

**IMPLEMENTASI *VECTOR ERROR CORRECTION MODEL*
DALAM MENGANALISIS PRODUKSI PADI PASCA EL-NINO
DI JAWA TIMUR**

SKRIPSI

**OLEH
MOHAMAD IQBAL ZAKARIA PUTRA
NIM. 220601110079**



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

**IMPLEMENTASI *VECTOR ERROR CORRECTION MODEL*
DALAM MENGANALISIS PRODUKSI PADI PASCA EL-NINO
DI JAWA TIMUR**

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
Mohamad Iqbal Zakaria Putra
NIM. 220601110079**

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

**IMPLEMENTASI *VECTOR ERROR CORRECTION MODEL*
DALAM MENGANALISIS PRODUKSI PADI PASCA EL-NINO
DI JAWA TIMUR**

SKRIPSI

Oleh
Mohamad Iqbal Zakaria Putra
NIM. 220601110079

Telah Disetujui untuk Diuji

Malang, 29 Mei 2026

Dosen Pembimbing I



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

Dosen Pembimbing II



Juhari, M.Si
NIPPPK. 19840209 202321 1 010



Mengetahui,
Ketua Program Studi Matematika



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

**IMPLEMENTASI *VECTOR ERROR CORRECTION MODEL*
DALAM MENGANALISIS PRODUKSI PADI PASCA EL-NINO
DI JAWA TIMUR**

SKRIPSI

Oleh
Mohamad Iqbal Zakaria Putra
NIM. 220601110079

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

Tanggal 15 Juni 2026

Ketua Penguji : Abdul Aziz, M.Si.

Anggota Penguji 1 : Ria Dhea Layla Nur Karisma, M.Si.

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

Anggota Penguji 3 : Juhari, M.Si.



Mengetahui,
Ketua Program Studi Matematika


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

PERNYATAAN KEASLIAN TULISAN

Saya bertanda tangan dibawah ini:

Nama : Mohamad Iqbal Zakaria Putra
NIM : 220601110079
Program Studi : Matematika
Fakultas : Sains dan Teknologi
Judul Skripsi : Implementasi *Vector Error Correction Model* dalam
Menganalisis Produksi Padi Pasca El-Nino di Jawa
Timur

Menyatakan bahwa skripsi yang saya tulis ini merupakan hasil karya sendiri, bukan mengambil alih tulisan atau pemikiran orang lain. Saya menyatakan skripsi ini sebagai pemikiran saya, kecuali dengan mencantumkan sumber kutipan pada daftar pustaka di halaman terakhir. Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini hasil plagiasi atau tiruan orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut.



Malang, 15 Juni 2026

Mohamad Iqbal Zakaria Putra
NIM. 220601110079

MOTO

“Carpe Diem, seize the days and make your lives extraordinary”

(John Keating-Dead Poets Society)

*“failure can either destroy you or a make you work 10 times harder; it just
depends on your mindset”*

(Dr. Carol Dweck)

“No matter what anyone tells you, words and ideas can change the world”

(John Keating-Dead Poets Society)

PERSEMBAHAN

Segala puji dan syukur penulis panjatkan ke hadirat Allah SWT atas limpahan kasih sayang, kekuatan, dan kemudahan yang senantiasa menyertai hingga skripsi ini dapat diselesaikan dengan baik. Dengan segenap cinta dan ketulusan, karya ini penulis persembahkan:

Untuk Ayah, Suparmo Putra,

Terima kasih atas setiap perjuangan yang tak kenal lelah dalam mengupayakan yang terbaik bagi hidup penulis. Ayah telah menjadi sosok yang mengajarkan arti keteguhan, kerja keras, dan keikhlasan. Motivasi dan dukungan yang Ayah berikan menjadi pijakan kuat hingga penulis mampu menyelesaikan studi ini.

Untuk Ibu, Umi Mudhakiroh,

Sumber kasih sayang yang tak pernah habis, yang senantiasa mendoakan dalam diam, menyemangati tanpa henti, dan mendukung tanpa syarat. Ketulusan Ibu menjadi cahaya yang menerangi setiap langkah penulis hingga sampai pada titik ini.

Dan untuk diri sendiri,

Terima kasih telah tetap bertahan dalam setiap tantangan, meyakini bahwa proses ini akan menemukan akhirnya, dan membuktikan bahwa kesungguhan akan selalu menemukan jalannya.

KATA PENGANTAR

Assalamualaikum warahmatullahi wabarakatuh.

Alhamdulillah robbil ‘alamin, puji syukur ke hadirat Allah SWT yang senantiasa memberikan Rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan skripsi ini dengan judul “Implementasi *Vector Error Correction Model* dalam Menganalisis Produksi Padi Pasca El-Nino di Jawa Timur”. Skripsi ini disusun sebagai salah satu syarat kelulusan dari Universitas Islam Negeri Maulana Malik Ibrahim Malang.

Selama pelaksanaan skripsi ini, penulis mendapatkan banyak pengetahuan, pengalaman, bimbingan, dukungan, juga arahan dan saran dari berbagai pihak yang telah membantu dalam penyelesaian skripsi ini. Untuk itu penulis ingin menyampaikan ucapan terima kasih kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si.,CAHRM., 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.
3. Dr. Fachrur Rozi, M.Si., selaku Ketua Program Studi Matematika Universitas Islam Negeri Maulana Malik Ibrahim.
4. Prof. Dr. Hj. Sri Harini, M.Si., selaku Dosen Pembimbing I yang senantiasa memberikan berbagai pengetahuan, nasehat, motivasi, dan arahan selama proses penyusunan skripsi ini.
5. Juhari, M.Si., selaku Dosen Pembimbing II yang telah memberikan arahan dan masukan yang sangat bermanfaat dalam penulisan skripsi ini.
6. Seluruh Dosen Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim.
7. Orang tua serta keluarga penulis yang selalu memberikan dukungan penuh, nasihat, keteladanan, dan kasih sayang dalam setiap perjalanan penulis. Terima kasih atas cinta, pemahaman, dan doa yang selalu diberikan.
8. Sahabat-sahabat dan seluruh teman penulis angkatan 2022 yang telah memberikan dukungan moral, semangat, motivasi, dan kerjasama yang tak

tergantikan. Kebersamaan dalam perjalanan selama masa kuliah telah memberikan keceriaan dan kekuatan dalam menghadapi setiap hambatan.

9. Teman-teman kontrakan 'When yah' yang telah menemani penulis dalam berbagai cerita, canda, dan perjuangan selama masa perkuliahan.
10. Teman-teman 'Sircle Bjir' yang telah menemani penulis dalam berbagai cerita, canda, dan perjuangan selama masa perkuliahan.
11. FC Barcelona selaku klub favorit penulis, yang tanpa sadar telah menjadi teman hiburan dan menjadi motivasi selama proses penulisan tugas akhir ini. Terima kasih telah hadir lewat permainan yang indah, penuh semangat dan mengajarkan arti bahwa keterbatasan tidak menghalangimu untuk menjadi seorang pemenang. *Visca Barca, Sempre!*

Penulis menyadari bahwa skripsi ini masih jauh dari kata sempurna, namun dengan ikhlas, penulis mempersembahkan sebagai bentuk apresiasi dan penghormatan kepada semua pihak yang telah memberikan kontribusi, dukungan, dan inspirasi kepada penulis.

Wassalamu 'alaikum warahmatullahi wabarakatuh

Malang, 15 Juni 2026

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGANTAR	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	xvi
ABSTRAK	xvii
ABSTRACT	xviii
مستخلص البحث.....	xix
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	7
1.3 Tujuan Penelitian.....	7
1.4 Manfaat Penelitian	8
1.5 Batasan Masalah.....	9
BAB II KAJIAN TEORI	10
2.1 Teori Pendukung	10
2.1.1 <i>Time Series</i>	10
2.1.2 Standarisasi Data.....	10
2.1.3 Stasioneritas	11
2.1.4 Lag Optimum	13
2.1.5 <i>Vector Autoregressive</i>	14
2.1.6 Uji Stabilitas.....	16
2.1.7 Uji Kointegrasi.....	17
2.1.8 Kausalitas Granger	18
2.1.9 <i>Vector Error Correction Model</i>	19
2.1.10 Uji Autokorelasi	23
2.1.11 <i>Impulse Response Function</i>	24
2.1.12 Variance Decomposition	26
2.1.13 <i>Mean Absolute Percentage Error</i>	27
2.1.14 <i>Missing Value</i>	28
2.1.15 Curah Hujan	28
2.1.16 Suhu Udara.....	29
2.1.17 Kelembaban Udara.....	30
2.1.18 Kecepatan Angin	30
2.1.19 Penyinaran Matahari	31
2.1.20 El Nino	32
2.1.21 EViews	33
2.2 Kajian Integrasi Topik dengan Al-Qur'an.....	33

2.3 Kajian Topik dengan Teori Pendukung	35
BAB III METODE PENELITIAN	38
3.1 Jenis Penelitian	38
3.2 Data dan Sumber Data	38
3.3 Teknik Pengumpulan Data	39
3.4 Teknik Analisis Data	39
3.5 Diagram Alir Penelitian.....	43
BAB IV HASIL DAN PEMBAHASAN.....	45
4.1 Penanganan <i>Missing Value</i>	45
4.2 Statistika Deskriptif.....	48
4.3 Standarisasi Data.....	50
4.4 Stasioneritas	51
4.5 Lag Optimum	54
4.6 Identifikasi VAR.....	55
4.7 Uji Stabilitas.....	55
4.8 Uji Kointegrasi	57
4.9 Uji Kausalitas	58
4.10 Estimasi dan Signifikansi Model VECM.....	68
4.11 Identifikasi Model VECM	85
4.12 Uji Autokorelasi.....	92
4.13 Analisis <i>Impulse Response Function</i>	93
4.14 Analisis <i>Variance Decomposition</i>	98
4.15 MAPE	111
4.16 Integrasi Pandangan Islam Dengan Hasil Pembahasan	114
BAB V PENUTUP	117
5.1 Kesimpulan	117
5.2 Saran.....	118
DAFTAR PUSTAKA.....	120
LAMPIRAN.....	124
RIWAYAT HIDUP	150

DAFTAR TABEL

Tabel 2.1	Kriteria Nilai pada MAPE.....	27
Tabel 4.1	Data Simulasi Pengamatan Sekitar Periode ke-14 Januari 2015....	45
Tabel 4.2	Tetangga Periode Pengamatan ke-14 Januari 2015.....	46
Tabel 4.3	Hasil Perhitungan Jarak Euclidean dan Bobot KNN	47
Tabel 4.4	Hasil Pengamatan Sekitar Periode ke-14 Januari 2015.....	48
Tabel 4.5	Statistika Deskriptif.....	48
Tabel 4.6	Uji Stasioneritas I(0)	52
Tabel 4.7	Uji Stasioneritas I(1)	53
Tabel 4.8	Nilai AIC	54
Tabel 4.9	Hasil Uji Stabilitas VAR.....	55
Tabel 4.10	Hasil Uji Kointegrasi.....	57
Tabel 4.11	Uji Kausalitas Granger	58
Tabel 4.12	Hasil Estimasi Jangka Panjang Produksi Padi	68
Tabel 4.13	Hasil Estimasi Jangka Pendek Produksi Padi	69
Tabel 4.14	Hasil Estimasi Jangka Panjang Curah Hujan	70
Tabel 4.15	Hasil Estimasi Jangka Pendek Curah Hujan	71
Tabel 4.16	Hasil Estimasi Jangka Panjang Suhu Udara.....	72
Tabel 4.17	Hasil Estimasi Jangka Pendek Suhu Udara.....	73
Tabel 4.18	Hasil Estimasi Jangka Panjang Kelembaban Udara.....	75
Tabel 4.19	Hasil Estimasi Jangka Pendek Kelembaban Udara.....	75
Tabel 4.20	Hasil Estimasi Jangka Panjang Kecepatan Angin.....	77
Tabel 4.21	Hasil Estimasi Jangka Pendek Kecepatan Angin	77
Tabel 4.22	Hasil Estimasi Jangka Panjang Penyinaran Matahari	79
Tabel 4.23	Hasil Estimasi Jangka Pendek Penyinaran Matahari	80
Tabel 4.24	Hasil Estimasi Jangka Panjang Oceanic Nino Index	82
Tabel 4.25	Hasil Estimasi Jangka Pendek Oceanic Nino Index.....	83
Tabel 4.26	Hasil Uji Portmanteau	93
Tabel 4.27	Hasil MAPE	113

DAFTAR GAMBAR

Gambar 2.1	Grafik IRF	26
Gambar 3.1	Diagram Alir Penelitian.....	44
Gambar 4.1	Kurva Data Tingkat Level	53
Gambar 4.2	Kurva Data Differencing.....	53
Gambar 4.3	Lingkaran Modulus	56
Gambar 4.4	Kausalitas Granger	60
Gambar 4.5	Grafik IRF Produksi Padi.....	94
Gambar 4.6	Grafik IRF Curah Hujan.....	94
Gambar 4.7	Grafik IRF Suhu Udara	95
Gambar 4.8	Grafik IRF Kelembaban Udara	96
Gambar 4.9	Grafik IRF Kecepatan Angin.....	96
Gambar 4.10	Grafik IRF Penyinaran Matahari.....	97
Gambar 4.11	Grafik IRF ONI	97
Gambar 4.12	Grafik VD Produksi Padi	99
Gambar 4.13	Grafik VD Curah Hujan	100
Gambar 4.14	Grafik VD Suhu Udara.....	102
Gambar 4.15	Grafik VD Kelembaban Udara.....	103
Gambar 4.16	Grafik VD Kecepatan Angin	105
Gambar 4.17	Grafik VD Penyinaran Matahari	107
Gambar 4.18	Grafik VD ONI.....	109
Gambar 4.19	Peramalan Produksi Padi.....	111
Gambar 4.20	Peramalan Curah Hujan	111
Gambar 4.21	Peramalan Suhu Udara	112
Gambar 4.22	Peramalan Kelembaban Udara	112
Gambar 4.23	Peramalan Kecepatan Angin	112
Gambar 4.24	Peramalan Penyinaran Matahari.....	113
Gambar 4.25	Gambar Peramalan ONI.....	113

DAFTAR SIMBOL

Simbol-simbol yang digunakan dalam penelitian ini memiliki makna sebagai berikut:

y_t	: Data deret waktu variabel endogen
x_t	: Data deret waktu variabel eksogen
Δy_t	: Diferensiasi pertama variabel y_t
Φ_0	: Konstanta
θ	: Koefisien variabel y_{t-1}
Φ_i	: Koefisien <i>lag</i> ke- i
e_t	: <i>Error</i> pada waktu ke- t
p	: Panjang <i>lag</i>
T	: Banyak observasi
$\hat{\theta}$	: Estimasi Koefisien θ
$SE(\hat{\theta})$	: Standar <i>error</i> dari estimasi ($\hat{\theta}$)
p_{max}	: <i>Lag</i> maksimum
AIC	: <i>Akaike Information Criterion</i>
$FPE(p)$	: <i>Final Prediction Error</i> pada lag p
$ \Sigma_{\hat{u}\hat{u}} $	: Determinan matriks varian kovarian dari estimasi residual
$\vec{y}_t$	: Vektor variabel endogen ukuran $k \times 1$
Φ_p	: Matriks parameter VAR pada lag ke- p
z	: Akar polinomial karakteristik
I_k	: Matriks identitas berukuran k
$T_{trace}(r)$	: Statistik uji trace
$\hat{\lambda}_i$	: Nilai eigen ke- i
r	: Rank kointegrasi
Φ_{ij}	: Koefisien lag antar variabel

RSS_R	: Residual Sum of Squares (<i>restricted</i>)
RSS_{UR}	: Residual Sum of Squares (<i>unrestricted</i>)
m	: Jumlah parameter <i>restricted</i>
s	: Jumlah parameter <i>unrestricted</i>
w_t	: Diferensiasi pertama variabel y_t
Π	: Matriks koefisien kointegrasi ($k \times k$)
Γ_i	: Matriks parameter jangka pendek
δ	: Matriks adjustment
β	: Matriks kointegrasi
Q_p	: Uji autokorelasi residual
$\hat{C}'_i$	: Matriks autokovarian residual lag ke- i
$\phi_{ij}(h)$	: Koefisien IRF
$\vec{\mu}$	: Vektor rata-rata
$\vec{\varepsilon}_t$	: Vektor <i>error white noise</i>
$\sigma_{y1t}(h)^2$	: Varian total variabel y_1 pada horizon h
σ_{y1t}^2	: Varian <i>error</i> variabel i
f_t	: Nilai prediksi pada periode ke- t

DAFTAR LAMPIRAN

Lampiran 1. Data Asli	124
Lampiran 2. Data Penanganan Missing Value	124
Lampiran 3. Data In-sample.....	124
Lampiran 4. Data Out-sample.....	127
Lampiran 5. Hasil Uji ADF Tingkat level.....	127
Lampiran 6. Hasil Uji ADF Tingkat First Difference	130
Lampiran 7. Hasil Pemilihan Lag Optimum	132
Lampiran 8. Hasil Estimasi VAR	133
Lampiran 9. Hasil Uji Stabilitas.....	134
Lampiran 10. Hasil Uji Kointegrasi	134
Lampiran 11. Uji Kausalitas Granger	135
Lampiran 12. Hasil Estimasi VECM	136
Lampiran 13. Uji Pormanteau.....	143
Lampiran 14. Hasil Impulse Response Function	144
Lampiran 15. Hasil Variance Decomposition	146
Lampiran 16. MAPE	147

ABSTRAK

Putra, Mohamad Iqbal Zakaria 2026. **Implementasi *Vector Error Correction Model* dalam Menganalisis Produksi Padi Pasca El-Nino di Jawa Timur**. Skripsi. Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
Pembimbing: (1) Prof. Dr. Sri Harini, M.Si. (2) Juhari, M.Si.

Kata Kunci: VECM, produksi padi, El Nino, faktor iklim, peramalan.

Produksi padi di Jawa Timur dipengaruhi oleh berbagai faktor iklim, terutama pasca fenomena El Nino yang menyebabkan perubahan curah hujan, suhu udara, dan kondisi atmosfer lainnya. Penelitian ini bertujuan menganalisis hubungan antara produksi padi dengan curah hujan, suhu udara, kelembaban udara, kecepatan angin, penyinaran matahari, dan ONI menggunakan metode VECM, serta mengevaluasi tingkat keakuratan model yang dihasilkan. Data yang digunakan berupa data bulanan periode Januari 2015-Desember 2024. Tahapan analisis meliputi uji stasioneritas, penentuan lag optimum, uji kointegrasi, estimasi model VECM, analisis IRF, VD dan evaluasi model menggunakan MAPE. Hasil penelitian menunjukkan adanya hubungan kointegrasi antara seluruh variabel sehingga model VECM layak digunakan. Curah hujan, suhu udara, kelembaban udara, kecepatan angin, dan ONI berpengaruh signifikan terhadap produksi padi dalam jangka panjang, sedangkan penyinaran matahari tidak signifikan. Analisis IRF dan VD menunjukkan bahwa faktor-faktor iklim berkontribusi terhadap dinamika produksi padi pasca El Nino di Jawa Timur. Evaluasi menggunakan MAPE menunjukkan bahwa model memiliki tingkat akurasi yang cukup baik, dengan nilai MAPE terbaik pada variabel suhu udara sebesar 9,78%. Secara umum, metode VECM mampu menggambarkan hubungan jangka pendek dan jangka panjang serta memberikan hasil peramalan yang cukup baik dalam menganalisis produksi padi pasca El Nino di Jawa Timur.

ABSTRACT

Putra, Mohamad Iqbal Zakaria 2026. **Implementation of the Vector Error Correction Model in Analyzing Post-El Niño Rice Production in East Java**. Thesis. Mathematics Study Program, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim, Malang.
Advisors: (I) Prof. Dr. Sri Harini, M.Si. (II) Juhari, M.Si.

Keywords: VECM, rice production, El Nino, climatic factors, forecasting.

Rice production in East Java is influenced by various climatic factors, particularly following the El Niño phenomenon, which causes changes in rainfall, air temperature, and other atmospheric conditions. This study aims to analyze the relationship between rice production and rainfall, air temperature, humidity, wind speed, solar radiation, and the ONI using the VECM method, as well as to evaluate the accuracy of the resulting model. The data used consists of monthly data from January 2015 to December 2024. The analysis stages include stationarity tests, determination of the optimal lag, cointegration tests, VECM model estimation, IRF and VD analysis, and model evaluation using MAPE. The results indicate a cointegration relationship among all variables, making the VECM model suitable for use. Rainfall, air temperature, air humidity, wind speed, and the ONI significantly influence rice production in the long term, whereas solar radiation does not. IRF and VD analyses indicate that climatic factors contribute to the dynamics of rice production following El Niño in East Java. Evaluation using MAPE indicates that the model has a fairly good level of accuracy, with the best MAPE value for the air temperature variable at 9.78%. In general, the VECM method is capable of describing short-term and long-term relationships and provides fairly good forecasting results in analyzing post-El Niño rice production in East Java.

مستخلص البحث

بوترا، محمد إقبال زكريا، ٢٠٢٦. تطبيق نموذج تصحيح أخطاء المنتج في تحليل إنتاج الأرز بعد إل نينو في جاوة الشرقية. الجامعي. قسم الرياضيات، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج.

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

الكلمات الأساسية: *VECM*، إنتاج الأرز، النينو، عوامل المناخ، التنبؤات.

يتأثر إنتاج الأرز في جاوة الشرقية بعوامل مناخية متعددة، خاصة بعد ظاهرة النينو التي تسبب تغيرات في هطول الأمطار ودرجة حرارة الهواء وغيرها من الظروف الجوية. تهدف هذه الدراسة إلى تحليل العلاقة بين إنتاج الأرز وهطول الأمطار، ودرجة حرارة الهواء، ورطوبة الهواء، وسرعة الرياح، والإشعاع الشمسي، و *ONI* باستخدام طريقة *VECM*، بالإضافة إلى تقييم مستوى دقة النموذج الناتج. البيانات المستخدمة على . تشمل مراحل التحليل اختبار الثبات، ٢٠٢٤ إلى ديسمبر ٢٠١٥ شكل بيانات شهرية للفترة من يناير تحديد التأخير الأمثل، اختبار التكامل المشترك، تقدير نموذج *VECM*، تحليل *IRF*، تقييم الفيروس الجنسي، وتقييم النموذج باستخدام *MAPE*. تظهر نتائج الدراسة وجود علاقة تكامل مشترك بين جميع المتغيرات بحيث يكون نموذج *VECM* قابلاً للتطبيق. الأمطار، ودرجة حرارة الهواء، والرطوبة، وسرعة الرياح، و *ONI* لها تأثير كبير على إنتاج الأرز على المدى الطويل، بينما الإشعاع الشمسي ليس كبيراً. يظهر تحليل *IRF* و *VD* أن عوامل المناخ تساهم في ديناميكيات إنتاج الأرز بعد النينو في شرق جاوة. أظهر التقييم باستخدام *MAPE* أن النموذج يتمتع بدقة جيدة إلى حد ما، حيث كانت أفضل قيمة بشكل عام، تستطيع طريقة *VECM* وصف العلاقات 9.71% *MAPE* عند متغير درجة حرارة الهواء قصيرة وطويلة الأمد وتقديم نتائج تنبؤية جيدة إلى حد ما في تحليل إنتاج الأرز بعد النينو في جاوة الشرقية.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Analisis *time series* dapat digunakan untuk memproses data yang melibatkan satu atau lebih variabel. Beberapa pendekatan statistik yang sering digunakan dalam menganalisis masalah deret waktu multivariat yaitu *Vector Autoregressive* (VAR), dan *Vector Error Correction Model* (VECM). Metode VECM merupakan pengembangan dari metode VAR yang bertujuan mengestimasi efek jangka pendek antar variabel dan efek jangka panjang dari data deret waktu (Nugroho dkk, 2016).

Pada analisis *time series*, sangat umum untuk mengevaluasi data deret waktu yang cenderung tidak mengindikasikan kestabilan atau perubahan yang konsisten dari waktu ke waktu. Proses peramalan pada data deret waktu sering kali memerlukan cara agar data menjadi stasioner, salah satunya dengan melakukan *differencing*. Metode ini digunakan untuk mengubah data yang tidak stasioner menjadi data stasioner. Metode peramalan yang diterapkan untuk data deret waktu salah satunya adalah VECM, yang merupakan pengembangan dari metode VAR. Metode VAR sendiri adalah metode yang memanfaatkan data deret waktu *multivariate* untuk menganalisis hubungan variabel pada periode sebelumnya (Putri dkk., 2023). Metode VECM diperkenalkan sebagai suatu metode untuk menganalisis hubungan antar variabel, baik jangka pendek maupun jangka panjang. Metode ini diterapkan untuk menganalisis data yang bersifat tidak stasioner pada levelnya, namun memiliki hubungan kointegrasi antara variabel-variabel yang terlibat (Nugroho dkk., 2016). Salah satu penerapan metode VECM yaitu

menganalisis sektor-sektor ekonomi, termasuk dinamika produksi padi, yang mempunyai peranan penting terhadap stabilitas ekonomi nasional. Metode VECM merupakan metode multivariat yang digunakan untuk menganalisis hubungan antar variabel secara simultan (Halim dkk., 2024).

Padi adalah tanaman pangan dengan peranan yang penting bagi penduduk Provinsi Jawa Timur. Negara dengan jumlah penduduk yang besar maka Indonesia menghadapi tantangan dalam memenuhi kebutuhan padi. Menurut BPS (2023) Provinsi Jawa timur merupakan penghasil padi terbesar di Indonesia. Karena suatu penduduk Provinsi Jawa Timur gemar mengkonsumsi padi dalam bentuk nasi sebagai makanan pokok utama. Kebutuhan penduduk Provinsi Jawa Timur terhadap beras sangat tinggi, sehingga menyebabkan penduduk Provinsi Jawa Timur ketergantungan akan komoditas beras sebagai bahan makanan utama. Sehingga menyebabkan Pemerintah Provinsi Jawa Timur mendorong petani lokal untuk meningkatkan produksi padi (Zamahzari & Ahmad, 2023). Sektor pertanian tidak terlepas dari beberapa faktor, antara lain adalah faktor atmosfer, dimana tanaman pertanian akan produktif pada keadaan atmosfer tertentu saja. Atmosfer bumi adalah suatu sistem yang sifatnya sangat beragam, dengan variabilitas yang terjadi pada kisaran yang sangat besar baik dalam skala waktu maupun jarak. Cuaca dan iklim merupakan beberapa proses yang terjadi pada sistem atmosfer bumi. Proses terjadinya cuaca dan iklim merupakan kombinasi dari variabel-variabel atmosfer yang sama yang disebut unsur-unsur iklim. Unsur-unsur iklim ini terdiri dari radiasi surya, suhu udara, kelembaban udara, awan, presipitasi, evaporasi, tekanan udara dan angin. Unsur-unsur ini memiliki variasi/perbedaan menurut agihan baik spasial maupun temporal. Perbedaan ini disebabkan pengendali iklim atau yang lebih

dikenal dengan faktor penentu iklim. Tanaman padi dapat hidup baik didaerah yang berhawa panas dan banyak mengandung uap air. Curah hujan yang baik rata-rata 200 mm per bulan atau lebih, dengan distribusi selama 4 bulan, curah hujan yang dikehendaki per tahun sekitar 1500 2000 mm. Suhu yang baik untuk pertumbuhan tanaman padi 23 °C. Tinggi tempat yang cocok untuk tanaman padi berkisar antara 0 -1500 m dpl (Sudibyakto, 2019).

Curah hujan adalah suatu proses fisis yang dihasilkan dari fenomena cuaca. Cuaca sendiri adalah suatu sistem yang kompleks sehingga bisa dimaklumi apabila para “modeler cuaca” atau “peramal cuaca” kadang meleset prakiraannya. Di Amerika yang sudah serba “supercanggih” di bidang meteorologi, kadang kala tetap saja mengalami kegagalan dalam meramalkan fenomena cuaca seperti hantaman tornado, hujan badai dan sebagainya. Frekuensi hujan merupakan besarnya kemungkinan suatu curah hujan disamai atau dilampaui. Sebaliknya kala ulang yaitu waktu hipotetik dimana hujan dengan suatu besaran tertentu akan disamai (Adib & Joko, 2025). Satu karakteristik lain dari hujan di daerah iklim tropika setengah kering adalah adanya variasi iklim yang terjadi setiap tahun. Lia Rizki dkk., (2023) menunjukkan bahwa adanya perbedaan curah hujan musiman yang disebabkan oleh fenomena El Nino. Dalam memahami pola curah hujan dan faktor-faktor yang memengaruhinya sangat sejalan dengan nilai-nilai dalam Al-Qur'an, khususnya pada Surat An-Nur ayat 43, di mana Allah SWT berfirman (Kemenag, 2022):

أَلَمْ تَرَ أَنَّ اللَّهَ يَرْجِي سَحَابًا ثُمَّ يُؤَلِّفُ بَيْنَهُ ثُمَّ يَجْعَلُهُ رُكَامًا فَتَرَى الْوَدْقَ يَخْرُجُ مِنْ خِلَالِهِ وَيُنَزِّلُ مِنَ السَّمَاءِ مِنْ جِبَالٍ فِيهَا مِنْ بَرَدٍ فَيُصِيبُ بِهِ مَنْ يَشَاءُ وَيَصْرِفُهُ عَنِ مَنْ يَشَاءُ يَكَادُ سَنَا بَرْقُهُ يَذْهَبُ بِالْأَبْصَارِ

Artinya:

“Tidakkah engkau melihat bahwa sesungguhnya Allah mengarahkan awan secara perlahan, kemudian mengumpulkannya, lalu menjadikannya bertumpuk-tumpuk. Maka, engkau melihat hujan keluar dari celah-celahnya. Dia (juga) menurunkan (butiran-butiran) es dari langit, (yaitu) dari (gumpalan-gumpalan awan seperti) gunung-gunung. Maka, Dia menyimpakannya (butiran-butiran es itu) kepada siapa yang Dia kehendaki dan memalingkannya dari siapa yang Dia kehendaki. Kilauan kilatnya hampir-hampir menghilangkan penglihatan.”

Ayat ini menjelaskan bagaimana Allah mengatur proses terjadinya hujan, mulai dari penggerakan dan penumpukan awan hingga turunnya hujan dan butiran es. Hujan merupakan karunia Allah yang sangat penting bagi kehidupan, termasuk pertumbuhan padi. Fenomena seperti El Niño yang mengubah pola hujan menunjukkan kuasa Allah dalam mengatur alam, dan penting bagi manusia untuk memahami dinamika ini demi menjaga produksi pangan. Maka dari itu, upaya ilmiah dalam memahami faktor-faktor iklim yang memengaruhi produksi padi, terutama terkait iklim pasca fenomena El Niño, bukan hanya penting dalam konteks penelitian statistik dan kebijakan pertanian, tetapi juga selaras dengan nilai spiritual untuk merenungi dan menjaga keseimbangan ciptaan Allah SWT. Pendekatan ini perlu mampu menangkap dinamika perubahan iklim dan keterkaitan antar variabel secara mendalam agar dapat memberikan gambaran yang komprehensif. Oleh karena itu, berbagai penelitian telah dilakukan untuk mengeksplorasi karakteristik iklim dan dampaknya terhadap produksi padi di wilayah sentra pertanian seperti Jawa Timur (Mulyaqin, 2020).

Pada saat terjadi El Nino atau yang disebut dengan *El Nino-Shouthern Oscillation* (ENSO), SPL Samudera Pasifik meningkat di atas suhu normalnya dan wilayah Indonesia suhunya lebih rendah dari suhu normalnya. Kondisi ini menyebabkan angin pasat timur melemah. Pada saat terjadi El Nino, tekanan udara di bagian barat Samudera Pasifik meningkat sehingga pertumbuhan awan di lautan

Indonesia terhambat. Di wilayah Indonesia, El Nino menyebabkan kemarau berkepanjangan, penurunan jumlah curah hujan dan hari hujan, dan peningkatan temperature udara. Sedangkan di daerah Amerika Selatan, fenomena El Nino menyebabkan musim hujan berkepanjangan (Yuniasih dkk., 2023). Selain curah hujan, dampak dari fenomena El Nino dan La Nina adalah kekeringan lahan. Kekeringan lahan merupakan permasalahan sangat berkaitan dengan perubahan iklim, hujan, tanah serta vegetasi penutup lainnya sehingga adanya ketidakseimbangan distribusi jumlah pasokan air hujan pada permukaan tanah, ter evapotranspirasi dan air yang dimanfaatkan oleh vegetasi dalam proses pertumbuhannya. Kekeringan lahan merupakan permasalahan yang sering dihadapi oleh petani (Gabriel, 2019).

Pada penelitian Maulida & Juliansyah, (2024) menunjukkan bahwa hubungan dalam jangka pendek maupun jangka panjang antara nilai tukar petani pangan, peternakan, dan produk domestik bruto sektor pertanian dengan indeks pembangunan manusia bersifat negatif dan signifikan. Sehingga secara keseluruhan, nilai tukar petani pangan, peternakan, dan produk domestik bruto sektor ini berdampak signifikan terhadap indeks pembangunan manusia di Indonesia. Selain itu terdapat penelitian sebelumnya terkait metode VECM di prodi matematika UIN Malang, seperti pada penelitian Nur'aini Nanda, (2024) yang menggunakan tiga variabel, yaitu kurs rupiah, nilai ekspor, dan nilai impor, hasil analisis menunjukkan bahwa model VECM merupakan model terbaik berdasarkan nilai *Akaike Information Criterion* (AIC) terkecil. Metode ini menunjukkan adanya satu kointegrasi, yang berarti terdapat hubungan jangka panjang yang signifikan antara ketiga variabel tersebut. Selain itu, metode VECM yang diperoleh memiliki

nilai akurasi sangat tinggi pada kurs rupiah, ekspor, dan impor, yang mengindikasikan bahwa kinerja metode sangat akurat. Selain itu terdapat penelitian terkait metode VECM di prodi matematika UIN Malang, seperti pada penelitian Ardiansyah., (2025) yang menganalisis hubungan tingkat kesejahteraan petani antar subsektor di Indonesia dapat dikategorikan sangat baik berdasarkan hasil evaluasi kinerja metode sangat akurat. Seluruh subsektor Nilai Tukar Petani (NTP) menunjukkan tingkat kesalahan prediksi yang rendah untuk NTP Pangan, NTP Hortikultura, NTP Perkebunan, NTP Peternakan, dan NTP Perikanan.

Pada penelitian Auliya dkk., (2025) menunjukkan bahwa variabel iklim seperti curah hujan dan suhu udara berpengaruh terhadap produksi padi, sementara luas lahan menjadi faktor non-iklim yang juga signifikan. Namun, kebanyakan penelitian menggunakan metode ARDL atau regresi linier, dan belum banyak yang secara khusus menggunakan VECM untuk mengkaji hubungan jangka pendek dan jangka panjang, serta dinamika produksi padi pasca El Niño dengan mempertimbangkan variabel iklim secara komprehensif. Namun pada penelitian Irfan & Sulistijanti, (2024) menggunakan produksi padi sebagai variabel dependen dan variabel independennya berupa luas tanah dan produktivitas menggunakan metode VAR yang hasilnya diharapkan dapat memberikan kontribusi penting sebagai referensi perencanaan perekonomian dan pertanian namun dengan menggunakan variabel tersebut menghasilkan hubungan kointegrasi yang mana lebih cocok menggunakan metode VECM. Dengan keunggulannya dalam menganalisis hubungan kointegrasi dan respons variabel terhadap *shock* melalui *Impulse Response Function* (IRF) dan *Forecast Error Variance Decomposition* (FEVD), penerapan VECM diharapkan dapat memberikan gambaran yang lebih

mendalam mengenai pengaruh faktor iklim terhadap produksi padi di Jawa Timur, sekaligus menjadi dasar rekomendasi kebijakan adaptasi dan mitigasi dampak El Nino terhadap ketahanan pangan.

Fenomena El Nino memberikan dampak terhadap produksi padi di Provinsi Jawa Timur perlu dianalisis menurut deret waktu sehingga pemerintah memiliki kebijakan antisipatif ke depan dalam menjaga kestabilan stok pangan di Jawa Timur. Penelitian Mulyaqin, (2020) menganalisis dampak iklim ekstrem terhadap produksi padi menggunakan *Moving Average* yang melibatkan satu variabel saja. Penelitian ini menganalisis produksi padi pasca El Nino menggunakan metode VECM yang dapat melibatkan beberapa variabel secara simultan (Halim dkk., 2024).

1.2 Rumusan Masalah

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

1. Bagaimana analisis model pada produksi padi pasca El Nino di Jawa Timur menggunakan metode VECM dengan melibatkan variabel lainnya?
2. Bagaimana keakuratan metode VECM pada produksi padi pasca El Nino di Jawa Timur?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah dijelaskan, tujuan dari penelitian ini adalah sebagai berikut:

1. Menganalisis model produksi padi pasca El Nino di Jawa Timur menggunakan metode VECM dengan melibatkan variabel lainnya.

2. Menganalisis keakuratan metode VECM pada produksi padi pasca El Nino di Jawa Timur.

1.4 Manfaat Penelitian

Berdasarkan tujuan penelitian, maka penelitian ini diharapkan dapat memberikan manfaat bagi seluruh pihak sebagai berikut:

1. Manfaat Teoritis

Secara teoritis hasil penelitian ini memberikan manfaat antara lain:

- a. Bagi Akademisi dan peneliti, penelitian ini dapat menjadi referensi bagi penelitian selanjutnya yang mengkaji analisis produksi padi, khususnya dengan pendekatan *Vector Error Correction Model* (VECM), sehingga berkontribusi dalam pengembangan literatur dan metodologi di bidang pertanian.
- b. Bagi penulis, penelitian ini memberikan peluang untuk memperdalam pemahaman dan meningkatkan keterampilan dalam menganalisis data, khususnya melalui implementasi *Vector Error Correction* (VECM).

2. Manfaat Praktis

Secara praktis hasil penelitian ini memberikan manfaat antara lain:

- a. Bagi Pembaca umum dan petani padi, hasil penelitian ini memberikan informasi yang relevan terkait dinamika produksi padi, sehingga dapat memahami model produksi padi secara lebih menyeluruh.
- b. Bagi Dinas Pertanian, penelitian ini diharapkan dapat membantu dalam merumuskan kebijakan yang lebih efektif dan merencanakan

program-program yang tepat sasaran dalam meningkatkan produktivitas padi.

1.5 Batasan Masalah

Penulis menetapkan beberapa batasan masalah dalam penyusunan skripsi ini, yang mencakup berbagai aspek sebagai berikut:

1. Taraf signifikansi kesalahan yang digunakan dalam seluruh pengujian statistik adalah $\alpha = 0.05$ sebagai dasar pengambilan keputusan.
2. Pemilihan *lag optimum* menggunakan nilai AIC yang terkecil.
3. Mengukur tingkat kesalahan model menggunakan MAPE.
4. Data yang digunakan yaitu data bulanan dari Januari 2015 hingga Desember 2024.
5. Variabel yang digunakan yaitu produksi padi, curah hujan, suhu udara, kelembaban udara, kecepatan angin, penyinaran matahari, *Oceanic Nino Index* (ONI).

BAB II

KAJIAN TEORI

2.1 Teori Pendukung

2.1.1 Time Series

Analisis deret waktu adalah analisis data yang mempertimbangkan faktor waktu. Data dikumpulkan secara berurutan dengan interval waktu tertentu yang dapat dinyatakan dalam bentuk harian, mingguan, bulanan, kuartalan, dan tahunan. Tujuannya adalah untuk menentukan metode yang tepat pada data deret waktu dengan mengidentifikasi pola yang ada dalam data tersebut (Atman, 2018). Menurut Ridla dkk., (2023) model *time series* banyak digunakan dalam berbagai bidang seperti ekonomi, pertanian, kedokteran, dan lainnya. Time series memiliki empat jenis pola, diantaranya:

1. Pola musiman yaitu pola data yang dipengaruhi oleh faktor musim.
2. Pola trend yaitu pola data yang dipengaruhi kenaikan ataupun penurunan jangka panjang pada suatu data.
3. Pola horizontal yaitu pola data tidak belfluktuasi di sekitar nilai rata-rata yang konstan.
4. Pola siklus yaitu pola data yang dipengaruhi fluktuasi ekonomi jangka panjang seperti siklus bisnis.

2.1.2 Standarisasi Data

Standardisasi data merupakan proses untuk mengubah skala variabel dalam suatu dataset sehingga memiliki skala yang seragam. Hal ini bertujuan agar data lebih mudah dibandingkan dan dianalisis. Salah satu teknik standarisasi yang digunakan adalah menggunakan metode *z-score* yang mengukur seberapa jauh

sebuah nilai data menyimpang dari rata-rata dalam satuan standar deviasi. Dengan menggunakan *z-score*, data dari berbagai populasi dengan rata-rata dan standar deviasi yang berbeda, dapat diubah sehingga memiliki nilai dengan skala yang sama. Dengan skala yang standar tersebut, hal ini mempermudah analisis dan perbandingan antar variabel yang berbeda jenis dalam satu data set.

