah ditentukan. Dalam penelitian ini digunakan taraf signifikansi sebesar 5%. Apabila nilai *p-value* < 0,05 maka parameter dinyatakan signifikan sehingga layak digunakan dalam model, sedangkan apabila nilai $|t - \text{hitung}| < t - \text{tabel}$ atau nilai *p-value* > 0,05 maka parameter dinyatakan tidak signifikan. Adapun hipotesis yang digunakan dalam pengujian signifikansi parameter adalah sebagai berikut:

H_0 : Parameter model tidak signifikan

H_1 : Parameter model signifikan

Suatu parameter dikatakan signifikan apabila memiliki nilai *p-value* lebih kecil dari 0,05, sehingga parameter tersebut layak digunakan dalam model atau nilai $|t - \text{hitung}| > t - \text{tabel}$. Sebaliknya, apabila nilai *p-value* lebih besar atau sama dengan 0,05 maka parameter dianggap tidak signifikan. Parameter yang signifikan menunjukkan bahwa komponen dalam model mampu menjelaskan pola data *time series* dengan baik. Ringkasan hasil pengujian ditulis pada Tabel 4.7 sebagai berikut:

Tabel 4.7 Nilai Estimasi dan Uji Signifikansi Parameter Model Awal

Model	Parameter	Estimasi	<i>Std error</i>	<i>T value</i>	<i>p-value</i>	Keterangan
SARIMA (0,1,1)(0,1,1) ₁₂	MA 1	0,913	0,060	15,17	0,000	Signifikan
	SMA 12	0,858	0,119	7,20	0,000	Signifikan
SARIMA (1,1,1)(0,1,1) ₁₂	AR 1	0,198	0,157	1,26	0,211	Tidak Signifikan
	MA 1	0,901	0,078	11,58	0,000	Signifikan
	SMA 12	0,830	0,135	6,16	0,000	Signifikan
SARIMA (0,1,1)(1,1,0) ₁₂	SAR 12	-0,424	0,124	-3,42	0,001	Signifikan
	MA 1	0,961	0,037	26,06	0,000	Signifikan
SARIMA (1,1,1)(1,1,0) ₁₂	AR 1	0,286	0,138	2,08	0,042	Signifikan
	SAR 12	-0,453	0,130	-3,48	0,001	Signifikan
	MA 1	0,980	0,042	23,30	0,000	Signifikan
SARIMA (0,1,2)(0,1,1) ₁₂	MA 1	0,355	0,110	3,22	0,002	Signifikan
	MA 2	0,596	0,114	5,21	0,000	Signifikan
	SMA 12	0,852	0,131	6,52	0,000	Signifikan
SARIMA (1,1,2)(0,1,1) ₁₂	AR 1	-0,130	0,232	-0,56	0,577	Tidak Signifikan
	MA 1	0,282	0,181	1,56	0,125	Tidak Signifikan
	MA 2	0,654	0,152	4,31	0,000	Signifikan
	SMA 12	0,853	0,133	6,40	0,000	Signifikan
SARIMA (0,1,1)(0,1,2) ₁₂	MA 1	0,858	0,065	13,19	0,000	Signifikan
	SMA 12	1,022	0,138	7,38	0,000	Signifikan
	SMA 24	-0,166	0,149	-1,11	0,270	Tidak Signifikan
SARIMA (1,1,1)(0,1,2) ₁₂	AR 1	0,205	0,171	1,20	0,236	Tidak Signifikan
	MA 1	0,858	0,087	9,68	0,000	Signifikan
	SMA 12	1,025	0,148	6,95	0,000	Signifikan
	SMA 24	-0,185	0,152	-1,21	0,230	Tidak Signifikan

Berdasarkan Tabel 4.7, parameter model dinyatakan signifikan apabila nilai absolut statistik uji $|t - \text{hitung}| > t - \text{tabel}$ pada taraf signifikansi 5%. Untuk model SARIMA (0,1,1)(0,1,1)₁₂, derajat bebas sebesar 70 sehingga diperoleh nilai t-tabel sebesar 1,994. Sementara itu, untuk model SARIMA (1,1,1)(1,1,0)₁₂, SARIMA (0,1,1)(1,1,0)₁₂, SARIMA (0,1,2)(0,1,1)₁₂, dan SARIMA (0,1,1)(0,1,2)₁₂ diperoleh derajat bebas sebesar 69 dengan nilai t-tabel sebesar 1,995. Adapun model SARIMA (1,1,1)(1,1,0)₁₂, SARIMA (1,1,2)(0,1,1)₁₂, dan SARIMA (1,1,1)(0,1,2)₁₂ memiliki derajat bebas sebesar 68 sehingga nilai t-tabel yang digunakan adalah 1,995. Parameter yang memiliki nilai $|t - \text{hitung}| > t - \text{tabel}$ atau $p\text{-value} < 0,05$ dinyatakan signifikan. diperoleh empat model sementara yang seluruh parameternya signifikan pada taraf signifikansi 5%, yaitu SARIMA (0,1,1)(0,1,1)₁₂, SARIMA (0,1,1)(1,1,0)₁₂, SARIMA (1,1,1)(1,1,0)₁₂, dan SARIMA (0,1,2)(0,1,1)₁₂. Keempat model tersebut dipertahankan untuk tahap selanjutnya karena seluruh parameter pada model-model tersebut memiliki nilai absolut $|t - \text{hitung}|$ yang lebih besar daripada $t - \text{tabel}$ ($|t - \text{hitung}| > t - \text{tabel}$) atau seluruh parameter memiliki nilai $p\text{-value}$ kurang dari 0,05. Selain itu, Sementara itu, model lainnya tidak dipertimbangkan lebih lanjut karena terdapat satu atau lebih parameter yang tidak signifikan. Selanjutnya, dilakukan pemilihan model terbaik dengan menggunakan kriteria *Akaike Information Criterion* (AIC). Model yang memiliki nilai AIC terkecil dipilih sebagai model terbaik karena mampu memberikan keseimbangan antara tingkat kesesuaian model dan kompleksitas model. Nilai AIC untuk masing-masing model SARIMA selanjutnya disajikan pada Tabel 4.8.

Tabel 4.8 Nilai AIC Model SARIMA

Model	AIC
SARIMA (0,1,1)(0,1,1) ₁₂	4,976562
SARIMA (0,1,1)(1,1,0) ₁₂	5,281041
SARIMA (1,1,1)(1,1,0) ₁₂	5,300187
SARIMA (0,1,2)(0,1,1) ₁₂	4,947841

Berdasarkan Tabel 4.8, diperoleh bahwa model dengan nilai AIC terkecil adalah ARIMA (0,1,2) dan *Seasonal* ARIMA(0,1,1)₁₂ dengan nilai AIC sebesar 4,947841. model tersebut dipilih sebagai model terbaik karena memiliki nilai AIC yang lebih kecil dibandingkan model lainnya, sehingga memberikan keseimbangan yang baik antara tingkat kesesuaian model dan kompleksitas model. Dari model SARIMA (0,1,2)(0,1,1)₁₂ tersebut dapat juga ditulis menggunakan Persamaan (2.20),

$$\Phi_P(B^S)\phi_p(B)(1-B)^d(1-B^S)^DW_t = \Theta_Q(B^S)\theta_q(B)e_t$$

$$\Phi_0(B^{12})\phi_0(B)(1-B)^1(1-B^{12})^1W_t = \Theta_1(B^{12})\theta_2(B)e_t$$

$$(1-B)(1-B^{12})W_t = (1-\Theta_1B^{12})(1-\theta_1B-\theta_2B^2)e_t$$

$$(1-B-B^{12}+B^{13})W_t$$

$$= (1-\theta_1B-\theta_2B^2-\Theta_1B^{12}+\theta_1\Theta_1B^{13}+\theta_2\Theta_1B^{14})e_t$$

dengan menggunakan sifat ($BW_t = W_{t-1}$), maka:

$$W_t - W_{t-1} - W_{t-12} + W_{t-13}$$

$$= e_t - \theta_1e_{t-1} - \theta_2e_{t-2} - \Theta_1e_{t-12} + \theta_1\Theta_1e_{t-13} + \theta_2\Theta_1e_{t-14}$$

sehingga diperoleh:

$$\begin{aligned}
W_t = W_{t-1} + W_{t-12} - W_{t-13} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \Theta_1 e_{t-1} \\
+ \theta_1 \Theta_1 e_{t-13} + \theta_2 \Theta_1 e_{t-14}
\end{aligned}
\quad (4.2)$$

Selanjutnya, model terpilih akan diuji melalui uji diagnostik residual untuk memastikan bahwa model telah memenuhi asumsi *white noise*.

4.2.4 Uji Asumsi Residual *White Noise*

Pengujian ini dilakukan untuk memastikan bahwa model yang dipilih telah memenuhi asumsi dalam analisis deret waktu. Pengujian dilakukan melalui uji residual *white noise*, yang bertujuan untuk mengetahui apakah residual model bersifat acak dan tidak mengandung autokorelasi. Residual yang memenuhi kondisi *white noise* menunjukkan bahwa seluruh informasi pada data telah berhasil dijelaskan oleh model. Pada penelitian ini, pengujian residual *white noise* dilakukan menggunakan metode *Ljung-Box Test*.

Uji *Ljung-Box* pada model SARIMA $(0,1,2)(0,1,1)_{12}$ menggunakan persamaan (2.34) dengan hipotesis sebagai berikut:

H_0 : residual memenuhi asumsi *white noise*

H_1 : residual tidak memenuhi asumsi *white noise*

dengan keputusan H_0 diterima apabila $p - value \geq \alpha$ atau jika $Q \leq \chi^2_{\alpha,df}$

Tabel 4.9 Uji *Ljung-Box Test*

Model	Lag	DF	Q	$\chi^2_{\alpha,df}$	<i>p-value</i>	Keterangan
SARIMA (0,1,2)(0,1,1) ₁₂	12	9	14,83	16,919	0,096	<i>White Noise</i>
	24	21	22,37	32,671	0,378	
	36	33	33,81	47,400	0,428	
	48	45	47,13	61,656	0,385	

Berdasarkan Tabel 4.8, hasil uji *Ljung-Box* menunjukkan bahwa pada model Sementara itu, pada model SARIMA $(0,1,2)(0,1,1)_{12}$ menunjukkan bahwa

nilai statistik Ljung-Box (Q) pada lag 12, 24, 36, dan 48 masing-masing sebesar 14,83; 22,37; 33,81; dan 47,13. Nilai tersebut lebih kecil daripada nilai kritis $\chi^2_{\alpha,df}$ masing-masing sebesar 16,919; 32,671; 47,400; dan 61,656. Selain itu, diperoleh nilai *p-value* pada lag 12, 24, 36, dan 48 masing-masing sebesar 0,096; 0,378; 0,428; dan 0,385, yang seluruhnya lebih besar dari $\alpha = 0,05$. Hal ini menunjukkan bahwa tidak terdapat autokorelasi yang signifikan pada residual, sehingga residual dapat dikatakan bersifat *white noise*.