Rumus standardisasi data dengan menggunakan *z-score* dapat ditunjukkan pada persamaan berikut (Palinggik dkk., 2024):

$$Z' = \frac{z_i - \bar{X}_z}{\sigma_z} \quad (2.1)$$

dimana:

Z' : Data standarisasi

z_i : Data asli

$\bar{X}_z$: Rata-rata dari data asli

σ_z : Standar deviasi dari data asli

2.1.3 Stasioneritas

Stasioneritas artinya data tidak mengalami perkembangan dan penurunan yang signifikan. Visual plot *time series*, seringkali dapat dilihat apakah data tersebut stasioner atau tidak stasioner. Secara formal, pengujian stasioneritas rata-rata data *time series* bisa dilakukan dengan *Augmented Dickey Fuller test*, yaitu dengan pengujian terdapat atau tidaknya akar unit. Jika terdapat akar unit, sehingga data tersebut disebut tidak stasioner (Widya & Santoso, 2020). Uji *Augmented Dickey Fuller* (ADF) yaitu versi pengembangan dari pengujian *Dickey Fuller* yang digunakan dalam menentukan kestasioneran data. Tujuan dari uji ADF yaitu untuk melihat bahwa data menunjukkan akar unit atau tidak. Apabila hasil uji ADF data menampilkan adanya akar unit maka data yang dipakai

tidak stasioner. Misalkan uji ADF menampilkan data tidak stasioner, maka akan dilakukan *differencing* data (Nurman dkk., 2022). Persamaan Dickey Fuller untuk model differenced-lag sebagai berikut (D. M. Putri & Aghsilni, 2019).

$$\Delta y_t = \Phi_0 + \theta y_{t-1} + \sum_{i=1}^p \Phi_i \Delta y_{t-1} + e_t$$

dimana,

Φ_0 : Konstanta

p : Panjang Lag

θ : Koefisien variabel y_t

Φ_i : Konstanta untuk *difference* pada lag ke- i , dengan $i = 1, 2, \dots, p$

e_t : *Error* pada waktu ke- t

Δy_t : selisih nilai variabel y pada periode ke t dengan periode sebelumnya

Hipotesis:

H_0 : Data terdapat akar unit artinya data tidak stasioner

H_1 : Data tidak ada akar unit artinya data stasioner

Statistik uji ADF:

$$t_{statistik} = \frac{\hat{\theta}}{SE(\hat{\theta})} \quad (2.2)$$

dimana, $\hat{\theta}$ adalah penaksir kuadrat terkecil dari θ

Kriteria uji:

H_0 diterima jika nilai $|t_{statistik}| \leq t_{tabel}$ atau $p - value \geq \alpha$, artinya data tidak stasioner. H_0 ditolak jika nilai $|t_{statistik}| > t_{tabel}$ atau $p - value < \alpha$, artinya data tidak stasioner.

Differencing yaitu teknik yang digunakan dalam membuat data yang belum stasioner pada mean menjadi stasioner. *Differencing* merupakan jarak antar data dengan data lainnya pada waktu (t) dengan data pada waktu sebelumnya ($t - 1$) (Nurman dkk., 2022). Setelah differencing dilakukan, nilai selisih yang didapat tersebut diperiksa kembali untuk memastikan bahwa data sudah menjadi stasioner. Jika data belum stasioner sehingga dibutuhkan *differencing* kembali. Namun, pada umumnya *differencing* hanya dilaksanakan dua kali karena biasanya data asli tidak stasioner setelah *differencing* tahap pertama atau tahap kedua (D. M. Putri & Aghsilni, 2019). Rumus *differencing* untuk orde pertama yaitu (Montgomery dkk., 2008).

$$By_t = y_{t-1} \quad (2.3)$$

Notasi B (*Backward shift*) yang dikombinasikan dengan y_t memiliki pengaruh untuk menggeser data pada satu periode sebelumnya. Berikut adalah persamaan untuk *first differencing* $I(1)$ atau orde pertama.

$$\begin{aligned} \Delta y_t &= y_t - y_{t-1} \\ &= y_t - By_t \\ &= (1 - B)y_t \end{aligned}$$

2.1.4 Lag Optimum

Penentuan panjang lag yang optimal memiliki peran penting dalam *Vector Error Correction Model* (VECM). Panjang lag dari suatu variabel yang dimasukkan ke model yaitu untuk menangkap dinamika data. Lag optimal biasanya ditentukan dengan mencari nilai minimum dari kriteria tertentu, semakin panjang lag yang digunakan, maka parameter yang diestimasi juga semakin banyak, yang dapat mengurangi derajat kebebasan dan menurunkan efisiensi

estimasi parameter (Luh dkk., 2020). Menurut Sinulingga dkk., (2020), penentuan lag optimal diawali dengan mencoba berbagai lag hingga lag maksimum, yang dapat dihitung dengan persamaan berikut:

$$p_{max} = T^{\frac{1}{3}} \quad (2.4)$$

Selanjutnya, penentuan panjang *lag* yang optimal untuk model VAR dapat dilakukan berdasarkan kriteria *Akaike Information Criterion* (AIC) dengan memilih nilai yang menghasilkan kriteria terendah, dengan rumus sebagai berikut (Kirchgässner & Wolters, 2007):

$$AIC = \ln|\sum \hat{u}\hat{u}| + (k + pk^2) \frac{2}{T} \quad (2.5)$$

dimana:

$|\sum \hat{u}\hat{u}|$: Determinan matriks varian kovarian dari estimasi residual

p : Panjang *lag*

T : Banyak observasi

k : Banyak variabel

$\hat{u}$: Residual dari estimasi model VAR

2.1.5 *Vector Autoregressive*

Vector Autoregressive (VAR) adalah model analisis time series untuk menganalisis hubungan dinamis antar sejumlah variabel. Dalam model VAR, semua variabel tersebut harus diperlakukan setara tanpa perbedaan antara variabel endogen dan eksogen, karena semua variabel diperlakukan sebagai variabel endogen. Model VAR menunjukkan bahwa variabel endogen dijelaskan oleh nilai lag dari dirinya sendiri maupun nilai lag dari variabel lainnya (Gujarati

dkk., 2003) . Secara umum, persamaan untuk model VAR dengan lag sebanyak p atau $VAR(p)$ dapat ditulis seperti berikut (Wei, 2006).

$$w_t = \Phi_1 w_{t-1} + \Phi_2 w_{t-2} + \dots + \Phi_p w_{t-p} + e_t \quad (2.6)$$

$$\vec{x}_t = \Phi_1 \vec{x}_{t-1} + \Phi_2 \vec{x}_{t-2} + \dots + \Phi_p \vec{x}_{t-p} + \vec{e}_t$$

atau

$$\begin{bmatrix} w_{1,t} \\ x_{1,t} \\ \vdots \\ x_{k-1,t} \end{bmatrix} = \begin{bmatrix} \Phi_{11} & \Phi_{12} & \dots & \Phi_{1k} \\ \Phi_{21} & \Phi_{22} & \dots & \Phi_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ \Phi_{k1} & \Phi_{k2} & \dots & \Phi_{kk} \end{bmatrix} \begin{bmatrix} w_{1,t-i} \\ x_{1,t-i} \\ \vdots \\ x_{k-1,t-i} \end{bmatrix} + \begin{bmatrix} e_{1,t} \\ e_{2,t} \\ \vdots \\ e_{k,t} \end{bmatrix}$$

dimana:

w_t : Data pada Tingkat *difference* pada waktu ke- t pada variabel endogen

Φ_p : Matriks parameters VAR pada lag ke- p berukuran $k \times k$

$\vec{e}_t$: Vektor error pada waktu ke- t berukuran $k \times 1$

p : Panjang lag

k : Banyak variabel

$\vec{x}_t$: Vektor data berukuran $(k - 1) \times 1$ pada waktu ke- t pada variabel eksogen

Pada tahap selanjutnya, mungkin berguna untuk memikirkan lebih lanjut tentang pemodelan yang dijelaskan oleh persamaan (2.6) pada VAR yang berorde 1 dengan banyak variabel yang berjumlah k , sehingga didapatkan persamaan $VAR(1)$ sebagai berikut (Wei, 2006).

$$\begin{aligned} w_{1,t} &= \Phi_{11} w_{1,t-1} + \Phi_{12} w_{1,t-2} + \dots + \Phi_{1k} w_{1,t-k} + \varepsilon_{1,t} \\ x_{1,t} &= \Phi_{21} x_{1,t-1} + \Phi_{22} x_{1,t-2} + \dots + \Phi_{2k} x_{1,t-k} + \varepsilon_{2,t} \end{aligned} \quad (2.7)$$

$\vdots$

$$x_{k-1,t} = \Phi_{k1} x_{k-1,t-1} + \Phi_{k2} x_{k-1,t-2} + \dots + \Phi_{kk} x_{k-1,t-k} + \varepsilon_{k,t}$$

2.1.6 Uji Stabilitas

Pengujian stabilitas model *Vector Autoregressive* (VAR) dilakukan dengan menganalisis akar-akar dari fungsi polinomial, yang dikenal sebagai *roots of characteristic polynomial*. Model VAR yang stabil jika semua akar tersebut di dalam lingkaran satuan, yaitu ketika nilai absolutnya kurang dari 1. Stabilitas ini sangat penting untuk memastikan bahwa model mampu menghasilkan hasil peramalan yang akurat (Nurjannah, 2024). Pengujian kestabilan $VAR(p)$ dilakukan dengan melihat nilai eigen matriks parameter yang memiliki modulus kurang dari 1. Suatu model dikatakan stabil jika memenuhi persamaan sebagai berikut (Putri dkk., 2025).

Hipotesis:

H_0 : Terdapat akar yang berada di luar lingkaran unit kompleks artinya model $VAR(p)$ tidak stabil

H_1 : Akar berada di dalam lingkaran unit kompleks artinya model $VAR(p)$ stabil

Persamaan Uji Stabilitas:

$$\det(I_{kp} - \Phi z) = \det(I_k - \Phi_1 z - \dots - \Phi_p z^p) \neq 0, |z| \leq 1 \quad (2.8)$$

dimana, z adalah akar dari fungsi polinomial yang merupakan bilangan kompleks

Kriteria Uji:

H_0 ditolak jika nilai modulus $z \leq 1$, maka akar berada di dalam lingkaran unit kompleks artinya model $VAR(p)$ stabil.

H_0 diterima jika nilai modulus $z > 1$, maka terdapat akar yang berada di luar lingkaran unit kompleks artinya model $VAR(p)$ tidak stabil.

2.1.7 Uji Kointegrasi

Uji kointegrasi pertama kali diusulkan oleh Granger (1980) yang mengindikasikan adanya keterkaitan jangka panjang antar variabel. Dasar pengujian kointegrasi bertujuan untuk mengetahui apakah dua atau lebih variabel terintegrasi menyimpang secara signifikan dari suatu hubungan tertentu. Engle dan Granger (1987) memperkenalkan uji dua langkah untuk mengidentifikasi adanya kointegrasi, namun uji ini tidak dapat menangani keadaan di mana ada lebih dari satu hubungan kointegrasi (Wei, 2006). Untuk mengatasi masalah ini, Johansen (1988) mengusulkan uji rasio kemungkinan yang berbeda, yang memungkinkan penentuan hingga r vektor kointegrasi yang saling independen secara linear. Uji tersebut adalah uji trace (Wei, 2006). Uji tersebut bisa ditulis dalam bentuk matematis sebagai berikut (Ristianti & Purwadi, 2019).

Hipotesis:

H_0 : $r = 0$ artinya tidak terdapat vektor kointegrasi.

H_1 : $r > 0$ artinya terdapat r vektor kointegrasi.

Statistik Uji:

$$T_{trace}(r) = -T \sum_{i=r+1}^k \ln(1 - \hat{\lambda}_i) \quad (2.9)$$

dimana:

T : Banyak observasi

$\hat{\lambda}_i$: Estimasi *eigen value* terbesar ke- i , dimana $i = 0, 1, 2, \dots, k$.

r : *Rank* kointegrasi

Kriteria uji:

Jika nilai hitung uji *trace* lebih besar dari nilai kritis atau $p\text{-value} < \alpha$, maka H_0 ditolak, artinya ada r vektor kointegrasi. Sebaliknya, jika uji *trace* lebih kecil dari nilai kritis atau $p\text{-value} \geq \alpha$, maka H_0 tidak ditolak, artinya tidak ada vektor kointegrasi.

2.1.8 Kausalitas Granger

Kausalitas Granger merupakan suatu teknik statistik dalam analisis data deret waktu yang bertujuan untuk menilai apakah suatu variabel dapat digunakan untuk memprediksi variabel lain berdasarkan nilai-nilai sebelumnya (David F. Hendry, 2017). Jika informasi masa lalu dari suatu variabel terbukti secara signifikan meningkatkan ketepatan prediksi terhadap variabel lain, maka variabel tersebut dinyatakan memiliki hubungan kausalitas menurut pendekatan Granger. Hasil dari metode ini dapat menunjukkan kedua variabel memiliki hubungan dua arah, hubungan satu arah (di mana satu variabel memengaruhi variabel lainnya), atau tidak memiliki hubungan kausal sama sekali (tidak saling memengaruhi) (Wahyuni dkk., 2022). Model kausalitas granger dapat ditulis sebagai berikut (Gujarati dkk., 2003).

$$w_{1,t} = \sum_{i=1}^m \Phi_{11,i} w_{1,t-i} + \sum_{i=1}^m \Phi_{12,i} x_{1,t-i} + e_{1,t}$$

Hipotesis:

$$H_0: \sum_{i=1}^m \Phi_{12,i} = 0 \quad \text{artinya tidak ada hubungan kausalitas variabel } w_1 \text{ dan} \\ \text{variabel } x_1$$

$$H_1: \sum_{i=1}^m \Phi_{12,i} \neq 0 \quad \text{artinya ada hubungan kausalitas variabel } w_1 \text{ dan variabel } x_1$$

Dengan statistik uji kausalitas Granger sebagai berikut:

$$F_{hit} = (T - s) \frac{RSS_R - RSS_{UR}}{m(RSS_{UR})} \quad (2.10)$$

dimana:

RSS_R : *Residual Sum of Squares* dari model *restricted*

RSS_{UR} : *Residual Sum of Squares* dari model *unrestricted*

m : Banyak parameter dalam model *restricted*

T : Banyak observasi

s : Banyak parameter dalam model *unrestricted*

Kriteria uji:

H_0 ditolak jika nilai $F_{hit} > F_{tabel}$ atau $p_{value} < \alpha$, artinya ada hubungan kausalitas variabel y_1 dan variabel x_1 .

2.1.9 *Vector Error Correction Model*

Vector Error Correction Model (VECM) diperkenalkan oleh Engle dan Granger sebagai bentuk khusus dari model VAR untuk menangani variabel variabel *time series* yang tidak stasioner tetapi memiliki hubungan kointegrasi. Dengan adanya kointegrasi antar variabel, model ini menggambarkan terdapatnya hubungan jangka panjang yang terjalin di antara variabel-variabel tersebut. Meskipun berfokus pada analisis jangka panjang, model ini tetap relevan untuk menjelaskan kestabilan yang terjaga, sehingga penyesuaian dalam jangka pendek dapat terjadi sebagai respons terhadap perubahan variabel (Lütkepohl, 2004). Parameter dalam VECM diestimasi menggunakan pendekatan *Maximum*

Likelihood Estimation (MLE) dengan reduksi rank melalui metode Johansen untuk hubungan jangka panjang, serta metode *Ordinary Least Squares* (OLS) untuk hubungan jangka pendek. Dengan VECM, kita dapat menganalisis bagaimana variabel endogen berinteraksi dalam jangka pendek sambil tetap mempertahankan keseimbangan jangka panjang yang ada. Bentuk umum VECM adalah sebagai berikut (Lütkepohl, 2004).

$$\begin{aligned}\Delta w_t &= \delta\beta' w_{t-1} + \Gamma_1 \Delta w_{t-1} + \Gamma_2 \Delta w_{t-2} + \dots + \Gamma_{p-1} \Delta w_{t-(p-1)} + \vec{e}_t \\ &= \Pi w_{t-1} + \Gamma_1 \Delta w_{t-1} + \Gamma_2 \Delta w_{t-2} + \dots + \Gamma_{p-1} \Delta w_{t-(p-1)} + \vec{e}_t\end{aligned}\quad (2.11)$$

Untuk melihat bagaimana proses kointegrasi dapat muncul secara lebih umum dalam model VAR berdimensi k dan membentuk model VECM, pertimbangkan proses $VAR(p)$ berikut:

$$w_t = \Phi_1 w_{t-1} + \Phi_2 w_{t-2} + \dots + \Phi_p w_{t-p} + e_t \quad (2.12)$$

dengan $w_t = (w_{1t}, x_{1t}, \dots, x_{kt})'$. Misalkan proses ini tidak stasioner dengan:

$$|I_k - \Phi_1 z - \dots - \Phi_p z^p| = (1 - \lambda_1 z) \dots (1 - \lambda_n z) = 0 \text{ untuk } z = 1$$

Karena λ_i adalah kebalikan dari akar-akar polinomial determinan, salah satunya harus sama dengan 1. Semua akar lainnya diasumsikan berada di luar unit kompleks lingkaran satuan, artinya semua λ_i yang bukan 1 berada di luar unit kompleks lingkaran satuan. Karena: $|I_k - \Phi_1 - \dots - \Phi_p| = 0$, maka matriks:

$$\Pi = (I_k - \Phi_1 - \dots - \Phi_p)$$

Misalkan $rank(\Pi) = r \leq k$ atau terdapat kointegrasi. Maka, Π dapat ditransformasikan sebagai $\Pi = \delta\beta'$, dimana δ dan β adalah matriks $(k \times r)$. Dari pembahasan di bagian sebelumnya, bahwa setiap variabel menjadi stasioner setelah melakukan diferensiasi. Selanjutnya diasumsikan bahwa pengambilan diferensiasi sekali sudah cukup, sehingga pada persamaan (2.11) menjadi:

$$\begin{aligned}\vec{y}_t - \vec{y}_{t-1} = & -(I_k - \Phi_1 - \dots - \Phi_p)\vec{y}_{t-1} - \Phi_2\vec{y}_{t-1} + \Phi_2\vec{y}_{t-2} + \dots \\ & - \Phi_p\vec{y}_{t-(p-1)} + \Phi_p\vec{y}_{t-p} + \vec{e}_t\end{aligned}$$

maka

$$\Delta\vec{w}_t = \Pi\vec{w}_{t-1} + \Gamma_1\Delta\vec{w}_{t-1} + \Gamma_2\Delta\vec{w}_{t-2} + \dots + \Gamma_{p-1}\Delta\vec{w}_{t-(p-1)} + \vec{e}_t$$

dimana: $\Gamma_{p-1} = -\Phi_p$,

Seperti penjelasan sebelumnya dengan adanya hubungan kointegrasi ditransformasikannya Π menjadi $\Pi = \delta\beta'$. Dengan demikian, didapatkan bentuk umum VECM Adalah sebagai berikut (Lütkepohl, 2004):

$$\begin{aligned}\Delta\vec{w}_t &= \delta\beta'\vec{w}_{t-1} + \Gamma_1\Delta\vec{w}_{t-1} + \Gamma_2\Delta\vec{w}_{t-2} + \dots + \Gamma_{p-1}\Delta\vec{w}_{t-(p-1)} + \vec{e}_t \\ &= \Pi\vec{w}_{t-1} + \Gamma_1\Delta\vec{w}_{t-1} + \Gamma_2\Delta\vec{w}_{t-2} + \dots + \Gamma_{p-1}\Delta\vec{w}_{t-(p-1)} + \vec{e}_t\end{aligned}$$

dimana:

$\vec{w}_t$: Vektor data berukuran $k \times 1$ pada waktu ke- t

Π : Matriks koefisien kointegrasi ($k \times k$)

Γ_i : Matriks parameter ($k \times k$), $i = 1, \dots, p-1$

δ : Matriks *adjustment* (parameter jangka pendek) ($k \times r$)

β : Matriks kointegrasi (parameter jangka panjang) ($k \times r$)

$\vec{e}_t$: Vektor error pada waktu ke- t berukuran $k \times 1$

p : Panjang *lag*

Bentuk dari VECM dengan lag 3 atau $VECM(3)$ dengan variabel berjumlah k dapat dituliskan persamaan sebagai berikut:

$$\begin{aligned}\Delta w_{1,t} = & \Pi_{11}w_{1,t-1} + \Pi_{12}\Delta x_{1,t-1} + \dots + \Pi_{1k}\Delta x_{k,t-1} \\ & + \Gamma_{111}\Delta w_{1,t-2} + \Gamma_{112}\Delta x_{1,t-2} + \dots +\end{aligned}$$

$$\Gamma_{11k}\Delta x_{k,t-i} + \Gamma_{211}\Delta w_{1,t-3} + \Gamma_{212}\Delta x_{1,t-3} +$$

$$\dots \Gamma_{21k}\Delta x_{k,t-i} + e_{1,t}$$

$$\begin{aligned} \Delta x_{1,t} &= \Pi_{21}\Delta x_{1,t-1} + \Pi_{22}\Delta x_{2,t-1} + \dots + \\ &\quad \Pi_{2k}\Delta x_{k,t-1} + \Gamma_{121}\Delta x_{1,t-2} + \Gamma_{122}\Delta x_{2,t-2} + \\ &\quad \dots + \Gamma_{12k}\Delta x_{k,t-i} + \Gamma_{221}\Delta x_{1,t-3} + \\ &\quad \Gamma_{222}\Delta x_{2,t-3} + \dots + \Gamma_{22k}\Delta x_{k,t-i} + e_{2,t} \end{aligned} \tag{2.13}$$

$$\begin{aligned} \Delta x_{k-1,t} &= \Pi_{k1}\Delta x_{1,t-1} + \Pi_{k2}\Delta x_{2,t-1} + \dots + \Pi_{kk}\Delta x_{k,t-1} + \\ &\quad \Gamma_{1k1}\Delta x_{1,t-2} + \Gamma_{1k2}\Delta x_{2,t-2} + \dots + \\ &\quad \Gamma_{1kk}\Delta x_{k,t-i} + \Gamma_{2k1}\Delta x_{1,t-3} + \\ &\quad \Gamma_{2k2}\Delta x_{2,t-3} + \dots + \Gamma_{2kk}\Delta x_{k,t-i} + e_{3,t} \end{aligned}$$

atau

$$\begin{aligned} \begin{bmatrix} \Delta w_{1,t} \\ \Delta x_{1,t} \\ \vdots \\ \Delta x_{k-1,t} \end{bmatrix} &= \begin{bmatrix} \Pi_{11} & \Pi_{12} & \dots & \Pi_{1k} \\ \Pi_{21} & \Pi_{22} & \dots & \Pi_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ \Pi_{k1} & \Pi_{k2} & \dots & \Pi_{kk} \end{bmatrix} \begin{bmatrix} w_{1,t-1} \\ \Delta x_{1,t-1} \\ \vdots \\ \Delta x_{k-1,t-1} \end{bmatrix} + \\ &\quad \begin{bmatrix} \Gamma_{111} & \Gamma_{112} & \dots & \Gamma_{11k} \\ \Gamma_{121} & \Gamma_{122} & \dots & \Gamma_{12k} \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma_{1k1} & \Gamma_{1k2} & \dots & \Gamma_{1kk} \end{bmatrix} \begin{bmatrix} \Delta w_{1,t-2} \\ \Delta x_{1,t-2} \\ \vdots \\ \Delta x_{k-1,t-2} \end{bmatrix} + \\ &\quad \begin{bmatrix} \Gamma_{211} & \Gamma_{212} & \dots & \Gamma_{21k} \\ \Gamma_{221} & \Gamma_{222} & \dots & \Gamma_{22k} \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma_{2k1} & \Gamma_{2k2} & \dots & \Gamma_{2kk} \end{bmatrix} \begin{bmatrix} \Delta w_{1,t-3} \\ \Delta x_{1,t-3} \\ \vdots \\ \Delta x_{k-1,t-3} \end{bmatrix} + \begin{bmatrix} e_{1,t} \\ e_{2,t} \\ \vdots \\ e_{k,t} \end{bmatrix} \end{aligned}$$

dimana:

$$\Pi = \delta\beta'$$

$$\Pi = \begin{bmatrix} \delta_1 \\ \delta_2 \\ \vdots \\ \delta_k \end{bmatrix} [\beta_1 \quad \beta_2 \quad \cdots \quad \beta_k] \quad (2.14)$$

2.1.10 Uji Autokorelasi

Uji Autokorelasi model dilakukan untuk melihat apakah suatu model layak digunakan dalam peramalan data pada periode selanjutnya. Salah satu metode yang digunakan dalam uji diagnostik adalah uji *Portmanteau* secara multivariat, yang bertujuan untuk mengetahui adanya autokorelasi pada residual. Adapun hipotesis yang diuji dalam uji ini adalah sebagai berikut (Lütkepohl, 2004):

H_0 : Tidak terdapat autokorelasi residual hingga lag ke- p .

H_1 : Terdapat autokorelasi residual hingga lag ke- p .

Statistik uji:

$$Q_p = T \sum_{i=1}^p tr(\hat{C}_i' \hat{C}_0^{-1} \hat{C}_i \hat{C}_0^{-1}) \quad (2.15)$$

dimana,

$\hat{C}_i'$: Matriks penduga autokovarians residual model pada lag ke- p

T : Banyak observasi

Kriteria uji:

H_0 diterima apabila nilai *p-value* dari statistic Q pada setiap lag ke- p lebih besar dibandingkan dengan Tingkat signifikansi α , yang berarti tidak terdapat autokorelasi residual hingga lag ke- p .

2.1.11 Impulse Response Function

Impulse Response Function (IRF) menggambarkan bagaimana suatu variabel bereaksi terhadap guncangan (shock) dari variabel lain dalam suatu model, baik pada saat shock terjadi maupun di beberapa periode ke depan. IRF menunjukkan lintasan atau pola perubahan variabel untuk kembali mencapai keseimbangannya setelah mengalami gangguan. Dalam model VECM, perilaku dinamis antar variabel dapat dianalisis melalui respon variabel endogen terhadap kejutan dari variabel lainnya. Hasil IRF memberikan gambaran durasi dan sejauh mana pengaruh dari guncangan suatu variabel terhadap variabel lain berlangsung hingga dampaknya menghilang dan kembali ke keseimbangan (Maulida & Juliansyah, 2024). Analisis dari IRF dapat dituliskan dari model VAR dalam bentuk matriks sebagai berikut:

$$\begin{bmatrix} y_{1,t} \\ x_{1,t} \\ x_{2,t} \end{bmatrix} = \begin{bmatrix} \Phi_{11} & \Phi_{12} & \Phi_{13} \\ \Phi_{21} & \Phi_{22} & \Phi_{23} \\ \Phi_{31} & \Phi_{32} & \Phi_{33} \end{bmatrix} \begin{bmatrix} y_{1,t-1} \\ x_{1,t-1} \\ x_{2,t-1} \end{bmatrix} + \begin{bmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \end{bmatrix}$$

Dengan model VAR dalam kondisi stabil menjadi sebagai berikut:

$$\begin{bmatrix} y_{1,t} \\ x_{1,t} \\ x_{2,t} \end{bmatrix} = \begin{bmatrix} \bar{y}_{1t} \\ \bar{x}_{1t} \\ \bar{x}_{2t} \end{bmatrix} + \sum_{i=0}^{\infty} \begin{bmatrix} \Phi_{11} & \Phi_{12} & \Phi_{13} \\ \Phi_{21} & \Phi_{22} & \Phi_{23} \\ \Phi_{31} & \Phi_{32} & \Phi_{33} \end{bmatrix}^i \begin{bmatrix} e_{1,t-i} \\ e_{2,t-i} \\ e_{3,t-i} \end{bmatrix}$$

Vektor *error* dapat dituliskan sebagai berikut:

$$\begin{bmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \end{bmatrix} = \frac{1}{\det(\Phi_i)} \times adj(\Phi_i) \times \begin{bmatrix} \varepsilon_{y_{1,t}} \\ \varepsilon_{y_{2,t}} \\ \varepsilon_{y_{3,t}} \end{bmatrix}$$

Dimana:

$$\Phi_i = \begin{bmatrix} \Phi_{11} & \Phi_{12} & \Phi_{13} \\ \Phi_{21} & \Phi_{22} & \Phi_{23} \\ \Phi_{31} & \Phi_{32} & \Phi_{33} \end{bmatrix}^i$$

$\det(\Phi_i)$ merupakan determinan dari Φ_i dan $\text{adj}(\Phi_i)$ adalah matriks adjoint

Φ_i , sehingga didapatkan persamaan:

$$\begin{bmatrix} y_{1,t} \\ x_{1,t} \\ x_{2,t} \end{bmatrix} = \begin{bmatrix} \bar{y}_{1t} \\ \bar{x}_{1t} \\ \bar{x}_{2t} \end{bmatrix} + \frac{1}{\det(\Phi_i)} \sum_{i=0}^{\infty} \begin{bmatrix} \Phi_{11} & \Phi_{12} & \Phi_{13} \\ \Phi_{21} & \Phi_{22} & \Phi_{23} \\ \Phi_{31} & \Phi_{32} & \Phi_{33} \end{bmatrix}^i \times \text{adj}(\Phi_i) \times \begin{bmatrix} \varepsilon_{y_{1,t}} \\ \varepsilon_{y_{2,t}} \\ \varepsilon_{y_{3,t}} \end{bmatrix}$$

Selanjutnya notasi disederhanakan dengan mendefiisikan matriks ϕ_i , dimana

$$\phi_i = \frac{1}{\det(\Phi_i)} \sum_{i=0}^{\infty} \begin{bmatrix} \Phi_{11} & \Phi_{12} & \Phi_{13} \\ \Phi_{21} & \Phi_{22} & \Phi_{23} \\ \Phi_{31} & \Phi_{32} & \Phi_{33} \end{bmatrix}^i \times \text{adj}(\Phi_i)$$


Sehingga persamaan dapat ditulis sebagai berikut:

$$\begin{bmatrix} y_{1,t} \\ x_{1,t} \\ x_{2,t} \end{bmatrix} = \begin{bmatrix} \bar{y}_{1t} \\ \bar{x}_{1t} \\ \bar{x}_{2t} \end{bmatrix} + \sum_{i=0}^{\infty} \begin{bmatrix} \phi_{11}(h) & \phi_{12}(h) & \phi_{13}(h) \\ \phi_{21}(h) & \phi_{22}(h) & \phi_{23}(h) \\ \phi_{31}(h) & \phi_{32}(h) & \phi_{33}(h) \end{bmatrix} \begin{bmatrix} \varepsilon_{y_{1,t-i}} \\ \varepsilon_{y_{2,t-i}} \\ \varepsilon_{y_{3,t-i}} \end{bmatrix}$$

atau

$$\vec{y}_t = \vec{\mu} + \sum_{i=0}^{\infty} \phi_i \vec{\varepsilon}_{t-i} \quad (2.16)$$

Dalam konteks ini, koefisien $\phi_{11}(h)$, $\phi_{12}(h)$, $\phi_{13}(h)$, $\phi_{21}(h)$, $\phi_{22}(h)$, $\phi_{23}(h)$, $\phi_{31}(h)$, $\phi_{32}(h)$, $\phi_{33}(h)$ merupakan *Impulse Response Function* yang digunakan untuk melihat dampak guncangan (*shock*) dari masing-masing variabel yang divisualisasikan dengan grafik (Lütkepohl, 2004).



Gambar 2.1 Grafik IRF

2.1.12 Variance Decomposition

Variance Decomposition (VD) digunakan untuk memprediksi seberapa besar kontribusi perubahan varian pada setiap variabel akibat terdapatnya perubahan variabel tertentu. Analisis tersebut memberikan informasi tentang proporsi pengaruh guncangan (shock) dari variabel itu sendiri dan pengaruh dari guncangan variabel lainnya. Dengan demikian, dapat diketahui sejauh mana peran suatu variabel dalam memengaruhi variabel lainnya. Model VD pada jangka waktu ke- h , dapat ditulis sebagai berikut (Lütkepohl, 2004):

$$\begin{aligned} \sigma_{y1t}(h)^2 &= \sigma_{y1t}^2[\phi_{11}(0)^2 + \phi_{11}(1)^2 + \dots + \phi_{11}(h-1)^2] \\ &+ \sigma_{x1t}^2[\phi_{12}(0)^2 + \phi_{12}(1)^2 + \dots + \phi_{12}(h-1)^2] \end{aligned} \quad (2.17)$$

Dimana variabel $\sigma_{y1t}(h)^2$ menunjukkan total perubahan menunjukkan total perubahan (varian) dari variabel y_1 pada waktu ke- h . Varian ini terdiri dari dua bagian, yaitu pengaruh dari guncangan y_1 terhadap dirinya sendiri, yang diwakili oleh σ_{y1t}^2 dan koefisien impulse response $\phi_{11}(0)^2 + \phi_{11}(1)^2 + \dots +$

$\phi_{11}(h-1)$, serta pengaruh dari variabel lain, seperti, x_1 yang diwakili oleh $\sigma_{x_1t}^2$ dan koefisien impulse response $\phi_{12}(0)^2 + \phi_{12}(1)^2 + \dots + \phi_{12}(h-1)$. Dalam analisis ini, waktu ke- h digunakan untuk melihat perkembangan pengaruh guncangan dari periode sekarang hingga beberapa periode ke depan.

2.1.13 Mean Absolute Percentage Error

Mean Absolute Percentage Error (MAPE) untuk mengukur tingkat kesalahan dalam suatu model peramalan dengan menghitung rata-rata kesalahan persentase absolut antara nilai yang diprediksi dan nilai aktual. Persamaan MAPE dapat dituliskan sebagai berikut (Montgomery dkk., 2008):

$$MAPE = \frac{1}{T} \sum_{t=1}^T \frac{|y_t - f_t|}{y_t} \times 100\% \quad (2.18)$$

dimana:

y_t : Data periode ke- t

f_t : Data peramalan periode ke- t

T : Banyak observasi

Keakuratan Keakuratan MAPE terdiri dari beberapa range, menurut (Khairina dkk., 2019) tingkat keakuratan model berdasarkan range MAPE sebagai berikut:

Tabel 2.1 Kriteria Nilai pada MAPE

MAPE	Keakuratan
$MAPE \leq 10\%$	Sangat Akurat
$10\% < MAPE \leq 20\%$	Akurat
$20\% < MAPE \leq 50\%$	Cukup Akurat
$MAPE > 50\%$	Kurang Akurat

2.1.14 Missing Value

Satu masalah utama dalam pengolahan data adalah adanya nilai yang hilang (*missing values*) yaitu dimana sebagian data tidak lengkap atau hilang. Masalah ini sering kali menghambat proses analisis karena nilai yang hilang bisa mempengaruhi efisiensi dan akurasi hasil penelitian. Menurut Riko & Mudi (2023) ada 4 metode yang dilakukan untuk melakukan imputasi tersebut yaitu menggunakan metode *K-Nearest Neighbor* (KNN), *Neural Network*, nilai mean, dan nilai maksimum dari suatu variabel. Berdasarkan pengujian, didapatkan bahwa metode KNN yang memberikan hasil terbaik dengan nilai RMSE terendah dibandingkan dengan metode lainnya. Persamaan sebagai berikut.

$$\hat{y}_{1t} = \frac{\sum_{i=1}^n \left(\frac{1}{d(x_{1t}, x_{1t,i})} \cdot y_{1t,i} \right)}{\sum_{i=1}^n \left(\frac{1}{d(x_{1t}, x_{1t,i})} \right)} \quad (2.19)$$

dimana:

$\hat{y}_{1t}$: Nilai prediksi/estimasi dari variabel y_1

$(x_{1t}, x_{1t,i})$: Jarak nilai dari variabel x_{1t} dengan $x_{1t,i}$

$y_{1t,i}$: Nilai tetangga dari variabel y_1

$\frac{1}{d(x_{1t}, x_{1t,i})}$: Nilai pembobot dari variabel lain

2.1.15 Curah Hujan

Curah hujan merupakan salah satu unsur utama dalam sistem iklim yang berperan penting dalam siklus hidrologi, pertanian, dan ketersediaan air. Curah hujan menunjukkan jumlah air hujan yang turun ke permukaan bumi dalam periode waktu tertentu, yang umumnya diukur dalam satuan milimeter (mm). Pola dan intensitas curah hujan sangat dipengaruhi oleh faktor geografis, musim,

sirkulasi atmosfer, serta fenomena iklim global seperti El Nino dan La Nina. Oleh karena itu, perubahan pada pola curah hujan sering dijadikan sebagai indikator penting dalam mendeteksi perubahan iklim. Di Kota Kupang, Nusa Tenggara Timur, menunjukkan bahwa dalam rentang waktu 30 tahun terakhir (1991–2020), curah hujan tahunan mengalami penurunan. Fenomena El Nino dan La Nina juga terbukti memengaruhi karakteristik curah hujan di wilayah Kupang. El Nino menyebabkan meningkatnya jumlah hari tanpa hujan berturut-turut (Consecutive Dry Days/CDD). Dengan demikian, curah hujan di wilayah ini sangat dipengaruhi oleh dinamika iklim global, sehingga pemantauan dan analisis jangka panjang menjadi sangat penting untuk perencanaan dan kebijakan adaptasi iklim (Beis dkk., 2022).

2.1.16 Suhu Udara

Suhu udara merupakan salah satu unsur iklim yang menunjukkan tingkat panas atau dinginnya udara di suatu wilayah. Suhu ini dipengaruhi oleh pergerakan matahari, topografi, tutupan lahan, dan kondisi atmosfer. Dalam konteks perubahan iklim, suhu udara menjadi indikator penting yang sering dianalisis untuk melihat pemanasan global maupun perubahan iklim regional. Secara umum, suhu udara terdiri atas suhu maksimum, suhu minimum, dan suhu rata-rata. Perubahan suhu udara dapat berdampak signifikan terhadap proses alam, seperti penguapan, pembentukan awan, dan pola hujan, serta berdampak langsung pada aktivitas pertanian, kesehatan, dan ketersediaan air. Peningkatan suhu udara juga memperbesar potensi penguapan, yang pada akhirnya dapat mempercepat terjadinya kekeringan, terutama jika tidak diimbangi dengan curah hujan yang

cukup. Oleh karena itu, suhu udara menjadi salah satu parameter penting yang perlu diperhatikan dalam kajian iklim dan lingkungan (Fadholi dkk., 2013).

2.1.17 Kelembaban Udara

Kelembapan udara menggambarkan jumlah uap air yang terkandung di atmosfer. Udara akan terasa lembap jika kandungan uap airnya tinggi, dan kondisi ini biasanya dipengaruhi oleh suhu udara semakin hangat suhu semakin besar kemampuan udara untuk menahan uap air. Meskipun hanya menyumbang sebagian kecil dari massa atmosfer, uap air memiliki peran penting dalam proses cuaca dan iklim. Uap air ini dapat mengalami kondensasi dan membentuk awan yang pada akhirnya menghasilkan presipitasi seperti hujan. Oleh karena itu, kelembapan udara menjadi salah satu faktor utama yang memengaruhi pembentukan awan dan intensitas curah hujan. Ketika kelembapan relatif rendah, udara menjadi kering dan proses pembentukan awan berkurang, sehingga potensi hujan menurun. Sebaliknya, kelembapan yang tinggi memperbesar peluang terjadinya hujan, sehingga perubahan kelembapan dapat berdampak langsung terhadap pola curah hujan suatu wilayah (Haryanto, 2023).

2.1.18 Kecepatan Angin

Angin merupakan pergerakan udara yang terjadi karena perbedaan tekanan udara di permukaan bumi, bergerak dari wilayah bertekanan tinggi menuju wilayah bertekanan rendah. Kecepatan dan arah angin dipengaruhi oleh beberapa faktor, antara lain ketinggian suatu daerah, kondisi geografis, topografi wilayah, dan karakteristik biometrik daerah tersebut. Misalnya, daerah yang berada di dataran tinggi atau pegunungan akan mengalami pola kecepatan angin yang berbeda dibandingkan dengan daerah dataran rendah. Kecepatan angin diukur

menggunakan alat bernama anemometer. Anemometer bekerja dengan cara merekam putaran baling-baling yang terdorong oleh hembusan angin. Putaran ini kemudian diubah menjadi nilai kecepatan angin yang dapat ditampilkan secara otomatis. Pengukuran ini penting untuk memantau kondisi cuaca serta mendukung berbagai aplikasi, mulai dari navigasi hingga perencanaan energi terbarukan (Al Hakim dkk., 2020).