Selain itu, terpenuhinya asumsi *white noise* menunjukkan bahwa model SARIMA (0,1,2)(0,1,1)₁₂ telah layak digunakan sebagai model dasar dalam pembentukan model SARIMAX. Model tersebut selanjutnya dikembangkan dengan menambahkan variabel eksogen yang diduga berpengaruh terhadap variabel respon.

4.2.5 Pemilihan Model SARIMA Terbaik

Pemilihan model SARIMA terbaik diantara kandidat SARIMA yang diuji dilakukan berdasarkan nilai *Mean Absolute Percentage Error* (MAPE). Nilai MAPE digunakan untuk mengukur tingkat akurasi peramalan dengan menghitung rata-rata persentase kesalahan absolut antara data aktual dan data hasil prediksi. Semakin kecil nilai MAPE yang diperoleh, maka semakin baik kemampuan model dalam melakukan peramalan. Berikut merupakan perhitungan manual dalam mencari nilai *error* dengan menggunakan MAPE berdasarkan persamaan (2.38)

$$\begin{aligned} \text{MAPE} &= \frac{100\%}{12} \left(\left| \frac{252.547 - 374.590,41}{252.547} \right| + \dots + \left| \frac{418.966 - 474.206,90}{418.966} \right| \right) \\ &= \frac{100\%}{12} (0,4833 + \dots + 0,1318) \end{aligned}$$

$$\begin{aligned}
&= \frac{100\%}{12} (6,4765) \\
&= 53,97\%
\end{aligned}$$

Berdasarkan hasil perhitungan diperoleh nilai MAPE sebesar 53,97%. Nilai tersebut menunjukkan bahwa rata-rata kesalahan hasil peramalan terhadap data aktual sebesar 53,97%. Karena nilai MAPE lebih besar dari 50%, maka model termasuk dalam kategori buruk (*poor forecasting*), sehingga model SARIMA yang digunakan belum mampu memberikan hasil peramalan yang akurat. Oleh karena itu, diperlukan pengembangan model yang dapat mengakomodasi pengaruh faktor-faktor eksternal yang diduga memengaruhi produksi padi.

4.3 Identifikasi Model SARIMAX

4.3.1 Analisis Variabel Eksogen

Analisis variabel eksogen dilakukan untuk mengetahui hubungan antara variabel eksogen dengan produksi padi serta mengidentifikasi adanya multikolinearitas antarvariabel eksogen. Variabel eksogen yang digunakan dalam penelitian ini meliputi luas lahan, curah hujan, suhu udara, kelembaban udara, lama penyinaran matahari, dan *Oceanic Niño Index* (ONI). Analisis dilakukan menggunakan korelasi Pearson dan uji multikolinearitas *Variance Inflation Factor* (VIF).

Uji korelasi Pearson digunakan karena mampu mengukur kekuatan dan arah hubungan linier antara dua variabel numerik. Selain nilai koefisien korelasi, pengujian signifikansi hubungan dilakukan menggunakan *p-value*. Hipotesis yang digunakan dalam pengujian korelasi Pearson adalah sebagai berikut:

H_0 : Tidak terdapat hubungan linier yang signifikan antara variabel eksogen dan variabel respon.

H_1 : Terdapat hubungan linier yang signifikan antara variabel eksogen dan variabel respon.

Dengan taraf signifikansi $\alpha = 5\%$, kriteria pengambilan keputusan adalah Jika $p\text{-value} < 0,05$ maka H_0 ditolak, sehingga terdapat hubungan linier yang signifikan antara variabel eksogen dan variabel respon. Hasil pengujian korelasi Pearson antara variabel respon dan variabel eksogen disajikan pada Tabel 4.9

Tabel 4.10 Uji Korelasi Pearson

Variabel	Korelasi	$p\text{-value}$
X_1	0,970	0,000
X_2	-0,258	0,031
X_3	0,329	0,006
X_4	0,200	0,024
X_5	-0,018	0,869
X_6	-0,247	0,024

Berdasarkan uji korelasi Pearson, variabel X_1 , X_2 , X_3 , X_4 dan X_6 memiliki $p\text{-value} < 0,05$ sehingga berhubungan signifikan dengan variabel respon dan dipertimbangkan sebagai kandidat variabel eksogen dalam pemodelan SARIMAX. Sementara itu, X_5 memiliki $p\text{-value} > 0,05$, sehingga tidak menunjukkan hubungan yang signifikan dengan variabel respon dan tidak diikutsertakan dalam tahap pemodelan selanjutnya.

Uji multikolinearitas dilakukan untuk mengetahui apakah terdapat hubungan linear yang kuat antarvariabel eksogen yang digunakan dalam model. Multikolinearitas yang tinggi dapat menyebabkan estimasi parameter menjadi tidak stabil dan mengurangi ketepatan interpretasi pengaruh masing-masing variabel terhadap variabel respon. Dalam penelitian ini, multikolinearitas diuji menggunakan *Variance Inflation Factor* (VIF). Variabel dinyatakan tidak mengalami multikolinearitas yang serius apabila memiliki nilai VIF kurang dari

10, sedangkan nilai VIF sebesar 10 atau lebih mengindikasikan adanya multikolinearitas yang serius.

Tabel 4.11 Uji *Variance Inflation Factor* (VIF)

Variabel	VIF	Keterangan
X_1	1,08	Tidak terjadi multikolinearitas
X_2	1,61	Tidak terjadi multikolinearitas
X_3	1,64	Tidak terjadi multikolinearitas
X_4	1,28	Tidak terjadi multikolinearitas
X_6	1,25	Tidak terjadi multikolinearitas

Berdasarkan Tabel 4.11, seluruh variabel eksogen memiliki nilai VIF kurang dari 10. Hal ini menunjukkan bahwa tidak terjadi multikolinearitas yang serius antarvariabel eksogen. Oleh karena itu, variabel X_1 , X_2 , X_3 , X_4 , dan X_6 dapat digunakan dalam pemodelan SARIMAX.

4.3.2 Uji Stasioner Variabel Eksogen

Sebelum digunakan dalam pemodelan SARIMAX, seluruh variabel eksogen perlu diuji stasioneritasnya untuk memastikan bahwa data tidak mengandung akar unit yang dapat menyebabkan hubungan semu (*spurious regression*). Pengujian stasioneritas dilakukan menggunakan uji Augmented Dickey-Fuller (ADF) pada variabel yang telah distandardisasi menggunakan metode *z-score*. Hipotesis yang digunakan dalam uji ADF adalah:

H_0 : Data memiliki *unit root* (tidak stasioner)

H_1 : Data tidak memiliki *unit root* (stasioner)

Kriteria pengambilan keputusan dalam uji ADF dapat dilakukan melalui dua pendekatan: Berdasarkan nilai p : Tolak H_0 jika nilai $p\text{-value} < \text{tingkat signifikansi}$ (α) dengan α sebesar 0,05 atau Berdasarkan statistik uji: Tolak H_0 jika nilai absolut dari statistik uji ($|t|$) lebih besar dari nilai kritis MacKinnon. Berikut adalah hasil uji stasioner variabel X_1 , X_2 , X_3 , X_4 , dan X_6 .

Tabel 4.12 Uji Stasioneritas terhadap Variabel Eksogen

Variabel	t- statistik	nilai kritis MacKinnon	<i>p-value</i>	Keterangan
X_1	-2,442331	-2,902358	0,1340	Tidak Stasioner
X_2	-1,610803	-2,901217	0,4721	Tidak Stasioner
X_3	-1,174430	-2,901779	0,6184	Tidak Stasioner
X_4	-3,707544	-2,898145	0,0057	Stasioner
X_6	-2,220703	-2,900137	0,2008	Tidak Stasioner

Berdasarkan Tabel 4.12, variabel X_4 memiliki nilai t-statistik sebesar $-3,707544$ yang lebih kecil daripada nilai kritis MacKinnon sebesar $-2,898145$ serta *p-value* sebesar $0,0057 (< 0,05)$, sehingga hipotesis nol ditolak dan variabel X_4 dinyatakan stasioner pada level, sedangkan variabel X_1 , X_2 , X_3 , dan X_6 memiliki nilai t-statistik yang lebih besar daripada nilai kritis MacKinnon dan *p-value* yang lebih besar dari $0,05$ sehingga belum stasioner pada level, oleh karena itu dilakukan *differencing* terhadap keempat variabel tersebut sebelum digunakan dalam pemodelan SARIMAX.

Tabel 4.13 Hasil Uji Stasioneritas Variabel Eksogen setelah *Differencing*

Variabel	Orde <i>Differencing</i>	t- statistik	nilai kritis MacKinnon (5%)	<i>p-value</i>	Keterangan
X_1	D(1)	-7,554192	-2,902953	0,0000	Stasioner
X_2	D(2)	-6,079820	-2,903566	0,0000	Stasioner
X_3	D(1)	-8,233849	-2,897233	0,0000	Stasioner
X_6	D(1)	-3,788942	-2,899619	0,0045	Stasioner

Berdasarkan Tabel 4.13, variabel X_1 , X_3 , dan X_6 telah stasioner setelah dilakukan *differencing* orde pertama, sedangkan variabel X_2 baru mencapai kondisi stasioner setelah *differencing* orde kedua. Hal ini ditunjukkan oleh nilai t-statistik masing-masing variabel yang lebih kecil daripada nilai kritis MacKinnon pada taraf signifikansi 5% serta nilai *p-value* yang lebih kecil dari $0,05$. Dengan demikian, seluruh variabel eksogen telah memenuhi asumsi stasioneritas dan

dapat digunakan dalam pemodelan SARIMAX.

4.3.3 Estimasi dan Uji Signifikansi Parameter Model

Berdasarkan hasil identifikasi model SARIMA, model yang terpilih yaitu model SARIMA $(0,1,2)(0,1,1)_{12}$ dari model tersebut maka terbentuk model SARIMA $(0,1,2)(0,1,1)_{12}$ sebagai model yang digunakan untuk peramalan Produksi padi di Jawa Barat dengan variabel eksogen yang dipilih berdasarkan hasil dari korelasi pearson yaitu Luas panen, Curah hujan, Suhu udara, Lama Penyinaran Matahari dan *Oceanic Niño Index* (ONI).

Berikut merupakan tabel hasil estimasi nilai parameter model dan uji signifikansi pada model SARIMAX. Model dikatakan signifikan apabila nilai $|t - \text{hitung}| > t - \text{tabel}$ atau nilai *p-value* lebih kecil daripada taraf signifikan.

Taraf signifikan yang digunakan adalah 5% ($\alpha = 0,05$) dengan hipotesis :

H_0 : Parameter model tidak signifikan

H_1 : Parameter model signifikan

Tabel 4.14 Nilai Estimasi dan Uji Signifikansi Parameter Model SARIMAX

Parameter	Estimasi	Std error	T-statistic	p-value	Keterangan
MA 1	-0,611656	0,070103	-8,725096	0,0000	Signifikan
MA 2	-0,383344	0,053026	-7,323617	0,0000	Signifikan
SMA 12	0,283082	0,117244	2,414478	0,0183	Signifikan
$D(X_1)$	3,197327	0,105824	30,21368	0,0000	Signifikan
$D(D(X_2))$	0,195659	0,070411	2,778799	0,0069	Signifikan
$D(X_3)$	-0,072829	0,110590	-0,658550	0,5123	Tidak Signifikan
X_4	-0,048660	0,029723	-1,637085	0,1059	Tidak Signifikan
$D(X_6)$	-0,248810	0,117716	-2,113650	0,0380	Signifikan

Berdasarkan Tabel 4.14, Pada taraf signifikansi 5% dengan derajat bebas sebesar $df = n - k = 72 - 8 = 64$, parameter MA(1), MA(2), SMA(12), ΔX_1 , $\Delta^2 X_2$, dan ΔX_6 signifikan pada taraf 5% karena memiliki $|t - \text{hitung}| > 1,997$ dan *p-value* $< 0,05$. Sementara itu, ΔX_3 dan X_4 tidak signifikan karena

memiliki $|t\text{-hitung}| < 1,997$ dan $p\text{-value} > 0,05$. Oleh karena itu, dilakukan estimasi ulang model dengan mengeliminasi ΔX_3 , yang memiliki $p\text{-value}$ terbesar, kemudian signifikansi parameter dievaluasi kembali hingga diperoleh model dengan seluruh parameter yang signifikan.

Tabel 4.15 Nilai Uji Signifikansi SARIMAX Variabel X_1, X_2, X_4 , dan X_6

Parameter	Estimasi	Std error	T-statistic	p-value	Keterangan
MA 1	-0,591522	0,061445	-9,626865	0,0000	Signifikan
MA 2	-0,408477	0,048423	-8,435629	0,0000	Signifikan
SMA 12	0,277935	0,112731	2,465467	0,0160	Signifikan
$D(X_1)$	3,191511	0,100425	31,78016	0,0000	Signifikan
$D(D(X_2))$	0,186217	0,064438	2,889845	0,0051	Signifikan
X_4	-0,053468	0,027680	-2,042560	0,0447	Signifikan
$D(X_6)$	-0,277381	0,106218	-2,611434	0,0109	Signifikan

Hasil estimasi pada Tabel 4.15 menunjukkan bahwa pada taraf signifikansi 5% dengan derajat bebas sebesar $df = 72 - 7 = 65$ diperoleh nilai t-tabel sebesar 1,997. Parameter MA(1), MA(2), SMA(12), ΔX_1 , $\Delta^2 X_2$, X_4 dan ΔX_6 memiliki nilai ($|t - \text{hitung}| > 1,997$) serta $p\text{-value}$ kurang dari 0,05, sehingga seluruh parameter tersebut signifikan pada taraf signifikansi 5%.

Tabel 4.16 Nilai AIC Model SARIMAX

Model	AIC
SARIMAX (0,1,2)(0,1,1) ₁₂ (X_1, X_2, X_3, X_4 dan X_6)	2,325160
SARIMAX (0,1,2)(0,1,1) ₁₂ (X_1, X_2, X_4 dan X_6)	2,306404

Berdasarkan perbandingan nilai *Akaike Information Criterion* (AIC), model SARIMAX (0,1,2)(0,1,1)₁₂ dengan variabel (X_1, X_2, X_4 , dan X_6) memiliki nilai AIC yang lebih kecil yaitu sebesar 2,306404 dibandingkan dengan model yang menggunakan seluruh variabel (X_1, X_2, X_3, X_4 dan X_6) sebesar 2,325160. Hal ini menunjukkan bahwa model hasil reduksi lebih efisien dan optimal dalam menjelaskan data. Dari model SARIMAX (0,1,2)(0,1,1)₁₂ dengan variabel ΔX_1 , $\Delta^2 X_2$, X_4 dan ΔX_6 tersebut dapat juga ditulis menggunakan Persamaan (2.24),

Berdasarkan hasil pengujian stasioneritas, variabel luas lahan (X_1) dan ENSO (X_6) menjadi stasioner setelah *differencing* orde satu, sedangkan variabel curah hujan (X_2) menjadi stasioner setelah *differencing* orde dua. Variabel lama penyinaran matahari (X_4) telah stasioner pada data asli. Oleh karena itu, variabel eksogen yang digunakan dalam model SARIMAX adalah ΔX_1 , $\Delta^2 X_2$, X_4 dan ΔX_6

$$\begin{aligned}
 \Delta W_t &= \beta_0 + \beta_1 \Delta X_{1,t} + \beta_2 \Delta^2 X_{2,t} + \beta_4 X_{4,t} + \beta_6 \Delta X_{6,t} + \frac{\theta_2(B)\theta_1(B^{12})}{(1-B)(1-B^{12})} e_t \\
 &= \beta_0 + \beta_1 \Delta X_{1,t} + \beta_2 \Delta^2 X_{2,t} + \beta_4 X_{4,t} + \beta_6 \Delta X_{6,t} \\
 &\quad + \frac{(1 - \theta_1 B - \theta_2 B^2)(1 - \theta_1 B^{12})}{(1 - B)(1 - B^{12})} e_t \\
 &= \beta_0 + \beta_1 \Delta X_{1,t} + \beta_2 \Delta^2 X_{2,t} + \beta_4 X_{4,t} + \beta_6 \Delta X_{6,t} \\
 &\quad + \frac{1 - \theta_1 B - \theta_2 B^2 - \theta_1 B^{12} + \theta_1 \theta_1 B^{13} + \theta_2 \theta_1 B^{14}}{(1 - B)(1 - B^{12})} e_t
 \end{aligned} \tag{4.3}$$

Parameter MA(1) dan MA(2) menunjukkan pengaruh error pada satu dan dua periode sebelumnya, sedangkan SMA(12) menunjukkan adanya pengaruh musiman tahunan. Selain itu, variabel X_1 , dan X_2 memiliki pengaruh positif terhadap variabel dependen, sedangkan variabel X_4 dan X_6 memiliki pengaruh negatif terhadap variabel dependen. berdasarkan Tabel 4.15, persamaan SARIMAX yang diperoleh

$$\begin{aligned}
 \Delta W_t &= 3,191511 \Delta X_{1,t} + 0,186217 \Delta^2 X_{2,t} - 0,053468 X_{4,t} \\
 &\quad - 0,277381 \Delta X_{6,t} \\
 &\quad + \frac{(1 - 0,591522B - 0,408477B^2)(1 + 0,277935B^{12})}{(1 - B)(1 - B^{12})} e_t
 \end{aligned} \tag{4.4}$$

Berdasarkan model SARIMAX (0,1,2)(0,1,1)₁₂ yang diperoleh, produksi padi di Provinsi Jawa Barat dipengaruhi oleh luas panen, curah hujan, lama penyinaran matahari, dan *Oceanic Niño Index* (ONI). Variabel luas panen menunjukkan bahwa setiap kenaikan satu satuan luas panen akan meningkatkan produksi padi sekitar 3,19 kali. Variabel curah hujan menunjukkan bahwa setiap kenaikan satu satuan curah hujan akan meningkatkan produksi padi sekitar 18,6%. Sebaliknya, lama penyinaran matahari menunjukkan bahwa setiap peningkatan satu satuan nilai lama penyinaran matahari cenderung menurunkan produksi padi sebesar 5,3% dan ONI menunjukkan bahwa setiap peningkatan satu satuan nilai ONI cenderung menurunkan produksi padi sebesar 27,7%, yang menunjukkan bahwa peningkatan lama penyinaran matahari maupun nilai ONI cenderung menurunkan produksi padi di Provinsi Jawa Barat.

Selain dipengaruhi oleh variabel eksogen, produksi padi juga dipengaruhi oleh komponen *moving average* dan *seasonal moving average*. Komponen MA(1) dan MA(2) masing-masing memiliki koefisien sebesar -0,591522 dan -0,408477, yang menunjukkan bahwa produksi padi pada periode saat ini dipengaruhi oleh gangguan atau residual pada satu dan dua periode sebelumnya. Sementara itu, komponen SMA(12) memiliki koefisien sebesar 0,277935 yang menunjukkan adanya pengaruh residual musiman dari dua belas periode sebelumnya. Hal ini mengindikasikan bahwa produksi padi di Provinsi Jawa Barat memiliki pola musiman tahunan yang cukup kuat dan dipengaruhi oleh kondisi pada periode-periode sebelumnya.

Karena data merupakan hasil *differencing* nonmusiman orde satu dan *differencing* musiman orde satu, maka berlaku

$$\Delta W_t = W_t - W_{t-1} - W_{t-12} + W_{t-13}$$

sehingga proses pengembalian ke bentuk sebelum *differencing* dilakukan menggunakan invers *differencing*

$$W_t = \Delta W_t + W_{t-1} + W_{t-12} - W_{t-13} \quad (4.5)$$

karena telah ditransformasi Box-cox dengan menggunakan rumus pada persamaan (4.1)

$$W_t = Z_t^{1/4}$$

maka, hasil dikembalikan ke dalam skala asli menggunakan transformasi invers, dari data transformasi adalah sebagai berikut:

$$Z_t = W_t^4 \quad (4.6)$$

Dengan demikian, nilai ramalan diperoleh dengan menghitung ΔW_t menggunakan Persamaan (4.4), kemudian melakukan *invers differencing* menggunakan Persamaan (4.5), dan selanjutnya menerapkan transformasi invers Box-Cox menggunakan Persamaan (4.6) untuk memperoleh nilai produksi padi pada skala asli.