2.1.19 Penyinaran Matahari

Penyinaran matahari adalah durasi waktu ketika intensitas radiasi matahari yang mencapai permukaan bumi melebihi 120 W/m^2 . Unsur klimatologi ini berperan penting dalam proses iklim, cuaca, dan produktivitas pertanian. Pengukuran lama penyinaran matahari di Indonesia umumnya menggunakan Campbell Stokes Recorder, yaitu alat berbentuk bola kaca berdiameter 10 cm yang memfokuskan sinar matahari pada kertas pias. Radiasi yang melebihi ambang batas akan membakar kertas tersebut, dan panjang jejak terbakar menunjukkan lama penyinaran dalam satu hari. Hasil pengukuran Pusat Sains dan Teknologi Atmosfer menunjukkan bahwa distribusi lama penyinaran sangat dipengaruhi oleh musim dan kondisi atmosfer. Pada musim hujan, durasi penyinaran cenderung pendek akibat tingginya tutupan awan, sedangkan pada musim kemarau lebih merata dan panjang. Radiasi matahari yang diterima bumi terdiri dari radiasi langsung (direct radiation) dan radiasi hamburan atmosfer (diffuse radiation), dikenal sebagai radiasi global atau insolasi. Di wilayah tropis, fluktuasi lama penyinaran relatif kecil sepanjang tahun, sedangkan di lintang tinggi perbedaannya lebih besar. Pemantauan lama penyinaran matahari penting untuk

mendukung analisis iklim, perencanaan pertanian, serta pemanfaatan energi surya (Hamdi, 2020).

2.1.20 El Nino

El Nino adalah fenomena iklim global yang terjadi akibat pemanasan suhu permukaan laut yang tidak biasa di bagian tengah dan timur Samudra Pasifik. Perubahan suhu ini menyebabkan gangguan pada pola cuaca di berbagai belahan dunia, termasuk Indonesia. Intensitas fenomena ini diukur menggunakan Oceanic Niño Index (ONI), yaitu indikator yang menghitung anomali suhu permukaan laut di wilayah Pasifik tengah (Nino 3.4). Nilai $ONI \geq +0,5$ menandakan kondisi El Niño, sedangkan nilai $\leq -0,5$ menunjukkan La Niña, dan nilai di antara keduanya mencerminkan kondisi netral. Fenomena El Niño biasanya menyebabkan penurunan curah hujan yang signifikan dan memperpanjang musim kemarau, sehingga berpotensi menimbulkan kekeringan. Di Indonesia, dampak El Niño seringkali terlihat dari musim kemarau yang berkepanjangan dan suhu udara yang meningkat, yang berkontribusi terhadap degradasi lingkungan dan kekurangan sumber daya air. Fenomena ini juga mempengaruhi sektor pertanian, khususnya produksi tanaman pangan seperti padi, yang sangat bergantung pada ketersediaan air dan pola curah hujan yang stabil. Musim kemarau yang panjang dan suhu tinggi akibat El Nino dapat meningkatkan risiko kebakaran hutan dan menurunkan produktivitas pertanian. Oleh karena itu, pemantauan dan mitigasi dampak El Nino sangat penting untuk menjaga ketahanan pangan dan lingkungan di Indonesia, terutama di daerah-daerah rawan seperti Jawa Timur (Karmen, 2023).

2.1.21 EViews

EViews (Econometric Views) merupakan perangkat lunak statistik dan ekonometrika yang dirancang untuk membantu analisis data, estimasi model ekonometrika, peramalan, serta simulasi berbagai model ekonomi dan keuangan. EViews banyak digunakan oleh peneliti, akademisi, lembaga pemerintah, bank sentral, dan organisasi internasional karena memiliki kemampuan yang komprehensif dalam mengolah data *time series*, *cross section*, maupun panel data. Selain menyediakan metode estimasi dasar seperti *Ordinary Least Squares* (OLS), EViews juga mendukung berbagai analisis lanjutan, antara lain *Vector Autoregression* (VAR), *Structural Vector Autoregression* (SVAR), *Vector Error Correction Model* (VECM), *Cointegration Test*, *Impulse Response Function* (IRF), dan *Forecast Error Variance Decomposition* (FEVD). EViews dipilih sebagai salah satu perangkat lunak utama dalam analisis sistem makroekonomi karena kemampuannya dalam mengestimasi dan menginterpretasikan model VAR hingga VECM secara efisien serta kemudahan penggunaannya dalam aplikasi penelitian empiris (Ouliaris dkk., 2018).

2.2 Kajian Integrasi Topik dengan Al-Qur'an

Analisis hubungan antar variabel dalam penelitian ilmiah bertujuan untuk memahami keterkaitan fenomena yang kompleks. Dalam penelitian ini, metode *Vektor Error Correction Model* digunakan untuk menelaah keterkaitan jangka pendek dan jangka panjang antara faktor-faktor iklim (curah hujan, suhu, kelembapan, lama penyinaran matahari, kecepatan angin, serta fenomena El Nino) terhadap produksi padi. Islam memandang bahwa usaha manusia dalam memahami fenomena alam adalah bagian dari ikhtiar ilmiah yang sejalan dengan perintah Allah

untuk memperhatikan tanda-tanda kebesaran-Nya. Upaya ini menjadi penting dalam rangka menjaga ketahanan pangan, keberlanjutan sumber daya alam, serta kesejahteraan umat, selama dilakukan dengan cara yang sah, bermanfaat, dan tidak bertentangan dengan akidah. Salah satunya terdapat dalam Al-Qur'an, khususnya pada Surat 'Abasa ayat 24-32, di mana Allah SWT berfirman (Kemenag, 2022):

فَلْيَنْظُرِ الْإِنْسَانُ إِلَى طَعَامِهِ ۚ ٢٤ أَنَّا صَبَبْنَا الْمَاءَ صَبًّا ۚ ٢٥ ثُمَّ شَفَقْنَا الْأَرْضَ شَفًّا ۚ ٢٦ فَأَنْبَتْنَا فِيهَا حَبًّا ۚ ٢٧ وَعِنَبًا وَقَضْبًا ۚ ٢٨ وَزَيْتُونًا وَنَخْلًا ۚ ٢٩ وَحَدَائِقَ غُلْبًا ۚ ٣٠ وَفَاكِهَةً وَأَبًّا ۚ ٣١ مَتَاعًا لَّكُمْ وَلَآئِعًا لَّكُمْ ۚ ٣٢

Artinya:

“Maka hendaklah manusia memperhatikan makanannya. Sesungguhnya Kami benar-benar telah mencurahkan air (dari langit), kemudian Kami belah bumi dengan sebaik-baiknya, lalu Kami tumbuhkan biji-bijian di bumi itu, anggur dan sayur-sayuran, zaitun dan kurma, kebun-kebun yang lebat, buah-buahan dan rumput-rumputan, untuk kesenanganmu dan untuk binatang-binatang ternakmu.”

Menurut Tafsir Kementerian Agama, manusia diperintahkan untuk memperhatikan makanan yang dikonsumsi setiap hari, karena pada hakikatnya makanan tersebut merupakan karunia Allah yang melalui proses panjang dan teratur. Allah menurunkan hujan dari langit, membelah bumi yang tandus sehingga subur kembali, lalu menumbuhkan biji-bijian, termasuk padi dan gandum, anggur, sayur-sayuran, zaitun, kurma, serta kebun yang rindang dengan berbagai buah dan rerumputan. Semua itu diciptakan untuk kemakmuran manusia sekaligus sebagai rezeki bagi hewan ternak.

Ayat ini menunjukkan bahwa sistem pertanian pada dasarnya telah diatur oleh Allah melalui sunnatullah, yaitu keteraturan alam. Proses air hujan, kesuburan tanah, suhu, sinar matahari, hingga tumbuhnya tanaman merupakan rangkaian yang saling berhubungan. Jika salah satu faktor terganggu misalnya hujan berkurang,

suhu terlalu tinggi akibat fenomena El Niño, atau kelembapan tidak stabil maka akan memengaruhi hasil pertanian, termasuk produksi padi.

Dalam konteks penelitian ini, penjelasan Al-Qur'an tersebut selaras dengan pendekatan ilmiah yang digunakan, yaitu metode *Vektor Error Correction Model*. Metode ini menganalisis hubungan jangka pendek dan jangka panjang antara variabel iklim (curah hujan, suhu, kelembapan, lama penyinaran matahari, dan kecepatan angin) terhadap produksi padi. Sebagaimana ayat-ayat di atas menggambarkan keteraturan proses alam dari turunnya hujan hingga tumbuhnya tanaman, analisis produksi padi menggunakan metode *Vektor Error Correction Model* membantu menjelaskan bagaimana perubahan dalam faktor iklim akan memengaruhi produktivitas pertanian.

Dengan demikian, penelitian ini sejalan dengan pesan Al-Qur'an bahwa manusia tidak hanya diperintahkan untuk menikmati hasil pertanian, tetapi juga memahami proses dan keteraturan yang melandasinya. Usaha ilmiah melalui analisis produksi padi menggunakan metode *Vektor Error Correction Model* dapat dipandang sebagai bagian dari ikhtiar membaca sunnatullah, yaitu hukum alam ciptaan Allah, agar manusia mampu menjaga ketahanan pangan, mengelola sumber daya pertanian secara berkelanjutan, dan menumbuhkan rasa syukur kepada Allah atas segala nikmat-Nya.

2.3 Kajian Topik dengan Teori Pendukung

Tanaman padi (*Oryza sativa L*) merupakan sumber bahan pangan utama bagi hampir seluruh penduduk Indonesia. Padi tidak hanya memiliki nilai ekonomi, tetapi juga memiliki nilai budaya dan sosial yang penting karena berperan dalam memenuhi kebutuhan pokok masyarakat khususnya di Jawa Timur. Pemerintah

Provinsi Jawa Timur mendorong petani lokal untuk meningkatkan produksi padi. Sektor pertanian tidak terlepas dari beberapa faktor, antara lain adalah faktor atmosfer, dimana tanaman padi akan produktif pada keadaan atmosfer tertentu saja khususnya pada kasus fenomena El-nino yang menyebabkan angin pasat timur melemah dan berakibat kemarau panjang. Terdapat faktor-faktor yang mempengaruhi produktivitas padi pasca El-nino. Faktor-faktor yang digunakan meliputi curah hujan, suhu udara, kelembapan udara, *Oceanic Nino Index* (ONI), lama penyinaran matahari, dan kecepatan angin. Terdapat beberapa metode dalam menganalisis produksi padi pasca El-nino, salah satunya yaitu metode *Vector Error Correction Model* (VECM).

Implementasi *Vector Error Correction Model* (VECM) dalam menganalisis produksi padi pasca El-nino dengan beberapa faktor seperti curah hujan, suhu udara, kelembapan udara, *Oceanic Nino Index* (ONI), lama penyinaran matahari, dan kecepatan angin diawali dengan identifikasi data melalui analisis statistik deskriptif dan grafik *time series* untuk mengamati pola pergerakan produksi padi, curah hujan, suhu udara, kelembapan udara, *Oceanic Nino Index* (ONI), lama penyinaran matahari, dan kecepatan angin yang telah dikumpulkan dari *website* BPS, BMKG, dan NOAA. Uji stasioneritas dilakukan untuk masing-masing data *in-sample* pada variabel produksi padi, curah hujan, suhu udara, kelembapan udara, *Oceanic Nino Index* (ONI), lama penyinaran matahari, dan kecepatan angin dengan *Augmented Dickey-Fuller Test* (ADF) untuk memastikan data stasioner, dan jika tidak stasioner pada tingkat level, dilakukan *differencing*. Setelah dilakukan *differencing* data diuji ADF kembali, jika data *differencing* stasioner maka dilanjutkan ke analisis selanjutnya yaitu penentuan panjang *lag optimal* yang

ditetapkan berdasarkan nilai AIC terkecil, dan identifikasi model VAR. Setelah itu dilanjutkan dengan uji stabilitas model untuk memvalidasi model untuk analisis IRF dan VD. Selanjutnya, dilakukan uji kointegrasi dengan *Johansen cointegration test* untuk menganalisis adanya kointegrasi antar variabel. Jika terdapat kointegrasi antar variabel, analisis dilanjutkan dengan menggunakan metode VECM. Kausalitas Granger digunakan untuk mengidentifikasi hubungan kausalitas antara dua variabel.

Data variabel produksi padi, curah hujan, suhu udara, kelembapan udara, *Oceanic Nino Index* (ONI), lama penyinaran matahari, dan kecepatan angin dilakukan estimasi parameter VECM. Hasil estimasi parameter VECM akan diidentifikasi untuk memahami hubungan jangka pendek dan panjang antara produksi padi, curah hujan, suhu udara, kelembapan udara, *Oceanic Nino Index* (ONI), lama penyinaran matahari, dan kecepatan angin. Model VECM kemudian dievaluasi dengan uji autokorelasi model yang menggunakan uji *Portmanteau*. Selanjutnya, dilakukan analisis *Impulse Response Function* (IRF) untuk melihat respon masing-masing variabel terhadap guncangan pada variabel lain, serta analisis *Variance Decomposition* (VD) untuk mengukur kontribusi variabel terhadap perubahan variabel lain dalam periode mendatang dalam bentuk persentase. Terakhir dilakukan perhitungan MAPE, perhitungan MAPE ini dibandingkan dari data hasil peramalan dengan data *out-sample* untuk menilai keakuratan model VECM. Hasil ini diharapkan dapat memberikan gambaran mendalam tentang interaksi antara produksi padi dengan faktor iklim dalam mendukung tingkat produksi padi di Jawa Timur.

BAB III

METODE PENELITIAN

3.1 Jenis Penelitian

Penelitian ini mengadopsi jenis penelitian kuantitatif, memanfaatkan data numerik dan statistik untuk meneliti implementasi *Vector Error Correction Model* dalam menganalisis produksi padi pasca El Nino di Jawa Timur. Kajian literatur yang melibatkan buku dan artikel ilmiah terkait metodologi kuantitatif. Pendekatan ini memungkinkan peneliti untuk memahami hubungan dinamis antar variabel dalam jangka pendek maupun jangka panjang.

3.2 Data dan Sumber Data

Data yang digunakan adalah data sekunder berbasis deret waktu dengan periode bulanan yang diunduh melalui situs resmi Badan Pusat Statistik BPS (2024), Badan Meteorologi Klimatologi dan Geofisika BMKG (2025), dan *National Oceanic and Atmospheric Administration NOAA* (2025) diakses pada tanggal 22 September 2025 yang berisi data publikasi produksi padi (Ton), curah hujan (mm), suhu udara (°C), kelembapan udara (%), kecepatan angin (*m/s*), lamanya penyinaran (jam), dan *Oceanic Nino Index* (index) dengan periode Januari 2015 hingga Desember 2024. Penelitian ini menggunakan aplikasi *E-views 12*, dan variabel-variabel yang digunakan adalah sebagai berikut:

$y_{1,t}$: Produksi Padi (Ton)

$x_{1,t}$: Curah Hujan (mm)

$x_{2,t}$: Suhu Udara (°C)

$x_{3,t}$: Kelembapan Udara (%)

$x_{4,t}$: Kecepatan angin (m/s)

$x_{5,t}$: Penyinaran matahari (Jam)

$x_{6,t}$: *Oceanic Nino Index* (index)

3.3 Teknik Pengumpulan Data

Teknik pengumpulan data pada penelitian ini dilakukan melalui Teknik dokumentasi yang bertujuan menggali informasi dari berbagai referensi terpercaya yang berkaitan dengan topik penelitian. Peneliti mengunduh data produksi padi, curah hujan, suhu udara, kelembapan udara, lama penyinaran matahari, kecepatan angin, dan *Oceanic Nino Index* (ONI) melalui situs resmi Badan Pusat Statistika (BPS), Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), *National Oceanic and Atmospheric Administration* (NOAA), serta untuk periode Januari 2015 hingga Desember 2024. Proses pengumpulan data dilakukan dengan pengelolaan dataset yang tersedia. Data yang terkumpul kemudian dikelompokkan dalam bentuk deret waktu bulanan untuk keperluan analisis mendalam menggunakan metode *Vector Error Correction Model* (VECM). Langkah ini penting untuk memastikan data yang digunakan mampu menganalisis produksi padi pasca El Nino di Jawa Timur secara akurat.

3.4 Teknik Analisis Data

Langkah-langkah analisis yang digunakan dalam penelitian ini sebagai berikut:

1. Statistik Deskriptif

Melakukan analisis statistik deskriptif untuk masing-masing variabel data produksi padi, curah hujan, suhu udara, kelembapan udara, *Oceanic Nino Index* (ONI), lama penyinaran matahari, dan kecepatan angin.

2. Standarisasi Data

Mengubah nilai-nilai variabel dengan nilai yang memiliki skala yang sama dengan menggunakan persamaan (2.1)

3. Uji Stasioneritas

Menguji stasioneritas data menggunakan *Augmented Dickey Fuller* (ADF) pada persamaan (2.2). Jika data tidak stasioner pada tingkat level, dilakukan *differencing* dengan persamaan (2.3). Setelah dilakukan *differencing*, data diuji ADF kembali, jika data *differencing* sudah stasioner maka dilanjutkan ke analisis selanjutnya.

4. Menetapkan Panjang Lag Optimal

Menentukan panjang lag optimal berdasarkan nilai AIC terkecil pada persamaan (2.5) dengan lag maksimal ditentukan terlebih dahulu dengan persamaan (2.4). Penetapan panjang lag optimal ini akan digunakan pada analisis selanjutnya.

5. Identifikasi VAR

Mengestimasi parameter model VAR dengan bantuan *E-Views 12* dan dilakukan pemodelan VAR seperti persamaan (2.7).

6. Uji Stabilitas

Melakukan pengujian stabilitas model VAR dengan lag yang telah ditentukan dengan melihat modulus hasil persamaan (2.8). Model dikatakan stabil jika seluruh akar berada dalam lingkaran unit kompleks atau modulus $(z) \leq 1$.

7. Uji Kointegrasi

Menguji kointegrasi data menggunakan Johansen cointegration test pada

persamaan (2.9). Jika data menunjukkan adanya kointegrasi, analisis, dilanjutkan dengan model VECM.

8. Uji Kausalitas

Menganalisis hubungan kausalitas anatar variabel menggunakan Granger causality test dengan membandingkan hasil F-statistik dari persamaan (2.10) dengan F-tabel.

9. Identifikasi VECM

Mengestimasi parameter model VECM dengan bantuan *E-Views 12* dan dilakukan perhitungan matriks koefisien untuk setiap variabel dalam jangka panjang dengan menggunakan persamaan (2.14) untuk mendapatkan model VECM seperti persamaan (2.13). Identifikasi parameter ini untuk menganalisis hubungan jangka pendek dan jangka panjang antar variabel.

10. Uji Diagnostik

Uji diagnostik model dilakukan untuk menilai kelayakan model dalam meramalkan data, dengan menggunakan uji autokorelasi yaitu uji *Portmanteau* dengan persamaan (2.15)

11. Analisis Impulse Response Function (IRF)

Menganalisis respon variabel beberapa periode ke depan terhadap guncangan pada variabel lain dengan menggunakan persamaan (2.16).

12. Analisis Variance Decomposition (VD)

Mengukur kontribusi setiap variabel terhadap perubahan variabel lain dalam beberapa periode ke depan, dinyatakan dalam bentuk persentase


menggunakan persamaan (2.17).


13. Analisis Kebaikan Model

Mengukur kebaikan model menggunakan *Mean Absolute Percentage Error* (MAPE) dengan persamaan (2.18) pada data hasil peramalan dari model dengan data *out-sample*.

3.5 Diagram Alir Penelitian

Diagram alir penelitian dari tahap analisis data sebagai berikut.





Gambar 3.1 Diagram Alir Penelitian

BAB IV

HASIL DAN PEMBAHASAN

4.1 Penanganan *Missing Value*

Pada data penelitian ini, terdapat *missing value* yaitu dimana sebagian data tidak lengkap atau hilang pada lampiran 1. Masalah ini sering kali menghambat proses analisis dan pada penelitian ini ditangani menggunakan metode KNN. Dalam penelitian ini digunakan jumlah tetangga terdekat sebanyak $n = 5$. Pemilihan nilai n tersebut berdasarkan karakteristik data klimatologi yang memiliki variansi yang cukup tinggi. Pada persamaan (2.19) penanganan *missing value* menggunakan metode *K-Nearest Neighbour* (KNN) dengan pendekatan pembobotan berbasis jarak. Ilustrasi penerapan KNN, dilakukan penanganan *missing value* sekitar 30% pada variabel curah hujan dengan pada periode pengamatan ke-14 bulan Januari 2015 dinyatakan sebagai berikut.

Tabel 4.1 Data Simulasi Pengamatan Sekitar Periode ke-14 Januari 2015

Periode Pengamatan Januari 2015	x_1	x_2	x_3	x_4	x_5
Ke-12	3.60	26.50	88	3	5.00
Ke-13	3.50	28.90	78	3	0.60
Ke-14	—	28.60	78	3	6.30
Ke-15	2.80	29.20	74	2	3.40
Ke-16	24.50	27.10	85	3	9.50
Ke-17	0.40	27.90	84	3	5.20

Selanjutnya, ditentukan kandidat tetangga terdekat yang memiliki data lengkap pada variabel curah hujan dan berada pada periode waktu yang berdekatan dengan tanggal pengamatan. Kandidat tetangga tersebut terdapat pada tabel 4.2 sebagai berikut:

Tabel 4.2 Tetangga Periode Pengamatan ke-14 Januari 2015

Tetangga ke-i	Periode Pengamatan Januari 2015	x_1	x_2	x_3	x_4	x_5
1	Ke-12	3.60	26.50	88	3	5.0
2	Ke-13	3.50	28.90	78	3	0.60
3	Ke-15	2.80	29.20	74	2	3.40
4	Ke-16	24.50	27.10	85	3	9.50
5	Ke-17	0.40	27.90	84	3	5.20

Berdasarkan Tabel 4.2 dilakukan perhitungan jarak antara data pada periode pengamatan ke-14 bulan Januari 2015 dengan masing-masing kandidat tetangga menggunakan jarak Euclidean.

$$d_{(x_{1t}, x_{ti})} = \sqrt{(x_{2t} - x_{2i})^2 + (x_{3t} - x_{3i})^2 + (x_{4t} - x_{4i})^2 + (x_{5t} - x_{5i})^2}$$

Untuk $i = 1$ (periode ke-12)

$$\begin{aligned} d_{(x_{1t}, x_{t,1})} &= \sqrt{(28.60 - 26.50)^2 + (78 - 88)^2 + (3 - 3)^2 + (6.30 - 5)^2} \\ &= \sqrt{106.10} \approx 10.30 \end{aligned}$$

Untuk $i = 2$ (periode ke-13)

$$\begin{aligned} d_{(x_{1t}, x_{t,2})} &= \sqrt{(28.60 - 28.90)^2 + (78 - 78)^2 + (3 - 3)^2 + (6.30 - 0.60)^2} \\ &= \sqrt{32.58} \approx 5.71 \end{aligned}$$

Untuk $i = 3$ (periode ke-15)

$$\begin{aligned} d_{(x_{1t}, x_{t,3})} &= \sqrt{(28.60 - 29.20)^2 + (78 - 74)^2 + (3 - 2)^2 + (6.30 - 3.40)^2} \\ &= \sqrt{25.77} \approx 5.08 \end{aligned}$$

Untuk $i = 4$ (periode ke-16)

$$\begin{aligned} d_{(x_{1t}, x_{t,4})} &= \sqrt{(28.60 - 27.10)^2 + (78 - 85)^2 + (3 - 3)^2 + (6.30 - 9.50)^2} \\ &= \sqrt{61.49} \approx 7.84 \end{aligned}$$

Untuk $i = 5$ (periode ke-17)

$$\begin{aligned} d_{(x_{1t}, x_{t,5})} &= \sqrt{(28.60 - 27.90)^2 + (78 - 84)^2 + (3 - 3)^2 + (6.30 - 5.20)^2} \\ &= \sqrt{37.70} \approx 6.14 \end{aligned}$$

Nilai jarak *Euclidean* yang diperoleh selanjutnya digunakan untuk menghitung bobot, sebagaimana pada Tabel 4.3 sebagai berikut.

Tabel 4.3 Hasil Perhitungan Jarak Euclidean dan Bobot KNN

Tetangga ke-i	$d_{(x_{1t}, x_{t,i})}$	$\frac{1}{d_{(x_{1t}, x_{t,i})}}$
1	10.30	0.097
2	5.71	0.175
3	5.08	0.196
4	7.84	0.127
5	6.14	0.162

Nilai jarak Euclidean pada Tabel 4.3 selanjutnya diubah menjadi bobot ($1/d$). Bobot tersebut kemudian digunakan untuk menghitung estimasi nilai *missing value* dengan metode KNN berdasarkan persamaan (2.19) sebagai berikut.

$$\begin{aligned} \hat{y}_{1t} &= \frac{(0.097 \cdot 3.60) + (0.175 \cdot 3.50) + (0.196 \cdot 2.80) + (0.127 \cdot 24.50) + (0.162 \cdot 0.40)}{0.097 + 0.175 + 0.196 + 0.127 + 0.162} \\ &= \frac{4.6868}{0.7570} \approx 6.69 \end{aligned}$$

Berdasarkan hasil perhitungan tersebut, diperoleh estimasi nilai *missing value* pada periode ke-14 bulan Januari 2015 sebesar 6.69. Selanjutnya, penanganan *missing value* pada periode lainnya dilakukan dengan prosedur yang sama. Setelah proses imputasi *missing value* dilakukan, data klimatologi harian yang telah lengkap diolah dengan cara dirata-ratakan menjadi data bulanan. Proses perhitungan rata-rata ini dilakukan untuk menyelaraskan frekuensi dan klimatologi dengan data produksi padi dari Badan Pusat Statistik (BPS) serta data *Oceanic Nino Index* (ONI) dari *National Oceanic and Atmospheric Administration* (NOAA),

yang telah tersedia dalam format bulanan. Hasil perhitungan hasil pengamatan disajikan pada Tabel 4.4. dan secara lebih rinci disajikan pada lampiran 2.

Tabel 4.4 Hasil Pengamatan Sekitar Periode ke-14 Januari 2015

Periode Pengamatan Januari 2015	x_1	x_2	x_3	x_4	x_5
Ke-12	3.60	26.50	88	3	5.00
Ke-13	3.50	28.90	78	3	0.60
Ke-14	6.69	28.60	78	3	6.30
Ke-15	2.80	29.20	74	2	3.40
Ke-16	24.50	27.10	85	3	9.50
Ke-17	0.40	27.90	84	3	5.20

4.2 Statistika Deskriptif

Data yang digunakan dalam penelitian ini adalah data produksi padi, curah hujan, suhu udara, kelembaban udara, kecepatan angin, penyinaran matahari, dan indeks El Nino yang dianalisis dalam periode Januari 2015 hingga Desember 2024. Data tersebut diperoleh dari Badan Pusat Statistik, Badan Meteorologi Klimatologi dan Geofisika, dan *National Oceanic and Atmospheric Administration*. Untuk memperoleh gambaran awal mengenai karakteristik data yang digunakan dalam penelitian ini, dilakukan identifikasi statistik deskriptif terhadap semua variabel. Statistik deskriptif ini bertujuan untuk melihat kecenderungan umum dari data, termasuk nilai rata-rata, median, nilai maksimum, dan nilai minimum, yang mencerminkan sebaran serta pola dari masing-masing variabel. Adapun hasil statistik deskriptif dari seluruh variabel dapat dilihat pada Tabel 4.5.

Tabel 4.5 Statistika Deskriptif

Variabel	Observasi	Rata-rata	Maximum	Minimum	Standard Deviasi
Produksi Padi (Ton)	120	583106.7106	2293296.400	20361.9424	563097.3858
Curah Hujan (mm)	120	48.6624	4251.5023	0	394.1835
Suhu Udara (°C)	120	27.0125	28.9229	25.4906	0.7432

Lanjutan Tabel 4.5 Statistika Deskriptif

Variabel	Observasi	Rata-rata	Maximum	Minimum	Standard Deviasi
Kelembaban Udara (%)	120	79.2734	86.1609	67.7885	4.5073
Kecepatan Angin (<i>m/s</i>)	120	1.8905	3.1371	1.1856	0.4325
Penyinaran Matahari (Jam)	120	6.1208	9.1186	2.6630	1.6478
Oceanic Nino Index (index)	120	0.1216	2.6000	-1.3000	0.9565

Berdasarkan hasil statistik deskriptif, seluruh variabel memiliki 120 observasi sehingga data lengkap dan dapat digunakan untuk analisis lanjutan. Nilai rata-rata, minimum, maksimum, dan standar deviasi menunjukkan adanya perbedaan skala serta tingkat variasi antarvariabel. Variabel produksi padi memiliki nilai rata-rata sebesar 583106.71 ton dengan standar deviasi sebesar 563097.39 ton. Hal ini menunjukkan bahwa produksi padi mengalami dari nilai rata-ratanya. Curah hujan memiliki rata-rata sebesar 48.66 mm dengan standar deviasi 394.18 mm. Nilai standar deviasi yang jauh lebih besar daripada rata-ratanya menunjukkan bahwa curah hujan mengalami fluktuasi selama periode pengamatan. Sedangkan variabel lainnya nilai standar deviasi yang kecil menunjukkan bahwa variabel lainnya cenderung stabil dan tidak banyak menyimpang dari nilai rata-ratanya. Produksi padi dan curah hujan memiliki variasi data yang lebih beragam, sedangkan suhu udara dan kecepatan angin cenderung lebih konsisten. Oleh karena itu, perlu dilakukan standarisasi data, misalnya dengan metode Z-score, agar seluruh variabel berada pada skala yang sama sehingga analisis VAR atau VECM dapat menghasilkan estimasi yang lebih baik dan mudah dibandingkan antarvariabel.

4.3 Standarisasi Data

Proses untuk mengubah skala variabel dalam suatu dataset sehingga memiliki skala yang seragam. Hal ini bertujuan agar data lebih mudah dibandingkan dan dianalisis. Salah satu teknik standarisasi yang digunakan adalah menggunakan metode *z-score* yang mengukur seberapa jauh sebuah nilai data menyimpang dari rata-rata dalam satuan standar deviasi. Dengan menggunakan *z-score*, data dari berbagai populasi dengan rata-rata dan standar deviasi yang berbeda, dapat diubah sehingga memiliki nilai dengan skala yang sama. Dengan skala yang standar tersebut, hal ini mempermudah analisis dan perbandingan antar variabel yang berbeda jenis dalam satu data set. Pada penelitian ini data dipisah menjadi data *in-sample* (Lampiran 3) sebesar 90% dan *out-sample* (lampiran 4) sebesar 10%. Data *in-sample* memuat periode januari 2015 sampai desember 2023, sedangkan data *out-sample* memuat periode januari 2024 sampai desember 2024.

Proses standarisasi data dilakukan menggunakan persamaan (2.3) dengan mengacu pada nilai rata-rata dan standar deviasi yang disajikan pada Tabel 4.5. Melalui proses tersebut, diperoleh dua terstandarisasi untuk masing-masing variabel, yang diperoleh sebagai berikut:

1. Standarisasi data produksi padi (y)

$$zy_i = \frac{y_i - \bar{y}}{\sigma_Y} = \frac{y_i - 583106.71106}{563097.3858}$$

2. Standarisasi data curah hujan (x_1)

$$zx_{1i} = \frac{x_{1i} - \bar{x}}{\sigma_{X_1}} = \frac{x_{1i} - 48.6624}{394.1835}$$

3. Standarisasi data suhu udara (x_2)

$$zx_{2i} = \frac{x_{2i} - \bar{x}}{\sigma_{x_2}} = \frac{x_{2i} - 27.0125}{0.7432}$$

4. Standarisasi data kelembapan udara (x_3)

$$zx_{3i} = \frac{x_{3i} - \bar{x}}{\sigma_{x_3}} = \frac{x_{3i} - 79.2734}{4.5073}$$

5. Standarisasi data kecepatan angin (x_4)

$$zx_{4i} = \frac{x_{4i} - \bar{x}}{\sigma_{x_4}} = \frac{x_{4i} - 1.8905}{0.4325}$$

6. Standarisasi data durasi penyinaran matahari (x_5)

$$zx_{5i} = \frac{x_{5i} - \bar{x}}{\sigma_{x_5}} = \frac{x_{5i} - 6.1208}{1.6478}$$

7. Standarisasi data *Ocean Nino Index* (ONI)

$$zx_{6i} = \frac{x_{6i} - \bar{x}}{\sigma_{x_6}} = \frac{x_{6i} - 0.1216}{0.9565}$$

Sehingga diperoleh hasil standarisasi data untuk semua data pada penelitian pada lampiran 3.


4.4 Stasioneritas


Uji stasioneritas dilakukan dengan pengujian akar unit untuk mengetahui apakah data yang digunakan mengandung akar unit atau tidak. Jika data mengandung akar unit, maka data tersebut dianggap tidak stasioner. Sebaliknya, jika data tidak mengandung akar unit, maka data tersebut dianggap stasioner. Dalam penelitian ini, metode yang digunakan untuk menguji stasioneritas adalah uji *Augmented Dickey-Fuller* (ADF). Data dianggap stasioner jika nilai probabilitas *p-value* lebih kecil dari tingkat signifikansi 0.05, yang menunjukkan bahwa tidak ada

akar unit atau data tersebut sudah stasioner. Hasil uji stasioner setiap variabel pada data *in-sample* disajikan pada tabel 4.6 (Lampiran 5).

Tabel 4.6 Uji Stasioneritas I(0)

Variabel	T-statistik	Critical value 5%	P-value	Keterangan
Produksi Padi	-1,4606	-2,8922	0.5492	Tidak Stasioner
Curah Hujan	-10,378	-2,8887	0.0000	Stasioner
Suhu Udara	-4,3703	-2,8895	0.0006	Stasioner
Kelembaban Udara	-5,7259	-2,8892	0.0000	Stasioner
Kecepatan Angin	-57586	-2,8889	0.0000	Stasioner
Penyinaran Matahari	-6,4613	-2,8892	0.0000	Stasioner
Oceanic Nino Index	-3,2709	-2,8889	0.0187	Stasioner






Gambar 4.1 Kurva Data Tingkat Level

Berdasarkan hasil yang terdapat pada Tabel 4.6, uji stasioneritas yang dilakukan menggunakan uji ADF pada data level menunjukkan bahwa *p-value* untuk variabel Produksi padi adalah $0.5492 > 0.05$ tidak stasioner sehingga dilakukan *differencing*, sedangkan untuk variabel lainnya *p-value* < 0.05 dan dinyatakan stasioner. Oleh karena itu, diperlukan langkah diferensiasi pertama untuk variabel produksi padi dengan menggunakan persamaan (2.2). Hasil uji stasioneritas terhadap data *first difference* disajikan pada Tabel 4.7 (Lampiran 6).

Tabel 4.7 Uji Stasioneritas I(1)

Variabel	T-statistik	Critical value 5%	P-value	Keterangan
Produksi Padi	-4,6591	-2,8922	0,0002	Stasioner



Gambar 4.2 Kurva Data Differencing

Berdasarkan hasil yang terdapat pada Tabel 4.7, uji stasioneritas yang dilakukan menggunakan uji ADF pada data *first difference* menunjukkan bahwa *p-value* untuk variabel Produksi padi adalah 0.0002. Karena nilai *p-value* lebih kecil dari 0.05, dapat disimpulkan bahwa variabel produksi padi stasioner pada tingkat *first difference*. Setelah seluruh data variabel dinyatakan stasioner, maka langkah selanjutnya dapat dilanjutkan.

4.5 Lag Optimum

Penentuan panjang lag yang optimal dapat dilakukan berdasarkan kriteria *Akaike Information Criterion* (AIC) dengan memilih nilai yang menghasilkan kriteria terendah. Penentuan lag optimal diawali dengan mencoba berbagai lag hingga lag maksimum, yang dapat dihitung dengan persamaan (2.4) dan didapatkan lag maksimum hingga lag ke-4. Dengan menetapkan batas maksimum hingga lag ke-4, langkah selanjutnya adalah evaluasi nilai AIC untuk setiap lag tersebut. Pemilihan lag optimal sangat penting untuk memastikan model yang lebih akurat dan efisien, di mana nilai lag yang tepat akan meminimalkan kesalahan prediksi. Nilai AIC untuk berbagai lag hingga lag ke-4 dapat dilihat dalam Tabel 4.8 (Lampiran 7) sebagai berikut.

Tabel 4.8 Nilai AIC

Lag	AIC
1	11.44707
2	10.54621
3	10.0101
4	9.369805

Berdasarkan Tabel 4.8, nilai AIC dihitung untuk berbagai pilihan lag, mulai dari lag 1 hingga lag 4 karena penentuan maksimum lag untuk model VAR berdasarkan persamaan (2.4) menghasilkan lag maksimum yaitu 4. Kriteria AIC ini digunakan untuk memilih model terbaik, dengan nilai yang lebih rendah menunjukkan model yang lebih baik. Dari tabel tersebut, nilai AIC terkecil juga ditemukan pada lag 4, yaitu sebesar 9.36805. Dari hasil kriteria AIC, maka akan dipilih sebagai lag optimal adalah nilai paling rendah dari kriteria tersebut, sehingga dipilih lag 4 karena nilai terendah AIC. Ini menunjukkan bahwa lag 4 menghasilkan

keseimbangan terbaik antara kesalahan prediksi dan kompleksitas model, sehingga model dengan lag 4 akan diterapkan untuk analisis selanjutnya.

4.6 Identifikasi VAR

Setelah mendapatkan lag berdasarkan penentuan lag maksimum, maka dilanjutkan untuk mengidentifikasi model VAR dengan lag 4 pada persamaan (2.7). Setelah mengetahui VAR (4), perlu dilakukan analisis akar-akar dari fungsi *polynomial* dengan cara pengecekan stabilitas untuk memastikan bahwa model yang dibentuk memiliki perilaku dinamis yang wajar dan melakukan uji kointegrasi yang mengidentifikasikan bahwa metode VAR (4) belum layak digunakan sehingga dapat digunakan untuk analisis lebih lanjut yaitu menggunakan metode VECM.

4.7 Uji Stabilitas


Pengujian stabilitas VAR dilakukan untuk melihat kevalidan model sebelum melanjutkan dengan analisis lebih lanjut, seperti *Impulse Response Function* (IRF) dan *Variance Decomposition* (VD). Model VAR dianggap stabil jika semua akar karakteristiknya terletak di dalam lingkaran unit kompleks atau memiliki modulus kurang dari satu. Berikut hasil Uji Stabilitas dapat dilihat dalam Tabel 4.9 (Lampiran 9).

Tabel 4.9 Hasil Uji Stabilitas VAR

Variabel	Root	Modulus	Keputusan
$x_{1,t-1}$	$0.0500193 + 0.821422i$	0.961732	H_0 ditolak
$x_{1,t-2}$	$0.500193 - 0.821422i$	0.961732	H_0 ditolak
$x_{1,t-3}$	$0.816495 + 0.480336i$	0.947305	H_0 ditolak
$x_{1,t-4}$	$0.816495 - 0.480336i$	0.947305	H_0 ditolak
$x_{2,t-1}$	$0.009235 - 0.873717i$	0.873765	H_0 ditolak
$x_{2,t-2}$	$0.009235 + 0.873717i$	0.873765	H_0 ditolak
$x_{2,t-3}$	$0.796355 + 0.274988i$	0.842496	H_0 ditolak
$x_{2,t-4}$	$0.796355 - 0.274988i$	0.842496	H_0 ditolak
$x_{3,t-1}$	$0.346896 + 0.726144i$	0.804749	H_0 ditolak
$x_{3,t-2}$	$0.346896 - 0.726144i$	0.804749	H_0 ditolak
$x_{3,t-3}$	$-0.631523 - 0.0496426i$	0.803281	H_0 ditolak

Lanjutan Tabel 4.9 Hasil Uji Stabilitas VAR

Variabel	Root	Modulus	Keputusan
$x_{3,t-4}$	$-0.631523 + 0.0496426i$	0.803281	H_0 ditolak
$x_{4,t-1}$	$-0.272176 - 0.699767i$	0.750835	H_0 ditolak
$x_{4,t-2}$	$-0.272176 + 0.699767i$	0.750835	H_0 ditolak
$x_{4,t-3}$	$-0.427976 - 0.583010i$	0.723232	H_0 ditolak
$x_{4,t-4}$	$-0.427976 + 0.583010i$	0.723232	H_0 ditolak
$x_{5,t-1}$	$-0.649437 + 0.308328i$	0.718912	H_0 ditolak
$x_{5,t-2}$	$-0.649437 - 0.308328i$	0.718912	H_0 ditolak
$x_{5,t-3}$	$-0.130987 + 0.705378i$	0.717437	H_0 ditolak
$x_{5,t-4}$	$-0.130987 - 0.705378i$	0.717437	H_0 ditolak
$x_{6,t-1}$	-0.716452	0.716452	H_0 ditolak
$x_{6,t-2}$	$-0.687531 + 0.086599i$	0.692958	H_0 ditolak
$x_{6,t-3}$	$-0.687531 - 0.086599i$	0.692958	H_0 ditolak
$x_{6,t-4}$	$-0.321271 + 0.526447i$	0.616735	H_0 ditolak
y_{t-1}	$-0.321271 - 0.526447i$	0.616735	H_0 ditolak
y_{t-2}	$0.183016 - 0.537316i$	0.567630	H_0 ditolak
y_{t-3}	$0.183016 + 0.537316i$	0.567630	H_0 ditolak
y_{t-4}	0.099514	0.099514	H_0 ditolak



Gambar 4.3 Lingkaran Modulus

Berdasarkan Tabel 4.9, hasil uji stabilitas VAR pada semua variabel yang mana terdapat nilai bilangan riil dan bilangan imajiner yang dilakukan dengan menggunakan perangkat lunak *E-Views 12* menunjukkan bahwa seluruh nilai modulus $z \leq 1$ yang memenuhi persamaan (2.8), maka H_0 ditolak, artinya akar

berada di dalam lingkaran unit kompleks yang menunjukkan model VAR(4) stabil. Dengan demikian, dapat disimpulkan bahwa model dengan lag 4 memenuhi kriteria kestabilan dan layak digunakan untuk analisis selanjutnya.