Pada perhitungan manual prediksi data ke-73 digunakan beberapa komponen yang berasal dari nilai data transformasi dan residual pada periode sebelumnya. Nilai 24,4703 merupakan nilai W_{72} (lag ke-1), nilai 26,2846 merupakan nilai W_{61} (lag ke-12), dan nilai 25,0098 merupakan nilai W_{60} (lag ke-13) yang muncul akibat proses *differencing* musiman pada model SARIMAX. Selain itu, digunakan residual periode sebelumnya yaitu ($e_{72} = 1,5000$), ($e_{71} = 1,4364$), dan ($e_{60} = 0,147348$) untuk komponen *moving average* dan *seasonal moving average*. Adapun nilai variabel eksogen yang digunakan adalah

$\Delta X_{1,73} = (-1,46703 + 1,18191)$, $\Delta^2 X_{2,73} = (0,74276 - 2(1,62084) + 4,22924)$, $X_{4,73} = -0,78999$, dan $\Delta X_{6,73} = (2,21766 - 2,45710)$. Perhitungan manual pada data ke 73:

$$\begin{aligned}\Delta W_{73} &= 3,191511(-1,46703 + 1,18191) + 0,186217(0,74276 \\ &\quad - 2(1,62084) + 4,22924) - 0,053468(-0,78999) \\ &\quad - 0,277381(2,21766 - 2,45710) - 0,591522(1,50) \\ &\quad - 0,408477(1,4364) + 0,277935(0,147348) \\ &\quad - 0,591522(0,277935)(1,3858) \\ &\quad - 0,408477(0,277935)(0,189513) \\ &= -2,15909\end{aligned}$$

Selanjutnya dilakukan invers *differencing*:

$$\begin{aligned}W_{73} &= \Delta W_{73} + W_{72} + W_{61} - W_{60} \\ &= -2,15909 + 24,4703 + 26,2846 - 25,0098 \\ &= 23,58601\end{aligned}$$

Karena data telah ditransformasi menggunakan Box-Cox dengan ($\lambda=0,25$), maka dilakukan transformasi invers:

$$\begin{aligned}Z_{73} &= W_{73}^4 \\ &= [23,58601]^4 \\ &= 309.496,70\end{aligned}$$

4.3.4 Akurasi Peramalan


Selanjutnya mencari nilai *error* menggunakan persamaan dari model SARIMAX (0,1,2)(0,1,1)₁₂ dengan variabel X_1 , X_2 , X_4 , dan X_6). Model yang telah diperoleh digunakan untuk melakukan peramalan produksi padi pada periode mendatang, yaitu selama 12 periode ke depan (Januari 2024 hingga

Desember 2024). Hasil peramalan kemudian dibandingkan dengan data *testing*, yaitu data aktual pada 12 periode terakhir yang tidak digunakan dalam proses pembentukan model. Hasil peramalan kemudian dibandingkan dengan data aktual pada data *testing* yang tidak digunakan dalam proses pembentukan model. Perbandingan tersebut digunakan untuk menghitung nilai *Mean Absolute Percentage Error* (MAPE) sebagai ukuran tingkat akurasi model. Berikut disajikan hasil prediksi produksi padi Provinsi Jawa Barat pada periode Januari 2024 sampai dengan Desember 2024.

Tabel 4.17 Hasil Prediksi SARIMAX (0,1,2)(0,1,1)₁₂ terhadap Data Aktual

Bulan	Data Aktual	Hasil Prediksi
Januari 2024	252.547	309.496,70
Februari 2024	151.954	271.990,67
Maret 2024	600.150	580.679,79
April 2024	1.430.700	1.396.960,59
Mei 2024	1.547.699	1.687.201,49
Juni 2024	575.487	555.566,63
Juli 2024	549.458	570.374,82
Agustus 2024	726.553	712.798,95
September 2024	697.391	667.989,67
Oktober 2024	933.710	827.839,65
November 2024	742.234	678.731,69
Desember 2024	418.996	431.507,98

Berdasarkan tabel tersebut, selanjutnya dibuat grafik sebagai berikut:



Gambar 4.11 Grafik Hasil Prediksi terhadap Data Aktual

Berdasarkan perbandingan antara data aktual dan hasil prediksi yang ditunjukkan pada Tabel 4.17 dan Gambar 4.11, terlihat bahwa model mampu mengikuti pola pergerakan data aktual dengan cukup baik. Meskipun demikian, diperlukan pengukuran secara kuantitatif untuk mengetahui tingkat akurasi model yang dihasilkan. Oleh karena itu, dilakukan perhitungan tingkat kesalahan peramalan menggunakan nilai MAPE. Secara matematis nilai MAPE didapatkan dengan rumus pada persamaan (2.38) sebagai berikut:

$$\begin{aligned}\text{MAPE} &= \frac{1,5143}{12} \times 100\% \\ &= 0,1262 \times 100\% = 12,62\%\end{aligned}$$

Berdasarkan hasil perhitungan, diperoleh nilai MAPE sebesar 12,62%. Nilai tersebut menunjukkan bahwa rata-rata kesalahan prediksi model terhadap data aktual sebesar 12,62%. Karena nilai MAPE $10\% \leq x < 20\%$, maka model yang digunakan tergolong baik dalam melakukan peramalan.

4.3.5 Uji Asumsi Residual *White Noise*

Uji Residual *White Noise* pada SARIMAX dilakukan untuk mengetahui kelayakan model, Uji ini membantu memastikan bahwa residual dari model bersifat acak dan tidak menunjukkan pola autokorelasi. Model dikatakan layak jika nilai probabilitas yang dihasilkan dari kedua uji tersebut lebih besar dari 0,05.

Tabel 4.18 Uji *Ljung-Box Test* SARIMAX

Model	Lag	DF	<i>Q-stat</i>	$\chi^2_{\alpha,df}$	<i>p-value</i>	Keterangan
SARIMAX (0,1,2)(0,1,1) ₁₂ dengan X_1 , X_2 , X_4 , dan X_6)	12	9	10,113	16,919	0,341	<i>White Noise</i>
	24	21	20,140	30,144	0,512	<i>White Noise</i>
	36	33	26,029	47,400	0,801	<i>White Noise</i>
	48	45	50,942	61,656	0,251	<i>White Noise</i>

Berdasarkan Tabel 4.18, hasil uji *Ljung-Box* pada model SARIMAX (0,1,2)(0,1,1)₁₂ dengan variabel X_1, X_2, X_4 , dan X_6 menunjukkan bahwa nilai

statistik Ljung-Box (Q -stat) pada lag 12, 24, 36, dan 48 masing-masing memiliki nilai lebih kecil dibandingkan nilai kritis $\chi^2_{\alpha,df}$. Selain itu, nilai p -value pada lag 12, 24, 36, dan 48 semuanya lebih besar dari taraf signifikansi $\alpha = 5\%$. Hal ini menunjukkan bahwa gagal menolak H_0 , sehingga dapat disimpulkan bahwa residual tidak mengandung autokorelasi dan telah memenuhi asumsi *white noise*.

Dengan demikian, model SARIMAX (0,1,2)(0,1,1)₁₂ dengan variabel X_1 , X_2 , X_4 , dan X_6) layak digunakan sebagai model yang baik dalam analisis dan peramalan.

4.3.6 Peramalan Jumlah Produksi Padi

Model SARIMAX memerlukan nilai variabel eksogen pada periode yang akan diramalkan sebagai input model. Dalam penelitian ini, variabel eksogen yang digunakan meliputi variabel X_1 , X_2 , X_4 , dan X_6 . Karena data keempat variabel tersebut untuk tahun 2025 belum tersedia pada saat penelitian dilakukan, maka digunakan pendekatan skenario dasar (*baseline scenario*) dengan mengasumsikan nilai variabel eksogen berada pada tingkat rata-rata historis selama periode pengamatan. Nilai rata-rata historis tersebut kemudian digunakan sebagai input dalam model SARIMAX untuk menghasilkan peramalan produksi padi tahun 2025. Perhitungan nilai rata-rata historis bulanan disajikan pada Lampiran 6.

Berdasarkan model SARIMAX (0,1,2)(0,1,1)₁₂ yang telah diperoleh, selanjutnya dilakukan peramalan untuk periode Januari hingga Desember 2025. Selain menghasilkan nilai peramalan, model juga menghasilkan *forecast standard error* yang digunakan untuk membentuk interval kepercayaan 95% melalui rumus:

$$\hat{Z}_t \pm 1,96(SE)$$

Interval kepercayaan digunakan untuk menunjukkan rentang nilai yang diperkirakan memuat nilai aktual produksi padi pada tingkat kepercayaan 95%. Interval ini dibentuk berdasarkan hasil peramalan dan *forecast standard error* yang dihasilkan model. Sebagai contoh, untuk bulan Januari 2025 diperoleh nilai hasil peramalan pada skala transformasi sebesar 25,81517 dengan *forecast standard error* sebesar 0,809682. Dengan menggunakan tingkat kepercayaan 95%, batas bawah dan batas atas interval dihitung menggunakan rumus $\hat{Z}_t \pm 1,96(SE)$ Hasil perhitungan tersebut memberikan rentang nilai yang diperkirakan memuat nilai aktual produksi padi pada bulan Januari 2025 dengan tingkat keyakinan sebesar 95%.

$$\text{Lower} = 25,81517 - 1,96(0,809682) = 24,22819$$

$$\text{Upper} = 25,81517 + 1,96(0,809682) = 27,40215$$

Selanjutnya dilakukan inverse transformasi Box-Cox

$$\text{Lower} = (24,22819)^4 = 344.687,07$$


$$\text{Upper} = (27,40215)^4 = 563.679,95$$

Dengan demikian, interval kepercayaan 95% untuk hasil peramalan produksi padi pada bulan Januari 2025 berada pada rentang 344.687,07 ton hingga 563.679,95 ton. Hasil peramalan beserta interval kepercayaan 95% untuk periode Januari hingga Desember 2025 selanjutnya disajikan pada Tabel 4.19.

Tabel 4.19 Peramalan Produksi Padi di Jawa Barat 2025

Bulan	Hasil Peramalan	Batas Bawah 95%	Batas atas 95%
Januari 2025	443.867,29	344.575,28	563.817,24
Februari 2025	529.992,81	416.231,33	665.795,19
Maret 2025	1.263.228,56	1.037.895,30	1.524.338,70
April 2025	1.308.718,03	1.076.747,24	1.577.324,53
Mei 2025	864.749,96	698.894,67	1.059.271,40
Juni 2025	710.212,77	567.421,77	877.790,74
Juli 2025	961.977,17	780.687,26	1.172.463,07
Agustus 2025	792.907,73	637.678,18	974.744,68
September 2025	711.475,13	569.576,51	880.337,92
Oktober 2025	627.131,88	497.159,55	780.458,73
November 2025	554.323,08	436.243,94	695.032,77
Desember 2025	448.516,75	348.300,54	569.560,74

Berdasarkan tabel hasil peramalan tersebut, selanjutnya dibuat grafik sebagai berikut:

**Gambar 4.12** Grafik Peramalan Produksi Padi di Jawa Barat Tahun 2025

Berdasarkan hasil peramalan pada Tabel 4.15 dan gambar 4.12, produksi padi di Provinsi Jawa Barat tahun 2025 diperkirakan menunjukkan pola yang berfluktuasi sepanjang periode peramalan. Pada awal tahun, produksi padi hasil peramalan sebesar 443.867,29 ton pada bulan Januari dan meningkat menjadi 529.992,81 ton pada bulan Februari. Peningkatan yang cukup besar terjadi pada

bulan Maret dengan hasil peramalan sebesar 1.263.228,56 ton dan mencapai puncaknya pada bulan April sebesar 1.308.718,03 ton.