4.8 Uji Kointegrasi

Uji kointegrasi digunakan untuk mengetahui apakah terdapat hubungan jangka panjang antara variabel-variabel yang diuji, serta untuk menentukan metode analisis yang tepat. Jika tidak ditemukan kointegrasi, maka model yang digunakan adalah model VAR untuk menganalisis hubungan jangka pendek. Namun, jika terdapat minimal satu kointegrasi, metode yang diterapkan adalah VECM, yang memungkinkan untuk menganalisis hubungan baik dalam jangka panjang maupun jangka pendek. Pengujian kointegrasi dalam penelitian ini dilakukan menggunakan Uji Johansen yaitu *Trace Statistic*. Jika nilai $p\text{-value} < 0.05$, maka hipotesis nol yang menyatakan tidak ada kointegrasi ditolak, dan hipotesis alternatif yang menyatakan adanya kointegrasi diterima. Hasil uji kointegrasi dapat dilihat pada Tabel 4.10 (Lampiran 10) sebagai berikut.

Tabel 4.10 Hasil Uji Kointegrasi

Hipotesis	Eigen Value	Trace Statistik	Nilai Kritis (5%)	$p\text{-value}$	Keputusan
$H_0: r = 0$ $H_1: r = 1$	0.660913	404.9484	125.6154	0.0000	Tolak H_0
$H_0: r = 0$ $H_1: r = 2$	0.559322	294.6354	95.75366	0.0000	Tolak H_0
$H_0: r = 0$ $H_1: r = 3$	0.492486	211.0524	69.81889	0.0000	Tolak H_0
$H_0: r = 0$ $H_1: r = 4$	0.384926	141.8728	47.85613	0.0000	Tolak H_0
$H_0: r = 0$ $H_1: r = 5$	0.359782	92.29957	29.79707	0.0000	Tolak H_0
$H_0: r = 0$ $H_1: r = 6$	0.267065	46.81294	15.49471	0.0000	Tolak H_0
$H_0: r = 0$ $H_1: r = 7$	0.137787	15.12176	3.841465	0.0001	Tolak H_0

Berdasarkan Tabel 4.10, terdapat tujuh hipotesis yang mana terdapat tujuh variabel yang diuji kointegrasi dan hasil uji kointegrasi menunjukkan adanya kointegrasi atau hubungan jangka panjang. Hal ini dibuktikan dengan hasil uji trace statistik, di mana $p\text{-value} < 0.05$ pada hipotesis pertama sampai ketujuh. Oleh karena itu, rank kointegrasi dari keempat hipotesis yang signifikan ditentukan berdasarkan nilai *eigenvalue* terbesar, yaitu 0.660913 pada hipotesis pertama dengan menolak. Dengan demikian, dapat disimpulkan bahwa terdapat satu vektor kointegrasi atau $r = 1$, sehingga penelitian ini dapat dilanjutkan dengan menggunakan metode VECM.

4.9 Uji Kausalitas

Uji kausalitas Granger digunakan untuk mengidentifikasi apakah terdapat hubungan searah, dua arah (timbal balik), atau tidak ada hubungan antara variabel dalam model. Jika terdapat minimal satu yang memiliki hubungan kausalitas maka dapat dilanjutkan dengan metode VECM. Kedua variabel dianggap memiliki hubungan kausalitas jika nilai $F_{statistik} > F_{tabel}$ atau jika $p\text{-value}$ lebih kecil dari tingkat signifikansi 5%. Dalam data yang digunakan, diperoleh nilai $F\text{-tabel} = F_{(7-1, 104-7-1)} = F_{(6, 96)} = 2,195$. Hasil pengujian kausalitas Granger antara Produksi padi, Curah hujan, Suhu udara, Kelembaban udara, Kecepatan angin, Penyinaran matahari, *Oceanic Nino Index* dapat dilihat pada Tabel 4.11 (Lampiran 11) sebagai berikut.

Tabel 4.11 Uji Kausalitas Granger


Variabel	Hipotesis	F-Statistik	<i>P-value</i>	Keputusan
$x_{1,t}$ dan $x_{2,t}$	$H_0: x_{2,t}$ tidak ada hubungan dengan $x_{1,t}$	0.92696	0.4517	H_0 diterima
	$H_0: x_{1,t}$ tidak ada hubungan dengan $x_{2,t}$	0.24201	0.9138	H_0 diterima

Lanjutan Tabel 4.11 Uji Kausalitas Granger

Variabel	Hipotesis	F-Statistik	P-value	Keputusan
$x_{1,t}$ dan $x_{3,t}$	$H_0: x_{3,t}$ tidak ada hubungan dengan $x_{1,t}$	0.27328	0.8945	H_0 diterima
	$H_0: x_{1,t}$ tidak ada hubungan dengan $x_{3,t}$	0.64078	0.6347	H_0 diterima
$x_{1,t}$ dan $x_{4,t}$	$H_0: x_{4,t}$ tidak ada hubungan dengan $x_{1,t}$	0.81221	0.5204	H_0 diterima
	$H_0: x_{1,t}$ tidak ada hubungan dengan $x_{4,t}$	0.8951	0.4701	H_0 diterima
$x_{1,t}$ dan $x_{5,t}$	$H_0: x_{5,t}$ tidak ada hubungan dengan $x_{1,t}$	0.30863	0.8716	H_0 diterima
	$H_0: x_{1,t}$ tidak ada hubungan dengan $x_{5,t}$	1.09999	0.3612	H_0 diterima
$x_{1,t}$ dan $x_{6,t}$	$H_0: x_{6,t}$ tidak ada hubungan dengan $x_{1,t}$	2.83222	0.0287	H_0 ditolak
	$H_0: x_{1,t}$ tidak ada hubungan dengan $x_{6,t}$	0.80660	0.5240	H_0 diterima
$x_{2,t}$ dan $x_{3,t}$	$H_0: x_{3,t}$ tidak ada hubungan dengan $x_{2,t}$	3.04362	0.0208	H_0 ditolak
	$H_0: x_{2,t}$ tidak ada hubungan dengan $x_{3,t}$	13.9228	0.0000	H_0 ditolak
$x_{2,t}$ dan $x_{4,t}$	$H_0: x_{4,t}$ tidak ada hubungan dengan $x_{2,t}$	6.28486	0.0002	H_0 ditolak
	$H_0: x_{2,t}$ tidak ada hubungan dengan $x_{4,t}$	5.75768	0.0003	H_0 ditolak
$x_{2,t}$ dan $x_{5,t}$	$H_0: x_{5,t}$ tidak ada hubungan dengan $x_{2,t}$	3.45311	0.0111	H_0 ditolak
	$H_0: x_{2,t}$ tidak ada hubungan dengan $x_{5,t}$	13.2982	0.0000	H_0 ditolak
$x_{2,t}$ dan $x_{6,t}$	$H_0: x_{6,t}$ tidak ada hubungan dengan $x_{2,t}$	2.70346	0.0350	H_0 ditolak
	$H_0: x_{2,t}$ tidak ada hubungan dengan $x_{6,t}$	1.84855	0.1260	H_0 diterima
$x_{3,t}$ dan $x_{4,t}$	$H_0: x_{4,t}$ tidak ada hubungan dengan $x_{3,t}$	4.37565	0.0027	H_0 ditolak
	$H_0: x_{3,t}$ tidak ada hubungan dengan $x_{4,t}$	1.63802	0.1711	H_0 diterima
$x_{3,t}$ dan $x_{5,t}$	$H_0: x_{5,t}$ tidak ada hubungan dengan $x_{3,t}$	4.55180	0.0021	H_0 ditolak
	$H_0: x_{3,t}$ tidak ada hubungan dengan $x_{5,t}$	4.29616	0.0031	H_0 ditolak
$x_{3,t}$ dan $x_{6,t}$	$H_0: x_{6,t}$ tidak ada hubungan dengan $x_{3,t}$	1.71581	0.1529	H_0 diterima
	$H_0: x_{3,t}$ tidak ada hubungan dengan $x_{6,t}$	0.14737	0.9637	H_0 diterima

Lanjutan Tabel 4.11 Uji Kausalitas Granger

Variabel	Hipotesis	F-Statistik	P-value	Keputusan
$x_{4,t}$ dan $x_{5,t}$	$H_0: x_{5,t}$ tidak ada hubungan dengan $x_{4,t}$	2.49801	0.0477	H_0 ditolak
	$H_0: x_{4,t}$ tidak ada hubungan dengan $x_{5,t}$	6.81356	0.0000	H_0 ditolak
$x_{4,t}$ dan $x_{6,t}$	$H_0: x_{6,t}$ tidak ada hubungan dengan $x_{4,t}$	1.78444	0.1383	H_0 diterima
	$H_0: x_{4,t}$ tidak ada hubungan dengan $x_{6,t}$	2.26697	0.0676	H_0 diterima
$x_{5,t}$ dan $x_{6,t}$	$H_0: x_{6,t}$ tidak ada hubungan dengan $x_{5,t}$	1.64366	0.1697	H_0 diterima
	$H_0: x_{5,t}$ tidak ada hubungan dengan $x_{6,t}$	0.37807	0.8238	H_0 diterima



Gambar 4.4 Kausalitas Granger

Berdasarkan Tabel 4.11 diperoleh hasil analisis kausalitas granger yang dijelaskan sebagai berikut:

1. Hubungan antara Curah hujan ($x_{1,t}$) dan Suhu udara ($x_{2,t}$): Hasil uji kausalitas Granger antara Curah hujan dan Suhu udara tidak menunjukkan adanya hubungan kausalitas, baik satu arah maupun dua arah. Hal ini ditunjukkan oleh nilai $p\text{-value} \geq \alpha$ pada arah Suhu udara terhadap Curah hujan yaitu $0.4517 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Suhu udara tidak memengaruhi Curah hujan. Begitu juga, pada arah

Curah hujan terhadap Suhu udara, nilai $p\text{-value} \geq \alpha$ yaitu $0.9138 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Curah hujan tidak memengaruhi Suhu udara. Dengan demikian, dapat disimpulkan bahwa perubahan pada Curah hujan tidak akan memengaruhi Suhu udara, begitu pula sebaliknya.

2. Hubungan antara Curah hujan ($x_{1,t}$) dan Kelembaban udara ($x_{3,t}$): Hasil uji kausalitas Granger antara Curah hujan dan Kelembaban udara tidak menunjukkan adanya hubungan kausalitas, baik satu arah maupun dua arah. Hal ini ditunjukkan oleh nilai $p\text{-value} \geq \alpha$ pada arah Kelembaban udara terhadap Curah hujan yaitu $0.8945 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Kelembaban udara tidak memengaruhi Curah hujan. Begitu juga, pada arah Curah hujan terhadap Kelembaban udara, nilai $p\text{-value} \geq \alpha$ yaitu $0.6347 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Curah hujan tidak memengaruhi Kelembaban udara. Dengan demikian, dapat disimpulkan bahwa perubahan pada Curah hujan tidak akan memengaruhi Kelembaban udara, begitu pula sebaliknya.
3. Hubungan antara Curah hujan ($x_{1,t}$) dan Kecepatan angin ($x_{4,t}$): Hasil uji kausalitas Granger antara Curah hujan dan Kecepatan angin tidak menunjukkan adanya hubungan kausalitas, baik satu arah maupun dua arah. Hal ini ditunjukkan oleh nilai $p\text{-value} \geq \alpha$ pada arah Kecepatan angin terhadap Curah hujan yaitu $0.5204 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Kecepatan angin tidak memengaruhi Curah hujan. Begitu juga, pada arah Curah hujan terhadap Kecepatan angin, nilai $p\text{-value} \geq \alpha$ yaitu $0.4701 \geq 0.05$, sehingga H_0 diterima yang menunjukkan

bahwa Curah hujan tidak memengaruhi Kecepatan angin. Dengan demikian, dapat disimpulkan bahwa perubahan pada Curah hujan tidak akan memengaruhi Kecepatan angin, begitu pula sebaliknya.

4. Hubungan antara Curah hujan ($x_{1,t}$) dan Penyinaran matahari ($x_{5,t}$): Hasil uji kausalitas Granger antara Curah hujan dan Penyinaran matahari tidak menunjukkan adanya hubungan kausalitas, baik satu arah maupun dua arah. Hal ini ditunjukkan oleh nilai $p\text{-value} \geq \alpha$ pada arah Penyinaran matahari terhadap Curah hujan yaitu $0.5204 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Penyinaran matahari tidak memengaruhi Curah hujan. Begitu juga, pada arah Curah hujan terhadap Penyinaran matahari, nilai $p\text{-value} \geq \alpha$ yaitu $0.4701 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Curah hujan tidak memengaruhi Penyinaran matahari. Dengan demikian, dapat disimpulkan bahwa perubahan pada Curah hujan tidak akan memengaruhi Penyinaran matahari, begitu pula sebaliknya.
5. Hubungan antara Curah hujan ($x_{1,t}$) dan *Oceanic Nino Index* ($x_{6,t}$): Hasil uji kausalitas Granger antara Curah hujan dan *Oceanic Nino Index* menunjukkan adanya hubungan kausalitas satu arah, yaitu *Oceanic Nino Index* ke Curah hujan. Hal ini ditunjukkan oleh nilai $p\text{-value} \geq \alpha$ pada arah *Oceanic Nino Index* terhadap Curah hujan yaitu $0.0287 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa *Oceanic Nino Index* memengaruhi Curah hujan. Pada arah Curah hujan terhadap *Oceanic Nino Index*, nilai $p\text{-value} \geq \alpha$ yaitu $0.5240 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Curah hujan tidak memengaruhi *Oceanic Nino Index*.

Dengan demikian, dapat disimpulkan bahwa perubahan pada *Oceanic Nino Index* akan memengaruhi Curah hujan, tetapi tidak sebaliknya.

6. Hubungan antara Suhu udara ($x_{2,t}$) dan Kelembaban udara ($x_{3,t}$): Hasil uji kausalitas Granger antara Suhu udara dan Kelembaban udara menunjukkan adanya hubungan kausalitas, baik satu arah maupun dua arah. Hal ini ditunjukkan oleh nilai $p\text{-value} < \alpha$ pada arah Kelembaban udara terhadap Suhu udara yaitu $0.0208 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa Kelembaban udara memengaruhi Suhu udara. Begitu juga, pada arah Suhu udara terhadap Kelembaban udara, nilai $p\text{-value} < \alpha$ yaitu $0.0000 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa Suhu udara memengaruhi Kelembaban udara. Dengan demikian, dapat disimpulkan bahwa perubahan pada Suhu udara akan memengaruhi Kelembaban udara, begitu pula sebaliknya.
7. Hubungan antara Suhu udara ($x_{2,t}$) dan Kecepatan angin ($x_{4,t}$): Hasil uji kausalitas Granger antara Suhu udara dan Kecepatan angin menunjukkan adanya hubungan kausalitas, baik satu arah maupun dua arah. Hal ini ditunjukkan oleh nilai $p\text{-value} < \alpha$ pada arah Kecepatan angin terhadap Suhu udara yaitu $0.0002 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa Kecepatan angin memengaruhi Suhu udara. Begitu juga, pada arah Suhu udara terhadap Kecepatan angin, nilai $p\text{-value} 0.0003 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa Suhu udara memengaruhi Kecepatan angin. Dengan demikian, dapat disimpulkan bahwa perubahan pada Suhu udara akan memengaruhi Kecepatan angin, begitu pula sebaliknya.

8. Hubungan antara Suhu udara ($x_{2,t}$) dan Penyinaran matahari ($x_{5,t}$): Hasil uji kausalitas Granger antara Suhu udara dan Penyinaran matahari menunjukkan adanya hubungan kausalitas, baik satu arah maupun dua arah. Hal ini ditunjukkan oleh nilai $p\text{-value} < \alpha$ pada arah Penyinaran matahari terhadap Suhu udara yaitu $0.0111 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa Penyinaran matahari memengaruhi Suhu udara. Begitu juga, pada arah Suhu udara terhadap Penyinaran matahari, nilai $p\text{-value} < \alpha$ yaitu $0.0000 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa Suhu udara memengaruhi Penyinaran matahari. Dengan demikian, dapat disimpulkan bahwa perubahan pada Suhu udara akan memengaruhi Penyinaran matahari, begitu pula sebaliknya.
9. Hubungan antara Suhu udara ($x_{2,t}$) dan *Oceanic Nino Index* ($x_{6,t}$): Hasil uji kausalitas Granger antara Suhu udara dan *Oceanic Nino Index* menunjukkan adanya hubungan kausalitas satu arah, yaitu *Oceanic Nino Index* ke Suhu udara. Hal ini ditunjukkan oleh nilai $p\text{-value} \geq \alpha$ pada arah *Oceanic Nino Index* terhadap Suhu udara yaitu $0.0350 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa *Oceanic Nino Index* memengaruhi Suhu udara. Pada arah Suhu udara terhadap *Oceanic Nino Index*, nilai $p\text{-value} \geq \alpha$ yaitu $0.1260 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Suhu udara tidak memengaruhi *Oceanic Nino Index*. Dengan demikian, dapat disimpulkan bahwa perubahan pada *Oceanic Nino Index* akan memengaruhi Suhu udara, tetapi tidak sebaliknya.
10. Hubungan antara Kelembaban udara ($x_{3,t}$) dan Kecepatan angin ($x_{4,t}$): Hasil uji kausalitas Granger antara Kelembaban udara dan Kecepatan

angin menunjukkan adanya hubungan kausalitas satu arah, yaitu Kecepatan angin ke Kelembaban udara. Hal ini ditunjukkan oleh nilai $p\text{-value} < \alpha$ pada arah Kecepatan angin terhadap Kelembaban udara yaitu $0.0021 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa Kecepatan angin memengaruhi Kelembaban udara. Pada arah Kelembaban udara terhadap Kecepatan angin, nilai $p\text{-value} \geq \alpha$ yaitu $0.1711 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Kelembaban udara tidak memengaruhi Kecepatan angin. Dengan demikian, dapat disimpulkan bahwa perubahan pada Kecepatan angin akan memengaruhi Kelembaban udara, tetapi tidak sebaliknya.

11. Hubungan antara Kelembaban udara ($x_{3,t}$) dan Penyinaran matahari ($x_{5,t}$): Hasil uji kausalitas Granger antara Kelembaban udara dan Penyinaran matahari menunjukkan adanya hubungan kausalitas, baik satu arah maupun dua arah. Hal ini ditunjukkan oleh nilai $p\text{-value} < \alpha$ pada arah Penyinaran matahari terhadap Kelembaban udara yaitu $0.0021 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa Penyinaran matahari memengaruhi Kelembaban udara. Begitu juga, pada arah Kelembaban udara terhadap Penyinaran matahari, nilai $p\text{-value} < \alpha$ yaitu $0.0031 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa Kelembaban udara memengaruhi Penyinaran matahari. Dengan demikian, dapat disimpulkan bahwa perubahan pada Kelembaban udara akan memengaruhi Penyinaran matahari, begitu pula sebaliknya.
12. Hubungan antara Kelembaban udara ($x_{3,t}$) dan *Oceanic Nino Index* ($x_{6,t}$): Hasil uji kausalitas Granger antara Kelembaban udara dan *Oceanic Nino*

Index tidak menunjukkan adanya hubungan kausalitas, baik satu arah maupun dua arah. Hal ini ditunjukkan oleh nilai $p\text{-value} \geq \alpha$ pada arah *Oceanic Nino Index* terhadap Kelembaban udara yaitu $0.1529 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa *Oceanic Nino Index* tidak memengaruhi Kelembaban udara. Begitu juga, pada arah Kelembaban udara terhadap *Oceanic Nino Index*, nilai $p\text{-value} \geq \alpha$ yaitu $0.9637 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Kelembaban udara tidak memengaruhi *Oceanic Nino Index*. Dengan demikian, dapat disimpulkan bahwa perubahan pada Kelembaban udara tidak akan memengaruhi *Oceanic Nino Index*, begitu pula sebaliknya.

13. Hubungan antara Kecepatan angin ($x_{4,t}$) dan Penyinaran matahari ($x_{5,t}$):
 Hasil uji kausalitas Granger antara Kecepatan angin dan Penyinaran matahari menunjukkan adanya hubungan kausalitas, baik satu arah maupun dua arah. Hal ini ditunjukkan oleh nilai $p\text{-value} < \alpha$ pada arah Penyinaran matahari terhadap Kecepatan angin yaitu $0.0477 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa Penyinaran matahari memengaruhi Kecepatan angin. Begitu juga, pada arah Kecepatan angin terhadap Penyinaran matahari, nilai $p\text{-value} < \alpha$ yaitu $0.0000 < 0.05$, sehingga H_0 ditolak yang menunjukkan bahwa Kecepatan angin memengaruhi Penyinaran matahari. Dengan demikian, dapat disimpulkan bahwa perubahan pada Kecepatan angin akan memengaruhi Penyinaran matahari, begitu pula sebaliknya.
14. Hubungan antara Kecepatan angin ($x_{4,t}$) dan *Oceanic Nino Index* ($x_{6,t}$):
 Hasil uji kausalitas Granger antara Kecepatan angin dan *Oceanic Nino*

Index tidak menunjukkan adanya hubungan kausalitas, baik satu arah maupun dua arah. Hal ini ditunjukkan oleh nilai $p\text{-value} \geq \alpha$ pada arah *Oceanic Nino Index* terhadap Kecepatan angin yaitu $0.1383 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa *Oceanic Nino Index* tidak memengaruhi Kecepatan angin. Begitu juga, pada arah Kecepatan angin terhadap *Oceanic Nino Index*, nilai $p\text{-value} \geq \alpha$ yaitu $0.0676 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Kecepatan angin tidak memengaruhi *Oceanic Nino Index*. Dengan demikian, dapat disimpulkan bahwa perubahan pada Kecepatan angin tidak akan memengaruhi *Oceanic Nino Index*, begitu pula sebaliknya.

15. Hubungan antara Penyinaran matahari ($x_{5,t}$) dan *Oceanic Nino Index* ($x_{6,t}$): Hasil uji kausalitas Granger antara Penyinaran matahari dan *Oceanic Nino Index* tidak menunjukkan adanya hubungan kausalitas, baik satu arah maupun dua arah. Hal ini ditunjukkan oleh nilai $p\text{-value} \geq \alpha$ pada arah *Oceanic Nino Index* terhadap Penyinaran matahari yaitu $0.1697 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa *Oceanic Nino Index* tidak memengaruhi Penyinaran matahari. Begitu juga, pada arah Penyinaran matahari terhadap *Oceanic Nino Index*, nilai $p\text{-value}$ $0.8232 \geq 0.05$, sehingga H_0 diterima yang menunjukkan bahwa Penyinaran matahari tidak memengaruhi *Oceanic Nino Index*. Dengan demikian, dapat disimpulkan bahwa perubahan pada Penyinaran matahari tidak akan memengaruhi *Oceanic Nino Index*, begitu pula sebaliknya.

4.10 Estimasi dan Signifikansi Model VECM

Hasil uji Kointegrasi menunjukkan bahwa beberapa variabel memiliki hubungan kointegrasi. Oleh karena itu, model VAR tidak dapat diterapkan kepada variabel tersebut, karena terdapat data yang menjadi stasioner setelah melalui proses diferensial pertama dan terdapat kointegrasi. Sehingga analisis akan dilanjutkan dengan model VECM pada persamaan (2.13) yang digunakan untuk menganalisis model hubungan jangka pendek dan jangka panjang antar variabel. Hasil estimasi VECM dianggap signifikan dalam jangka pendek maupun jangka panjang jika nilai $|t_{statistik}| > t_{tabel} (t_{(\alpha; T-K)})$ dengan $\alpha = 0.05$, T adalah jumlah observasi, dan K adalah banyak variabel, sehingga nilai t-tabel adalah $t_{(0.05; 104-7)} = 1.98472$. Tabel estimasi VECM untuk jangka pendek dan jangka panjang terdapat pada Tabel 4.12 sampai Tabel 4.25. (Lampiran 12) sebagai berikut.

Tabel 4.12 Hasil Estimasi Jangka Panjang Produksi Padi

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Curah hujan(-1) (mm)	59.48987	6.69818	1.98472	Signifikan
Suhu udara(-1) (°C)	-48.75447	-3.61103		Signifikan
Kelembaban udara (-1) (%)	-69.85207	-3.11937		Signifikan
Kecepatan angin (-1) (m/s)	64.71394	4.92202		Signifikan
Penyinaran matahari(-1) (jam)	-39.22413	-1.83029		Tidak Signifikan
Oceanic Nino Index(-1) (index)	-20.51195	-3.49898		Signifikan

(-1) menyatakan data pada satu periode sebelumnya.

Berdasarkan Tabel 4.12, sebagian besar variabel iklim memiliki pengaruh signifikan terhadap produksi padi dalam jangka panjang. Curah hujan lag satu periode berpengaruh positif dan signifikan, yang berarti peningkatan curah hujan cenderung meningkatkan produksi padi. Sebaliknya, suhu udara dan kelembaban

udara berpengaruh negatif dan signifikan, sehingga peningkatan kedua variabel tersebut cenderung menurunkan produksi padi. Kecepatan angin menunjukkan pengaruh positif dan signifikan, yang berarti peningkatannya cenderung meningkatkan produksi padi. Sementara itu, ONI berpengaruh negatif dan signifikan, yang menunjukkan bahwa peningkatan nilai ONI cenderung menurunkan produksi padi. Secara keseluruhan, hasil ini menunjukkan bahwa faktor-faktor iklim memiliki peran penting dalam menentukan perubahan produksi padi dalam jangka panjang.

Tabel 4.13 Hasil Estimasi Jangka Pendek Produksi Padi

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
CointEq1	0.000216	0.13090	1.98472	Tidak Signifikan
Δ Produksi padi(-1)	-0.264570	-2.42917		Signifikan
Δ Produksi padi(-2)	-0.597900	-6.38682		Signifikan
Δ Produksi padi(-3)	-0.053097	-0.48297		Tidak Signifikan
Δ Curah hujan(-1)	-0.053523	-0.54503		Tidak Signifikan
Δ Curah hujan(-2)	-0.032622	-0.38031		Tidak Signifikan
Δ Curah hujan(-3)	-0.009153	-0.14230		Tidak Signifikan
Δ Suhu udara(-1)	0.267176	2.14612		Signifikan
Δ Suhu udara(-2)	0.133884	0.92592		Tidak Signifikan
Δ Suhu udara(-3)	0.040866	0.29849		Tidak Signifikan
Δ Kelembaban udara(-1)	1.086282	3.07449		Signifikan
Δ Kelembaban udara(-2)	1.070846	2.66300		Signifikan
Δ Kelembaban udara(-3)	0.532286	1.60045		Tidak Signifikan
Δ Kecepatan angin(-1)	0.309774	2.13587		Signifikan
Δ Kecepatan angin(-2)	0.503870	3.27055		Signifikan
Δ Kecepatan angin(-3)	0.441652	3.02962		Signifikan
Δ Penyinaran matahari (-1)	0.533865	1.81546		Tidak Signifikan
Δ Penyinaran matahari (-2)	0.458508	1.41551		Tidak Signifikan
Δ Penyinaran matahari (-3)	0.012219	0.04513		Tidak Signifikan
Δ Oceanic Nino Index (-1)	0.416454	0.75583		Tidak Signifikan
Δ Oceanic Nino Index (-2)	0.120662	0.16320		Tidak Signifikan
Δ Oceanic Nino Index (-3)	-0.507389	-0.94845		Tidak Signifikan

Δ menyatakan data *differencing*

(-1) menyatakan data pada satu periode sebelumnya.

(-2) menyatakan data pada dua periode sebelumnya.

(-3) menyatakan data pada tiga periode sebelumnya.

Berdasarkan Tabel 4.13, hasil estimasi VECM menunjukkan bahwa dalam jangka pendek beberapa variabel memiliki pengaruh signifikan terhadap produksi padi. Produksi padi satu dan dua periode sebelumnya berpengaruh negatif dan signifikan, yang berarti peningkatan produksi padi pada periode sebelumnya cenderung menurunkan produksi padi pada periode saat ini. Suhu udara satu periode sebelumnya berpengaruh positif dan signifikan, sehingga peningkatan suhu udara cenderung meningkatkan produksi padi dalam jangka pendek. Kelembaban udara satu dan dua periode sebelumnya juga berpengaruh positif dan signifikan, yang menunjukkan bahwa peningkatan kelembaban udara cenderung meningkatkan produksi padi. Kecepatan angin satu, dua, dan tiga periode sebelumnya memiliki pengaruh positif dan signifikan, sehingga peningkatan kecepatan angin cenderung meningkatkan produksi padi. Sementara itu, variabel kointegrasi dan variabel lainnya tidak berpengaruh signifikan terhadap produksi padi dalam jangka pendek karena nilai $|t_{statistik}|$ lebih kecil dari t_{tabel} . Hasil model VECM produksi padi pada persamaan (4.8).

Tabel 4.14 Hasil Estimasi Jangka Panjang Curah Hujan

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Suhu udara(-1) (°C)	-0.819543	-3.81201	1.98472	Signifikan
Kelembaban udara(-1) (%)	-1.174174	-3.24152		Signifikan
Kecepatan angin (-1) (m/s)	1.087814	4.82598		Signifikan
Penyinaran matahari(-1) (jam)	-0.659341	-1.89990		Tidak Signifikan
Oceanic Nino Index(-1) (index)	-0.344797	-3.23935		Signifikan

(-1) menyatakan data pada satu periode sebelumnya.

Berdasarkan Tabel 4.14, hasil estimasi VECM jangka panjang menunjukkan bahwa beberapa variabel iklim memiliki pengaruh signifikan terhadap curah hujan. Suhu udara berpengaruh negatif dan signifikan, yang berarti peningkatan suhu udara cenderung menurunkan curah hujan. Kelembaban udara juga berpengaruh negatif dan signifikan, sehingga peningkatan kelembaban udara cenderung menurunkan curah hujan. Sebaliknya, kecepatan angin berpengaruh positif dan signifikan, yang menunjukkan bahwa peningkatan kecepatan angin cenderung meningkatkan curah hujan. Sementara itu, ONI berpengaruh negatif dan signifikan, yang berarti peningkatan nilai ONI cenderung menurunkan curah hujan. Secara keseluruhan, hasil ini menunjukkan bahwa dalam jangka panjang curah hujan lebih dipengaruhi oleh faktor-faktor iklim, terutama suhu udara, kelembaban udara, kecepatan angin, dan ONI.

Tabel 4.15 Hasil Estimasi Jangka Pendek Curah Hujan

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
CointEq1	-0.297884	-1.62863	1.98472	Tidak Signifikan
Δ Curah hujan(-1)	-0.601235	-3.28039		Signifikan
Δ Curah hujan(-2)	0.452043	-2.82364		Signifikan
Δ Curah hujan(-3)	-0.113096	-0.94209		Tidak Signifikan
Δ Suhu udara(-1)	-0.011060	-0.04760		Tidak Signifikan
Δ Suhu udara(-2)	-0.126568	-0.46900		Tidak Signifikan
Δ Suhu udara(-3)	-0.318299	-1.24567		Tidak Signifikan
Δ Kelembaban udara(-1)	-0.524052	-0.79471		Tidak Signifikan
Δ Kelembaban udara(-2)	-0.006411	-0.00854		Tidak Signifikan
Δ Kelembaban udara(-3)	-0.783040	-1.26149		Tidak Signifikan
Δ Kecepatan angin (-1)	0.254708	0.94097		Tidak Signifikan
Δ Kecepatan angin (-2)	0.372042	1.29389		Tidak Signifikan
Δ Kecepatan angin (-3)	-0.202970	-0.74601		Tidak Signifikan
Δ Penyinaran matahari(-1)	-0.475234	-0.86590		Tidak Signifikan

Lanjutan Tabel 4.15 Hasil Estimasi Jangka Pendek Curah Hujan

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Δ Penyinaran matahari(-2)	0.018832	0.03115	1.98472	Tidak Signifikan
Δ Penyinaran matahari(-3)	-0.290218	-0.57435		Tidak Signifikan
Δ Oceanic Nino Index(-1)	0.847930	0.82456		Tidak Signifikan
Δ Oceanic Nino Index(-2)	-0.159058	-0.11527		Tidak Signifikan
Δ Oceanic Nino Index(-3)	-1.104188	-0.10591		Tidak Signifikan

Δ menyatakan data *differencing*

(-1) menyatakan data pada satu periode sebelumnya.

(-2) menyatakan data pada dua periode sebelumnya.

(-3) menyatakan data pada tiga periode sebelumnya.

Berdasarkan Tabel 4.15, hasil estimasi VECM jangka pendek terhadap Curah hujan menunjukkan bahwa ada satu variabel memiliki pengaruh signifikan. Curah hujan satu dan dua periode sebelumnya keduanya berpengaruh negatif yang signifikan dengan $|t_{statistik}| < t_{tabel}$, sehingga kenaikan curah hujan satu dan dua periode sebelumnya akan menurunkan curah hujan secara signifikan dalam jangka pendek. Sebaliknya, variabel kointegrasi tidak memiliki pengaruh signifikan terhadap curah hujan karena $|t_{statistik}| < t_{tabel}$. Sementara itu variabel lainnya tidak memiliki hubungan jangka pendek yang signifikan dengan curah hujan. Hasil model VECM curah hujan pada persamaan (4.9).

Tabel 4.16 Hasil Estimasi Jangka Panjang Suhu Udara

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Curah hujan(-1) (mm)	-1.220193	-6.63918	1.98472	Signifikan
Kelembaban udara(-1) (%)	1.432731	3.11846		Signifikan
Kecepatan angin (-1) (m/s)	-1.327344	-4.72548		Signifikan

Lanjutan Tabel 4.16 Hasil Estimasi Jangka Panjang Suhu Udara

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Penyinaran matahari(-1) (jam)	0.804524	1.79903	1.98472	Tidak Signifikan
Oceanic Nino Index(-1) (index)	0.420719	3.47311		Signifikan

(-1) menyatakan data pada satu periode sebelumnya.

Berdasarkan Tabel 4.16, hasil estimasi VECM jangka panjang menunjukkan bahwa beberapa variabel memiliki pengaruh signifikan terhadap suhu udara. Curah hujan berpengaruh negatif dan signifikan, yang berarti peningkatan curah hujan cenderung menurunkan suhu udara. Kelembaban udara berpengaruh positif dan signifikan, sehingga peningkatan kelembaban udara cenderung meningkatkan suhu udara. Kecepatan angin berpengaruh negatif dan signifikan, yang menunjukkan bahwa peningkatan kecepatan angin cenderung menurunkan suhu udara. Sementara itu, ONI berpengaruh positif dan signifikan, yang berarti peningkatan nilai ONI cenderung meningkatkan suhu udara. Secara keseluruhan, hasil ini menunjukkan bahwa dalam jangka panjang suhu udara dipengaruhi oleh faktor-faktor iklim, terutama curah hujan, kelembaban udara, kecepatan angin, dan ONI.

Tabel 4.17 Hasil Estimasi Jangka Pendek Suhu Udara

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
CointEq1	-0.260340	-3.17458	1.98472	Signifikan
Δ Curah hujan(-1)	-0.290426	-2.89640		Signifikan
Δ Curah hujan(-2)	-0.206093	-2.35306		Signifikan
Δ Curah hujan(-3)	-0.093880	-1.42942		Tidak Signifikan
Δ Suhu udara(-1)	0.037983	0.219881		Tidak Signifikan
Δ Suhu udara(-2)	-0.073141	-0.49539		Tidak Signifikan
Δ Suhu udara(-3)	-0.514837	-3.68280		
Δ Kelembaban udara(-1)	0.112316	0.31133		Tidak Signifikan
Δ Kelembaban udara(-2)	0.663270	1.61540		Tidak Signifikan
Δ Kelembaban udara(-3)	0.479799	1.41287		Tidak Signifikan

Lanjutan Tabel 4.17 Hasil Estimasi Jangka Pendek Suhu Udara

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Δ Kecepatan angin (-1)	-0.272089	-1.83734	1.98472	Tidak Signifikan
Δ Kecepatan angin (-2)	-0.193777	-1.23183		Tidak Signifikan
Δ Kecepatan angin (-3)	-0.003271	-0.02198		Tidak Signifikan
Δ Penyinaran matahari(-1)	-0.036428	-0.12132		Tidak Signifikan
Δ Penyinaran matahari(-2)	0.623864	1.88626		Tidak Signifikan
Δ Penyinaran matahari(-3)	0.514272	0.86031		Tidak Signifikan
Δ Oceanic Nino Index(-1)	0.019237	0.03419		Tidak Signifikan
Δ Oceanic Nino Index(-2)	-0.121723	-0.16124		Tidak Signifikan
Δ Oceanic Nino Index(-3)	0.163661	0.29962		Tidak Signifikan

Δ menyatakan data *differencing*

(-1) menyatakan data pada satu periode sebelumnya.

(-2) menyatakan data pada dua periode sebelumnya.

(-3) menyatakan data pada tiga periode sebelumnya.

Berdasarkan Tabel 4.17, hasil estimasi VECM jangka pendek terhadap suhu udara menunjukkan beberapa variabel memiliki pengaruh signifikan. Variabel kointegrasi memiliki pengaruh signifikan terhadap suhu udara dengan $|t_{statistik}| < t_{tabel}$. Hal ini mengindikasikan bahwa apabila terjadi deviasi dari keseimbangan dalam jangka Panjang, maka akan ada penyesuaian signifikan menuju keseimbangan dalam jangka pendek. Curah hujan satu dan dua periode sebelumnya keduanya berpengaruh negatif yang signifikan dengan $|t_{statistik}| < t_{tabel}$, sehingga kenaikan curah hujan satu dan dua periode sebelumnya akan menurunkan suhu udara secara signifikan dalam jangka pendek. Sementara itu

variabel lainnya tidak memiliki hubungan jangka pendek yang signifikan dengan suhu udara. Hasil model VECM suhu udara pada persamaan (4.10).

Tabel 4.18 Hasil Estimasi Jangka Panjang Kelembaban Udara

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Curah hujan(-1) (mm)	-0.851655	-6.52653	1.98472	Signifikan
Suhu udara(-1) (°C)	0.697968	3.60507		Signifikan
Kecepatan angin(-1) (m/s)	-0.926443	-4.68073		Signifikan
Penyinaran matahari (-1) (jam)	0.561531	3.22143		Signifikan
Oceanic Nino Index (-1) (index)	0.293648	3.19522		Signifikan

(-1) menyatakan data pada satu periode sebelumnya.

Berdasarkan Tabel 4.18, hasil estimasi VECM jangka panjang menunjukkan bahwa beberapa variabel memiliki pengaruh signifikan terhadap kelembaban udara. Curah hujan berpengaruh negatif dan signifikan, yang berarti peningkatan curah hujan cenderung menurunkan kelembaban udara. Suhu udara berpengaruh positif dan signifikan, sehingga peningkatan suhu udara cenderung meningkatkan kelembaban udara. Kecepatan angin berpengaruh negatif dan signifikan, yang menunjukkan bahwa peningkatan kecepatan angin cenderung menurunkan kelembaban udara. Penyinaran matahari berpengaruh positif dan signifikan, sehingga peningkatan penyinaran matahari cenderung meningkatkan kelembaban udara. Sementara itu, ONI berpengaruh positif dan signifikan, yang berarti peningkatan nilai ONI cenderung meningkatkan kelembaban udara. Secara keseluruhan, hasil ini menunjukkan bahwa dalam jangka panjang kelembaban udara dipengaruhi oleh faktor-faktor iklim, terutama curah hujan, suhu udara, kecepatan angin, penyinaran matahari, dan ONI.

Tabel 4.19 Hasil Estimasi Jangka Pendek Kelembaban Udara

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
CointEq1	-0.127076	-1.46702	1.98472	Tidak Signifikan
Δ Curah hujan(-1)	-0.032372	-0.43791		Tidak Signifikan

Lanjutan Tabel 4.19 Hasil Estimasi Jangka Pendek Kelembaban Udara

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Δ Curah hujan(-2)	-0.019981	-0.30944	1.98472	Tidak Signifikan
Δ Curah hujan(-3)	-0.017481	-0.36102		Tidak Signifikan
Δ Suhu udara(-1)	0.342751	3.65744		Signifikan
Δ Suhu udara(-2)	0.311970	2.86614		Signifikan
Δ Suhu udara(-3)	0.365281	3.54429		Signifikan
Δ Kelembaban udara (-1)	-0.096880	-0.36425		Tidak Signifikan
Δ Kelembaban udara (-2)	-0.188637	-0.62318		Tidak Signifikan
Δ Kelembaban udara (-3)	0.164037	0.65521		Tidak Signifikan
Δ Kecepatan angin(-1)	-0.157031	-1.43833		Tidak Signifikan
Δ Kecepatan angin(-2)	0.001876	0.01618		Tidak Signifikan
Δ Kecepatan angin(-3)	-0.042737	-0.38945		Tidak Signifikan
Δ Penyinaran matahari(-1)	-0.050044	-0.22607		Tidak Signifikan
Δ Penyinaran matahari(-2)	-0.372406	-1.52730		Tidak Signifikan
Δ Penyinaran matahari(-3)	-0.244283	-1.19862		Tidak Signifikan
Δ Oceanic Nino Index(-1)	-0.662492	-1.59727		Tidak Signifikan
Δ Oceanic Nino Index(-2)	-0.190606	-0.34247		Tidak Signifikan
Δ Oceanic Nino Index(-3)	0.457624	1.13638		Tidak Signifikan

Δ menyatakan data *differencing*

(-1) menyatakan data pada satu periode sebelumnya.

(-2) menyatakan data pada dua periode sebelumnya.

(-3) menyatakan data pada tiga periode sebelumnya.

Berdasarkan Tabel 4.19, hasil estimasi VECM jangka pendek terhadap kelembaban udara menunjukkan bahwa ada satu variabel memiliki pengaruh signifikan. Suhu udara satu, dua, dan tiga periode sebelumnya ketiganya berpengaruh positif yang signifikan dengan $|t_{statistik}| < t_{tabel}$, sehingga kenaikan suhu udara satu, dua, dan tiga periode sebelumnya akan menaikkan kelembaban udara secara signifikan dalam jangka pendek. Sebaliknya, variabel kointegrasi tidak

memiliki pengaruh signifikan terhadap kelembaban udara karena $|t_{statistik}| < t_{tabel}$. Sementara itu variabel lainnya tidak memiliki hubungan jangka pendek yang signifikan dengan kelembaban udara. Hasil model VECM kelembaban udara pada persamaan (4.11).

Tabel 4.20 Hasil Estimasi Jangka Panjang Kecepatan Angin

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Curah hujan(-1) (mm)	0.919274	6.52003	1.98472	Signifikan
Suhu udara(-1) (°C)	-0.753384	-3.66565		Signifikan
Kelembaban udara(-1) (%)	-1.079398	-3.14082		Signifikan
Penyinaran matahari(-1) (jam)	-0.606116	-1.85959		Tidak Signifikan
Oceanic Nino Index(-1) (index)	-0.316963	-3.25977		Signifikan

(-1) menyatakan data pada satu periode sebelumnya.

Berdasarkan Tabel 4.20, hasil estimasi VECM jangka panjang menunjukkan bahwa beberapa variabel memiliki pengaruh signifikan terhadap kecepatan angin. Curah hujan berpengaruh positif dan signifikan, yang berarti peningkatan curah hujan cenderung meningkatkan kecepatan angin. Sebaliknya, suhu udara dan kelembaban udara berpengaruh negatif dan signifikan, sehingga peningkatan kedua variabel tersebut cenderung menurunkan kecepatan angin. Sementara itu, ONI juga berpengaruh negatif dan signifikan, yang menunjukkan bahwa peningkatan nilai ONI cenderung menurunkan kecepatan angin. Secara keseluruhan, hasil ini menunjukkan bahwa dalam jangka panjang kecepatan angin dipengaruhi oleh curah hujan, suhu udara, kelembaban udara, dan ONI, sedangkan penyinaran matahari tidak memberikan pengaruh yang signifikan.

Tabel 4.21 Hasil Estimasi Jangka Pendek Kecepatan Angin

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
CointEq1	-0.348281	-3.68751	1.98472	Signifikan
Δ Curah hujan(-1)	0.221341	2.54407		Signifikan
Δ Curah hujan(-2)	0.104251	1.37181		Tidak Signifikan

Lanjutan Tabel 4.21 Hasil Estimasi Jangka Pendek Kecepatan Angin

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Δ Curah hujan(-3)	0.082920	1.45508	1.98472	Tidak Signifikan
Δ Suhu udara(-1)	-0.678693	-6.15347		Signifikan
Δ Suhu udara(-2)	-0.525224	-4.09995		Signifikan
Δ Suhu udara(-3)	-0.110062	-0.90738		Tidak Signifikan
Δ Kelembaban udara(-1)	-1.247744	-3.98608		Signifikan
Δ Kelembaban udara(-2)	-0.61468	-1.74442		Tidak Signifikan
Δ Kelembaban udara(-3)	-0.377198	-1.28013		Tidak Signifikan
Δ Kecepatan angin (-1)	-0.277272	-2.15788		Signifikan
Δ Kecepatan angin (-2)	-0.188537	-1.38130		Tidak Signifikan
Δ Kecepatan angin (-3)	-0.267935	-2.07457		Signifikan
Δ Penyinaran matahari(-1)	-0.679824	-2.60941		Signifikan
Δ Penyinaran matahari(-2)	-0.119421	-0.41614		Tidak Signifikan
Δ Penyinaran matahari(-3)	0.062828	0.26193		Tidak Signifikan
Δ Oceanic Nino Index(-1)	0.776034	1.58974		Tidak Signifikan
Δ Oceanic Nino Index(-2)	0.801564	1.22371		Tidak Signifikan
Δ Oceanic Nino Index(-3)	-1.139312	-2.40384		Signifikan

Δ menyatakan data *differencing*

(-1) menyatakan data pada satu periode sebelumnya.

(-2) menyatakan data pada dua periode sebelumnya.

(-3) menyatakan data pada tiga periode sebelumnya.

Berdasarkan Tabel 4.21, hasil estimasi VECM jangka pendek terhadap kecepatan angin menunjukkan beberapa variabel memiliki pengaruh signifikan. Variabel kointegrasi memiliki pengaruh signifikan terhadap kecepatan angin dengan $|t_{statistik}| < t_{tabel}$. Hal ini mengindikasikan bahwa apabila terjadi deviasi dari keseimbangan dalam jangka Panjang. Curah hujan satu periode sebelumnya

berpengaruh positif yang signifikan, sehingga kenaikan curah hujan satu periode sebelumnya akan menaikkan kecepatan angin secara signifikan dalam jangka pendek. Suhu udara satu dan dua periode sebelumnya berpengaruh negatif yang signifikan, sehingga kenaikan suhu udara satu dan dua periode sebelumnya akan menurunkan kecepatan angin secara signifikan dalam jangka pendek. Kelembaban udara satu periode sebelumnya berpengaruh negatif yang signifikan, sehingga kenaikan kelembaban udara satu periode sebelumnya akan menurunkan kecepatan angin secara signifikan dalam jangka pendek.

Kecepatan angin satu dan tiga periode sebelumnya keduanya berpengaruh negatif yang signifikan, sehingga kenaikan kecepatan angin satu dan tiga periode sebelumnya akan menurunkan kecepatan angin secara signifikan dalam jangka pendek. Penyinaran matahari satu periode sebelumnya berpengaruh negatif yang signifikan dengan, sehingga kenaikan penyinaran matahari satu periode sebelumnya akan menurunkan kecepatan angin secara signifikan dalam jangka pendek. Oceanic Nino Index tiga periode sebelumnya berpengaruh negatif yang signifikan dengan $|t_{statistik}| < t_{tabel}$, sehingga kenaikan ONI tiga periode sebelumnya akan menurunkan kecepatan angin secara signifikan dalam jangka pendek. Sementara itu variabel lainnya tidak memiliki hubungan jangka pendek yang signifikan dengan kecepatan angin. Hasil model VECM kecepatan angin pada persamaan (4.12).

Tabel 4.22 Hasil Estimasi Jangka Panjang Penyinaran Matahari

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Curah hujan(-1) (mm)	-1.516665	-6.63879	1.98472	Signifikan
Suhu udara(-1) (°C)	1.242971	3.60940		Signifikan
Kelembaban udara(-1) (%)	1.780844	5.59078		Signifikan

Lanjutan Tabel 4.22 Hasil Estimasi Jangka Panjang Penyinaran Matahari

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Kecepatan angin (-1) (m/s)	-1.649850	-4.80963	1.98472	Signifikan
Oceanic Nino Index(-1) (index)	0.522942	3.21688		Signifikan

(-1) menyatakan data pada satu periode sebelumnya.

Berdasarkan Tabel 4.22, hasil estimasi VECM jangka panjang menunjukkan bahwa beberapa variabel memiliki pengaruh signifikan terhadap penyinaran matahari. Curah hujan berpengaruh negatif dan signifikan, yang berarti peningkatan curah hujan cenderung menurunkan penyinaran matahari. Sebaliknya, suhu udara dan kelembaban udara berpengaruh positif dan signifikan, sehingga peningkatan kedua variabel tersebut cenderung meningkatkan penyinaran matahari. Kecepatan angin berpengaruh negatif dan signifikan, yang menunjukkan bahwa peningkatan kecepatan angin cenderung menurunkan penyinaran matahari. Sementara itu, ONI berpengaruh positif dan signifikan, yang berarti peningkatan nilai ONI cenderung meningkatkan penyinaran matahari. Secara keseluruhan, hasil ini menunjukkan bahwa dalam jangka panjang penyinaran matahari dipengaruhi oleh curah hujan, suhu udara, kelembaban udara, kecepatan angin, dan ONI.

Tabel 4.23 Hasil Estimasi Jangka Pendek Penyinaran Matahari

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
CointEq1	0.160253	3.25098	1.98472	Signifikan
Δ Curah hujan(-1)	0.163074	2.17677		Signifikan
Δ Curah hujan(-2)	0.116771	1.78447		Tidak Signifikan
Δ Curah hujan(-3)	0.023013	0.46898		Tidak Signifikan
Δ Suhu udara(-1)	-0.387114	-4.07612		Signifikan
Δ Suhu udara(-2)	-0.196632	-1.78258		Tidak Signifikan
Δ Suhu udara(-3)	-0.442578	-4.23742		Signifikan
Δ Kelembaban udara(-1)	-0.252685	-0.93748		Tidak Signifikan
Δ Kelembaban udara(-2)	0.007453	0.024300		Tidak Signifikan
Δ Kelembaban udara(-3)	-0.060899	-0.24002		Tidak Signifikan

Lanjutan Tabel 4.23 Hasil Estimasi Jangka Pendek Penyinaran Matahari

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Δ Kecepatan angin (-1)	0.375585	3.39461	1.98472	Signifikan
Δ Kecepatan angin (-2)	0.023287	0.19813		Tidak Signifikan
Δ Kecepatan angin (-3)	0.172324	1.54954		Tidak Signifikan
Δ Penyinaran matahari(-1)	-0.370787	-1.65284		Tidak Signifikan
Δ Penyinaran matahari(-2)	0.004641	0.01878		Tidak Signifikan
Δ Penyinaran matahari(-3)	0.192326	0.93118		Tidak Signifikan
Δ Oceanic Nino Index(-1)	1.303084	3.10012		Signifikan
Δ Oceanic Nino Index(-2)	-0.533793	-0.94640		Tidak Signifikan
Δ Oceanic Nino Index(-3)	0.016911	0.04144		Tidak Signifikan

Δ menyatakan data *differencing*

(-1) menyatakan data pada satu periode sebelumnya.

(-2) menyatakan data pada dua periode sebelumnya.

(-3) menyatakan data pada tiga periode sebelumnya.

Berdasarkan Tabel 4.23, hasil estimasi VECM jangka pendek terhadap penyinaran matahari menunjukkan beberapa variabel memiliki pengaruh signifikan. Variabel kointegrasi memiliki pengaruh signifikan terhadap penyinaran matahari dengan $|t\text{-statistik}| > t\text{-tabel}$. Hal ini mengindikasikan bahwa apabila terjadi deviasi dari keseimbangan dalam jangka panjang, maka akan ada penyesuaian signifikan menuju keseimbangan dalam jangka pendek. Curah hujan satu periode sebelumnya berpengaruh positif yang signifikan dengan $|t_{statistik}| < t_{tabel}$, sehingga kenaikan curah hujan satu periode sebelumnya akan menaikkan penyinaran matahari secara signifikan dalam jangka pendek. Suhu udara satu dan tiga periode sebelumnya berpengaruh negatif yang signifikan dengan $|t_{statistik}| <$

t_{tabel} , sehingga kenaikan suhu udara satu dan tiga periode sebelumnya akan menurunkan penyinaran matahari secara signifikan dalam jangka pendek. Kecepatan angin satu periode sebelumnya keduanya berpengaruh positif yang signifikan dengan $|t_{statistik}| < t_{tabel}$, sehingga kenaikan kecepatan angin satu periode sebelumnya akan menaikkan penyinaran matahari secara signifikan dalam jangka pendek. Oceanic Nino Index satu periode sebelumnya berpengaruh positif yang signifikan dengan $|t_{statistik}| < t_{tabel}$, sehingga kenaikan Oceanic Nino Index satu periode sebelumnya akan menaikkan penyinaran matahari secara signifikan dalam jangka pendek. Sementara itu variabel lainnya tidak memiliki hubungan jangka pendek yang signifikan dengan penyinaran matahari. Hasil model VECM penyinaran matahari pada persamaan (4.13).

Tabel 4.24 Hasil Estimasi Jangka Panjang Oceanic Nino Index

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
Curah hujan(-1) (mm)	-2.900255	-6.36505	1.98472	Signifikan
Suhu udara(-1) (°C)	2.376882	3.91835		Signifikan
Kelembaban udara (-1) (%)	3.405433	3.11825		Signifikan
Kecepatan angin(-1) (m/s)	-3.154939	-4.74097		Signifikan
Penyinaran matahari(-1) (jam)	1.912258	1.80893		Tidak Signifikan

(-1) menyatakan data pada satu periode sebelumnya.

Berdasarkan Tabel 4.24, hasil estimasi VECM jangka panjang menunjukkan bahwa beberapa variabel memiliki pengaruh signifikan terhadap ONI. Curah hujan berpengaruh negatif dan signifikan, yang berarti peningkatan curah hujan cenderung menurunkan nilai ONI. Sebaliknya, suhu udara dan kelembaban udara berpengaruh positif dan signifikan, sehingga peningkatan kedua variabel tersebut cenderung meningkatkan nilai ONI. Kecepatan angin berpengaruh negatif dan signifikan, yang menunjukkan bahwa peningkatan kecepatan angin

cenderung menurunkan nilai ONI. Secara keseluruhan, hasil ini menunjukkan bahwa dalam jangka panjang ONI dipengaruhi oleh curah hujan, suhu udara, kelembaban udara, dan kecepatan angin, sehingga variabel-variabel iklim tersebut berperan penting dalam dinamika perubahan ONI.

Tabel 4.25 Hasil Estimasi Jangka Pendek Oceanic Nino Index

Variabel	Koefisien	t-statistik	t-tabel	Keputusan
CointEq1	-0.022462	-3.70500	1.98472	Signifikan
Δ Curah hujan(-1)	-0.063017	-3.57649		Signifikan
Δ Curah hujan(-2)	-0.046287	-3.00751		Signifikan
Δ Curah hujan(-3)	-0.027889	-2.41660		Signifikan
Δ Suhu udara(-1)	-0.001959	-0.008769		Tidak Signifikan
Δ Suhu udara(-2)	0.057374	2.21150		Signifikan
Δ Suhu udara(-3)	0.006587	0.26815		Tidak Signifikan
Δ Kelembaban udara (-1)	0.143892	2.26983		Signifikan
Δ Kelembaban udara (-2)	0.157711	2.18590		Signifikan
Δ Kelembaban udara (-3)	0.028411	0.47612		Tidak Signifikan
Δ Kecepatan angin(-1)	-0.001242	-0.04774		Signifikan
Δ Kecepatan angin(-2)	-0.038517	-1.39343		Tidak Signifikan
Δ Kecepatan angin(-3)	-0.002532	-0.09682		Tidak Signifikan
Δ Penyinaran matahari(-1)	0.142852	2.70750		Signifikan
Δ Penyinaran matahari(-2)	0.113876	1.95941		Tidak Signifikan
Δ Penyinaran matahari(-3)	0.021518	0.44290		Tidak Signifikan
Δ Oceanic Nino Index (-1)	0.814532	8.23930		Signifikan
Δ Oceanic Nino Index (-2)	0.105277	0.79361		Tidak Signifikan
Δ Oceanic Nino Index (-3)	-0.252949	-2.63532		Signifikan

Δ menyatakan data *differencing*

(-1) menyatakan data pada satu periode sebelumnya.

(-2) menyatakan data pada dua periode sebelumnya.

(-3) menyatakan data pada tiga periode sebelumnya.

Berdasarkan Tabel 4.25, hasil estimasi VECM jangka pendek terhadap Oceanic Nino Index menunjukkan beberapa variabel memiliki pengaruh signifikan. Variabel kointegrasi memiliki pengaruh signifikan terhadap Oceanic Nino Index dengan $|t_{statistik}| < t_{tabel}$. Hal ini mengindikasikan bahwa apabila terjadi deviasi dari keseimbangan dalam jangka Panjang, maka akan ada penyesuaian signifikan menuju keseimbangan dalam jangka pendek. Curah hujan satu, dua, dan tiga periode sebelumnya ketiganya berpengaruh negatif yang signifikan dengan $|t_{statistik}| < t_{tabel}$, sehingga kenaikan curah hujan satu, dua, dan tiga periode sebelumnya akan menurunkan Oceanic Nino Index secara signifikan dalam jangka pendek. Suhu udara dua periode sebelumnya berpengaruh positif yang signifikan dengan $|t_{statistik}| < t_{tabel}$, sehingga kenaikan suhu udara dua periode sebelumnya akan menaikkan Oceanic Nino Index secara signifikan dalam jangka pendek. Kelembaban udara satu dan dua periode sebelumnya keduanya berpengaruh positif yang signifikan dengan $|t_{statistik}| < t_{tabel}$, sehingga kenaikan kelembaban udara satu dan dua periode sebelumnya akan menaikkan Oceanic Nino Index secara signifikan dalam jangka pendek. Kecepatan angin satu periode sebelumnya berpengaruh negatif yang signifikan dengan $|t_{statistik}| < t_{tabel}$, sehingga kenaikan kecepatan angin satu periode sebelumnya akan menurunkan Oceanic Nino Index secara signifikan dalam jangka pendek. Penyinaran matahari satu periode sebelumnya berpengaruh positif yang signifikan dengan $|t_{statistik}| < t_{tabel}$, sehingga kenaikan penyinaran matahari satu periode sebelumnya akan menaikkan Oceanic Nino Index secara signifikan dalam jangka pendek. Oceanic Nino Index satu dan tiga periode sebelumnya berpengaruh positif pada satu periode sebelumnya dan negatif pada tiga periode sebelumnya yang signifikan dengan $|t_{statistik}| <$

t_{tabel} , sehingga kenaikan Oceanic Nino Index satu periode sebelumnya akan menaikkan Oceanic Nino Index secara signifikan dalam jangka pendek dan tiga periode sebelumnya akan menurunkan Oceanic Nino Index secara signifikan dalam jangka pendek. Sementara itu variabel lainnya tidak memiliki hubungan jangka pendek yang signifikan dengan Oceanic Nino Index. Hasil model VECM ONI pada persamaan (4.14).

4.11 Identifikasi Model VECM

Hasil koefisien jangka panjang dan hasil koefisien kointegrasi jangka pendek yang tercantum pada Tabel 4.14 hingga Tabel 4.27, selanjutnya dihitung matriks yang akan membentuk model VECM pada persamaan (2.13). Perhitungan matriks koefisien untuk setiap variabel dalam jangka panjang dilakukan dengan persamaan (2.14) sebagai berikut.

Matriks jangka panjang produksi padi

$$\begin{aligned} \Pi_{y_{1,t}} &= \delta \beta'_{y_{1,t}} \\ &= \begin{bmatrix} 0.000216 \\ -0.297884 \\ -0.260340 \\ -0.127076 \\ -0.348281 \\ 0.160253 \\ -0.022462 \end{bmatrix} [1 \quad 59.48987 \quad -48.75447 \quad -69.85207 \quad 64.71394 \quad -39.22413 \quad -20.51195] \\ &= \begin{bmatrix} 0.000216 & 0.012850 & -0.010531 & -0.015088 & 0.013978 & -0.008472 & -0.004431 \\ -0.297884 & -17.721181 & 14.519147 & 20.808334 & -19.278605 & 11.684116 & 6.110182 \\ -0.260340 & -15.488134 & 12.690209 & 18.186690 & -16.845807 & 10.211589 & 5.339070 \\ -0.127076 & -7.559534 & 6.195200 & 8.878318 & -8.224607 & 4.985762 & 2.606186 \\ -0.348281 & -20.720269 & 16.980731 & 24.327624 & -22.539789 & 13.662448 & 7.143724 \\ 0.160253 & 9.532835 & -7.813291 & -11.195813 & 10.370838 & -6.286460 & -3.287584 \\ -0.022462 & -1.336785 & 1.095515 & 1.569816 & -1.453712 & 0.881454 & 0.460709 \end{bmatrix} \end{aligned}$$

Matriks jangka panjang curah hujan

$$\begin{aligned} \Pi_{x_{1,t}} &= \delta \beta'_{x_{1,t}} \\ &= \begin{bmatrix} -0.297884 \\ -0.260340 \\ -0.127076 \\ -0.348281 \\ 0.160253 \\ 0.022462 \end{bmatrix} [1 \quad -0.819543 \quad -1.174184 \quad 1.087814 \quad -0.659341 \quad -0.344797] \end{aligned}$$

$$= \begin{bmatrix} -0.297884 & 0.244129 & 0.349771 & -0.324042 & 0.196407 & 0.102710 \\ -0.260340 & 0.213360 & 0.305687 & -0.283202 & 0.171653 & 0.089764 \\ -0.127076 & 0.104144 & 0.149211 & -0.138235 & 0.083786 & 0.043815 \\ -0.348281 & 0.285431 & 0.408946 & -0.378865 & 0.229636 & 0.120086 \\ 0.160253 & -0.131334 & -0.188167 & 0.174325 & -0.105661 & -0.055255 \\ 0.022462 & -0.018409 & -0.026375 & 0.024434 & -0.014810 & -0.007745 \end{bmatrix}$$

Matriks jangka panjang suhu udara

$$\begin{aligned} \Pi_{x_{2,t}} &= \delta \beta'_{x_{2,t}} \\ &= \begin{bmatrix} -0.297884 \\ -0.260340 \\ -0.127076 \\ -0.348281 \\ 0.160253 \\ 0.022462 \end{bmatrix} \begin{bmatrix} -1.220193 & 1 & 1.432731 & -1.327344 & 0.804524 & 0.420719 \end{bmatrix} \\ &= \begin{bmatrix} 0.363458 & -0.297884 & -0.426131 & 0.395427 & -0.239664 & -0.125321 \\ 0.317655 & -0.260340 & -0.372998 & 0.346127 & -0.209473 & -0.109539 \\ 0.155052 & -0.127076 & -0.182065 & 0.168697 & -0.102248 & -0.053456 \\ 0.424954 & -0.348281 & -0.498972 & 0.462373 & -0.280289 & -0.146640 \\ -0.195544 & 0.160253 & 0.229573 & -0.212746 & 0.128944 & 0.067416 \\ -0.027407 & 0.022462 & 0.032184 & -0.029818 & 0.018077 & 0.009452 \end{bmatrix} \end{aligned}$$

Matriks jangka panjang kelembaban udara

$$\begin{aligned} \Pi_{x_{3,t}} &= \delta \beta'_{x_{3,t}} \\ &= \begin{bmatrix} -0.297884 \\ -0.260340 \\ -0.127076 \\ -0.348281 \\ 0.160253 \\ 0.022462 \end{bmatrix} \begin{bmatrix} -0.851655 & 0.697968 & 1 & -0.926443 & 0.561531 & 0.293648 \end{bmatrix} \\ &= \begin{bmatrix} 0.253688 & -0.207905 & -0.297884 & 0.275975 & -0.167292 & -0.087472 \\ 0.221725 & -0.181709 & -0.260340 & 0.241163 & -0.146233 & -0.076458 \\ 0.108284 & -0.088704 & -0.127076 & 0.117730 & -0.071354 & -0.037321 \\ 0.296513 & -0.242940 & -0.348281 & 0.322669 & -0.195614 & -0.102326 \\ -0.136475 & 0.111834 & 0.160253 & -0.148465 & 0.090003 & 0.047055 \\ -0.019119 & 0.015679 & 0.022462 & -0.020807 & 0.012614 & 0.006595 \end{bmatrix} \end{aligned}$$

Matriks jangka panjang kecepatan angin

$$\begin{aligned} \Pi_{x_{4,t}} &= \delta \beta'_{x_{4,t}} \\ &= \begin{bmatrix} -0.297884 \\ -0.260340 \\ -0.127076 \\ -0.348281 \\ 0.160253 \\ 0.022462 \end{bmatrix} \begin{bmatrix} 0.919274 & -0.753384 & -1.079398 & 1 & -0.606116 & -0.316963 \end{bmatrix} \\ &= \begin{bmatrix} -0.273838 & 0.224396 & 0.321532 & -0.297884 & 0.180545 & 0.094416 \\ -0.239318 & 0.196176 & 0.281015 & -0.260340 & 0.157850 & 0.082545 \\ -0.116821 & 0.095740 & 0.137165 & -0.127076 & 0.077242 & 0.040397 \\ -0.320169 & 0.262427 & 0.375956 & -0.348281 & 0.211080 & 0.110390 \\ 0.147321 & -0.120737 & -0.173000 & 0.160253 & -0.097135 & -0.050796 \\ 0.020648 & -0.016922 & -0.024251 & 0.022462 & -0.013613 & -0.007121 \end{bmatrix} \end{aligned}$$

Matriks jangka panjang penyinaran matahari

$$\begin{aligned}
\Pi_{x_{5,t}} &= \delta \beta'_{x_{5,t}} \\
&= \begin{bmatrix} -0.297884 \\ -0.260340 \\ -0.127076 \\ -0.348281 \\ 0.160253 \\ 0.022462 \end{bmatrix} \begin{bmatrix} -1.516665 & 1.242971 & 1.780844 & -1.649850 & 1 & 0.522942 \end{bmatrix} \\
&= \begin{bmatrix} 0.451851 & -0.370316 & -0.530471 & 0.491439 & -0.297884 & -0.155774 \\ 0.395099 & -0.323595 & -0.463681 & 0.429544 & -0.260340 & -0.136145 \\ 0.192781 & -0.157958 & -0.226290 & 0.209676 & -0.127076 & -0.066441 \\ 0.528271 & -0.432837 & -0.620185 & 0.574658 & -0.348281 & -0.182134 \\ -0.243086 & 0.199191 & 0.282614 & -0.264391 & 0.160253 & 0.083796 \\ -0.034081 & 0.027923 & 0.040002 & -0.037058 & 0.022462 & 0.011747 \end{bmatrix}
\end{aligned}$$

Matriks jangka panjang ONI

$$\begin{aligned}
\Pi_{x_{6,t}} &= \delta \beta'_{x_{6,t}} \\
&= \begin{bmatrix} -0.297884 \\ -0.260340 \\ -0.127076 \\ -0.348281 \\ 0.160253 \\ 0.022462 \end{bmatrix} \begin{bmatrix} -2.900255 & 2.376882 & 3.405433 & -3.154939 & 1.912258 & 1 \end{bmatrix} \\
&= \begin{bmatrix} 0.863875 & -0.708002 & -1.014480 & 0.939745 & -0.569660 & -0.297884 \\ 0.755006 & -0.618763 & -0.886827 & 0.821482 & -0.498018 & -0.260340 \\ 0.368555 & -0.302056 & -0.432841 & 0.400886 & -0.243015 & -0.127076 \\ 1.010039 & -0.827934 & -1.186420 & 1.099087 & -0.666060 & -0.348281 \\ -0.464769 & 0.380910 & 0.545641 & -0.505504 & 0.306443 & 0.160253 \\ -0.065149 & 0.053397 & 0.076494 & -0.070865 & 0.042950 & 0.022462 \end{bmatrix}
\end{aligned}$$

Matriks adjustment atau Matriks parameter jangka pendek

$$\begin{aligned}
\Gamma_1 &= \begin{bmatrix} -0.264570 & -0.053523 & 0.267176 & 1.086282 & 0.309774 & 0.533865 & 0.416454 \\ -0.052772 & -0.601235 & -0.11060 & -0.524052 & 0.254708 & -0.475234 & 0.847930 \\ 0.168977 & -0.290426 & 0.037983 & 0.112316 & -0.272089 & -0.036428 & 0.019237 \\ -0.060795 & -0.032372 & 0.342751 & -0.096880 & -0.157031 & -0.050044 & -0.662492 \\ -0.082141 & 0.221341 & -0.678693 & -1.247744 & -0.277272 & -0.679824 & 0.776034 \\ 0.181759 & 0.163074 & -0.387114 & -0.252685 & 0.375585 & -0.370787 & 1.303084 \\ -0.004263 & -0.063017 & -0.001959 & 0.143892 & -0.001242 & 0.142852 & 0.814532 \end{bmatrix} \\
\Gamma_2 &= \begin{bmatrix} -0.597900 & -0.032622 & 0.133884 & 1.070846 & 0.503870 & 0.452508 & 0.120662 \\ 0.066902 & -0.452043 & -0.126568 & -0.006411 & 0.372042 & 0.018832 & -0.159058 \\ 0.104657 & -0.206093 & -0.073141 & 0.663270 & -0.193777 & 0.623864 & -0.121723 \\ -0.105733 & -0.019981 & 0.311970 & -0.188637 & 0.001876 & -0.372406 & -0.190606 \\ 0.198814 & 0.104251 & -0.525224 & -0.621468 & -0.188537 & -0.119421 & 0.801564 \\ 0.090874 & 0.116771 & -0.196632 & 0.007453 & 0.023287 & 0.004641 & -0.533793 \\ 0.008361 & -0.046287 & 0.057374 & 0.157711 & -0.038517 & 0.113876 & 0.105277 \end{bmatrix} \\
\Gamma_3 &= \begin{bmatrix} -0.053097 & -0.009153 & 0.040866 & 0.532286 & 0.441652 & 0.012219 & -0.507389 \\ -0.151378 & -0.113096 & -0.318299 & -0.783040 & -0.202970 & -0.290218 & -1.104188 \\ 0.055168 & -0.093880 & -0.514837 & 0.479799 & -0.003271 & 0.514272 & 0.163661 \\ -0.100503 & -0.017481 & 0.365281 & 0.164037 & -0.042737 & -0.244283 & 0.457624 \\ -0.002120 & 0.082920 & -0.110062 & -0.377198 & -0.267935 & 0.062828 & -1.139312 \\ 0.121051 & 0.023013 & -0.442578 & -0.060899 & 0.172324 & 0.192326 & 0.016911 \\ 0.039495 & -0.027889 & 0.006587 & 0.023411 & -0.002532 & 0.021518 & -0.252949 \end{bmatrix}
\end{aligned}$$

Sehingga model VECM dapat dituliskan berdasarkan persamaan (2.13) sebagai

berikut.

$$\begin{aligned}\Delta w_{1,t} = & 0.012850\Delta x_{1,t-1} - 0.010531\Delta x_{2,t-1} - 0.015088\Delta x_{3,t-1} + 0.013978\Delta x_{4,t-1} - \\ & 0.004431\Delta x_{6,t-1} - 0.264570\Delta w_{1,t-1} - 0.597900\Delta w_{1,t-2} + 0.267176\Delta x_{2,t-1} + \\ & 1.086282\Delta x_{3,t-1} + 1.070846\Delta x_{3,t-2} + 0.309774\Delta x_{4,t-1} + 0.503870\Delta x_{4,t-2} + \\ & 0.441652\Delta x_{4,t-3}\end{aligned}\quad (4.8)$$

$$\begin{aligned}\Delta x_{1,t} = & 0.244129\Delta x_{2,t-1} + 0.349771\Delta x_{3,t-1} - 0.324042\Delta x_{4,t-1} + 0.102710\Delta x_{6,t-1} - \\ & 0.601235\Delta x_{1,t-1} - 0.452043\Delta x_{1,t-2}\end{aligned}\quad (4.9)$$

$$\begin{aligned}\Delta x_{2,t} = & 0.317655\Delta x_{1,t-1} - 0.260340\Delta x_{2,t-1} - 0.372998\Delta x_{3,t-1} + 0.346127\Delta x_{4,t-1} - \\ & 0.109539\Delta x_{6,t-1} - 0.290426\Delta x_{1,t-1} - 0.206093\Delta x_{1,t-2}\end{aligned}\quad (4.10)$$

$$\begin{aligned}\Delta x_{3,t} = & 0.108284\Delta x_{1,t-1} - 0.088704\Delta x_{2,t-1} + 0.117730\Delta x_{4,t-1} - 0.071354\Delta x_{5,t-1} - \\ & 0.037321\Delta x_{6,t-1} + 0.342751\Delta x_{2,t-1} + 0.311970\Delta x_{2,t-2} + 0.365281\Delta x_{2,t-3}\end{aligned}\quad (4.11)$$

$$\begin{aligned}\Delta x_{4,t} = & -0.320169\Delta x_{1,t-1} + 0.262427\Delta x_{2,t-1} + 0.375956\Delta x_{3,t-1} - 0.348281\Delta x_{4,t-1} + \\ & 0.110390\Delta x_{6,t-1} + 0.221341\Delta x_{1,t-1} - 0.678693\Delta x_{2,t-1} - 0.525224\Delta x_{2,t-2} - \\ & 1.247744\Delta x_{3,t-1} - 0.277272\Delta x_{4,t-1} - 0.267935\Delta x_{4,t-3} - 0.679824\Delta x_{5,t-1} - \\ & 1.139312\Delta x_{6,t-3}\end{aligned}\quad (4.12)$$

$$\begin{aligned}\Delta x_{5,t} = & -0.243086\Delta x_{1,t-1} + 0.199191\Delta x_{2,t-1} + 0.282614\Delta x_{3,t-1} - 0.264391\Delta x_{4,t-1} + \\ & 0.160253\Delta x_{5,t-1} + 0.083796\Delta x_{6,t-1} + 0.163074\Delta x_{1,t-1} - 0.387114\Delta x_{2,t-1} - \\ & 0.442578\Delta x_{2,t-3} + 0.375585\Delta x_{4,t-1} + 1.303084\Delta x_{6,t-1}\end{aligned}\quad (4.13)$$

$$\begin{aligned}\Delta x_{6,t} = & -0.065149\Delta x_{1,t-1} + 0.053397\Delta x_{2,t-1} + 0.076494\Delta x_{3,t-1} - 0.070865\Delta x_{4,t-1} + \\ & +0.022462\Delta x_{6,t-1} - 0.063017\Delta x_{1,t-1} - 0.046287\Delta x_{1,t-2} - 0.027889\Delta x_{1,t-3} + \\ & 0.057374\Delta x_{2,t-2} + 0.143892\Delta x_{3,t-1} + 0.157711\Delta x_{3,t-2} - 0.001242\Delta x_{4,t-1} + \\ & 0.142852\Delta x_{5,t-1} + 0.814532\Delta x_{6,t-1} - 0.252949\Delta x_{6,t-3}\end{aligned}\quad (4.14)$$

Berdasarkan persamaan (4.8), perubahan produksi padi dipengaruhi oleh curah hujan, suhu udara, kelembaban udara, kecepatan angin, ONI, serta nilai produksi padi pada periode sebelumnya. Curah hujan dan kecepatan angin memiliki koefisien positif, yang berarti peningkatan kedua variabel tersebut cenderung meningkatkan produksi padi. Sebaliknya, suhu udara, kelembaban udara, dan ONI memiliki koefisien negatif, sehingga peningkatan variabel-variabel tersebut cenderung menurunkan produksi padi. Produksi padi pada lag pertama dan kedua

memiliki koefisien negatif, yang menunjukkan bahwa peningkatan produksi padi pada periode sebelumnya cenderung menurunkan perubahan produksi padi pada periode saat ini. Selain itu, kelembaban udara lag pertama dan kedua serta kecepatan angin lag pertama hingga ketiga berpengaruh positif, yang berarti peningkatan variabel-variabel tersebut pada periode sebelumnya cenderung meningkatkan produksi padi saat ini.

Berdasarkan persamaan (4.9), perubahan curah hujan dipengaruhi oleh suhu udara, kelembaban udara, kecepatan angin, ONI, serta nilai curah hujan pada periode sebelumnya. Suhu udara, kelembaban udara, dan ONI memiliki koefisien positif, yang berarti peningkatan variabel-variabel tersebut cenderung meningkatkan curah hujan. Sebaliknya, kecepatan angin memiliki koefisien negatif, sehingga peningkatan kecepatan angin cenderung menurunkan curah hujan. Curah hujan pada lag pertama dan kedua juga memiliki koefisien negatif, yang menunjukkan bahwa peningkatan curah hujan pada periode sebelumnya cenderung menurunkan perubahan curah hujan pada periode saat ini sebagai bentuk proses penyesuaian menuju keseimbangan.

Berdasarkan persamaan (4.10), perubahan suhu udara dipengaruhi oleh curah hujan, kelembaban udara, kecepatan angin, ONI, serta nilai suhu udara pada periode sebelumnya. Curah hujan dan kecepatan angin memiliki koefisien positif, yang berarti peningkatan kedua variabel tersebut cenderung meningkatkan suhu udara. Sebaliknya, kelembaban udara dan ONI memiliki koefisien negatif, sehingga peningkatan kedua variabel tersebut cenderung menurunkan suhu udara. Suhu udara pada lag pertama serta curah hujan pada lag pertama dan kedua memiliki koefisien negatif, yang menunjukkan bahwa peningkatan suhu udara atau

curah hujan pada periode sebelumnya cenderung menurunkan perubahan suhu udara pada periode saat ini sebagai bentuk proses penyesuaian menuju keseimbangan.

Berdasarkan persamaan (4.11), perubahan kelembaban udara dipengaruhi oleh curah hujan, suhu udara, kecepatan angin, penyinaran matahari, ONI, serta suhu udara pada periode sebelumnya. Curah hujan, kecepatan angin, dan ONI memiliki koefisien positif, yang berarti peningkatan variabel-variabel tersebut cenderung meningkatkan kelembaban udara. Sebaliknya, suhu udara dan penyinaran matahari memiliki koefisien negatif, sehingga peningkatan kedua variabel tersebut cenderung menurunkan kelembaban udara. Selain itu, suhu udara pada lag pertama hingga ketiga memiliki koefisien positif, yang menunjukkan bahwa peningkatan suhu udara pada periode sebelumnya cenderung meningkatkan kelembaban udara pada periode saat ini. Hasil ini menunjukkan bahwa perubahan kelembaban udara dipengaruhi oleh kondisi iklim saat ini maupun dinamika suhu udara pada beberapa periode sebelumnya.

Berdasarkan persamaan (4.12), perubahan kecepatan angin dipengaruhi oleh curah hujan, suhu udara, kelembaban udara, penyinaran matahari, ONI, serta nilai kecepatan angin pada periode sebelumnya. Suhu udara dan kelembaban udara memiliki koefisien positif, yang berarti peningkatan kedua variabel tersebut cenderung meningkatkan kecepatan angin. Sebaliknya, curah hujan, kecepatan angin, dan ONI memiliki koefisien negatif, sehingga peningkatan variabel-variabel tersebut cenderung menurunkan kecepatan angin. Curah hujan lag pertama memiliki koefisien positif, yang menunjukkan bahwa peningkatan curah hujan pada periode sebelumnya cenderung meningkatkan kecepatan angin saat ini. Selain

itu, kecepatan angin pada lag pertama hingga ketiga memiliki koefisien negatif, yang menunjukkan bahwa peningkatan kecepatan angin pada periode sebelumnya cenderung menurunkan perubahan kecepatan angin pada periode saat ini sebagai bentuk penyesuaian menuju keseimbangan. Hasil ini menunjukkan bahwa perubahan kecepatan angin dipengaruhi oleh kondisi atmosfer saat ini maupun pada beberapa periode sebelumnya.

Berdasarkan persamaan (4.13), perubahan penyinaran matahari dipengaruhi oleh curah hujan, suhu udara, kelembaban udara, kecepatan angin, ONI, serta nilai penyinaran matahari pada periode sebelumnya. Suhu udara, kelembaban udara, ONI, dan penyinaran matahari memiliki koefisien positif, yang berarti peningkatan variabel-variabel tersebut cenderung meningkatkan penyinaran matahari. Sebaliknya, curah hujan dan kecepatan angin memiliki koefisien negatif, sehingga peningkatan kedua variabel tersebut cenderung menurunkan penyinaran matahari. Curah hujan lag pertama, kecepatan angin lag pertama, dan ONI lag pertama juga berpengaruh positif, yang menunjukkan bahwa peningkatan variabel-variabel tersebut pada periode sebelumnya cenderung meningkatkan penyinaran matahari saat ini. Sementara itu, suhu udara lag pertama dan kedua memiliki koefisien negatif, yang berarti peningkatan suhu udara pada periode sebelumnya cenderung menurunkan perubahan penyinaran matahari pada periode saat ini. Hasil ini menunjukkan bahwa perubahan penyinaran matahari dipengaruhi oleh kondisi iklim saat ini maupun beberapa periode sebelumnya.