Setelah mencapai nilai tertinggi pada bulan April, produksi padi diperkirakan mengalami penurunan menjadi 864.749,96 ton pada bulan Mei dan kembali menurun menjadi 710.212,77 ton pada bulan Juni. Pada bulan Juli terjadi peningkatan kembali menjadi 961.977,17 ton, namun selanjutnya produksi padi cenderung menurun secara bertahap hingga akhir tahun, yaitu sebesar 792.907,73 ton pada bulan Agustus, 711.475,13 ton pada bulan September, 627.131,88 ton pada bulan Oktober, 554.323,08 ton pada bulan November, dan 448.516,75 ton pada bulan Desember.

Secara umum, hasil peramalan menunjukkan adanya pola musiman tahunan pada produksi padi di Provinsi Jawa Barat. Produksi cenderung meningkat pada awal hingga pertengahan tahun dan mencapai puncak pada bulan Maret–April yang bertepatan dengan periode panen utama, kemudian menurun pada paruh akhir tahun setelah periode panen berakhir. Pola musiman tersebut berhasil ditangkap oleh model SARIMAX $(0,1,2)(0,1,1)_{12}$ melalui komponen musiman orde 12 yang terdapat dalam model.

Selain dipengaruhi oleh pola historis dan komponen musiman, hasil peramalan juga dipengaruhi oleh variabel eksogen yang digunakan dalam model, yaitu luas panen X_1 , curah hujan X_2 , lama penyinaran matahari X_4 , dan *Oceanic Niño Index* (ONI) X_6 . Berdasarkan hasil estimasi parameter, luas panen memiliki pengaruh positif terhadap produksi padi dengan koefisien sebesar 3,191511. Curah hujan juga memiliki pengaruh positif dengan koefisien sebesar 0,186217, yang menunjukkan bahwa peningkatan curah hujan cenderung meningkatkan

produksi padi. Sebaliknya, lama penyinaran matahari memiliki koefisien negatif sebesar -0,053468 dan ONI memiliki koefisien negatif sebesar -0,277381, yang mengindikasikan bahwa peningkatan kedua variabel tersebut cenderung menurunkan produksi padi. Seluruh variabel eksogen tersebut signifikan pada taraf signifikansi 5%, sehingga memberikan kontribusi yang nyata dalam menjelaskan perubahan produksi padi di Provinsi Jawa Barat.

4.4 Integrasi Islam

Hasil peramalan menggunakan model SARIMAX menunjukkan bahwa produksi padi di Provinsi Jawa Barat tahun 2025 diperkirakan berfluktuasi dengan produksi tertinggi terjadi pada bulan April sebesar 1.308.718,03 ton dan terendah pada bulan Januari sebesar 443.867,29 ton. Informasi ini dapat digunakan sebagai dasar dalam menyusun strategi pengelolaan pangan, perencanaan produksi, serta antisipasi terhadap risiko yang dapat memengaruhi ketahanan pangan.

Dalam perspektif Islam, kegiatan peramalan merupakan salah satu bentuk ikhtiar manusia untuk mempersiapkan masa depan berdasarkan informasi yang tersedia. Hal ini sejalan dengan firman Allah Swt. dalam Q.S. Al-Hasyr ayat 18, yang berbunyi (Kemenag, 2022):

يَا أَيُّهَا الَّذِينَ آمَنُوا اتَّقُوا اللَّهَ وَلْتَنْظُرْ نَفْسٌ مَّا قَدَّمَتْ لِغَدٍ وَاتَّقُوا اللَّهَ ۚ إِنَّ اللَّهَ خَبِيرٌ بِمَا تَعْمَلُونَ

“Wahai orang-orang yang beriman! Bertakwalah kepada Allah dan hendaklah setiap orang memperhatikan apa yang telah diperbuatnya untuk hari esok (akhirat), dan bertakwalah kepada Allah. Sungguh, Allah Maha teliti terhadap apa yang kamu kerjakan.” (Q.S. Al-Hasyr: 18)

Ayat tersebut mengajarkan pentingnya perencanaan dan persiapan dalam menghadapi masa depan. Dalam penelitian ini, peramalan produksi padi dilakukan sebagai upaya untuk menyediakan informasi yang dapat mendukung pengambilan keputusan dan perencanaan sektor pertanian. Selain itu, terdapat pula dalil lain yang

berkaitan dengan pentingnya perencanaan dan usaha dalam kehidupan, yaitu pada surat Yusuf ayat 47–48 (Kemenag, 2022):

قَالَ تَزْرَعُونَ سَبْعَ سِنِينَ دَأْبًا فَمَا حَصَدْتُمْ فَذَرُوهُ فِي سُنْبُلِهِ إِلَّا قَلِيلًا مِّمَّا تَأْكُلُونَ ﴿٤٧﴾ ثُمَّ يَأْتِي مِنْ بَعْدِ ذَلِكَ سَبْعٌ شِدَادٌ يَأْكُلْنَ مَا قَدَّمْتُمْ لَهُنَّ إِلَّا قَلِيلًا مِّمَّا تُخْصِنُونَ

“Dia (Yusuf) berkata, ‘Agar kamu bercocok tanam tujuh tahun (berturut-turut) sebagaimana biasa; kemudian apa yang kamu tuai hendaklah kamu biarkan di tangkainya kecuali sedikit untuk kamu makan. Kemudian setelah itu akan datang tujuh tahun yang sangat sulit, yang menghabiskan apa yang kamu simpan untuk menghadapinya, kecuali sedikit dari apa yang kamu simpan.’” (Q.S. Yusuf: 47–48)

Ayat tersebut menunjukkan pentingnya perencanaan, pengelolaan hasil pertanian, dan penyusunan strategi untuk menghadapi kemungkinan terjadinya kondisi yang kurang menguntungkan di masa mendatang. Dalam konteks penelitian ini, hasil peramalan produksi padi dapat dimanfaatkan sebagai dasar dalam pengelolaan cadangan pangan, penyusunan kebijakan pertanian, serta mitigasi risiko akibat perubahan iklim, curah hujan, dan fenomena El Niño. Dengan demikian, penggunaan metode SARIMAX dapat dipandang sebagai bentuk ikhtiar yang memanfaatkan ilmu pengetahuan untuk mendukung ketahanan pangan dan kesejahteraan masyarakat.

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan dari penelitian yang dilakukan, didapatkan beberapa kesimpulan sebagai berikut:

1. Hasil evaluasi akurasi model SARIMAX $(0,1,2)(0,1,1)_{12}$ dengan variabel eksogen X_1 , X_2 , X_4 dan X_6 menunjukkan bahwa nilai *Mean Absolute Percentage Error* (MAPE) yang diperoleh sebesar 12,62%. Nilai tersebut berada pada rentang 10%-20%, yang menunjukkan bahwa model memiliki tingkat akurasi yang baik dalam melakukan peramalan. Hal ini mengindikasikan bahwa model mampu memprediksi produksi padi dengan tingkat kesalahan yang relatif rendah dibandingkan nilai aktual. Oleh karena itu, model SARIMAX $(0,1,2)(0,1,1)_{12}$ layak digunakan untuk melakukan peramalan produksi padi di Provinsi Jawa Barat pada periode Januari hingga Desember 2025.
2. Hasil peramalan produksi padi di Provinsi Jawa Barat tahun 2025 menunjukkan pola musiman tahunan yang jelas, dengan produksi tertinggi diperkirakan terjadi pada bulan April sebesar 1.308.718,03 ton dan terendah pada bulan Desember sebesar 448.516,75 ton. Hasil ini menunjukkan bahwa model SARIMAX $(0,1,2)(0,1,1)_{12}$ mampu menangkap pola musiman produksi padi dengan baik. Selain itu, produksi padi juga dipengaruhi oleh variabel eksogen yang signifikan, yaitu luas panen X_1 dan curah hujan X_2 yang berpengaruh positif, serta lama penyinaran matahari X_4 dan *Oceanic Niño Index* (ONI) X_6 yang berpengaruh negatif terhadap produksi padi.

5.2 Saran

Hasil peramalan produksi padi yang diperoleh pada penelitian ini dapat digunakan oleh Pemerintah Provinsi Jawa Barat, Dinas Tanaman Pangan dan Hortikultura Provinsi Jawa Barat, Dinas Ketahanan Pangan dan Peternakan Provinsi Jawa Barat, Badan Pusat Statistik (BPS) Provinsi Jawa Barat, serta Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) sebagai bahan pertimbangan dalam perencanaan produksi, penyusunan kebijakan ketahanan pangan, serta pengelolaan distribusi beras pada periode mendatang. Berdasarkan hasil pemodelan, luas panen dan curah hujan memiliki pengaruh positif terhadap produksi padi, sehingga diperlukan upaya untuk menjaga keberlanjutan lahan pertanian produktif, mengoptimalkan pemanfaatan lahan pertanian, serta meningkatkan pengelolaan sumber daya air dan sistem irigasi. Selain itu, pengaruh negatif lama penyinaran matahari dan *Oceanic Niño Index* (ONI) menunjukkan pentingnya pemantauan kondisi iklim dan penyusunan strategi mitigasi yang tepat untuk mengurangi dampak anomali iklim terhadap produksi padi.

Berdasarkan kesimpulan pada penelitian ini, penelitian selanjutnya disarankan untuk mengombinasikan atau membandingkan model SARIMAX dengan metode lain, seperti *Vector Autoregression* (VAR) untuk menangkap hubungan antarvariabel, serta metode berbasis *machine learning* seperti *Long Short-Term Memory* (LSTM) yang mampu menangkap pola nonlinier pada data deret waktu. Selain itu, pendekatan hybrid yang menggabungkan model SARIMAX dengan metode machine learning juga dapat dipertimbangkan untuk meningkatkan akurasi hasil peramalan.