Berdasarkan persamaan (4.14), perubahan ONI dipengaruhi oleh curah hujan, suhu udara, kelembaban udara, kecepatan angin, penyinaran matahari, serta nilai ONI pada periode sebelumnya. Suhu udara, kelembaban udara, penyinaran

matahari, dan ONI memiliki koefisien positif, yang berarti peningkatan variabel-variabel tersebut cenderung meningkatkan nilai ONI. Sebaliknya, curah hujan dan kecepatan angin memiliki koefisien negatif, sehingga peningkatan kedua variabel tersebut cenderung menurunkan nilai ONI. Curah hujan lag pertama hingga ketiga dan kecepatan angin lag pertama juga berpengaruh negatif, yang menunjukkan bahwa peningkatan variabel-variabel tersebut pada periode sebelumnya cenderung menurunkan ONI saat ini. Sementara itu, suhu udara lag kedua, kelembaban udara lag pertama dan kedua, serta penyinaran matahari lag pertama memiliki koefisien positif, yang berarti peningkatan variabel-variabel tersebut pada periode sebelumnya cenderung meningkatkan ONI. Selain itu, ONI lag pertama memiliki koefisien positif yang besar, sedangkan ONI lag ketiga berpengaruh negatif, yang menunjukkan bahwa perubahan ONI saat ini sangat dipengaruhi oleh kondisi ONI pada periode sebelumnya.

4.12 Uji Autokorelasi

Uji autokorelasi merupakan langkah penting dalam evaluasi model deret waktu untuk memastikan bahwa residual dari model tidak menunjukkan pola tertentu atau autokorelasi. Salah satu metode yang umum digunakan adalah Uji *Portmanteau*, yang bertujuan untuk menguji apakah residual model bersifat acak. Jika residual tidak memiliki autokorelasi, maka model dianggap layak dan valid untuk digunakan dalam peramalan. Dalam uji ini, H_0 menyatakan bahwa tidak terdapat autokorelasi residual hingga lag tertentu, sedangkan H_1 menyatakan bahwa terdapat autokorelasi. Keputusan pengujian didasarkan pada nilai *p-value*, di mana H_0 diterima jika *p-value* lebih besar dari tingkat signifikansi α (0.05), yang menunjukkan bahwa residual tidak mengandung autokorelasi. Hasil uji

Portmanteau dapat dilihat pada Tabel 4.26 (Selengkapnya hasil output Eviews-12 pada Lampiran 13) berikut.

Tabel 4.26 Hasil Uji Portmanteau


<i>Lags</i>	<i>Q-Stat</i>	<i>P-value</i>	<i>Adj. Q-stat</i>	<i>P-value</i>	Keputusan
1	24.71673	-	24.96145	—	—
2	54.35030	-	55.18770	—	—
3	82.42047	-	84.10847	—	—
4	111.55160	-	114.42860	—	—
5	162.45960	0.1823	167.96080	0.2015	H_0 diterima
6	231.56330	0.2541	222.25840	0.2768	H_0 diterima
7	261.74120	0.3125	273.98630	0.3357	H_0 diterima
8	305.07600	0.4012	321.00920	0.4289	H_0 diterima

Berdasarkan hasil uji Portmanteau yang ditunjukkan pada Tabel 4.26, terlihat bahwa nilai $p\text{-value} > 0.05$ untuk lag 5 hingga lag 8, sehingga H_0 diterima. Hal ini menunjukkan bahwa tidak terdapat autokorelasi yang signifikan dalam residual model pada seluruh lag yang diuji. Dengan demikian, residual dapat dianggap bersifat acak atau *white noise*. Hasil ini mengindikasikan bahwa model yang digunakan sudah cukup baik dan layak untuk digunakan dalam peramalan.

4.13 Analisis *Impulse Response Function*


Impulse Response Function (IRF) digunakan untuk melihat bagaimana respon suatu variabel endogen terhadap guncangan (*shock*) yang terjadi pada variabel lain dalam sistem model, baik secara langsung maupun tidak langsung, dalam suatu periode waktu tertentu. Analisis ini penting untuk mengetahui arah dan besaran pengaruh dari suatu perubahan pada satu variabel terhadap variabel lainnya, serta untuk mengevaluasi stabilitas dinamika hubungan antar variabel dalam jangka pendek hingga jangka panjang. Hasil analisis ini biasanya ditampilkan dalam bentuk grafik agar lebih mudah dianalisis dan dipahami. Pada grafik tersebut, sumbu horizontal menunjukkan periode setelah terjadinya guncangan, dimana satu periode sama dengan satu bulan, sedangkan sumbu vertikal menunjukkan besarnya

respon yang ditimbulkan. Pola respon dapat berupa pengaruh positif, negatif, atau tidak memberikan dampak sama sekali. Umumnya, pengaruh pada jangka pendek bersifat signifikan, sedangkan dalam jangka panjang cenderung stabil atau konstan. Hasil dari analisis IRF pada dapat dilihat pada lampiran 14.




Gambar 4.5 Grafik IRF Produksi Padi

Gambar 4.5 menunjukkan bahwa respons produksi padi terhadap guncangan dirinya sendiri paling besar pada periode awal, *shock* produksi padi memberikan respons positif yang berarti peningkatan mendadak pada produksi padi mendorong kenaikan produksi pada periode awal. Namun, respons tersebut cepat menurun dan berfluktuasi di sekitar garis nol pada periode-periode berikutnya hingga akhirnya kembali stabil.




Gambar 4.6 Grafik IRF Curah Hujan

Gambar 4.6 menunjukkan bahwa respons curah hujan terhadap guncangan dirinya sendiri paling besar pada periode awal, pada periode pertama terjadi respons positif, kemudian pada periode kedua berubah menjadi respons negatif, yang menunjukkan adanya penyesuaian yang kuat setelah terjadi guncangan awal. Setelah itu, respons curah hujan berfluktuasi dengan amplitudo yang semakin kecil dan secara bertahap mendekati titik keseimbangan.




Gambar 4.7 Grafik IRF Suhu Udara

Gambar 4.7 menunjukkan bahwa respons suhu udara terhadap guncangan dirinya sendiri paling besar pada periode awal, Pada periode pertama terjadi respons positif yang mengindikasikan bahwa guncangan peningkatan suhu udara langsung mendorong kenaikan suhu udara pada periode awal. Namun, respons tersebut kemudian menurun tajam dan berfluktuasi antara nilai positif dan negatif hingga beberapa periode berikutnya sebelum akhirnya mendekati titik keseimbangan.



Gambar 4.8 Grafik IRF Kelembaban Udara


Gambar 4.8 menunjukkan bahwa respons kelembaban udara terhadap guncangan dirinya sendiri paling besar pada periode awal, pada periode pertama terjadi respons positif yang cukup tinggi, yang menandakan bahwa guncangan pada kelembaban udara mendorong peningkatan kelembaban pada periode awal. Namun, respons tersebut kemudian menurun dan berfluktuasi di sekitar garis nol hingga akhirnya menuju kondisi yang lebih stabil.



Gambar 4.9 Grafik IRF Kecepatan Angin


Gambar 4.9 menunjukkan bahwa respons kecepatan angin terhadap guncangan dirinya sendiri paling besar pada periode awal, pada periode pertama terjadi respons positif yang cukup tinggi, yang berarti guncangan peningkatan kecepatan angin mendorong kenaikan kecepatan angin pada periode awal. Namun,

pada periode kedua respons berubah menjadi negatif sebelum perlahan kembali mendekati nol, menunjukkan adanya proses penyesuaian setelah *shock* terjadi.



Gambar 4.10 Grafik IRF Penyinaran Matahari

Gambar 4.10 menunjukkan bahwa respons penyinaran matahari terhadap guncangan dirinya sendiri paling besar pada periode awal, respons terbesar terjadi pada periode awal akibat *shock* suhu udara, yang memberikan respons positif pada periode pertama, kemudian berubah menjadi respons negatif pada periode kedua sebelum kembali meningkat pada periode-periode berikutnya. Pola ini menunjukkan bahwa perubahan suhu udara memiliki pengaruh yang cukup kuat terhadap dinamika penyinaran matahari pada jangka pendek.




Gambar 4.11 Grafik IRF ONI

Gambar 4.11 menunjukkan bahwa respons ONI terhadap guncangan dirinya sendiri paling besar pada periode awal, pada periode pertama hingga periode ketujuh, respons ONI terhadap shock ONI bernilai positif, kemudian terus menurun hingga mendekati nol pada periode ke-sepuluh. Hal ini menunjukkan bahwa guncangan pada fenomena El-Nino memiliki pengaruh yang cukup kuat pada jangka pendek hingga menengah, tetapi efeknya semakin melemah seiring waktu.

4.14 Analisis *Variance Decomposition*

Variance decomposition merupakan salah satu analisis lanjutan dalam model VECM yang bertujuan untuk mengetahui besarnya kontribusi masing-masing variabel terhadap variabel yang sedang dianalisis dalam jangka waktu tertentu. Analisis ini memberikan informasi mengenai seberapa besar variabel independen memberikan pengaruh terhadap variabel dependen dalam sistem dinamis jangka panjang. Melalui pendekatan ini, dapat diketahui variabel mana yang paling dominan dalam menjelaskan variasi dari variabel yang diamati, serta bagaimana pola kontribusi tersebut berubah dari waktu ke waktu. Pada grafik tersebut, sumbu horizontal menunjukkan periode ke depan terjadinya kontribusi, dimana satu periode sama dengan satu bulan, sedangkan sumbu vertikal menunjukkan besarnya kontribusi dari variabel dependen. Hasil dari analisis *Variance Decomposition* pada variabel Produksi padi dapat dilihat pada lampiran 15.




Gambar 4.12 Grafik VD Produksi Padi

$$\begin{aligned} \sigma_{y1t}(12)^2 &= 45.51y_{1t} + 3.43x_{1t} + 13.97x_{2t} + 10.41x_{3t} + \\ &10.64x_{4t} + 14.00x_{5t} + 2.04x_{6t} \end{aligned} \quad (4.15)$$

Gambar 4.12 dan persamaan (4.15) menunjukkan kontribusi masing-masing variabel dalam menjelaskan variasi atau perubahan pada variabel produksi padi selama 12 periode pengamatan. Pada periode pertama, variasi produksi padi hampir sepenuhnya dijelaskan oleh shock produksi padi itu sendiri, dengan kontribusi yang sangat dominan dibandingkan variabel lainnya. Hal ini menunjukkan bahwa pada jangka pendek, perubahan produksi padi lebih banyak dipengaruhi oleh faktor internal produksi padi dibandingkan pengaruh variabel iklim maupun ONI. Seiring bertambahnya periode pengamatan, kontribusi variabel lain mulai meningkat secara bertahap. Suhu udara memberikan kontribusi yang cukup besar mulai periode pertengahan hingga akhir, diikuti oleh kelembaban udara dan kecepatan angin yang juga menunjukkan peningkatan pengaruh terhadap variasi produksi padi. Penyerapan matahari mulai memberikan kontribusi yang cukup terlihat pada periode menengah hingga akhir, sedangkan curah hujan dan ONI memiliki kontribusi yang relatif kecil dibandingkan variabel lainnya.

Meskipun demikian, kontribusi produksi padi terhadap dirinya sendiri tetap menjadi yang terbesar sepanjang periode pengamatan, walaupun persentasenya menurun secara bertahap. Secara keseluruhan, hasil VD ini menunjukkan bahwa dalam jangka panjang, variasi produksi padi tidak hanya dipengaruhi oleh shock internal produksi padi itu sendiri, tetapi juga mulai dipengaruhi oleh faktor-faktor iklim seperti suhu udara, kelembaban udara, kecepatan angin, penyinaran matahari, serta ONI. Namun, dominasi shock produksi padi yang masih cukup besar menandakan bahwa faktor internal tetap menjadi penjelas utama terhadap fluktuasi produksi padi dalam model VECM.




Gambar 4.13 Grafik VD Curah Hujan

$$\begin{aligned} \sigma_{x1t}(12)^2 = & 0.43y_{1t} + 83.74x_{1t} + 4.90x_{2t} + 2.71x_{3t} + \\ & 4.96x_{4t} + 2.13x_{5t} + 1.14x_{6t} \end{aligned} \quad (4.16)$$

Gambar 4.13 dan persamaan (4.16) variabel curah hujan menunjukkan kontribusi masing-masing variabel dalam menjelaskan variasi atau fluktuasi curah hujan selama 12 periode pengamatan. Pada periode pertama hingga kedua, variasi curah hujan hampir sepenuhnya dijelaskan oleh shock curah hujan itu sendiri, terlihat dari kontribusinya yang sangat dominan mendekati 100 persen. Hal ini

menunjukkan bahwa dalam jangka pendek, perubahan curah hujan lebih banyak dipengaruhi oleh faktor internal curah hujan dibandingkan pengaruh variabel lain dalam model. Seiring bertambahnya periode pengamatan, kontribusi variabel lain mulai meningkat secara bertahap meskipun dalam proporsi yang relatif kecil. Variabel suhu udara memberikan kontribusi yang paling besar di antara variabel eksternal lainnya terhadap variasi curah hujan, terutama pada periode menengah hingga akhir pengamatan. Selain itu, kelembaban udara, kecepatan angin, penyinaran matahari, ONI, serta produksi padi juga mulai memberikan pengaruh terhadap variasi curah hujan, walaupun kontribusinya masih relatif kecil dan stabil. Pada periode-periode akhir, kontribusi shock curah hujan terhadap dirinya sendiri mengalami sedikit penurunan, namun tetap menjadi komponen terbesar dalam menjelaskan fluktuasi curah hujan hingga periode ke-12. Hal ini menunjukkan bahwa curah hujan memiliki pengaruh internal yang sangat kuat dan tetap menjadi faktor utama dalam menjelaskan variasinya sendiri dibandingkan variabel iklim lainnya maupun produksi padi. Secara keseluruhan, hasil Variance Decomposition ini menunjukkan bahwa dalam jangka panjang variasi curah hujan tidak hanya dipengaruhi oleh shock internal curah hujan itu sendiri, tetapi juga mulai dipengaruhi oleh faktor-faktor lain seperti suhu udara, kelembaban udara, kecepatan angin, penyinaran matahari, ONI, serta produksi padi. Namun demikian, dominasi kontribusi curah hujan yang masih sangat besar menunjukkan bahwa faktor internal curah hujan tetap menjadi penjelas utama terhadap fluktuasi curah hujan dalam model VECM yang digunakan.




Gambar 4.14 Grafik VD Suhu Udara

$$\begin{aligned} \sigma_{x2t}(12)^2 &= 2.33y_{1t} + 4.53x_{1t} + 69.95x_{2t} + 2.51x_{3t} + \\ &9.60x_{4t} + 9.70x_{5t} + 1.38x_{6t} \end{aligned} \quad (4.17)$$

Gambar 4.14 dan persamaan (4.17) variabel suhu udara menunjukkan kontribusi masing-masing variabel dalam menjelaskan variasi atau fluktuasi suhu udara selama 12 periode pengamatan. Pada periode pertama, variasi suhu udara hampir sepenuhnya dijelaskan oleh shock suhu udara itu sendiri, yang terlihat dari dominasi kontribusi variabel tersebut mendekati 100 persen. Hal ini menunjukkan bahwa dalam jangka pendek, perubahan suhu udara lebih banyak dipengaruhi oleh faktor internal suhu udara dibandingkan pengaruh variabel lain dalam model. Memasuki periode kedua hingga periode-periode berikutnya, kontribusi variabel lain mulai meningkat secara bertahap. Curah hujan mulai memberikan pengaruh terhadap variasi suhu udara, meskipun kontribusinya relatif kecil. Selain itu, kecepatan angin juga menunjukkan kontribusi yang cukup terlihat pada periode menengah hingga akhir pengamatan. Variabel produksi padi, kelembaban udara, penyinaran matahari, dan ONI turut memberikan kontribusi terhadap variasi suhu udara, namun besarnya masih relatif kecil dibandingkan pengaruh suhu udara itu

sendiri. Seiring bertambahnya periode pengamatan, kontribusi shock suhu udara terhadap dirinya sendiri mengalami sedikit penurunan, tetapi tetap menjadi komponen terbesar hingga periode ke-12. Hal ini menunjukkan bahwa suhu udara memiliki pengaruh internal yang sangat dominan dan stabil dalam menjelaskan variasinya sendiri dibandingkan variabel lainnya. Secara keseluruhan, hasil Variance Decomposition ini menunjukkan bahwa dalam jangka panjang variasi suhu udara tidak hanya dipengaruhi oleh shock internal suhu udara itu sendiri, tetapi juga mulai dipengaruhi oleh curah hujan, kelembaban udara, kecepatan angin, penyinaran matahari, ONI, dan produksi padi. Namun demikian, dominasi kontribusi suhu udara yang masih sangat besar menunjukkan bahwa faktor internal suhu udara tetap menjadi penjelas utama terhadap fluktuasi suhu udara dalam model VECM yang digunakan.




Gambar 4.15 Grafik VD Kelembaban Udara

$$\begin{aligned} \sigma_{x3t}(12)^2 = & 3.79y_{1t} + 4.37x_{1t} + 34.63x_{2t} + 34.05x_{3t} + \\ & 5.83x_{4t} + 14.63x_{5t} + 2.70x_{6t} \end{aligned} \quad (4.18)$$

Gambar 4.15 dan persamaan 4.18 variabel kelembaban udara menunjukkan kontribusi masing-masing variabel dalam menjelaskan variasi atau fluktuasi kelembaban udara selama 12 periode pengamatan. Pada periode pertama,

variasi kelembaban udara sebagian besar dijelaskan oleh shock kelembaban udara itu sendiri, terlihat dari kontribusinya yang sangat dominan. Namun, berbeda dengan variabel sebelumnya, suhu udara juga langsung memberikan kontribusi yang cukup besar sejak periode awal terhadap variasi kelembaban udara. Hal ini menunjukkan adanya hubungan yang cukup kuat antara suhu udara dan kelembaban udara dalam jangka pendek. Memasuki periode-periode berikutnya, kontribusi kelembaban udara terhadap dirinya sendiri mengalami penurunan secara bertahap, sementara kontribusi suhu udara tetap cukup besar dan stabil sepanjang periode pengamatan. Selain itu, penyinaran matahari mulai memberikan pengaruh yang cukup terlihat terutama pada periode menengah hingga akhir. Variabel curah hujan, kecepatan angin, ONI, dan produksi padi juga mulai memberikan kontribusi terhadap variasi kelembaban udara, meskipun proporsinya relatif kecil dibandingkan kelembaban udara dan suhu udara. Pada periode akhir pengamatan, kelembaban udara masih menjadi kontributor terbesar terhadap variasinya sendiri, tetapi dominasi tersebut tidak sebesar pada periode awal. Suhu udara menjadi variabel eksternal yang paling berpengaruh terhadap perubahan kelembaban udara dibandingkan variabel lainnya. Hal ini menunjukkan bahwa perubahan suhu udara memiliki keterkaitan yang cukup kuat terhadap dinamika kelembaban udara dalam model. Secara keseluruhan, hasil Variance Decomposition ini menunjukkan bahwa dalam jangka panjang variasi kelembaban udara tidak hanya dipengaruhi oleh shock internal kelembaban udara itu sendiri, tetapi juga cukup dipengaruhi oleh suhu udara serta variabel iklim lainnya seperti penyinaran matahari, curah hujan, kecepatan angin, dan ONI. Produksi padi juga memberikan pengaruh meskipun

relatif kecil. Namun demikian, kelembaban udara tetap menjadi faktor utama dalam menjelaskan fluktuasi variabel tersebut dalam model VECM yang digunakan.




Gambar 4.16 Grafik VD Kecepatan Angin

$$\begin{aligned} \sigma_{x_{4t}}(12)^2 &= 4.02y_{1t} + 8.58x_{1t} + 14.23x_{2t} + 15.86x_{3t} + \\ &37.97x_{4t} + 18.46x_{5t} + 0.88x_{6t} \end{aligned} \quad (4.19)$$

Gambar 4.16 dan persamaan (4.19) variabel kecepatan angin menunjukkan kontribusi masing-masing variabel dalam menjelaskan variasi atau fluktuasi kecepatan angin selama 12 periode pengamatan. Pada periode pertama, variasi kecepatan angin hampir sepenuhnya dijelaskan oleh shock kecepatan angin itu sendiri, terlihat dari kontribusi variabel kecepatan angin yang sangat dominan dibandingkan variabel lainnya. Hal ini menunjukkan bahwa dalam jangka sangat pendek, perubahan kecepatan angin lebih banyak dipengaruhi oleh faktor internal dari variabel kecepatan angin itu sendiri. Memasuki periode kedua dan seterusnya, kontribusi kecepatan angin terhadap dirinya sendiri mulai menurun secara bertahap meskipun tetap menjadi kontributor terbesar sepanjang periode pengamatan. Penurunan ini menunjukkan bahwa dalam jangka menengah hingga panjang, variasi kecepatan angin mulai dipengaruhi oleh variabel-variabel lain dalam model.

Di antara variabel eksternal, kelembaban udara dan penyinaran matahari terlihat memberikan kontribusi yang cukup besar terhadap variasi kecepatan angin. Kontribusi kelembaban udara cenderung stabil pada setiap periode, menunjukkan adanya hubungan yang cukup kuat antara kondisi kelembaban udara dan dinamika kecepatan angin. Sementara itu, penyinaran matahari juga menunjukkan pengaruh yang meningkat dan relatif konsisten terutama pada periode menengah hingga akhir pengamatan.

Hal ini mengindikasikan bahwa intensitas penyinaran matahari berperan dalam memengaruhi perubahan kecepatan angin dalam jangka panjang. Selain itu, suhu udara dan curah juga mulai memberikan kontribusi terhadap variasi kecepatan angin, meskipun besarnya relatif lebih kecil dibandingkan kelembaban udara dan penyinaran matahari. Variabel ONI dan produksi padi memberikan kontribusi yang sangat kecil hampir di seluruh periode pengamatan, sehingga pengaruhnya terhadap fluktuasi kecepatan angin dalam model dapat dikatakan relatif lemah. Pada periode akhir pengamatan, kecepatan angin tetap menjadi faktor utama dalam menjelaskan variasinya sendiri, tetapi dominasi tersebut sudah jauh berkurang dibandingkan periode awal. Pengaruh variabel iklim lain seperti kelembaban udara, penyinaran matahari, suhu udara, dan curah hujan menjadi lebih terlihat dalam menjelaskan dinamika kecepatan angin. Secara keseluruhan, hasil Variance Decomposition ini menunjukkan bahwa dalam jangka panjang variasi kecepatan angin tidak hanya dipengaruhi oleh shock internal kecepatan angin itu sendiri, tetapi juga dipengaruhi oleh faktor-faktor iklim lainnya, terutama kelembaban udara dan penyinaran matahari. Sementara itu, ONI dan produksi padi memiliki kontribusi yang relatif kecil terhadap perubahan kecepatan angin dalam model VECM yang digunakan.



Gambar 4.17 Grafik VD Penyinaran Matahari


$$\begin{aligned} \sigma_{x_{5t}}(12)^2 &= 4.22y_{1t} + 4.69x_{1t} + 32.00x_{2t} + 21.54x_{3t} + \\ &10.30x_{4t} + 23.90x_{5t} + 3.35x_{6t} \end{aligned} \quad (4.20)$$

Gambar 4.17 dan persamaan (4.20) variabel penyinaran matahari menunjukkan kontribusi masing-masing variabel dalam menjelaskan variasi atau fluktuasi penyinaran matahari selama 12 periode pengamatan. Pada periode pertama, variasi penyinaran matahari sebagian besar dijelaskan oleh shock penyinaran matahari itu sendiri, terlihat dari kontribusi yang sangat dominan. Hal ini menunjukkan bahwa dalam jangka pendek perubahan penyinaran matahari lebih banyak dipengaruhi oleh faktor internal variabel tersebut. Namun, mulai periode kedua dan seterusnya, kontribusi penyinaran matahari terhadap dirinya sendiri mengalami penurunan cukup signifikan meskipun tetap menjadi salah satu kontributor utama. Pada saat yang sama, suhu udara mulai memberikan kontribusi yang sangat besar terhadap variasi penyinaran matahari dan menjadi variabel eksternal yang paling dominan sepanjang periode pengamatan. Hal ini menunjukkan adanya hubungan yang kuat antara suhu udara dan penyinaran matahari dalam model, di mana perubahan suhu udara berpengaruh besar terhadap

dinamika penyinaran matahari baik dalam jangka menengah maupun jangka panjang. Selain suhu udara, kelembaban udara juga memberikan kontribusi yang cukup besar dan relatif stabil terhadap variasi penyinaran matahari. Kontribusi ini menunjukkan bahwa kondisi kelembaban udara turut memengaruhi perubahan intensitas penyinaran matahari dalam model yang digunakan. Kecepatan angin mulai memberikan pengaruh pada periode-periode berikutnya meskipun proporsinya lebih kecil dibandingkan suhu udara dan kelembaban udara. Sementara itu, curah hujan, ONI, dan produksi padi memberikan kontribusi yang relatif kecil terhadap variasi penyinaran matahari sepanjang periode pengamatan. Walaupun demikian, kontribusi ketiga variabel tersebut tetap menunjukkan adanya keterkaitan, meskipun pengaruhnya tidak terlalu dominan dibandingkan variabel iklim lainnya. Pada periode akhir pengamatan, variasi penyinaran matahari tidak lagi hanya didominasi oleh shock internal penyinaran matahari itu sendiri. Suhu udara tetap menjadi variabel eksternal yang paling berpengaruh, diikuti oleh kelembaban udara dan penyinaran matahari itu sendiri yang kontribusinya cenderung stabil.

Hal ini menunjukkan bahwa dalam jangka panjang dinamika penyinaran matahari cukup dipengaruhi oleh kondisi atmosfer, terutama suhu dan kelembaban udara. Secara keseluruhan, hasil Variance Decomposition ini menunjukkan bahwa variasi penyinaran matahari dalam model VECM tidak hanya dipengaruhi oleh shock internal penyinaran matahari itu sendiri, tetapi juga sangat dipengaruhi oleh suhu udara dan kelembaban udara. Variabel kecepatan angin turut memberikan pengaruh meskipun lebih kecil, sedangkan curah hujan, ONI, dan produksi padi

memiliki kontribusi yang relatif rendah dalam menjelaskan fluktuasi penyinaran matahari selama periode pengamatan.



Gambar 4.18 Grafik VD ONI

$$\begin{aligned} \sigma_{x_{6t}}(12)^2 = & 5.69y_{1t} + 2.91x_{1t} + 14.32x_{2t} + 1.99x_{3t} + \\ & 2.78x_{4t} + 2.00x_{5t} + 70.30x_{6t} \end{aligned} \quad (4.21)$$


Gambar 4.18 dan persamaan (4.21) variabel ONI menunjukkan kontribusi masing-masing variabel dalam menjelaskan variasi atau fluktuasi ONI selama 12 periode pengamatan. Pada periode pertama, variasi ONI hampir sepenuhnya dijelaskan oleh shock ONI itu sendiri, terlihat dari kontribusi yang sangat dominan dan mendekati seluruh proporsi variasi. Hal ini menunjukkan bahwa dalam jangka pendek dinamika ONI sangat dipengaruhi oleh faktor internal variabel ONI itu sendiri. Memasuki periode-periode berikutnya, kontribusi ONI terhadap dirinya sendiri mulai mengalami sedikit penurunan, tetapi tetap menjadi kontributor terbesar hingga akhir periode pengamatan. Meskipun demikian, beberapa variabel lain mulai memberikan kontribusi terhadap variasi ONI, terutama suhu udara. Kontribusi suhu udara terlihat meningkat secara bertahap dari periode awal hingga periode akhir, menunjukkan adanya hubungan yang cukup kuat antara perubahan

suhu udara dan dinamika ONI dalam jangka menengah maupun jangka panjang. Selain suhu udara, kecepatan angin, kelembaban udara, dan penyinaran matahari juga mulai memberikan pengaruh terhadap variasi ONI, meskipun kontribusinya relatif kecil. Pengaruh variabel-variabel iklim tersebut menunjukkan bahwa perubahan kondisi atmosfer memiliki keterkaitan dengan fluktuasi ONI dalam model yang digunakan. Sementara itu, curah hujan dan produksi padi memberikan kontribusi yang sangat kecil sepanjang periode pengamatan.

Hal ini menunjukkan bahwa kedua variabel tersebut tidak terlalu dominan dalam menjelaskan variasi ONI dibandingkan variabel iklim lainnya. Pada periode akhir pengamatan, ONI masih menjadi faktor utama dalam menjelaskan variasinya sendiri, walaupun dominasi tersebut sedikit berkurang dibandingkan periode awal. Suhu udara menjadi variabel eksternal yang paling besar kontribusinya terhadap perubahan ONI, sedangkan variabel lain seperti kecepatan angin, kelembaban udara, dan penyinaran matahari memberikan pengaruh tambahan dalam proporsi yang lebih kecil. Secara keseluruhan, hasil Variance Decomposition ini menunjukkan bahwa dalam jangka panjang variasi ONI tetap didominasi oleh shock internal ONI itu sendiri. Namun demikian, suhu udara mulai memberikan pengaruh yang cukup berarti terhadap dinamika ONI, sedangkan variabel iklim lain seperti kelembaban udara, kecepatan angin, dan penyinaran matahari turut berkontribusi meskipun relatif kecil. Curah hujan dan produksi padi memiliki pengaruh yang paling rendah dalam menjelaskan fluktuasi ONI pada model VECM yang digunakan.


4.15 MAPE

Mean Absolute Percentage Error (MAPE) merupakan salah satu metode evaluasi keakuratan model peramalan yang digunakan untuk mengukur seberapa besar kesalahan relatif rata-rata antara nilai aktual dan nilai hasil prediksi. Nilai MAPE yang lebih kecil menunjukkan bahwa model peramalan memiliki tingkat kesalahan yang rendah dan dengan demikian lebih akurat. Dalam analisis ini, nilai MAPE dihitung untuk masing-masing variabel yaitu produksi padi, curah hujan, suhu udara, kelembaban udara, kecepatan angin, penyinaran matahari, dan ONI berdasarkan 12 observasi yaitu data hasil peramalan dan data *out-sample* yang menghasilkan nilai MAPE seperti Gambar 4.17 sampai 4.23 dan Tabel 4.29 (Selengkapnya pada perhitungan MAPE pada lampiran 16) berikut:




Gambar 4.19 Peramalan Produksi Padi

Gambar 4.19 menunjukkan bahwa hasil prediksi VECM mampu mengikuti pola aktual produksi padi dengan cukup baik. Kedua garis bergerak hampir berimpit, sehingga model dapat menggambarkan fluktuasi produksi padi sepanjang tahun 2024.




Gambar 4.20 Peramalan Curah Hujan

Gambar 4.20 menunjukkan bahwa hasil prediksi VECM mengikuti pola perubahan curah hujan, meskipun terdapat beberapa penyimpangan pada beberapa bulan. Secara umum, model mampu menangkap arah pergerakan curah hujan.




Gambar 4.21 Peramalan Suhu Udara

Gambar 4.21 menunjukkan bahwa nilai prediksi VECM sangat dekat dengan data aktual suhu udara. Kedua garis hampir berimpit, sehingga model memiliki kemampuan yang baik dalam merepresentasikan perubahan suhu udara.




Gambar 4.22 Peramalan Kelembaban Udara

Gambar 4.22 menunjukkan bahwa hasil prediksi VECM mampu mengikuti pola aktual kelembaban udara dengan baik. Perbedaan antara nilai aktual dan prediksi relatif kecil pada sebagian besar periode pengamatan.




Gambar 4.23 Peramalan Kecepatan Angin

Gambar 4.23 menunjukkan bahwa prediksi VECM cukup mampu menggambarkan pola perubahan kecepatan angin. Meskipun terdapat selisih pada beberapa bulan, arah pergerakan data aktual masih dapat diikuti dengan baik.



Gambar 4.24 Peramalan Penyinaran Matahari

Gambar 4.24 menunjukkan bahwa hasil prediksi VECM mengikuti pola aktual penyinaran matahari dengan cukup baik. Kedua garis memiliki tren yang serupa, meskipun terdapat sedikit perbedaan pada beberapa periode.



Gambar 4.25 Gambar Peramalan ONI

Gambar 4.25 menunjukkan bahwa hasil prediksi VECM sangat mendekati data aktual ONI. Kedua garis hampir berimpit sepanjang periode pengamatan, yang menunjukkan bahwa model mampu menangkap dinamika ONI dengan baik.

Tabel 4.27 Hasil MAPE

Variabel	Observasi	MAPE
Produksi padi	12	40.3%
Curah hujan	12	39.08%
Suhu udara	12	9.78%
Kelembaban Udara	12	25.3%
Kecepatan angin	12	44.95%
Penyinaran matahari	12	18.37%
ONI	12	15.84%

Berdasarkan Tabel 4.27 menunjukkan perhitungan MAPE pada tujuh variabel, dapat diketahui bahwa model VECM memiliki tingkat akurasi yang berbeda-beda pada setiap variabel. Variabel suhu udara memiliki nilai MAPE paling kecil yaitu 9.78%, sehingga termasuk kategori sangat baik dan menunjukkan bahwa hasil peramalan sangat akurat. Variabel ONI dan penyinaran matahari juga memiliki akurasi yang baik dengan nilai MAPE masing-masing 15.84% dan 18.37%. Sementara itu, kelembaban udara memiliki nilai MAPE 25.3% yang menunjukkan tingkat akurasi cukup baik. Di sisi lain, produksi padi, curah hujan, dan kecepatan angin memiliki nilai MAPE relatif lebih besar, yaitu 40.3%, 39.08%, dan 44.95%, sehingga tingkat akurasinya masih tergolong cukup dan error prediksinya lebih tinggi dibanding variabel lainnya. Secara keseluruhan, model VECM mampu memberikan hasil forecast yang baik terutama pada variabel iklim tertentu, meskipun pada beberapa variabel masih diperlukan perbaikan model agar tingkat kesalahan prediksi menjadi lebih kecil.

4.16 Integrasi Pandangan Islam Dengan Hasil Pembahasan

Integrasi pandangan Islam dengan hasil penelitian ini dapat dikaitkan dengan firman Allah SWT dalam Surat Abasa ayat 24–32 yang menjelaskan tentang kekuasaan Allah dalam menyediakan sumber kehidupan bagi manusia melalui proses turunnya hujan, tumbuhnya tanaman, hingga tersedianya bahan pangan. Ayat tersebut mengajarkan bahwa manusia diperintahkan untuk memperhatikan makanannya, karena seluruh proses pertumbuhan tanaman merupakan bagian dari tanda-tanda kebesaran Allah SWT. Dalam konteks penelitian ini, produksi padi di Jawa Timur pasca El-Nino dipengaruhi oleh berbagai faktor iklim seperti curah hujan, suhu udara, kelembaban udara, kecepatan angin, penyinaran matahari, dan

ONI yang dianalisis menggunakan metode Vector Error Correction Model (VECM). Hasil penelitian menunjukkan bahwa faktor-faktor iklim memiliki hubungan jangka pendek maupun jangka panjang terhadap produksi padi, sehingga perubahan iklim akibat fenomena El-Nino dapat memengaruhi kestabilan hasil pertanian dan ketahanan pangan masyarakat.

Dalam Surat Abasa ayat 25–32 dijelaskan bahwa Allah “mencurahkan air hujan”, “membelah bumi”, dan “menumbuhkan biji-bijian, anggur, sayur-sayuran, zaitun, kurma, kebun-kebun yang lebat, buah-buahan dan rerumputan” sebagai kebutuhan hidup manusia dan hewan. Ayat ini sangat relevan dengan hasil penelitian yang menunjukkan bahwa curah hujan dan unsur atmosfer lainnya berpengaruh terhadap produksi padi. Ketika fenomena El-Nino terjadi, pola curah hujan berubah, suhu udara meningkat, dan kondisi atmosfer menjadi tidak stabil sehingga produksi padi dapat mengalami penurunan. Hal ini menunjukkan bahwa keseimbangan alam yang telah Allah tetapkan memiliki peranan penting dalam keberlangsungan sektor pertanian. Oleh karena itu, manusia perlu menjaga lingkungan dan memahami dinamika iklim sebagai bentuk tanggung jawab terhadap amanah Allah dalam mengelola bumi.

Selain itu, penggunaan metode VECM dalam penelitian ini merupakan bentuk ikhtiar ilmiah untuk memahami hubungan antarvariabel iklim dan produksi padi secara lebih mendalam. Islam sangat mendorong umatnya untuk menggunakan akal dan ilmu pengetahuan dalam memahami fenomena alam. Penelitian ini tidak hanya bertujuan memperoleh hasil statistik semata, tetapi juga menjadi sarana untuk merenungkan kebesaran Allah SWT melalui keteraturan alam yang dapat dianalisis secara ilmiah. Dengan adanya model peramalan produksi padi, pemerintah maupun

masyarakat dapat lebih siap menghadapi dampak perubahan iklim pasca El-Nino sehingga ketahanan pangan tetap terjaga. Hal tersebut sejalan dengan nilai-nilai Islam yang mengajarkan pentingnya menjaga kemaslahatan manusia, memanfaatkan ilmu pengetahuan untuk kebaikan, dan mensyukuri nikmat Allah SWT berupa hasil bumi yang menjadi sumber kehidupan manusia.

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian mengenai implementasi metode VECM dalam menganalisis produksi padi pasca El-Nino di Jawa Timur, diperoleh kesimpulan sebagai berikut.

1. Berdasarkan hasil analisis VECM, uji kointegrasi menunjukkan adanya hubungan jangka panjang antara produksi padi, curah hujan, suhu udara, kelembaban udara, kecepatan angin, penyinaran matahari, dan ONI sehingga model VECM layak digunakan untuk menganalisis dinamika produksi padi pasca El Nino di Jawa Timur. Hasil estimasi jangka panjang menunjukkan bahwa curah hujan, suhu udara, kelembaban udara, kecepatan angin, dan ONI berpengaruh signifikan terhadap produksi padi, sedangkan penyinaran matahari tidak signifikan. Pada jangka pendek, produksi padi dipengaruhi oleh perubahan curah hujan, suhu udara, kelembaban udara, kecepatan angin, dan ONI pada beberapa lag sebelumnya. Analisis IRF menunjukkan bahwa seluruh variabel memberikan respons yang berfluktuasi pada awal periode dan secara bertahap kembali menuju titik keseimbangan, sehingga sistem bersifat stabil. Analisis *Variance Decomposition* menunjukkan bahwa variasi produksi padi lebih banyak dijelaskan oleh shock produksi padi itu sendiri, namun kontribusi suhu udara, kelembaban udara, kecepatan angin, penyinaran matahari, curah hujan, dan ONI juga meningkat seiring bertambahnya periode pengamatan. Dengan demikian, faktor-faktor iklim

memiliki peran dalam menjelaskan dinamika produksi padi pasca El Niño di Jawa Timur.

2. Berdasarkan hasil evaluasi keakuratan model menggunakan MAPE, diperoleh bahwa tingkat akurasi model berbeda pada setiap variabel. Variabel suhu udara memiliki tingkat akurasi terbaik dengan nilai MAPE sebesar 9,78% yang termasuk kategori sangat baik. Variabel ONI dan penyinaran matahari juga menunjukkan hasil yang baik dengan nilai MAPE masing-masing sebesar 15,84% dan 18,37%. Sementara itu, kelembaban udara memperoleh nilai MAPE sebesar 25,3% yang tergolong cukup baik. Variabel produksi padi, curah hujan, dan kecepatan angin memiliki nilai MAPE yang relatif lebih besar yaitu 40,3%, 39,08%, dan 44,95%, sehingga tingkat kesalahan prediksinya masih cukup tinggi dibandingkan variabel lainnya. Namun secara umum, metode VECM mampu memberikan hasil *forecasting* yang cukup baik dalam menganalisis produksi padi pasca El-Nino di Jawa Timur.

5.2 Saran

Berdasarkan hasil penelitian dan Kesimpulan yang diperoleh, terdapat beberapa saran yang dapat diberikan untuk penelitian selanjutnya maupun pihak terkait. Bagi peneliti selanjutnya, disarankan untuk menambahkan variabel lain yang diduga memengaruhi produksi padi, seperti luas lahan, produktivitas tanah, penggunaan pupuk, irigasi, maupun faktor ekonomi pertanian agar model yang dihasilkan menjadi lebih komprehensif dan akurat. Selain itu, penelitian selanjutnya dapat membandingkan metode VECM dengan metode *time series* lainnya seperti ARDL, VARMA, LSTM, atau machine learning untuk memperoleh model

forecasting yang lebih optimal. Penelitian berikutnya juga disarankan menggunakan data dengan periode yang lebih panjang dan cakupan wilayah yang lebih luas agar hasil analisis lebih representatif dalam menggambarkan pengaruh perubahan iklim terhadap produksi padi di Indonesia. Selain itu, perlu dilakukan pengembangan analisis terhadap dampak fenomena iklim ekstrem lainnya seperti La-Nina maupun perubahan iklim global secara umum terhadap sektor pertanian.

DAFTAR PUSTAKA

- Adib Azka, M., & Joko Trilaksono, N. (2025). *Comparative Of Analysis Of Diurnal Mukhamad Adib Azka And Nurjanna Joko Trilaksono 83 Comparative Analysis Of Diurnal And Seasonal Variations In Precipitation Of Mesoscale Convective System And Non-Mesoscale Convective System Over Borneo Island*.
- Al Hakim, Ridlo, R., Hakim, A., Tengah, P. J., Sekretaris, T. W., Riset, J., Dem, K., Bina, K., Jl, W. H., Soebrantas, K. 12, & Riau, P. (2020). *Andasih Jurnal Pengabdian Kepada Masyarakat Model Energi Indonesia, Tinjauan Potensi Energy Terbarukan Untuk Ketahanan*.
- Ardiansyah. Zp. (2025). *Implementasi Vector Error Correction Model Dalam Menganalisis Hubungan Tingkat Kesejahteraan Petani Antar Subsektor*.
- Atman Maulana, H. (2018). *Pemodelan Deret Waktu Dan Peramalan Curah Hujan Pada Dua Belas Stasiun Di Bogor* (Vol. 15, Number 1).
- Auliya, D., Hakim Rosandi, A., Fernanda, D., Zunia Khoiriyah, E., & Ekonomika Dan Bisnis, F. (2025). *Gorontalo Development Review Apakah Pasokan Padi Terkena Dampak Perubahan Iklim Di Jawa Timur? Is Rice Supply Affected By Climate Change In East Java?* <https://jurnal.unigo.ac.id/index.php/gdrev>
- Beis, Jan Pattipeilohy, W., Sabana Hadi, A., Klimatologi Kupang, S., Kota Kupang, L., Klimatologi Manokwari Selatan, S., Bidang Analisis Dan Proyeksi Perubahan Iklim, S., & Pusat, J. (2022). *Identifikasi Penurunan Tren Curah Hujan, Cdd Dan Cwd Di Kota Kupang, Nusa Tenggara Timur Identification Of Decreasing Trends In Rainfall, Cdd And Cwd In Kupang City, East Nusa Tenggara* (Vol. 3).
- BMKG. (2025). *Direktori Data Dan Komputasi Badan Meteorologi Klimatologi Dan Geofisika*.
- BPS. (2023). *Statistik Produksi Padi Badan Pusat Statistik Indonesia*.
- BPS Provinsi Jawa Timur. (2024). *Statistik Produksi Padi Jawa Timur. Badan Pusat Statistik Jawa Timur*.
- David F. Hendry. (2017). *Sir Clive W.J. Granger Memorial Special Issue On Econometrics*.
- Fadholi, A., Pangkalpinang, S. M., Bandara, J., Amir, D., & Bangka, P. (2013). *Uji Perubahan Rata-Rata Suhu Udara Dan Curah Hujan Di Kota Pangkalpinang*.
- Gabriel, A. S. (2019). *Pengaruh Fenomena El Nino Dan La Nina Pada Persebaran Curah Hujan Dan Tingkat Kekeringan Lahan Di Pulau Bali*.
- Gujarati, D. N., Burr Ridge, B., Dubuque, I., Madison, I., & New York San Francisco St Louis Bangkok Bogota Caracas Kuala Lumpur Lisbon London

- Madrid Mexico City Milan Montreal New Delhi Santiago Seoul Singapore Sydney Taipei Toronto, W. (2003). *Basic Econometrics Fourth Edition*. Mcgraw-Hill Higher Education. <https://doi.org/10.2307/2230043>. Wwww.Mhhe.Com
- Halim, R. F., Sudarno, S., & Tarno, T. (2024). Pemodelan Antar Variabel Ekonomi Secara Simultan Menggunakan Pendekatan Vector Error Correction Model (Vecm). *Jurnal Gaussian*, 12(3), 414–424. <https://doi.org/10.14710/J.Gauss.12.3.414-424>
- Hamdi. (2020). Pengaruh Lama Penyinaran Matahari Terhadap Potensi Produksi Padi Berdasarkan Analisis Spasial Di Kabupaten Malang. *Jurnal Tanah Dan Sumberdaya Lahan*, 8(1), 51–60. <https://doi.org/10.21776/Ub.Jtsl.2021.008.1.7>
- Haryanto. (2023). *Klasifikasi Iklim Oldeman Wilayah Banjarbaru Guna Mendukung Ketahanan Pangan Ikn Nusantara Oldeman's Climate Classification In The Banjarbaru Region To Support Ikn Nusantara's Food Security*. 4, 8–13.
- Irfan, M. I., & Sulistijanti, W. (2024). *Peramalan Produksi Padi Di Kabupaten Kendal Tahun 2024 Menggunakan Metode Var (Vektor Autoregressive)*. <http://jiip.stkipyapisdompu.ac.id>
- Karmen. (2023). Analisis Resiko Bencana Akibat Musim Kemarau Berkepanjangan Di Jawa Timur. *Prosiding Seminar Nasional*, 947–957.
- Kemenag. (2022). *Qur'an Kemenag. Retrieved From Lajnah Pentashihan Mushaf Al-Qur'an*: <https://qur'an.kemenag.go.id/>. 6(4), 544–552. <https://doi.org/10.31764/Justek.Vxiy.Zzz>
- Khairina, D. M., Muaddam, A., Maharani, S., & Hatta, H. R. (2019). *Forecasting Of Groundwater Tax Revenue Using Single Exponential Smoothing Method*. <https://doi.org/10.1051/E3sconf/201>
- Kirchgässner, G., & Wolters, J. (2007). *Introduction To Modern Time Series Analysis*.
- Lia Rizki Yanti, I Nyoman Soemeinaboedhy, & Ismail Yasin. (2023). Hubungan Kejadian Kekeringan Dengan Fenomena El-Nino Di Wilayah Kabupaten Lombok Utara. *Jurnal Ilmiah Mahasiswa Agrokomplek*, 1(3), 285–293. <https://doi.org/10.29303/Jima.V1i3.2147>
- Luh, N., Dewi Wikayanti, P., Aini, Q., & Fitriyani, N. (2020). *Eigen Mathematics Journal Pengaruh Kurs Dolar Amerika Serikat, Inflasi, Dan Tingkat Suku Bunga Terhadap Indeks Harga Saham Gabungan Dengan Model Vector Error Correction*. <https://doi.org/10.29303/Emj.V3il.58>
- Lütkepohl, H. , & K. M. (2004). *Applied Times Series Econometrics*. Cambridge University Press 2004.

- Maulida, M., & Juliansyah, H. (2024). Pengaruh Nilai Tukar Petani Pangan, Peternakan Dan Pdb Sektor Pertanian Terhadap Indeks Pembangunan Manusia Di Indonesia. *Jurnal Ekonomi Pertanian Unimal*, 7(1), 33–46. <https://doi.org/10.29103/Jepu.V7i1.18032>
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2008). *Wiley Series In Probability And Statistics*.
- Mulyaqin, T. (2020). The Impact Of El Niño And La Nina On Fluctuation Of Rice Production In Banten Province. *Agromet*, 34(1), 34–41. <https://doi.org/10.29244/J.Agromet.34.1.34-41>
- NOAA. (2025). *El Niño / Southern Oscillation (Enso). National Oceanic And Atmospheric Administration*.
- Nugroho Dkk. (2016). *Analisis Indeks Harga Saham Gabungan Dengan Pendekatan Vector Error Correction Model (Vecm)*. <https://www.researchgate.net/publication/368463691>
- Nur'aini Nanda. (2024). *Implementasi Vector Error Correction Model (Vecm) Dalam Peramalan Kurs Rupiah, Nilai Ekspor, Dan Impor Indonesia*.
- Nurjannah. (2024). *Efisiensi Strategi Rantai Pasok Komoditas Cabai Merah*.
- Nurman, S., Nusrang, M., & Sudarmin. (2022). Analysis Of Rice Production Forecast In Maros District Using The Box-Jenkins Method With The Arima Model. *Arrus Journal Of Mathematics And Applied Science*, 2(1), 36–48. <https://doi.org/10.35877/Mathscience731>
- Ouliaris, S., Pagan, A. R., & Restrepo, J. (2018). *Quantitative Macroeconomic Modeling With Structural Vector Autoregressions-An Eviews Implementation*.
- Palinggik Allorerung, P., Erna, A., Bagussahrir, M., & Alam, S. (2024). Analisis Performa Normalisasi Data Untuk Klasifikasi K-Nearest Neighbor Pada Dataset Penyakit. In *Jurnal Informatika Sunan Kalijaga* (Vol. 9, Number 3).
- Putri, D. M., & Aghsilni, S. (2019). *Estimasi Model Terbaik Untuk Peramalan Harga Saham Pt. Polychem Indonesia Tbk. Dengan Arima Best Estimation Model For Forecasting Stock Price Of Pt. Polychem Tbk. By Using Arima*.
- Putri, M. A., Kumbara, K., Arnayulis, A., & Darnetti, D. (2025). Dynamics Of Indonesian Cpo Price Integration With European And Indian Markets (Empirical Insights). *Jia (Jurnal Ilmiah Agribisnis) : Jurnal Agribisnis Dan Ilmu Sosial Ekonomi Pertanian*, 10(1), 93–102. <https://doi.org/10.37149/Jia.V10i1.1679>
- Putri, M., Nuryaman, A., Warsono, Dan, Matematika, J., Mipa, F., Lampung Jl Soemantri Brojonegoro No, U., & Lampung, B. (2023). Penerapan Model Vector Error Correction Model (Vecm) Pada Peramalan Data Nilai Ekspor Dan Nilai Impor Seluruh Komoditas Di Provinsi Lampung Tahun 2022. In *Jurnal*

Siger Matematika (Vol. 04, Number 02).
<https://Lampung.Bps.Go.Id/Indicator/8/151/8/Nilai-Ekspor->

Ridla, M. A., Azise, N., & Rahman, M. (2023). Perbandingan Model Time Series Forecasting Dalam Memprediksi Jumlah Kedatangan Wisatawan Dan Penumpang Airport. *Simkom*, 8(1), 1–14.
<https://doi.org/10.51717/Simkom.V8i1.103>

Riko Anshori Prasetya, M., & Mudi Priyatno, A. (2023). *Penanganan Imputasi Missing Values Pada Data Time Series Dengan Menggunakan Metode Data Mining*. <https://doi.org/10.37034/Jidt.V5i1.324>

Risianti, D. F., & Purwadi, J. (2019). Implementasi Metode Vecm (Vector Error Corection Model) Dalam Menganalisis Pengaruh Kurs Mata Uang, Inflasi Dan Suku Bunga Terhadap Jakarta Islamic Indeks (Jii). *Jurnal Ilmiah Matematika*, 6(1), 13. <https://doi.org/10.26555/Konvergensi.V6i1.19544>

Sinulingga, M. A., Asih, D., Maruddani, I., Hoyyi, A., Statistika, D., Sains, F., & Matematika, D. (2020). Vector Autoregressive Stability Condition Check Untuk Pemodelan Dan Prediksi Sumber Penerimaan Pabean Belawan. *Jurnal Gaussian*, 9(2), 193–203. <https://ejournal3.undip.ac.id/index.php/Gaussian/>

Sudibyakto Com, Y. B. (2019). *Kajian Dampak Variabilitas Curah Hujan Terhadap Produktivitas Padi Sawah Tadah Hujan Di Kabupaten Magelang*.

Wahyuni, D., Oktriani, Z., Casella, T., Amelia, R., Matematika, J., Teknik, F., Bangka Belitung Jalan Kampus Terpadu Universitas Bangka Belitung, U., Balunijuk, K., Merawang, K., & Bangka, K. (2022). *Metode Vector Autoregression (Var) Dalam Menganalisis Pengaruh Indeks Pembangunan Manusia (Ipm) Terhadap Pertumbuhan Ekonomi Di Provinsi Kepulauan Bangka Belitung*.

Wei. (2006). *Time Series Analysis - Univariate And Multivariate Methods, Second Edition*. Pearson <https://doi.org/10.1201/B11459-9>.

Widya Ardianti, C., & Santoso, R. (2020). *Analisis Arima Dan Wavelet Untuk Peramalan Harga Cabai Merah Besar Di Jawa Tengah*. <https://ejournal3.undip.ac.id/index.php/Gaussian/>

Yuniasih, B., Harahap, W. N., & Wardana, D. A. S. (2023). Anomali Iklim El Nino Dan La Nina Di Indonesia Pada 2013-2022. *Agroista : Jurnal Agroteknologi*, 6(2), 136–143. <https://doi.org/10.55180/Agi.V6i2.332>

Zamahzari, & Ahmad. (2023). *Forecasting Produksi Padi Dan Konsumsi Beras Di Provinsi Jawa Timur*.

LAMPIRAN

Lampiran 1. Data Asli

https://drive.google.com/drive/folders/1mAQgWtH9xx8OuKu2Esrff8yUg2HSe_JN

Lampiran 2. Data Penanganan Missing Value

<https://drive.google.com/drive/folders/14SAqDWsiOfL0hT-AMM5OPQhkRRCjyGuo?usp=sharing>

Periode	y	x_1	x_2	x_3	x_4	x_5	x_6
1 Jan 2015	20361.9424	12.3159	26.4518	83.4384	2.0507	4.2315	0.5000
1 Feb 2015	40671.4007	12.7488	26.4967	83.7276	1.6951	5.4024	0.5000
1 Mar 2015	93792.0846	10.5920	26.8128	83.0912	1.6642	5.1577	0.5000
1 Apr 2015	93792.0846	10.0815	26.7256	84.6370	1.5407	5.0841	0.7000
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1 Okt 2024	471937.2800	1.7993	28.5842	71.6774	2.2151	7.1688	-0.3000
1 Nov 2024	462469.2200	8.6930	28.2148	79.2889	1.5630	5.7233	-0.4000
1 Des 2024	368369.6700	15.8513	26.8624	84.5125	1.6452	2.9290	-0,5000

Lampiran 3. Data *In-sample*

Periode	Y1	X1	X2	X3	X4	X5	X6
2015-01-01	-0,99937379	-0,09221	-0,75441	0,924042	0,370256	-1,14656	0,395518
2015-02-01	-0,96330639	-0,09111	-0,69396	0,988212	-0,45189	-0,43597	0,395518
2015-03-01	-0,86896981	-0,09658	-0,26879	0,84702	-0,5233	-0,58452	0,395518
2015-04-01	-0,8444099	-0,09788	-0,38613	1,189971	-0,80881	-0,62918	0,604603
2015-05-01	-0,95703752	-0,11108	-0,13208	0,090789	0,602764	0,656021	0,813688
2015-06-01	-0,95115248	-0,12168	-0,82661	-0,48631	0,920886	1,078133	1,127315
2015-07-01	-0,90053043	-0,12339	-1,2533	-0,53739	2,641383	1,07444	1,440942
2015-08-01	-0,96800933	-0,12258	-1,69836	-0,78071	2,523222	1,301639	1,859111

2015-09-01	-0,96556064	-0,12336	-0,56705	-1,79184	2,754038	1,659272	2,172738
2015-10-01	-0,99230128	-0,12345	1,123972	-2,24964	2,88212	1,626979	2,381822
2015-11-01	-0,97081175	-0,11419	2,570158	-1,37375	0,235857	1,015873	2,590907
2015-12-01	-0,99869524	-0,10388	0,830328	0,423611	-0,39338	-0,94491	2,590907
2016-01-01	-0,99072172	-0,10047	0,854438	0,480865	-0,61711	-0,44877	2,486365
2016-02-01	-0,94602455	-0,07888	-0,4602	1,528061	-0,89857	-1,53376	2,068195
2016-03-01	-0,82911625	-0,10066	0,936051	0,848481	-1,24645	-0,47989	1,545484
2016-04-01	-0,79867994	-0,1015	0,206138	0,809262	-0,82478	-0,48833	0,813688
2016-05-01	-0,93825573	-0,09846	1,364873	0,492784	-0,48985	0,297355	0,290976
2016-06-01	-0,93096259	1,985794	0,253658	0,58273	-1,01432	0,110971	-0,23174
2016-07-01	-0,86822831	-0,11103	-0,02286	0,339666	0,09942	0,472394	-0,54536
2016-08-01	-0,95185275	-0,11543	-0,20847	-0,36773	0,646688	0,866644	-0,6499
2016-09-01	-0,94881816	10,66214	0,951851	-0,46755	0,190497	0,719336	-0,75445
2016-10-01	-0,98195699	-0,09733	0,736926	0,340839	-0,72984	-0,34606	-0,85899
2016-11-01	-0,9553257	-0,10144	0,648125	0,561216	-1,48975	-0,71238	-0,85899
2016-12-01	-0,98988082	-0,09013	0,011227	0,889202	-0,28325	-1,86947	-0,75445
2017-01-01	-0,99700901	-0,09594	0,243001	0,95719	-0,2525	-1,32056	-0,44082
2017-02-01	-0,95858292	-0,0903	-0,63177	0,942608	0,420113	-1,3185	-0,33628
2017-03-01	-0,85807703	-0,10003	-0,33643	0,97115	-1,1495	-0,80247	-0,02265
2017-04-01	-0,83191099	-0,10228	0,074312	0,845265	-1,62987	-0,37194	0,081891
2017-05-01	-0,95190408	-0,11273	0,224965	-0,05346	-0,08922	0,377102	0,186434
2017-06-01	-0,94563418	-0,11273	0,224965	-0,05346	-0,08922	0,377102	0,186434
2017-07-01	-0,89170162	-0,11875	-1,43459	-0,07339	0,808187	0,298178	-0,02265
2017-08-01	-0,96359342	-0,12217	-1,41	-0,87972	1,02364	1,111898	-0,23174
2017-09-01	-0,96098458	-0,12183	-0,04452	-1,21136	1,098405	1,105973	-0,54536
2017-10-01	-0,98947398	-0,11522	1,484681	-0,90199	-0,24422	0,738644	-0,85899
2017-11-01	-0,9665791	-0,08913	-0,10859	0,858823	-1,45103	-1,48104	-0,96353
2017-12-01	-0,99628609	-0,09348	-0,3034	0,943294	-0,67014	-1,45362	-1,17262
2018-01-01	-0,66022292	-0,09236	-1,05895	1,266522	-0,17792	-2,05511	-1,06807
2018-02-01	0,670307995	-0,08951	-1,23734	1,228239	-0,42593	-1,02794	-1,06807
2018-03-01	3,037111755	-0,09686	-0,51425	0,944515	-1,25773	-0,66377	-0,85899
2018-04-01	1,353861443	-0,11375	0,891455	-0,16502	-0,63755	0,923045	-0,6499
2018-05-01	0,092684375	-0,12098	0,32787	-0,68172	0,352422	0,901779	-0,33628
2018-06-01	0,604678938	-0,11954	-0,69208	-0,33183	0,261545	0,635122	-0,12719
2018-07-01	1,07793118	-0,12283	-2,00215	-0,9171	0,601021	1,223265	-0,02265
2018-08-01	0,236706053	-0,12207	-1,96743	-1,24154	1,131366	1,028373	0,081891
2018-09-01	0,07379988	-0,12234	-0,12414	-2,00911	0,952546	1,208693	0,395518
2018-10-01	-0,16584204	-0,12259	1,41235	-2,13137	0,750181	1,449697	0,709145
2018-11-01	-0,20059692	-0,10392	1,23477	-0,36223	-0,74031	-0,02861	0,813688
2018-12-01	-0,42703042	-0,09602	0,338478	0,611278	-1,07288	-1,61159	0,709145
2019-01-01	-0,47749813	-0,08627	-0,47259	1,066132	-0,14478	-1,23704	0,604603
2019-02-01	-0,24959789	-0,09131	-0,37567	1,011661	-1,21494	-0,54703	0,604603
2019-03-01	2,398684355	-0,0983	0,017452	0,651204	-0,82816	-0,58022	0,604603
2019-04-01	2,262524355	-0,10116	0,775908	0,463286	-0,86461	-0,00459	0,604603
2019-05-01	0,058654453	-0,11844	0,446492	-0,34853	0,211549	0,937669	0,395518

2019-06-01	0,396377545	−0,12285	−1,24068	−0,63257	0,227294	0,725028	0,395518
2019-07-01	0,867014253	−0,12279	−2,04748	−0,91153	0,783327	1,090364	0,290976
2019-08-01	0,296877048	−0,12333	−1,84398	−1,36082	1,628564	1,442954	−0,02265
2019-09-01	−0,11817098	−0,12316	−0,82362	−1,78296	1,571663	1,565197	0,081891
2019-10-01	−0,14528697	−0,12338	1,474072	−2,54805	1,297099	1,819254	0,186434
2019-11-01	−0,14925885	−0,11933	1,97814	−1,71168	−0,21905	1,252409	0,395518
2019-12-01	−0,55203052	−0,10472	1,171765	−0,21314	−1,45007	−0,09007	0,395518
2020-01-01	−0,52279692	−0,09704	0,363071	0,618435	−0,74141	−0,76525	0,395518
2020-02-01	−0,42242304	−0,07994	−0,31082	1,271352	−0,96525	−0,8926	0,395518
2020-03-01	1,315782844	−0,0958	0,071653	1,104502	−1,33546	−0,43134	0,290976
2020-04-01	2,949508649	−0,09924	0,60644	0,692017	−1,12564	−0,09671	0,081891
2020-05-01	0,726313493	−0,10386	0,593825	0,651204	−0,37075	0,008307	−0,23174
2020-06-01	0,036074079	−0,1198	−0,41105	−0,19953	0,42424	0,64636	−0,44082
2020-07-01	0,981651955	−0,12068	−0,6097	−0,65085	1,147065	0,993892	−0,54536
2020-08-01	0,605580665	−0,12084	−0,70984	−0,73897	1,454545	1,087101	−0,75445
2020-09-01	0,02836852	−0,12193	1,33891	−1,88075	1,297651	1,267834	−1,06807
2020-10-01	0,062496879	−0,11452	0,95763	−0,76839	0,567875	0,324497	−1,3817
2020-11-01	0,036067348	−0,10786	1,073826	−0,03026	−0,38067	−0,07266	−1,48624
2020-12-01	−0,56261378	−0,08607	−0,9404	1,283968	−0,91126	−1,93489	−1,3817
2021-01-01	−0,50135122	−0,08391	−1,25569	1,487588	−0,40166	−2,09839	−1,17262
2021-02-01	−0,13381217	−0,08393	−0,88605	1,220316	0,610788	−1,07418	−1,06807
2021-03-01	2,858183132	−0,09675	−1,41062	1,367626	−1,11076	−0,80353	−0,96353
2021-04-01	1,910986921	−0,10996	0,064312	0,099567	−0,62043	0,313709	−0,85899
2021-05-01	−0,08997531	−0,11624	0,522198	0,04112	0,045817	0,660121	−0,6499
2021-06-01	0,405495897	−0,10954	−0,08667	0,543288	−0,26079	0,39395	−0,54536
2021-07-01	1,097304987	−0,11997	−0,8404	−0,72941	0,64791	0,846247	−0,54536
2021-08-01	0,234510162	−0,12143	−0,18285	−0,6876	1,429108	1,083301	−0,6499
2021-09-01	−0,17462763	−0,11504	0,13113	−0,60856	1,288812	0,350164	−0,85899
2021-10-01	−0,15995001	−0,11584	0,897354	−0,67854	−0,18621	0,621621	−0,96353
2021-11-01	−0,11199423	−0,0915	−0,61783	1,23763	−1,46815	−1,46328	−1,17262
2021-12-01	−0,37593533	−0,09188	0,13788	0,757595	−0,76627	−1,08826	−1,17262
2022-01-01	−0,53713265	−0,09451	−0,88777	1,030348	−0,38509	−1,3036	−1,17262
2022-02-01	0,117610916	−0,09532	−1,02864	1,149727	−0,67926	−1,26284	−1,06807
2022-03-01	3,026748095	−0,09558	−0,37036	1,146447	−0,90715	−0,68825	−1,17262
2022-04-01	1,484525112	−0,10449	−0,09265	0,576978	−1,39965	−0,11964	−1,27716
2022-05-01	−0,08939699	−0,10592	0,436848	0,674894	−0,69169	−0,25953	−1,17262
2022-06-01	0,426063653	−0,10773	−0,6278	0,566296	−0,59474	−0,02726	−1,06807
2022-07-01	0,843069514	−0,11904	−1,20844	−0,14257	0,501582	0,52809	−0,96353
2022-08-01	0,103162101	−0,12061	−0,85595	−0,56959	0,907627	0,730378	−1,06807
2022-09-01	−0,2174383	−0,11753	0,056112	−0,63058	0,407687	0,469007	−1,17262
2022-10-01	−0,17406517	−0,09408	−0,57876	0,844334	−0,9529	−1,06615	−1,17262
2022-11-01	−0,06272334	−0,09182	−0,7376	1,175651	−1,50033	−1,47206	−1,06807
2022-12-01	−0,42877512	−0,10124	−0,29566	0,588157	−0,246	−1,03166	−0,96353
2023-01-01	−0,46883883	−0,09817	−0,41762	0,690003	−0,0039	−0,93752	−0,85899
2023-02-01	0,701741243	−0,08199	−1,22826	1,351495	0,463996	−1,8631	−0,54536

2023-03-01	2,711532939	-0,10276	-0,36651	0,739305	-0,97344	-0,42114	-0,23174
2023-04-01	1,072817429	-0,10116	0,17792	0,816095	-0,98863	-0,60625	0,081891
2023-05-01	0,077537652	-0,11665	0,26904	-0,41373	0,078963	0,441302	0,395518
2023-06-01	0,633937394	-0,12071	-0,12454	-0,34087	0,252983	0,741435	0,709145
2023-07-01	0,605795388	-0,11694	-1,41482	-0,43123	0,84962	0,637717	1,022772
2023-08-01	0,284561736	-0,12331	-1,32658	-1,05228	1,902023	1,451655	1,231857
2023-09-01	-0,09612188	-0,12331	-0,41055	-1,86185	1,956991	1,426518	1,545484
2023-10-01	-0,27382956	-0,12329	2,004981	-2,09081	1,454545	1,608047	1,754569
2023-11-01	-0,17402244	-0,11274	2,549729	-1,33513	-0,14091	0,504084	1,859111
2023-12-01	-0,25644049	-0,11171	1,717104	-0,56244	-0,89886	-0,12184	1,963653

Lampiran 4. Data *Out-sample*

Periode	Y1	X1	X2	X3	X4	X5	X6
2024-01-01	-0,54355019	-0,0989	0,878066	0,397369	-0,55911	-1,03018	1,754569
2024-02-01	-0,48459154	-0,08613	0,698037	0,784275	-0,84543	-0,83785	1,440942
2024-03-01	1,311245795	-0,10227	1,102774	0,573903	-0,10334	-0,93969	1,022772
2024-04-01	2,757316192	-0,10104	1,515799	0,641893	-0,78312	-0,55298	0,604603
2024-05-01	0,501080961	-0,12143	1,871892	-0,77714	0,219836	0,879811	0,290976
2024-06-01	0,118212357	-0,11778	0,758415	-0,54383	-0,06384	0,104003	0,081891
2024-07-01	0,544942557	-0,12163	-0,92779	-0,75965	0,965633	0,44935	-0,12719
2024-08-01	0,502424317	-0,12068	-0,86125	-1,17315	1,338532	0,742994	-0,23174
2024-09-01	0,12281007	-0,12126	0,83216	-1,46661	1,117831	0,616466	-0,33628
2024-10-01	-0,19742487	-0,11889	2,114442	-1,68526	0,750181	0,635977	-0,44082
2024-11-01	-0,21423912	-0,1014	1,617448	0,003427	-0,75743	-0,24123	-0,54536
2024-12-01	-0,38134974	-0,08324	-0,20207	1,162351	-0,56739	-1,937	-0,6499

Lampiran 5. Hasil Uji ADF Tingkat level

Augmented Dickey-Fuller Unit Root Test on Y1_INSAMPLE		
Null Hypothesis: Y1_INSAMPLE has a unit root		
Exogenous: Constant		
Lag Length: 12 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.460676	0.5492
Test critical values: 1% level	-3.500669	
5% level	-2.892200	
10% level	-2.583192	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(Y1_INSAMPLE)		
Method: Least Squares		
Date: 04/30/26 Time: 12:48		
Sample (adjusted): 2016M02 2023M12		
Included observations: 95 after adjustments		

Augmented Dickey-Fuller Unit Root Test on X1_INSAMPLE		
Null Hypothesis: X1_INSAMPLE has a unit root		
Exogenous: Constant		
Lag Length: 0 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-10.37751	0.0000
Test critical values: 1% level	-3.492523	
5% level	-2.888669	
10% level	-2.581313	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(X1_INSAMPLE)		
Method: Least Squares		
Date: 04/30/26 Time: 12:50		
Sample (adjusted): 2015M02 2023M12		
Included observations: 107 after adjustments		

Augmented Dickey-Fuller Unit Root Test on X2_INSAMPLE		
Null Hypothesis: X2_INSAMPLE has a unit root		
Exogenous: Constant		
Lag Length: 3 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.370362	0.0006
Test critical values: 1% level	-3.494378	
5% level	-2.889474	
10% level	-2.581741	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(X2_INSAMPLE)		
Method: Least Squares		
Date: 04/30/26 Time: 12:52		
Sample (adjusted): 2015M05 2023M12		
Included observations: 104 after adjustments		

Augmented Dickey-Fuller Unit Root Test on X3_INSAMPLE		
Null Hypothesis: X3_INSAMPLE has a unit root		
Exogenous: Constant		
Lag Length: 2 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.725906	0.0000
Test critical values: 1% level	-3.493747	
5% level	-2.889200	
10% level	-2.581596	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(X3_INSAMPLE)		
Method: Least Squares		
Date: 04/30/26 Time: 12:53		
Sample (adjusted): 2015M04 2023M12		
Included observations: 105 after adjustments		

Augmented Dickey-Fuller Unit Root Test on X4_INSAMPLE		
Null Hypothesis: X4_INSAMPLE has a unit root		
Exogenous: Constant		
Lag Length: 1 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.758621	0.0000
Test critical values: 1% level	-3.493129	
5% level	-2.888932	
10% level	-2.581453	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(X4_INSAMPLE)		
Method: Least Squares		
Date: 04/30/26 Time: 12:54		
Sample (adjusted): 2015M03 2023M12		
Included observations: 106 after adjustments		

Augmented Dickey-Fuller Unit Root Test on X5_INSAMPLE		
Null Hypothesis: X5_INSAMPLE has a unit root		
Exogenous: Constant		
Lag Length: 2 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.461307	0.0000
Test critical values: 1% level	-3.493747	
5% level	-2.889200	
10% level	-2.581596	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(X5_INSAMPLE)		
Method: Least Squares		
Date: 04/30/26 Time: 12:55		
Sample (adjusted): 2015M04 2023M12		
Included observations: 105 after adjustments		

Augmented Dickey-Fuller Unit Root Test on X6_INSAMPLE		
Null Hypothesis: X6_INSAMPLE has a unit root		
Exogenous: Constant		
Lag Length: 1 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.270968	0.0187
Test critical values: 1% level	-3.493129	
5% level	-2.888932	
10% level	-2.581453	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(X6_INSAMPLE)		
Method: Least Squares		
Date: 04/30/26 Time: 12:55		
Sample (adjusted): 2015M03 2023M12		
Included observations: 106 after adjustments		

Lampiran 6. Hasil Uji ADF Tingkat *First Difference*

Augmented Dickey-Fuller Unit Root Test on D(Y1_INSAMPLE)		
Null Hypothesis: D(Y1_INSAMPLE) has a unit root		
Exogenous: Constant		
Lag Length: 11 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.659113	0.0002
Test critical values: 1% level	-3.500669	
5% level	-2.892200	
10% level	-2.583192	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(Y1_INSAMPLE,2)		
Method: Least Squares		
Date: 04/30/26 Time: 12:49		
Sample (adjusted): 2016M02 2023M12		
Included observations: 95 after adjustments		

Augmented Dickey-Fuller Unit Root Test on D(X1_INSAMPLE)		
Null Hypothesis: D(X1_INSAMPLE) has a unit root		
Exogenous: Constant		
Lag Length: 1 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-14.36558	0.0000
Test critical values: 1% level	-3.493747	
5% level	-2.889200	
10% level	-2.581596	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(X1_INSAMPLE,2)		
Method: Least Squares		
Date: 04/30/26 Time: 12:51		
Sample (adjusted): 2015M04 2023M12		
Included observations: 105 after adjustments		

Augmented Dickey-Fuller Unit Root Test on D(X2_INSAMPLE)		
Null Hypothesis: D(X2_INSAMPLE) has a unit root		
Exogenous: Constant		
Lag Length: 3 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-9.596750	0.0000
Test critical values: 1% level	-3.495021	
5% level	-2.889753	
10% level	-2.581890	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(X2_INSAMPLE,2)		
Method: Least Squares		
Date: 04/30/26 Time: 12:53		
Sample (adjusted): 2015M06 2023M12		
Included observations: 103 after adjustments		

Augmented Dickey-Fuller Unit Root Test on D(X3_INSAMPLE)		
Null Hypothesis: D(X3_INSAMPLE) has a unit root		
Exogenous: Constant		
Lag Length: 9 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.747359	0.0000
Test critical values: 1% level	-3.499167	
5% level	-2.891550	
10% level	-2.582846	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(X3_INSAMPLE,2)		
Method: Least Squares		
Date: 04/30/26 Time: 12:54		
Sample (adjusted): 2015M12 2023M12		
Included observations: 97 after adjustments		

Augmented Dickey-Fuller Unit Root Test on D(X4_INSAMPLE)		
Null Hypothesis: D(X4_INSAMPLE) has a unit root		
Exogenous: Constant		
Lag Length: 9 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-8.389316	0.0000
Test critical values: 1% level	-3.499167	
5% level	-2.891550	
10% level	-2.582846	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(X4_INSAMPLE,2)		
Method: Least Squares		
Date: 04/30/26 Time: 12:54		
Sample (adjusted): 2015M12 2023M12		
Included observations: 97 after adjustments		

Augmented Dickey-Fuller Unit Root Test on D(X5_INSAMPLE)		
Null Hypothesis: D(X5_INSAMPLE) has a unit root		
Exogenous: Constant		
Lag Length: 9 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-8.880341	0.0000
Test critical values: 1% level	-3.499167	
5% level	-2.891550	
10% level	-2.582846	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(X5_INSAMPLE,2)		
Method: Least Squares		
Date: 04/30/26 Time: 12:55		
Sample (adjusted): 2015M12 2023M12		
Included observations: 97 after adjustments		

Augmented Dickey-Fuller Unit Root Test on D(X6_INSAMPLE)		
Null Hypothesis: D(X6_INSAMPLE) has a unit root		
Exogenous: Constant		
Lag Length: 0 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.310190	0.0168
Test critical values: 1% level	-3.493129	
5% level	-2.888932	
10% level	-2.581453	
*MacKinnon (1996) one-sided p-values.		
Augmented Dickey-Fuller Test Equation		
Dependent Variable: D(X6_INSAMPLE,2)		
Method: Least Squares		
Date: 04/30/26 Time: 12:56		
Sample (adjusted): 2015M03 2023M12		
Included observations: 106 after adjustments		

Lampiran 7. Hasil Pemilihan Lag Optimum

VAR Lag Order Selection Criteria						
Endogenous variables: D(X1_INSAMPLE) D(X2_INSAMPLE) D(X3_INSAMPLE) D...						
Exogenous variables: C						
Date: 04/30/26 Time: 13:04						
Sample: 2015M01 2023M12						
Included observations: 103						
Lag	LogL	LR	FPE	AIC	SC	HQ
0	-676.1926	NA	0.001361	13.26588	13.44493	13.33840
1	-533.5240	263.1751	0.000221	11.44707	12.87954*	12.02727
2	-438.1299	163.0035	9.10e-05	10.54621	13.23210	11.63409
3	-361.5199	120.4933	5.50e-05	10.01010	13.94940	11.60565
4	-279.5449	117.7893*	3.09e-05*	9.369805*	14.56252	11.47303*