DAFTAR PUSTAKA

- Adib Azka, M., & Trilaksono, N. J. (2025). Comparative analysis of diurnal and seasonal variations in precipitation of mesoscale convective system and non-mesoscale convective system over Borneo Island.
- Aditya, F., Gusmayanti, E., & Sudrajat, J. (2021). Pengaruh perubahan curah hujan terhadap produktivitas padi sawah di Kalimantan Barat. *Jurnal Ilmu Lingkungan*, 19(1), 13–22.
- Ahanda, B., Yolcu, T., & Watson, R. (2025). *Forecasting Arctic sea ice extent trend using time series models: NNAR, SARIMA and SARIMAX using the data prior to the COVID-19 pandemic*. *Discover Geoscience*, 3, 18. <https://doi.org/10.1007/s44288-025-00113-w>
- Akaike, H. (1974). *A new look at the statistical model identification*. *IEEE Transactions on Automatic Control*, 19(6), 716–723.
- Ansari, A., Pranesti, A., Telaumbanua, M., Alam, T., Taryono, T., Wulandari, R. A., Nugroho, B. D. A., & Supriyanta. (2023). Evaluating the effect of climate change on rice production in Indonesia using multimodelling approach. *Heliyon*, 9(11), e19639. <https://doi.org/10.1016/j.heliyon.2023.e19639>
- Aswi, A., & Sukarna, A. (2006). *Analisis deret waktu: Teori dan aplikasi*. Yogyakarta: Andi.
- Badan Pusat Statistik Provinsi Jawa Barat. (2024). *Produksi Tanaman Padi Kabupaten/Kota menurut Bulan di Provinsi Jawa Barat (Ton-GKG)*.
- BMKG. (2025). Direktori Data Dan Komputasi. Badan Meteorologi Klimatologi Dan Geofisika.
- Contreras-Reyes, J. E., & Palma, W. (2023). SARIMAX models for forecasting environmental and economic time series. *Environmental Modelling & Software*. <https://doi.org/10.1016/j.envsoft.2023.105753>
- Cryer, J. D. (2008). *Time series analysis: With applications in R* (2nd ed.). New York: Springer. <https://doi.org/10.1007/978-0-387-75959-3>
- Deshafa, A. F., Nurfaida, A. S., & Ananda, M. (2025). *ENSO and IOD Variability: Impacts on Precipitation and Rainfall Patterns in Indonesia*. *Jurnal Penelitian Sains Atmosfer*, 14(1), 22–34.
- Dewi, N. P. A. S., & Meydianawathi, L. G. (2025). *Analysis of rice production scale in Kerambitan Sub-district, Tabanan Regency*. *International Journal of Economics, Management and Accounting (IJEMA)*.
- Enders, W. (2015). *Applied econometric time series* (4th ed.). Hoboken, NJ: Wiley.
- Hermawan, W. (2024). *Spatial rainfall distribution in the eastern part of West Java*. *Journal of Science and Technology for Meteorology and Climatology*, 1(1), 15–25.
- Hyndman, R. J., & Athanasopoulos, G. (2023). *Forecasting: Principles and practice* (3rd ed.). Melbourne: OTexts.
- Juswadi, J., Sumarna, P., & Mulyati, N. S. (2020). *Keragaan produktivitas padi sawah Jawa Barat dan faktor yang mempengaruhinya*. *Paspalum: Jurnal Ilmiah Pertanian*, 8(2), 123–130. <https://doi.org/10.35138/paspalum.v8i2.199>

- Kemenag. (2022). Qur'an Kemenag. Lajnah Pentashihan Mushaf Al-Qur'an. <https://quran.kemenag.go.id/>
- Kothe, S., Pfeifroth, U., Cremer, R., Trentmann, J., & Hollmann, R. (2024). A satellite-based sunshine duration climate record for global agroclimate monitoring. *Remote Sensing*, 16(2), 112-128.
- Muslim. (2008). *Sahih Muslim*, Hadith No. 1553a (Book 22, Hadith 12). from <https://sunnah.com/muslim:1553a>
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1999). *Forecasting: Methods and applications*. New York: John Wiley & Sons.
- Nasirudin, F. & Ahmad Dzikrullah, A. (2023). *Pemodelan Harga Cabai Indonesia dengan Metode Seasonal ARIMAX*. *Jurnal Statistika dan Aplikasinya*, 7(1), 105–115. <https://doi.org/10.21009/jsa.07110>
- NOAA. (2025). *Ocean Niño Index (ONI) Monitoring Report*. National Oceanic and Atmospheric Administration
- Novita Dharma, P. H., Setyawan, F. O., & Siregar, D. (2024). *El Niño dan La Niña: Pengaruhnya terhadap Parameter Oseanografi di Bali*. *Jurnal Ilmu Kelautan Tropis*, 12(1), 45–56.
- Oh, D., Lee, J., & Kim, H. (2023). Effect of elevated air temperature on the growth and yield of paddy rice. *Agriculture*, 13(12), 2887.
- Prasetyo, O. R., & Kadir, K. (2023). Climate change impact on paddy yield in Indonesia: Farmers' experience based on the 2021 crop-cutting survey's results. *MPRA Paper No. 119446*.
- Purwaningrum, Y., Simbolon, D., & Siregar, R. (2025). Pengaruh perubahan iklim terhadap produktivitas tanaman padi gogo (*Oryza sativa* L.). *AGRILAND Jurnal Ilmu Pertanian*, 13(1), 18–22.
- Rahmawati, N., Prasetyo, D., & Munandar, A. (2023). Influence of air humidity and temperature variation on rice growth and yield under tropical climate conditions. *Journal of Agronomic Research*, 15(2), 97–108. <https://doi.org/10.1016/j.jar.2023.00211>
- Ruminta, R., Hasanah, S., & Permana, R. (2024). Identifikasi perubahan suhu dan curah hujan serta korelasinya dengan produktivitas padi di Kabupaten Garut. *Jurnal Agrikultura*, 35(3), 145–153.
- Santoso, A. B., Supriana, T., & Girsang, M. (2022). Pengaruh curah hujan terhadap produksi padi gogo di Indonesia. *Jurnal Ilmu Pertanian Indonesia*, 27(3), 321–330.
- Semiwati, S. (2025). *Pengaruh modal, luas lahan, dan harga jual terhadap pendapatan petani padi di Desa Hijrah Baru, Kabupaten Sumbawa*. *PENDAS: Jurnal Ilmiah Pendidikan Dasar*.
- Song, L., Zhang, W., & Chen, H. (2023). Effects of sunshine duration and seasonal radiation patterns on rice productivity in tropical agriculture. *Agronomy*, 13(4), 566-580.
- Sungkawa, I., & Megasari, R. T. (2023). Penerapan MAPE dalam evaluasi peramalan data deret waktu. *ComTech Journal*, 2(2). <https://doi.org/10.21512/comtech.v2i2.2813>
- Syahna, E. S., Yunizar, Z., & Fitri, Z. (2024). *Implementation of the Seasonal Autoregressive Integrated Moving Average with Exogenous Variables (SARIMAX) Algorithm for Rice Price Prediction*. In *Proceedings of*

- International Conference on Multidisciplinary Engineering (ICOMDEN)*, 2, Article 00024.
- Vannieuwenhoven, N., Dekimpe, M. G., & Franses, P. H. (2024). Advances in time series forecasting: New methods and applications. *International Journal of Forecasting*, 40(1), 1–20. <https://doi.org/10.1016/j.ijforecast.2023.05.004>
- Wang, B.-X., Hof, A. R., & Ma, C.-S. (2021). *Impacts of climate change on crop production, pests and pathogens of wheat and rice*. Frontiers in Agricultural Science and Engineering. <https://doi.org/10.15302/J-FASE-2021432>
- Wei, W. W. S. (2006). *Time series analysis: Univariate and multivariate methods* (2nd ed.). Boston: Pearson Addison Wesley.
- World Meteorological Organization. (2023). *Guidelines on meteorological variables and observation standards*. WMO Publications.
- Yuniasih, B., Harahap, W. N., & Wardana, D. A. S. (2023). Anomali iklim El Niño dan La Niña di Indonesia pada 2013–2022. *AGROISTA: Jurnal Agroteknologi*, 6(2), 136–143.
- Zhang, Q., Li, Z., & Huang, P. (2024). Spatiotemporal variations of atmospheric humidity and its relationship with land surface characteristics: A remote sensing approach. *Environmental Research Letters*, 19(1), 015004.
- Zhang, Y., Chen, Y., & Li, J. (2022). A hybrid SARIMAX model for time series forecasting with external factors. *Journal of Applied Statistics*, 49(12), 3075–3090. <https://doi.org/10.1080/02664763.2021.1981234>

LAMPIRAN

Lampiran 1. Data Bulanan Tahun 2018-2024

Tahun	Bulan	Produksi	Luas	RR	TAVG	ss	RH_AVG	ONI
2018	Jan	299729	53407	249,2	25,3	7,2	87,3	-0,9
	Feb	728002	127733	215,5	25,4	7,9	86,0	-0,9
	Mar	1473786	253241	238,2	25,9	8,5	84,6	-0,7
	Apr	1195083	202103	169,9	26,8	8,1	81,7	-0,5
	Mei	836143	149670	24,3	26,0	8,1	78,9	-0,2
	Jun	837327	153378	19,9	25,0	7,5	80,9	0,0
	Jul	1024003	182673	25,7	24,2	8,4	78,9	0,1
	Agu	886827	157794	4,3	24,3	8,6	76,8	0,2
	Sep	834177	150409	4,1	25,4	9,0	76,2	0,5
	Okt	592588	108137	0,0	26,5	9,0	75,0	0,8
	Nov	583845	104713	144,8	26,6	7,9	81,1	0,9
	Des	355850	63994	269,0	26,1	7,8	85,5	0,8
2019	Jan	247675	44060	299,1	26,0	7,6	85,5	0,7
	Feb	324349	57841	305,8	26,1	8,4	85,4	0,7
	Mar	1399151	240718	398,2	25,8	7,7	87,0	0,7
	Apr	1656632	283842	247,8	26,4	8,1	83,8	0,7
	Mei	786210	141728	67,7	26,3	8,0	79,1	0,5
	Jun	646971	121038	2,5	24,6	8,1	79,1	0,5
	Jul	850949	159249	0,0	23,9	8,4	78,5	0,3
	Agu	871335	161737	0,0	24,1	8,8	76,1	0,1
	Sep	752681	121134	0,0	25,3	9,5	73,3	0,2
	Okt	559023	89857	1,0	26,7	9,7	71,8	0,3
	Nov	566848	89823	49,7	27,4	9,6	74,8	0,5
	Des	423134	67810	210,1	26,9	7,8	81,2	0,5
2020	Jan	261729	45801	303,0	26,7	7,4	82,2	0,5
	Feb	163279	28837	231,3	26,3	7,3	85,0	0,5
	Mar	423837	74802	363,4	26,3	7,8	85,9	0,4
	Apr	1696127	299445	339,7	26,6	7,8	83,8	0,2
	Mei	1275305	238138	191,4	26,3	7,4	83,7	-0,1
	Jun	644211	120574	153,3	25,2	7,3	83,3	-0,3
	Jul	706354	131530	7,4	24,5	7,8	82,3	-0,4
	Agu	940312	173635	16,0	24,8	8,4	80,0	-0,6
	Sep	1079807	175691	4,5	27,7	8,9	69,4	-0,9
	Okt	750530	122146	131,6	26,2	8,2	80,7	-1,2
	Nov	630998	103368	157,0	26,5	8,0	83,8	-1,3
	Des	444284	72921	298,0	25,6	7,2	86,1	-1,2
2021	Jan	401495	69881	179,8	25,4	6,8	88,0	-1,0
	Feb	542940	94646	484,8	25,9	7,3	83,8	-0,9
	Mar	1340411	237492	233,0	25,8	8,6	84,6	-0,8
	Apr	1167477	201427	301,3	26,0	8,4	81,3	-0,7
	Mei	755057	134231	479,1	26,2	7,8	81,0	-0,5
	Jun	729856	130764	281,0	26,0	6,8	82,0	-0,4

	Jul	1167557	213367	115,6	24,7	7,9	80,3	-0,4
	Agu	641697	118129	351,2	25,1	8,2	80,6	-0,5
	Sep	615202	105126	317,4	25,8	8,9	79,9	-0,7
	Okt	682706	116071	566,4	26,3	8,4	79,4	-0,8
	Nov	545924	93310	175,9	25,8	7,6	87,7	-1,0
	Des	523253	89664	279,1	27,6	7,7	79,5	-1,0
2022	Jan	423391	73475	106,6	26,0	8,1	83,8	-1,0
	Feb	464403	83261	145,8	25,8	7,4	84,8	-0,9
	Mar	1500151	262764	112,1	26,2	7,8	85,4	-1,0
	Apr	1340685	222166	316,6	25,8	7,7	84,5	-1,1
	Mei	656580	118689	226,5	26,4	7,2	83,6	-1,0
	Jun	757632	139911	463,7	25,5	6,8	82,9	-0,9
	Jul	1022174	190213	358,9	24,9	7,2	80,0	-0,8
	Agu	759794	140209	384,9	25,0	7,9	79,8	-0,9
	Sep	800153	137010	344,2	25,6	7,9	81,5	-1,0
	Okt	724268	123568	499,6	25,3	7,5	87,2	-1,0
	Nov	593254	103291	321,0	25,5	7,6	87,0	-0,9
	Des	391237	67847	226,0	25,9	7,1	85,1	-0,8
2023	Jan	477312	84526	211,1	26,1	7,8	82,6	-0,7
	Feb	599117	107318	258,3	25,6	6,8	87,5	-0,4
	Mar	1322271	231551	325,8	25,9	8,0	83,1	-0,1
	Apr	1049983	176421	312,8	26,2	8,5	83,8	0,2
	Mei	1027200	180806	294,2	26,0	7,7	80,5	0,5
	Jun	746141	131839	310,7	26,0	7,4	77,4	0,8
	Jul	893430	159251	134,4	24,3	7,5	83,3	1,1
	Agu	646621	116294	144,7	24,0	8,5	79,6	1,3
	Sep	714232	119144	62,2	24,9	9,4	74,1	1,6
	Okt	792892	130363	102,1	27,3	9,6	72,4	1,8
	Nov	512287	85999	1068,0	29,5	8,4	66,6	1,9
	Des	358554	60145	563,6	28,6	8,7	71,2	2,0
2024	Jan	252547	42493	393,8	28,3	7,4	77,1	1,8
	Feb	151954	25607	232,8	28,6	7,8	76,7	1,5
	Mar	600150	102281	723,2	28,4	7,2	77,4	1,1
	Apr	1430700	242125	618,3	28,4	7,9	78,1	0,7
	Mei	1547699	270691	550,6	27,5	7,3	83,1	0,4
	Jun	575487	103630	223,9	27,1	7,2	81,9	0,2
	Jul	549458	100834	138,4	26,3	7,6	78,9	0,0
	Agu	726553	130110	122,7	26,7	8,4	77,5	-0,1
	Sep	697391	116140	402,7	26,8	8,8	78,6	-0,2
	Okt	933710	151422	493,6	27,2	9,2	78,6	-0,3
	Nov	742234	120196	680,4	26,7	7,6	84,4	-0,4
	Des	418996	69834	232,0	26,2	6,6	85,3	-0,5

Lampiran 2. Hasil Standardisasi

Data ke	Luas	RR	TAVG	ss	RH AVG	ONI
1	-1,29074	-0,00501	-0,72285	-1,12333	1,413331	-1,01476
2	-0,09018	-0,17928	-0,62425	-0,06221	1,121103	-1,01476
3	1,93711	-0,0619	-0,12653	0,70091	0,797565	-0,77532
4	1,111104	-0,41509	0,655202	0,16601	0,154803	-0,53589
5	0,264175	-1,16803	-0,04704	0,21981	-0,48615	-0,17673
6	0,324067	-1,19079	-0,97728	-0,65885	-0,03393	0,06271
7	0,797262	-1,16079	-1,69707	0,64148	-0,49346	0,182429
8	0,395393	-1,27146	-1,61223	0,97343	-0,96833	0,302149
9	0,27611	-1,27249	-0,61451	1,43814	-1,10592	0,661306
10	-0,4067	-1,2937	0,388876	1,45322	-1,36283	1,020464
11	-0,462	-0,54489	0,483302	-0,12031	0,012149	1,140183
12	-1,11973	0,09738	0,049507	-0,25534	1,004212	1,020464
13	-1,44172	0,253036	-0,08507	-0,58728	1,018823	0,900745
14	-1,21912	0,287684	0,023804	0,67950	0,991688	0,900745
15	1,734836	0,765511	-0,25768	-0,44177	1,354885	0,900745
16	2,431401	-0,01225	0,331729	0,25489	0,630404	0,900745
17	0,135883	-0,9436	0,192861	0,03756	-0,44962	0,661306
18	-0,19831	-1,28077	-1,33401	0,19772	-0,43404	0,661306
19	0,418895	-1,2937	-1,99256	0,57639	-0,58112	0,421868
20	0,459085	-1,2937	-1,77899	1,15149	-1,11444	0,182429
21	-0,19677	-1,2937	-0,68404	2,18998	-1,7476	0,302149
22	-0,70198	-1,28853	0,590742	2,55181	-2,0861	0,421868
23	-0,70252	-1,03668	1,190293	2,34083	-1,40789	0,661306
24	-1,05809	-0,20721	0,701914	-0,17119	0,025249	0,661306
25	-1,41359	0,273204	0,596593	-0,76534	0,259031	0,661306
26	-1,6876	-0,09758	0,20184	-0,90681	0,902436	0,661306
27	-0,94515	0,58555	0,192666	-0,18374	1,090906	0,541587
28	2,683437	0,462991	0,494977	-0,23897	0,615305	0,302149
29	1,693161	-0,30391	0,216266	-0,85600	0,602399	-0,05701
30	-0,20582	-0,50094	-0,84124	-0,89809	0,517166	-0,29645
31	-0,02884	-1,25543	-1,4718	-0,24883	0,288254	-0,41617
32	0,651268	-1,21096	-1,18217	0,67681	-0,24506	-0,65561
33	0,684476	-1,27043	1,46842	1,29594	-2,63086	-1,01476
34	-0,18042	-0,61316	0,122647	0,39461	-0,07703	-1,37392
35	-0,48374	-0,4818	0,395215	0,05696	0,622855	-1,49364
36	-0,97553	0,247348	-0,46832	-1,06196	1,135715	-1,37392
37	-1,02463	-0,3639	-0,62923	-1,73841	1,581362	-1,13448
38	-0,62462	1,213345	-0,12843	-0,99181	0,611531	-1,01476
39	1,682725	-0,08879	-0,27816	0,87766	0,799653	-0,89504
40	1,100184	0,264413	-0,1036	0,59502	0,066816	-0,77532
41	0,014792	1,183869	0,093391	-0,30555	-0,01859	-0,53589
42	-0,04122	0,159436	-0,04011	-1,65089	0,222746	-0,41617
43	1,293051	-0,6959	-1,27222	-0,05945	-0,18114	-0,41617
44	-0,2453	0,52246	-0,8556	0,28104	-0,11036	-0,53589
45	-0,45534	0,347671	-0,28986	1,33374	-0,25967	-0,77532

46	-0,27855	1,635322	0,157754	0,58337	-0,37656	-0,89504
47	-0,64619	-0,38407	-0,28801	-0,54787	1,498564	-1,13448
48	-0,70508	0,14961	1,404057	-0,32926	-0,34004	-1,13448
49	-0,96659	-0,74244	-0,088	0,17889	0,61701	-1,13448
50	-0,80851	-0,53972	-0,21913	-0,88629	0,838007	-1,01476
51	2,090935	-0,714	0,064135	-0,21582	0,974989	-1,13448
52	1,435178	0,343534	-0,26382	-0,36051	0,788938	-1,2542
53	-0,23627	-0,1224	0,309885	-1,15680	0,587787	-1,13448
54	0,106539	1,104231	-0,49963	-1,69749	0,426575	-1,01476
55	0,919051	0,562279	-1,0827	-1,06196	-0,23776	-0,89504
56	0,111339	0,696733	-1,00663	-0,04845	-0,2889	-1,01476
57	0,059676	0,486261	-0,4573	-0,08860	0,109508	-1,13448
58	-0,15744	1,28988	-0,73748	-0,67376	1,384108	-1,13448
59	-0,48497	0,366287	-0,548	-0,57526	1,34758	-1,01476
60	-1,0575	-0,12499	-0,18454	-1,28326	0,916544	-0,89504
61	-0,78808	-0,20204	0,035464	-0,29518	0,343534	-0,77532
62	-0,41993	0,042048	-0,46529	-1,64242	1,468906	-0,41617
63	1,586758	0,39111	-0,13773	0,08638	0,456285	-0,05701
64	0,696261	0,323883	0,151802	0,69644	0,621293	0,302149
65	0,767104	0,227697	-0,06752	-0,36691	-0,12817	0,661306
66	-0,02385	0,313023	-0,06732	-0,86494	-0,8266	1,020464
67	0,418924	-0,59868	-1,5859	-0,63191	0,51473	1,379622
68	-0,27494	-0,54541	-1,88138	0,77398	-0,31812	1,619061
69	-0,22891	-0,97204	-1,09216	2,10303	-1,56642	1,978218
70	-0,0477	-0,76571	1,140753	2,31935	-1,9619	2,217657
71	-0,76429	4,229242	3,146247	0,58781	-3,26499	2,337376
72	-1,18191	1,620843	2,252478	1,06688	-2,23221	2,457095
73	-1,46703	0,742758	1,968696	-0,78999	-0,88796	2,217657
74	-1,73978	-0,08982	2,269023	-0,26223	-0,98747	1,858499
75	-0,5013	2,446181	2,062315	-1,08753	-0,83682	1,379622
76	1,757557	1,903712	2,115366	-0,07899	-0,66806	0,900745
77	2,218979	1,553616	1,304586	-0,96386	0,463591	0,541587
78	-0,4795	-0,13584	0,909144	-1,08017	0,200098	0,302149
79	-0,52467	-0,57799	0,204758	-0,46269	-0,49443	0,06271
80	-0,05178	-0,65918	0,573188	0,63032	-0,80029	-0,05701
81	-0,27743	0,788782	0,631017	1,23397	-0,54727	-0,17673
82	0,292465	1,258852	1,044209	1,80841	-0,55921	-0,29645
83	-0,21191	2,22485	0,570555	-0,47437	0,751191	-0,41617
84	-1,02539	-0,09396	0,081689	-1,90113	0,967684	-0,53589

Lampiran 3. Hasil Transformasi

Data ke	Transformasi	Data ke	Transformasi	Data ke	Transformasi
1	23,3982	29	33,6050	57	29,9084
2	29,2101	30	28,3307	58	29,1726
3	34,8424	31	28,9905	59	27,7530
4	33,0636	32	31,1400	60	25,0098
5	30,2392	33	32,2357	61	26,2846
6	30,2499	34	29,4335	62	27,8213
7	31,8109	35	28,1843	63	33,9102
8	30,6874	36	25,8176	64	32,0107
9	30,2214	37	25,1721	65	31,8357
10	27,7452	38	27,1449	66	29,3904
11	27,6423	39	34,0259	67	30,7443
12	24,4240	40	32,8709	68	28,3571
13	22,3085	41	29,4778	69	29,0710
14	23,8646	42	29,2287	70	29,8403
15	34,3927	43	32,8715	71	26,7534
16	35,8762	44	28,3030	72	24,4703
17	29,7773	45	28,0062	73	22,4174
18	28,3610	46	28,7447	74	19,7437
19	30,3722	47	27,1821	75	27,8333
20	30,5525	48	26,8954	76	34,5850
21	29,4546	49	25,5085	77	35,2713
22	27,3437	50	26,1050	78	27,5429
23	27,4389	51	34,9972	79	27,2260
24	25,5047	52	34,0276	80	29,1956
25	22,6185	53	28,4657	81	28,8981
26	20,1017	54	29,5029	82	31,0852
27	25,5152	55	31,7966	83	29,3518
28	36,0881	56	29,5239	84	25,4421

Lampiran 4. Hasil *Differencing* non musiman

Data ke	<i>Differencing</i>	Data ke	<i>Differencing</i>	Data ke	<i>Differencing</i>
1	*	29	-2,48318	57	0,38449
2	5,8119	30	-5,27429	58	-0,73582
3	5,6323	31	0,65982	59	-1,41956
4	-1,7789	32	2,14946	60	-2,74323
5	-2,8244	33	1,09570	61	1,27477
6	0,0107	34	-2,80215	62	1,53677
7	1,5610	35	-1,24923	63	6,08885
8	-1,1235	36	-2,36673	64	-1,89945
9	-0,4660	37	-0,64542	65	-0,17508
10	-2,4762	38	1,97274	66	-2,44527
11	-0,1029	39	6,88101	67	1,35395
12	-3,2183	40	-1,15495	68	-2,38719
13	-2,1155	41	-3,39314	69	0,71384
14	1,5560	42	-0,24911	70	0,76934
15	10,5281	43	3,64281	71	-3,08697
16	1,4835	44	-4,56850	72	-2,28310
17	-6,0989	45	-0,29678	73	-2,05283
18	-1,4163	46	0,73853	74	-2,67374
19	2,0112	47	-1,56265	75	8,08963
20	0,1803	48	-0,28671	76	6,75163
21	-1,0979	49	-1,38685	77	0,68636
22	-2,1109	50	0,59647	78	-7,72846
23	0,0952	51	8,89224	79	-0,31687
24	-1,9342	52	-0,96961	80	1,96957
25	-2,8862	53	-5,56192	81	-0,29747
26	-2,5168	54	1,03718	82	2,18707
27	5,4136	55	2,29375	83	-1,73332
28	10,5729	56	-2,27273	84	-3,90977

Lampiran 5. Hasil *Differencing* musiman

Data ke	<i>Differencing</i>	Data ke	<i>Differencing</i>	Data ke	<i>Differencing</i>
1	*	29	3,6158	57	0,68127
2	*	30	-3,8580	58	-1,47435
3	*	31	-1,3514	59	0,14308
4	*	32	1,9692	60	-2,45652
5	*	33	2,1936	61	2,66162
6	*	34	-0,6913	62	0,94030
7	*	35	-1,3444	63	-2,80338
8	*	36	-0,4325	64	-0,92984
9	*	37	2,2408	65	5,38684
10	*	38	4,4895	66	-3,48245
11	*	39	1,4674	67	-0,93980
12	*	40	-11,7279	68	-0,11447
13	*	41	-0,9100	69	0,32935
14	-4,25588	42	5,0252	70	1,50517
15	4,89580	43	2,9830	71	-1,66740
16	3,26241	44	-6,7180	72	0,46012
17	-3,27458	45	-1,3925	73	-3,32760
18	-1,42697	46	3,5407	74	-4,21051
19	0,45023	47	-0,3134	75	2,00078
20	1,30377	48	2,0800	76	8,65108
21	-0,63192	49	-0,7414	77	0,86144
22	0,36531	50	-1,3763	78	-5,28319
23	0,19810	51	2,0112	79	-1,67082
24	1,28408	52	0,1853	80	4,35676
25	-0,77071	53	-2,1688	81	-1,01132
26	-4,07283	54	1,2863	82	1,41773
27	-5,11458	55	-1,3491	83	1,35364
28	9,08939	56	2,2958	84	-1,62666

Lampiran 6. Rata-rata Historis

Data	X_1	X_2	X_4	X_6
1	-1.06958	-0.13119	-0.73152	-0.03991
2	-0.72747	0.121083	-0.58175	-0.0057
3	1.335994	0.146247	-0.0377	-0.0057
4	1.430952	0.161247	0.147699	-0.0228
5	0.402674	-0.18773	-0.48454	-0.0057
6	-0.08716	-0.23264	-0.9504	0.045607
7	0.653774	-0.74037	-0.17814	0.045607
8	0.153472	-0.51706	0.63409	-0.0228
9	-0.0493	-0.66246	1.358026	-0.0228
10	-0.35086	-0.17265	1.205286	-0.0057
11	-0.61548	0.358015	0.181114	0.011402
12	-1.02889	0.297163	-0.56218	0.028505

RIWAYAT HIDUP



Jeem Shabigh Badar Ramadani, lahir di Lamongan pada tanggal 19 November 2002 Tinggal di Desa Gedangan Kecamatan Maduran Kabupaten Lamongan, Merupakan anak kedua dari empat bersaudara dari pasangan Bapak Ahmad Djudiono dan Ibu Umu Aslamah. Riwayat Pendidikan menempuh pendidikan formal di MI Muhammadiyah 10 Gedangan kemudian melanjutkan pendidikan di SMP Negeri 1 Maduran, dan melanjutkan di MA Muhammadiyah 1 Paciran. Setelah menyelesaikan pendidikan menengah, pada tahun 2022 melanjutkan studi di Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang melalui jalur SNBT Selama menempuh pendidikan di perguruan tinggi, penulis aktif mengikuti berbagai kegiatan akademik maupun nonakademik.



BUKTI KONSULTASI SKRIPSI

Nama : Jeem Shabigh Badar Ramadani
NIM : 220601110083
Fakultas / Jurusan : Sains dan Teknologi / Matematika
Judul Skripsi : Penerapan Metode Seasonal Autoregressive Integrated Moving Average With Exogenous Variables pada Peramalan Produksi Padi di Jawa Barat
Pembimbing I : Prof. Dr. Hj. Sri Harini, M.Si
Pembimbing II : Dr. Mohammad Jamhuri, M.Si

No	Tanggal	Hal	Tanda Tangan
1.	15 Agustus 2025	Konsultasi Topik	1.
2.	21 Agustus 2025	Konsultasi Topik	2.
3.	10 September 2025	Konsultasi Bab I, II, III	3.
4.	23 September 2025	Konsultasi Bab I, II, III	4.
5.	30 September 2025	Konsultasi Bab I, II, III	5.
6.	3 Oktober 2025	Konsultasi Bab I, II, III	6.
7.	7 Oktober 2025	Konsultasi Bab I, II, III	7.
8.	29 Oktober 2025	Konsultasi Bab I, II, III	8.
9.	25 November 2025	Konsultasi Bab I, II, III	9.
10.	4 Desember 2025	ACC Bab I, II, dan III	10.
11.	5 Desember 2025	ACC Kajian Agama Bab I dan II	11.
12.	12 Januari 2026	ACC Seminar Proposal	12.
13.	5 Mei 2026	Konsultasi Bab IV dan V	13.
14.	8 Mei 2026	Konsultasi Bab IV dan V	14.



KEMENTERIAN AGAMA RI

UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM

MALANG FAKULTAS SAINS DAN TEKNOLOGI

Jl. Gajayana No. 50 Malang 65144 Telp. / Fax. (0341) 558933

15.	11 Mei 2026	ACC Bab IV dan V	15. f
16.	13 Mei 2026	ACC Kajian Agama Bab IV	16.
17.	25 Mei 2026	ACC Seminar Hasil	17. f
18.	4 Juni 2026	Revisi Seminar Hasil	18. f
19.	5 Juni 2026	ACC Sidang Skripsi	19. f
20.	8 Juni 2026	Konsultasi Kajian Agama	20.
21.	9 Juni 2026	ACC Kajian Agama	21.
22.	17 Juni 2026	ACC Keseluruhan	22. f

Malang, 17 Juni 2026

Mengetahui,

Ketua Program Studi Matematika



Dr. Fachrur Rozi, M.Si.

NIP. 19800527 200801 1 012