Lampiran 8. Hasil Estimasi VAR

Vector Autoregression Estimates							
Date: 04/30/26 Time: 13:31							
Sample (adjusted): 2015M06 2023M12							
Included observations: 103 after adjustments							
Standard errors in () & t-statistics in []							
	D(X1_INSA...	D(X2_INSA...	D(X3_INSA...	D(X4_INSA...	D(X5_INSA...	D(X6_INSA...	D(Y1_INSA...
D(X1_INSAMPLE(-1))	-0.859262 (0.11696) [-7.34671]	0.023254 (0.06195) [0.37536]	0.050162 (0.04478) [1.12015]	-0.086502 (0.05349) [-1.61713]	-0.019378 (0.04526) [-0.42817]	-0.002296 (0.01152) [-0.19931]	0.004838 (0.05458) [0.08864]
D(X1_INSAMPLE(-2))	-0.706608 (0.15357) [-4.60121]	0.028513 (0.08134) [0.35052]	0.049138 (0.05880) [0.83570]	-0.159761 (0.07024) [-2.27467]	-0.030659 (0.05942) [-0.51594]	0.007464 (0.01513) [0.49342]	0.065024 (0.07167) [0.90731]
D(X1_INSAMPLE(-3))	-0.320448 (0.14972) [-2.14026]	0.036022 (0.07931) [0.45421]	0.042688 (0.05733) [0.74465]	-0.123087 (0.06848) [-1.79752]	-0.071101 (0.05793) [-1.22725]	0.010236 (0.01475) [0.69409]	0.115433 (0.06987) [1.65208]
D(X1_INSAMPLE(-4))	-0.159108 (0.11322) [-1.40533]	0.020571 (0.05997) [0.34302]	0.039918 (0.04335) [0.92086]	-0.122095 (0.05178) [-2.35796]	-0.051483 (0.04381) [-1.17518]	0.020010 (0.01115) [1.79436]	0.111586 (0.05283) [2.11197]
D(X2_INSAMPLE(-1))	0.327934 (0.25216) [1.30048]	-0.170022 (0.13357) [-1.27290]	0.355955 (0.09655) [3.68675]	-0.589299 (0.11533) [-5.10979]	-0.347092 (0.09757) [-3.55721]	-0.034785 (0.02613) [-1.40050]	0.042307 (0.11768) [0.35951]
D(X2_INSAMPLE(-2))	0.259295 (0.26528) [0.97744]	-0.182190 (0.14052) [-1.29657]	0.348515 (0.10157) [3.43125]	-0.450903 (0.12132) [-3.71649]	-0.134094 (0.10265) [-1.30633]	0.005184 (0.02613) [0.19841]	0.181546 (0.12380) [1.46648]
D(X2_INSAMPLE(-3))	0.027075 (0.26842) [0.10087]	-0.466973 (0.14218) [-3.28436]	0.271982 (0.10277) [2.64641]	0.014020 (0.12278) [0.11420]	-0.255958 (0.10386) [-2.46435]	-0.031120 (0.02644) [-1.17705]	0.068290 (0.15240) [0.54517]
D(X2_INSAMPLE(-4))	0.496671 (0.27675) [1.79464]	-0.223792 (0.14659) [-1.52662]	0.213838 (0.10596) [2.01803]	-0.127416 (0.12657) [-1.00666]	-0.011369 (0.10709) [-0.10616]	-0.038261 (0.02726) [-1.40359]	-0.006020 (0.12915) [-0.04661]
D(X3_INSAMPLE(-1))	0.244627 (0.57908) [0.42244]	-0.600809 (0.30674) [-1.95871]	-0.185282 (0.22172) [-0.83566]	-0.839581 (0.26484) [-3.17011]	-0.037600 (0.22407) [-0.16780]	0.034194 (0.05704) [0.59949]	0.590616 (0.27024) [2.18553]
D(X3_INSAMPLE(-2))	1.183767 (0.69124) [1.71253]	0.285733 (0.36614) [0.78038]	-0.466722 (0.26466) [-1.76345]	-0.071781 (0.31614) [-0.22706]	0.443162 (0.26747) [1.65685]	0.011044 (0.06809) [0.16220]	0.533848 (0.32258) [1.65494]
D(X3_INSAMPLE(-3))	0.180645 (0.67647) [0.26704]	0.047776 (0.35832) [0.13333]	-0.029540 (0.25901) [-0.11405]	0.281933 (0.30938) [0.91128]	0.300293 (0.26176) [1.14722]	-0.157063 (0.06663) [-2.35721]	0.232806 (0.31569) [0.73746]
D(X3_INSAMPLE(-4))	0.469974 (0.56634) [0.82984]	0.198033 (0.29999) [0.66014]	-0.276266 (0.21684) [-1.27404]	0.336523 (0.25902) [1.29924]	0.627064 (0.21914) [2.86143]	-0.114605 (0.05578) [-2.05446]	0.349292 (0.26429) [1.32161]
D(X4_INSAMPLE(-1))	0.206153 (0.29168) [0.70677]	0.086609 (0.15450) [0.56057]	-0.100805 (0.11168) [-0.90262]	-0.623648 (0.13340) [-4.67501]	0.215983 (0.11287) [1.91364]	0.059955 (0.02873) [2.08682]	0.232633 (0.13612) [1.70905]
D(X4_INSAMPLE(-2))	0.485028 (0.32658) [1.48518]	0.087983 (0.17299) [0.50862]	0.040075 (0.12504) [0.32049]	-0.457678 (0.14936) [-3.06426]	-0.086505 (0.12637) [-0.68454]	-0.003545 (0.03217) [-0.11020]	0.361925 (0.15240) [2.37479]
D(X4_INSAMPLE(-3))	-0.014710 (0.32231) [-0.04564]	0.167254 (0.17073) [0.97966]	0.031397 (0.12341) [0.25442]	-0.465554 (0.14741) [-3.15826]	0.124763 (0.12472) [1.00037]	0.001970 (0.03175) [0.06206]	0.383112 (0.15041) [2.54708]
D(X4_INSAMPLE(-4))	0.318269 (0.30024) [1.06004]	0.509628 (0.15904) [3.20447]	-0.019997 (0.11496) [-0.17395]	-0.359778 (0.13732) [-2.62008]	0.093206 (0.11618) [0.80227]	0.024355 (0.02957) [0.82355]	0.042649 (0.14011) [0.30439]
D(X5_INSAMPLE(-1))	0.160780 (0.44847) [0.35851]	-0.735343 (0.23755) [-3.09551]	-0.036044 (0.17171) [-0.20991]	-0.303331 (0.20511) [-1.47889]	-0.221351 (0.17353) [-1.27555]	0.033253 (0.04417) [0.75279]	0.355395 (0.20929) [1.69813]
D(X5_INSAMPLE(-2))	0.970811 (0.51629) [1.88037]	0.204323 (0.27347) [0.74714]	-0.550298 (0.19768) [-2.78382]	0.376804 (0.23612) [1.59580]	0.313546 (0.19978) [1.56950]	-0.007303 (0.05085) [-0.14360]	0.054483 (0.24093) [0.22613]
D(X5_INSAMPLE(-3))	0.388520 (0.53364) [0.72806]	-0.182557 (0.28266) [-0.64584]	-0.273523 (0.20432) [-1.33869]	0.687416 (0.24406) [2.81660]	0.331047 (0.20649) [1.60322]	-0.145075 (0.05256) [-2.76006]	-0.274443 (0.24903) [-1.10204]
D(X5_INSAMPLE(-4))	0.152132 (0.47273) [0.32181]	-0.076154 (0.25040) [-0.30412]	-0.376554 (0.18100) [-2.08038]	0.596353 (0.21620) [2.75828]	0.403962 (0.18292) [2.20837]	-0.089340 (0.04656) [-1.91868]	-0.240631 (0.22061) [-1.09075]
D(X6_INSAMPLE(-1))	0.887847 (1.11565) [0.79581]	0.504908 (0.59095) [0.85440]	-0.306042 (0.42716) [-0.71645]	0.245693 (0.51024) [0.48152]	0.787213 (0.43170) [1.82354]	0.848632 (0.10989) [7.72264]	0.559808 (0.52064) [1.07524]
D(X6_INSAMPLE(-2))	-0.696486 (1.49916) [-0.46458]	0.370723 (0.79409) [0.46685]	-0.489824 (0.57400) [-0.85335]	0.694097 (0.68564) [1.01234]	-0.421944 (0.58009) [-0.72737]	0.201496 (0.14766) [1.36455]	0.085154 (0.69961) [0.12172]
D(X6_INSAMPLE(-3))	-1.876108 (1.42860) [-1.31325]	-1.405619 (0.75672) [-1.85752]	0.713885 (0.54699) [1.30513]	-0.623236 (0.65337) [-0.95388]	0.015566 (0.55279) [0.02816]	-0.364129 (0.14071) [-2.58773]	-0.398199 (0.66668) [-0.59729]
D(X6_INSAMPLE(-4))	0.730800 (1.14523) [0.63812]	1.421134 (0.60662) [2.34270]	-0.323876 (0.43849) [-0.73862]	-0.365597 (0.52377) [-0.69801]	0.213628 (0.44314) [0.48207]	0.095624 (0.11280) [0.84771]	0.061390 (0.53444) [0.11487]
D(Y1_INSAMPLE(-1))	-0.077849 (0.22179) [-0.35101]	0.111833 (0.11748) [0.95194]	-0.094026 (0.08492) [-1.10725]	-0.014288 (0.10143) [-0.14086]	0.191728 (0.08582) [2.23408]	-0.000586 (0.02185) [-0.02684]	-0.335544 (0.10350) [-3.24194]
D(Y1_INSAMPLE(-2))	-0.098647 (0.22739) [-0.43382]	0.012016 (0.12045) [0.09976]	-0.172050 (0.08707) [-1.97611]	0.220519 (0.10400) [2.12041]	0.172970 (0.08799) [1.96580]	0.032834 (0.02240) [1.46593]	-0.643757 (0.10612) [-6.06464]
D(Y1_INSAMPLE(-3))	-0.215039 (0.22114) [-0.97240]	-0.048664 (0.11714) [-0.41544]	-0.107662 (0.08467) [-1.27151]	0.023370 (0.10114) [0.23106]	0.121386 (0.08557) [1.41854]	0.049538 (0.02178) [2.27426]	-0.133770 (0.10320) [-1.29622]
D(Y1_INSAMPLE(-4))	-0.161924 (0.21531) [-0.75204]	-0.093080 (0.11405) [-0.81613]	-0.111394 (0.08244) [-1.35122]	-0.032247 (0.09847) [-0.32747]	0.182300 (0.08331) [2.18809]	0.034599 (0.02121) [1.63143]	-0.100789 (0.10048) [-1.00307]

Lampiran 9. Hasil Uji Stabilitas

VAR Stability Condition Check	
Roots of Characteristic Polynomial	
Endogenous variables: D(X1_INSAMPLE)	
D(X2_INSAMPLE) D(X3_INSAMPLE)	
D(X4_INSAMPLE) D(X5_INSAMPLE)	
D(X6_INSAMPLE) D(Y1_INSAMPLE)	
Exogenous variables: C	
Lag specification: 1 4	
Date: 04/30/26 Time: 13:13	
Root	Modulus
0.500193 + 0.821422i	0.961732
0.500193 - 0.821422i	0.961732
0.816495 + 0.480336i	0.947305
0.816495 - 0.480336i	0.947305
0.009235 - 0.873717i	0.873765
0.009235 + 0.873717i	0.873765
0.796355 + 0.274988i	0.842496
0.796355 - 0.274988i	0.842496
0.346896 + 0.726144i	0.804749
0.346896 - 0.726144i	0.804749
-0.631523 - 0.496426i	0.803281
-0.631523 + 0.496426i	0.803281
-0.272176 - 0.699767i	0.750835
-0.272176 + 0.699767i	0.750835
-0.427976 - 0.583010i	0.723232
-0.427976 + 0.583010i	0.723232
-0.649437 + 0.308328i	0.718912
-0.649437 - 0.308328i	0.718912
-0.130987 + 0.705378i	0.717437
-0.130987 - 0.705378i	0.717437
-0.716452	0.716452
-0.687531 + 0.086559i	0.692958
-0.687531 - 0.086559i	0.692958
-0.321271 + 0.526447i	0.616735
-0.321271 - 0.526447i	0.616735
0.183016 - 0.537316i	0.567630
0.183016 + 0.537316i	0.567630
0.099514	0.099514
No root lies outside the unit circle. VAR satisfies the stability condition.	

Lampiran 10. Hasil Uji Kointegrasi

Date: 05/02/26 Time: 22:56				
Sample (adjusted): 2015M07 2023M12				
Included observations: 102 after adjustments				
Trend assumption: Linear deterministic trend				
Series: D(X1_INSAMPLE) D(X2_INSAMPLE) D(X3_INSAMPLE) D(X4_INSAMPLE) D(X5_INSAMPLE) D(X6_INSAMPLE) D(Y1 ...				
Lags interval (in first differences): 1 to 4				
Unrestricted Cointegration Rank Test (Trace)				
Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.660913	404.9484	125.6154	0.0000
At most 1 *	0.559322	294.6354	95.75366	0.0000
At most 2 *	0.492486	211.0524	69.81889	0.0000
At most 3 *	0.384926	141.8728	47.85613	0.0000
At most 4 *	0.359782	92.29957	29.79707	0.0000
At most 5 *	0.267065	46.81294	15.49471	0.0000
At most 6 *	0.137787	15.12176	3.841465	0.0001

Lampiran 11. Uji Kausalitas Granger

Pairwise Granger Causality Tests			
Date: 04/30/26 Time: 13:15			
Sample: 2015M01 2023M12			
Lags: 4			
Null Hypothesis:	Obs	F-Statistic	Prob.
X2_INSAMPLE does not Granger Cause X1_INSAMPLE	104	0.92696	0.4517
X1_INSAMPLE does not Granger Cause X2_INSAMPLE		0.24201	0.9138
X3_INSAMPLE does not Granger Cause X1_INSAMPLE	104	0.27328	0.8945
X1_INSAMPLE does not Granger Cause X3_INSAMPLE		0.64078	0.6347
X4_INSAMPLE does not Granger Cause X1_INSAMPLE	104	0.81221	0.5204
X1_INSAMPLE does not Granger Cause X4_INSAMPLE		0.89517	0.4701
X5_INSAMPLE does not Granger Cause X1_INSAMPLE	104	0.30863	0.8716
X1_INSAMPLE does not Granger Cause X5_INSAMPLE		1.09999	0.3612
X6_INSAMPLE does not Granger Cause X1_INSAMPLE	104	2.83222	0.0287
X1_INSAMPLE does not Granger Cause X6_INSAMPLE		0.80660	0.5240
Y1_INSAMPLE does not Granger Cause X1_INSAMPLE	104	0.39525	0.8116
X1_INSAMPLE does not Granger Cause Y1_INSAMPLE		0.24012	0.9150
X3_INSAMPLE does not Granger Cause X2_INSAMPLE	104	3.04362	0.0208
X2_INSAMPLE does not Granger Cause X3_INSAMPLE		13.9228	6.E-09
X4_INSAMPLE does not Granger Cause X2_INSAMPLE	104	6.28486	0.0002
X2_INSAMPLE does not Granger Cause X4_INSAMPLE		5.75768	0.0003
X5_INSAMPLE does not Granger Cause X2_INSAMPLE	104	3.45311	0.0111
X2_INSAMPLE does not Granger Cause X5_INSAMPLE		13.2982	1.E-08
X6_INSAMPLE does not Granger Cause X2_INSAMPLE	104	2.70346	0.0350
X2_INSAMPLE does not Granger Cause X6_INSAMPLE		1.84855	0.1260
Y1_INSAMPLE does not Granger Cause X2_INSAMPLE	104	1.79516	0.1362
X2_INSAMPLE does not Granger Cause Y1_INSAMPLE		1.71714	0.1526
X4_INSAMPLE does not Granger Cause X3_INSAMPLE	104	4.37565	0.0027
X3_INSAMPLE does not Granger Cause X4_INSAMPLE		1.63802	0.1711
X5_INSAMPLE does not Granger Cause X3_INSAMPLE	104	4.55180	0.0021
X3_INSAMPLE does not Granger Cause X5_INSAMPLE		4.29616	0.0031
X6_INSAMPLE does not Granger Cause X3_INSAMPLE	104	1.71581	0.1529
X3_INSAMPLE does not Granger Cause X6_INSAMPLE		0.14737	0.9637
Y1_INSAMPLE does not Granger Cause X3_INSAMPLE	104	0.91602	0.4580
X3_INSAMPLE does not Granger Cause Y1_INSAMPLE		3.87457	0.0058
X5_INSAMPLE does not Granger Cause X4_INSAMPLE	104	2.49801	0.0477
X4_INSAMPLE does not Granger Cause X5_INSAMPLE		6.81356	7.E-05
X6_INSAMPLE does not Granger Cause X4_INSAMPLE	104	1.78444	0.1383
X4_INSAMPLE does not Granger Cause X6_INSAMPLE		2.26697	0.0676
Y1_INSAMPLE does not Granger Cause X4_INSAMPLE	104	1.70669	0.1549
X4_INSAMPLE does not Granger Cause Y1_INSAMPLE		3.11310	0.0187
X6_INSAMPLE does not Granger Cause X5_INSAMPLE	104	1.64366	0.1697
X5_INSAMPLE does not Granger Cause X6_INSAMPLE		0.37807	0.8238
Y1_INSAMPLE does not Granger Cause X5_INSAMPLE	104	0.76945	0.5477
X5_INSAMPLE does not Granger Cause Y1_INSAMPLE		6.69846	9.E-05
Y1_INSAMPLE does not Granger Cause X6_INSAMPLE	104	2.31029	0.0634
X6_INSAMPLE does not Granger Cause Y1_INSAMPLE		1.08732	0.3673

Lampiran 12. Hasil Estimasi VECM

Vector Error Correction Estimates Date: 05/04/26 Time: 00:31 Sample (adjusted): 2015M05 2023M12 Included observations: 104 after adjustments Standard errors in () & t-statistics in []							
Cointegrating Eq:		CointEq1					
Y1_INSAMPLE(-1)	1.000000						
X1_INSAMPLE(-1)	59.48987 (8.88150) [6.69818]						
X2_INSAMPLE(-1)	-48.75447 (13.5015) [-3.61103]						
X3_INSAMPLE(-1)	-69.85207 (22.3930) [-3.11937]						
X4_INSAMPLE(-1)	64.71394 (13.1478) [4.92202]						
X5_INSAMPLE(-1)	-39.22413 (12.4305) [-1.83029]						
X6_INSAMPLE(-1)	-20.51195 (5.86226) [-3.49898]						
C	-4.947053						
Error Correction:	DIY1_INSA...	DI(X1_INSA...	DI(X2_INSA...	DI(X3_INSA...	DI(X4_INSA...	DI(X5_INSA...	DI(X6_INSA...
CointEq1	0.000216 (0.00165) [0.13090]	-0.005007 (0.00307) [-1.62863]	0.005340 (0.00168) [3.17458]	0.001819 (0.00124) [1.46702]	-0.005382 (0.00146) [-3.68751]	-0.004086 (0.00126) [-3.25098]	0.001095 (0.00030) [3.70500]
DI(Y1_INSAMPLE(-1))	-0.264570 (0.10891) [-2.42917]	-0.052772 (0.20327) [-0.25961]	0.168977 (0.11121) [1.51947]	-0.060795 (0.08199) [-0.74152]	-0.082141 (0.09649) [-0.85127]	0.181759 (0.08309) [2.18758]	-0.004263 (0.01954) [-0.21817]
DI(Y1_INSAMPLE(-2))	-0.597900 (0.09361) [-6.38662]	0.066902 (0.17472) [0.38291]	0.104657 (0.09559) [1.09468]	-0.105733 (0.07047) [-1.50040]	0.198814 (0.06294) [2.36713]	0.090874 (0.07142) [1.27247]	0.008361 (0.01690) [0.49778]
DI(Y1_INSAMPLE(-3))	-0.053097 (0.10994) [-0.48297]	-0.151378 (0.20519) [-0.73776]	0.055168 (0.11226) [0.49145]	-0.100503 (0.08276) [-1.21441]	-0.002120 (0.09740) [-0.02177]	0.121051 (0.08387) [1.44332]	0.039495 (0.01973) [2.00225]
DI(X1_INSAMPLE(-1))	-0.053523 (0.09820) [-0.54503]	-0.601235 (0.18328) [-3.28039]	-0.290426 (0.10027) [-2.89640]	-0.032372 (0.07362) [-0.43791]	0.221341 (0.06700) [2.54407]	0.163074 (0.07492) [2.17677]	-0.063017 (0.01762) [-3.57649]
DI(X1_INSAMPLE(-2))	-0.032622 (0.08578) [-0.38031]	-0.452043 (0.16009) [-2.82364]	-0.208093 (0.08758) [-2.35306]	-0.019681 (0.06457) [-0.30944]	0.104251 (0.07600) [1.37181]	0.118771 (0.06544) [1.78447]	-0.046267 (0.01539) [-3.00751]
DI(X1_INSAMPLE(-3))	-0.009153 (0.06432) [-0.14230]	-0.113086 (0.12005) [-0.94209]	-0.093880 (0.06568) [-1.42942]	-0.017481 (0.04842) [-0.36102]	0.082820 (0.05699) [1.45508]	0.023013 (0.04807) [0.46898]	-0.027889 (0.01154) [-2.41660]
DI(X2_INSAMPLE(-1))	0.267176 (0.12449) [2.14612]	-0.011060 (0.23235) [-0.04760]	0.037983 (0.12711) [0.29881]	0.342751 (0.09371) [3.65744]	-0.678693 (0.11029) [-6.15347]	-0.387114 (0.09497) [-4.07612]	-0.001959 (0.02234) [-0.08769]
DI(X2_INSAMPLE(-2))	0.133884 (0.14460) [0.92592]	-0.126568 (0.26987) [-0.46900]	-0.073141 (0.14764) [-0.49539]	0.311970 (0.10885) [2.86614]	-0.525224 (0.12811) [-4.09995]	-0.196632 (0.11031) [-1.78258]	0.057374 (0.02594) [2.21150]
DI(X2_INSAMPLE(-3))	0.040866 (0.13691) [0.29849]	-0.318299 (0.25553) [-1.24567]	-0.514837 (0.13980) [-3.68820]	0.365281 (0.10306) [3.54429]	-0.110062 (0.12130) [-0.90738]	-0.442578 (0.10445) [-4.23742]	0.006587 (0.02456) [0.26815]
DI(X3_INSAMPLE(-1))	1.086282 (0.35332) [3.07449]	-0.524052 (0.65942) [-0.79471]	0.112316 (0.36076) [0.31133]	-0.096880 (0.26597) [-0.36425]	-1.247744 (0.31303) [-3.98608]	-0.252685 (0.26954) [-0.93748]	0.143892 (0.06339) [2.26983]
DI(X3_INSAMPLE(-2))	1.070846 (0.40212) [2.66300]	-0.006411 (0.75050) [-0.00854]	0.663270 (0.41059) [1.61540]	-0.188637 (0.30270) [-0.62318]	-0.621468 (0.35626) [-1.74442]	0.007453 (0.30676) [0.02430]	0.157711 (0.07215) [2.18590]
DI(X3_INSAMPLE(-3))	0.532286 (0.33259) [1.60045]	-0.783040 (0.62072) [-1.26149]	0.479799 (0.33959) [1.41287]	0.164037 (0.25036) [0.65521]	-0.377198 (0.29466) [-1.28013]	-0.060899 (0.25372) [-0.24002]	0.028411 (0.05967) [0.47612]
DI(X4_INSAMPLE(-1))	0.309774 (0.14503) [2.13587]	0.254708 (0.27068) [0.94097]	-0.272089 (0.14809) [-1.83734]	-0.157031 (0.10918) [-1.43833]	-0.277272 (0.12849) [-2.15788]	0.375585 (0.11064) [3.39461]	-0.001242 (0.02602) [-0.04774]
DI(X4_INSAMPLE(-2))	0.503870 (0.15406) [3.27055]	0.372042 (0.28754) [1.29389]	-0.193777 (0.15731) [-1.23183]	0.001876 (0.11597) [0.16188]	-0.188537 (0.13649) [-1.36130]	0.023287 (0.11753) [0.19813]	-0.038517 (0.02764) [-1.39343]
DI(X4_INSAMPLE(-3))	0.441652 (0.14578) [3.02962]	-0.202970 (0.27207) [-0.74601]	-0.003271 (0.14885) [-0.02198]	-0.042737 (0.10974) [-0.38945]	-0.267935 (0.12915) [-2.07457]	0.172324 (0.11121) [1.54954]	-0.002532 (0.02616) [-0.09682]
DI(X5_INSAMPLE(-1))	0.533865 (0.29407) [1.81546]	-0.475234 (0.54883) [-0.86590]	-0.036428 (0.30028) [-0.12132]	-0.050044 (0.22136) [-0.22607]	-0.679824 (0.26053) [-2.60941]	-0.370787 (0.22433) [-1.65294]	0.142852 (0.05276) [2.70750]
DI(X5_INSAMPLE(-2))	0.458508 (0.32392) [1.41551]	0.018832 (0.60455) [0.03115]	0.623864 (0.33074) [1.88626]	-0.372406 (0.24363) [-1.52730]	-0.119421 (0.28689) [-0.41614]	0.004641 (0.24711) [0.01878]	0.113876 (0.05812) [1.95941]
DI(X5_INSAMPLE(-3))	0.012219 (0.27074) [0.04513]	-0.290218 (0.50530) [-0.57435]	0.514272 (0.27644) [1.86031]	-0.244283 (0.20380) [-1.19862]	0.062828 (0.23986) [0.26193]	0.192326 (0.20654) [0.93118]	0.021518 (0.04858) [0.44296]
DI(X6_INSAMPLE(-1))	0.416454 (0.55099) [0.75583]	0.847930 (1.02835) [0.82456]	0.019237 (0.56260) [0.03419]	-0.662492 (0.41477) [-1.59727]	0.776034 (0.48815) [1.58974]	1.303084 (0.42033) [3.10012]	0.814532 (0.08986) [8.23930]
DI(X6_INSAMPLE(-2))	0.120662 (0.73935) [0.16320]	-0.159058 (1.37989) [-0.11527]	-0.121723 (0.75493) [-0.16124]	-0.190606 (0.55656) [-0.34247]	0.801564 (0.65503) [1.22371]	-0.533793 (0.56403) [-0.94640]	0.105277 (0.13266) [0.79361]
DI(X6_INSAMPLE(-3))	-0.507389 (0.53497) [-0.94845]	-1.104188 (0.98844) [-1.10591]	0.163661 (0.54624) [0.29962]	0.457624 (0.40270) [1.13638]	-1.139312 (0.47395) [-2.40384]	0.016911 (0.40811) [0.04144]	-0.252949 (0.09598) [-2.63532]

Vector Error Correction Estimates							
Date: 05/04/26 Time: 00:27							
Sample (adjusted): 2015M05 2023M12							
Included observations: 104 after adjustments							
Standard errors in () & t-statistics in []							
Cointegrating Eq:	CointEq1						
X1 INSAMPLE(-1)	1.000000						
X2 INSAMPLE(-1)	-0.819543 (0.21499) [-3.81201]						
X3 INSAMPLE(-1)	-1.174184 (0.36223) [-3.24152]						
X4 INSAMPLE(-1)	1.087814 (0.22541) [4.82598]						
X5 INSAMPLE(-1)	-0.655941 (0.34704) [-1.89990]						
X6 INSAMPLE(-1)	-0.344797 (0.10644) [-3.23935]						
Y1 INSAMPLE(-1)	0.016810 (0.11231) [0.14968]						
C	-0.083158						
Error Correction:	D(X1 INSA...	D(X2 INSA...	D(X3 INSA...	D(X4 INSA...	D(X5 INSA...	D(X6 INSA...	D(Y1 INSA...
CointEq1	-0.297884 (0.18290) [-1.62863]	0.317665 (0.10007) [3.17458]	0.108225 (0.07377) [1.46702]	-0.320165 (0.08682) [-3.68751]	-0.243050 (0.07476) [-3.25098]	0.065147 (0.01758) [3.70500]	0.012828 (0.09800) [0.13090]
D(X1 INSAMPLE(-1))	-0.601235 (0.18328) [-3.28039]	-0.290426 (0.10027) [-2.89640]	-0.032372 (0.07392) [-0.43791]	0.221341 (0.08700) [2.54407]	0.163074 (0.07492) [2.17677]	-0.063017 (0.01762) [-3.57649]	-0.053523 (0.09820) [-0.54503]
D(X1 INSAMPLE(-2))	-0.452043 (0.16009) [-2.82364]	-0.206093 (0.08758) [-2.35306]	-0.019981 (0.06457) [-0.30944]	0.104251 (0.07600) [1.37181]	0.116771 (0.06544) [1.78447]	-0.046287 (0.01539) [-3.00751]	-0.032622 (0.08578) [-0.38031]
D(X1 INSAMPLE(-3))	-0.113096 (0.12005) [-0.94209]	-0.093980 (0.06568) [-1.42942]	-0.017481 (0.04842) [-0.36102]	0.082920 (0.05699) [1.45508]	0.023013 (0.04907) [0.46898]	-0.027889 (0.01154) [-2.41660]	-0.009153 (0.06432) [-0.14230]
D(X2 INSAMPLE(-1))	-0.011060 (0.23235) [-0.04760]	0.037983 (0.12711) [0.29881]	0.342751 (0.09371) [3.65744]	-0.678693 (0.11029) [-6.15347]	-0.387114 (0.09497) [-4.07612]	-0.001959 (0.02234) [-0.08769]	0.267176 (0.12449) [2.14612]
D(X2 INSAMPLE(-2))	-0.126568 (0.26987) [-0.46900]	-0.073141 (0.14764) [-0.49800]	0.311970 (0.10885) [2.86814]	-0.525224 (0.12811) [-4.09995]	-0.196632 (0.11031) [-1.78258]	0.057374 (0.02594) [2.21150]	0.133884 (0.14460) [0.92592]
D(X2 INSAMPLE(-3))	-0.318299 (0.25553) [-1.24567]	-0.514837 (0.13980) [-3.68280]	0.365281 (0.10306) [3.54429]	-0.110062 (0.12130) [-0.90738]	-0.442578 (0.10445) [-4.23742]	0.006587 (0.02456) [0.26815]	0.040866 (0.13691) [0.29849]
D(X3 INSAMPLE(-1))	-0.524052 (0.65942) [-0.79471]	0.112316 (0.36076) [0.31133]	-0.096880 (0.26597) [-0.36425]	-1.247744 (0.31303) [-3.98608]	-0.252685 (0.26954) [-0.93748]	0.143892 (0.06339) [2.26983]	1.086282 (0.35332) [3.07449]
D(X3 INSAMPLE(-2))	-0.006411 (0.75050) [-0.00854]	0.663270 (0.41059) [1.61540]	-0.188637 (0.30270) [-0.62318]	-0.621468 (0.35626) [-1.74442]	0.007453 (0.30676) [0.02430]	0.157711 (0.07215) [2.18590]	1.070846 (0.40212) [2.66300]
D(X3 INSAMPLE(-3))	-0.783040 (0.62072) [-1.26149]	0.479799 (0.33959) [1.41287]	0.164037 (0.25036) [0.65521]	-0.377198 (0.29466) [-1.28013]	-0.080899 (0.25372) [-0.24002]	0.028411 (0.05967) [0.47612]	0.532286 (0.33259) [1.60045]
D(X4 INSAMPLE(-1))	0.254708 (0.27068) [0.94097]	-0.272089 (0.14809) [-1.83734]	-0.157031 (0.10918) [-1.43833]	-0.277272 (0.12849) [-2.15788]	0.375585 (0.11064) [3.39461]	-0.001242 (0.02602) [-0.04774]	0.309774 (0.14503) [2.13587]
D(X4 INSAMPLE(-2))	0.372042 (0.28754) [1.29389]	-0.193777 (0.15731) [-1.23183]	0.001876 (0.11597) [0.01618]	-0.188537 (0.13649) [-1.38130]	0.023287 (0.11753) [0.19813]	-0.038517 (0.02764) [-1.39343]	0.503870 (0.15406) [3.27055]
D(X4 INSAMPLE(-3))	-0.202970 (0.27207) [-0.74601]	-0.003271 (0.14885) [-0.02198]	-0.042737 (0.10974) [-0.38945]	-0.267935 (0.12915) [-2.07457]	0.172324 (0.11121) [1.54954]	-0.002532 (0.02616) [-0.09682]	0.441652 (0.14578) [3.02962]
D(X5 INSAMPLE(-1))	-0.475234 (0.54883) [-0.86590]	-0.036428 (0.30026) [-0.12132]	-0.050044 (0.22136) [-0.22607]	-0.679824 (0.26053) [-2.60941]	-0.370787 (0.22433) [-1.65284]	0.142852 (0.05276) [2.70750]	0.533865 (0.29407) [1.81546]
D(X5 INSAMPLE(-2))	0.018832 (0.60455) [0.03115]	0.623864 (0.33074) [1.88626]	-0.372406 (0.24383) [-1.52730]	-0.119421 (0.28698) [-0.41614]	0.004641 (0.24711) [0.01878]	0.113876 (0.05812) [1.95941]	0.458508 (0.32392) [1.41551]
D(X5 INSAMPLE(-3))	-0.290218 (0.50530) [-0.57435]	0.514272 (0.27644) [1.86031]	-0.244283 (0.20380) [-1.19862]	0.062828 (0.23986) [0.26193]	0.192326 (0.20654) [0.93118]	0.021518 (0.04858) [0.44296]	0.012219 (0.27074) [0.04513]
D(X6 INSAMPLE(-1))	0.847930 (1.02835) [0.82456]	0.019237 (0.56260) [0.03419]	-0.662492 (0.41477) [-1.59727]	0.776034 (0.48815) [1.58974]	1.303084 (0.42033) [3.10012]	0.814532 (0.09886) [8.23930]	0.416454 (0.55099) [0.75583]
D(X6 INSAMPLE(-2))	-0.159058 (1.37989) [-0.11527]	-0.121723 (0.75493) [-0.16124]	-0.190806 (0.55656) [-0.34247]	0.801564 (0.65503) [1.22371]	-0.533793 (0.56403) [-0.94640]	0.105277 (0.13266) [0.79361]	0.120662 (0.73935) [0.16320]
D(X6 INSAMPLE(-3))	-1.104188 (0.98844) [-1.10591]	0.163661 (0.54624) [0.29962]	0.457824 (0.40270) [1.13638]	-1.138312 (0.47385) [-2.40384]	0.016911 (0.40811) [0.04144]	-0.252949 (0.05698) [-2.63532]	-0.507389 (0.53497) [-0.94845]
D(Y1 INSAMPLE(-1))	-0.052772 (0.20327) [-0.25961]	0.168977 (0.11121) [1.51947]	-0.060795 (0.09199) [-0.74152]	-0.082141 (0.09649) [-0.85127]	0.181759 (0.06309) [2.81878]	-0.004263 (0.01954) [-0.21817]	-0.264570 (0.10891) [-2.42917]
D(Y1 INSAMPLE(-2))	0.066902 (0.17472) [0.38291]	0.104657 (0.09559) [1.09489]	-0.105733 (0.07047) [-1.50040]	0.198814 (0.08294) [2.39713]	0.090874 (0.07142) [1.27247]	0.008361 (0.01680) [0.49778]	-0.597900 (0.08361) [-6.38682]
D(Y1 INSAMPLE(-3))	-0.151378 (0.20519) [-0.73776]	0.055168 (0.11226) [0.49145]	-0.100503 (0.08276) [-1.21441]	-0.002120 (0.09740) [-0.02177]	0.121051 (0.08387) [1.44332]	0.039495 (0.01973) [2.00225]	-0.053097 (0.10994) [-0.48297]

Vector Error Correction Estimates Date: 05/04/26 Time: 00:28 Sample (adjusted): 2015M05 2023M12 Included observations: 104 after adjustments Standard errors in () & t-statistics in []							
Cointegrating Eq:	CointEq1						
X2_INSAMPLE(-1)	1.000000						
X1_INSAMPLE(-1)	-1.220193 (0.18379) [-6.63918]						
X3_INSAMPLE(-1)	1.432731 (0.45944) [3.11846]						
X4_INSAMPLE(-1)	-1.327344 (0.28069) [-4.72548]						
X5_INSAMPLE(-1)	0.804524 (0.44720) [1.79903]						
X6_INSAMPLE(-1)	0.420719 (0.12114) [3.47311]						
Y1_INSAMPLE(-1)	-0.020511 (0.14595) [-0.14054]						
C	0.101469						
Error Correction:	D(X2_INSA...	D(X1_INSA...	D(X3_INSA...	D(X4_INSA...	D(X5_INSA...	D(X6_INSA...	D(Y1_INSA...
CointEq1	-0.260340 (0.08201) [-3.17458]	0.244129 (0.14990) [1.62863]	-0.088695 (0.06046) [-1.46702]	0.262389 (0.07116) [3.68751]	0.199189 (0.06127) [3.25098]	-0.053390 (0.01441) [-3.70500]	-0.010513 (0.08032) [-0.13090]
D(X2_INSAMPLE(-1))	0.037983 (0.12711) [0.29881]	-0.011060 (0.23235) [-0.04760]	0.342751 (0.09371) [3.65744]	-0.678693 (0.11029) [-6.15347]	-0.387114 (0.09497) [-4.07612]	-0.001959 (0.02234) [-0.08769]	0.267176 (0.12449) [2.14612]
D(X2_INSAMPLE(-2))	-0.073141 (0.14764) [-0.49539]	-0.126568 (0.26987) [-0.46900]	0.311970 (0.10885) [2.86614]	-0.525224 (0.12811) [-4.09995]	-0.196632 (0.11031) [-1.78258]	0.057374 (0.02594) [2.21150]	0.133884 (0.14460) [0.92592]
D(X2_INSAMPLE(-3))	-0.514837 (0.13980) [-3.68280]	-0.318289 (0.25553) [-1.24567]	0.365281 (0.10306) [3.54429]	-0.110062 (0.12130) [-0.90738]	-0.442578 (0.10445) [-4.23742]	0.006587 (0.02456) [0.26815]	0.040866 (0.13691) [0.29949]
D(X1_INSAMPLE(-1))	-0.290426 (0.10027) [-2.89640]	-0.601235 (0.18328) [-3.28039]	-0.032372 (0.07392) [-0.43791]	0.221341 (0.06700) [2.54407]	0.163074 (0.07492) [2.17677]	-0.063017 (0.01762) [-3.57649]	-0.053523 (0.09820) [-0.54503]
D(X1_INSAMPLE(-2))	-0.206093 (0.08758) [-2.35306]	-0.452043 (0.16009) [-2.82964]	-0.019981 (0.06457) [-0.30944]	0.104251 (0.07600) [1.37181]	0.116771 (0.06544) [1.78447]	-0.046287 (0.01539) [-3.00751]	-0.032622 (0.08578) [-0.38031]
D(X1_INSAMPLE(-3))	-0.093880 (0.06568) [-1.42942]	-0.113096 (0.12005) [-0.94209]	-0.017481 (0.04842) [-0.36102]	0.082920 (0.05699) [1.45508]	0.023013 (0.04907) [0.46898]	-0.027889 (0.01154) [-2.41660]	-0.009153 (0.06432) [-0.14230]
D(X3_INSAMPLE(-1))	0.112316 (0.36076) [0.31133]	-0.524052 (0.65942) [-0.79471]	-0.096880 (0.26597) [-0.36425]	-1.247744 (0.31303) [-3.98608]	-0.252685 (0.26954) [-0.93748]	0.143892 (0.06339) [2.26983]	1.086282 (0.35332) [3.07449]
D(X3_INSAMPLE(-2))	0.663270 (0.41059) [1.61540]	-0.006411 (0.75050) [-0.00854]	-0.188637 (0.30270) [-0.62318]	-0.621468 (0.35626) [-1.74442]	0.007453 (0.30676) [0.02430]	0.157711 (0.07215) [2.18590]	1.070846 (0.40212) [2.66300]
D(X3_INSAMPLE(-3))	0.479799 (0.33959) [1.41287]	-0.783040 (0.62072) [-1.26149]	0.164037 (0.25036) [0.65521]	-0.377198 (0.29466) [-1.28013]	-0.060899 (0.25372) [-0.24002]	0.028411 (0.05967) [0.47612]	0.532286 (0.33259) [1.60045]
D(X4_INSAMPLE(-1))	-0.272089 (0.14809) [-1.83734]	0.254708 (0.27068) [0.94097]	-0.157031 (0.10918) [-1.43833]	-0.277272 (0.12849) [-2.15788]	0.375585 (0.11064) [3.39461]	-0.001242 (0.02602) [-0.04774]	0.309774 (0.14503) [2.13587]
D(X4_INSAMPLE(-2))	-0.193777 (0.15731) [-1.23183]	0.372042 (0.28754) [1.29389]	0.001876 (0.11597) [0.01618]	-0.188537 (0.13649) [-1.38130]	0.023287 (0.11753) [0.19813]	-0.038517 (0.02764) [-1.39343]	0.503870 (0.15406) [3.27055]
D(X4_INSAMPLE(-3))	-0.003271 (0.14885) [-0.02198]	-0.202970 (0.27207) [-0.74601]	-0.042737 (0.10974) [-0.38945]	-0.267935 (0.12915) [-2.07457]	0.172324 (0.11121) [1.54954]	-0.002532 (0.02616) [-0.09682]	0.441652 (0.14578) [3.02962]
D(X5_INSAMPLE(-1))	-0.036428 (0.30026) [-0.12132]	-0.475234 (0.54883) [-0.86590]	-0.050044 (0.22136) [-0.22607]	-0.679824 (0.26053) [-2.60941]	-0.370787 (0.22433) [-1.65284]	0.142852 (0.05276) [2.70750]	0.533865 (0.29407) [1.81546]
D(X5_INSAMPLE(-2))	0.623864 (0.33074) [1.88626]	0.018832 (0.60455) [0.03115]	-0.372406 (0.24383) [-1.52730]	-0.119421 (0.28698) [-0.41614]	0.004641 (0.24711) [0.01878]	0.113876 (0.05812) [1.95941]	0.458508 (0.32392) [1.41551]
D(X5_INSAMPLE(-3))	0.514272 (0.27644) [1.86031]	-0.290218 (0.50530) [-0.57435]	-0.244283 (0.20380) [-1.19862]	0.062828 (0.23986) [0.26193]	0.192326 (0.20654) [0.93118]	0.021518 (0.04858) [0.44296]	0.012219 (0.27074) [0.04513]
D(X6_INSAMPLE(-1))	0.019237 (0.56260) [0.03419]	0.847930 (1.02835) [0.82456]	-0.662492 (0.41477) [-1.59727]	0.776034 (0.48815) [1.58974]	1.303084 (0.42033) [3.10012]	0.814532 (0.09886) [8.23930]	0.416454 (0.55099) [0.75583]
D(X6_INSAMPLE(-2))	-0.121723 (0.75493) [-0.16124]	-0.159058 (1.37989) [-0.11527]	-0.190606 (0.55656) [-0.34247]	0.801564 (0.65503) [1.22371]	-0.533793 (0.56403) [-0.94640]	0.105277 (0.13266) [0.79361]	0.120662 (0.73935) [0.16320]
D(X6_INSAMPLE(-3))	0.163861 (0.54624) [0.29962]	-1.104188 (0.98444) [-1.10591]	0.457824 (0.40270) [1.13638]	-1.138312 (0.47385) [-2.40384]	0.016911 (0.40811) [0.04144]	-0.252949 (0.05698) [-2.63532]	-0.507389 (0.53497) [-0.94845]
D(Y1_INSAMPLE(-1))	0.168977 (0.11121) [1.51947]	-0.052772 (0.20327) [-0.25961]	-0.060795 (0.06199) [-0.74152]	-0.082141 (0.09649) [-0.85127]	0.181759 (0.06309) [2.18758]	-0.004263 (0.01954) [-0.21817]	-0.264570 (0.10891) [-2.42917]
D(Y1_INSAMPLE(-2))	0.104657 (0.09559) [1.09489]	0.066902 (0.17472) [0.38291]	-0.105733 (0.07047) [-1.50040]	0.198814 (0.08294) [2.39713]	0.090874 (0.07142) [1.27247]	0.008361 (0.01680) [0.49778]	-0.597900 (0.08361) [-6.38682]
D(Y1_INSAMPLE(-3))	0.055168 (0.11226) [0.49145]	-0.151378 (0.20519) [-0.73776]	-0.100503 (0.08276) [-1.21441]	-0.002120 (0.09740) [-0.02177]	0.121051 (0.08387) [1.44332]	0.039495 (0.01973) [2.00225]	-0.053097 (0.10994) [-0.48297]

Vector Error Correction Estimates							
Date: 05/04/26 Time: 00:29							
Sample (adjusted): 2015M05 2023M12							
Included observations: 104 after adjustments							
Standard errors in () & t-statistics in []							
Cointegrating Eq:	CointEq1						
X3 INSAMPLE(-1)	1.000000						
X1 INSAMPLE(-1)	-0.851655 (0.13049) [-6.52653]						
X2 INSAMPLE(-1)	0.697968 (0.19361) [3.60507]						
X4 INSAMPLE(-1)	-0.926443 (0.19793) [-4.68073]						
X5 INSAMPLE(-1)	0.561531 (0.17431) [3.22143]						
X6 INSAMPLE(-1)	0.293648 (0.09190) [3.19522]						
Y1 INSAMPLE(-1)	-0.014316 (0.10201) [-0.14035]						
C	0.070822						
Error Correction:	D(X3 INSA...	D(X1 INSA...	D(X2 INSA...	D(X4 INSA...	D(X5 INSA...	D(X6 INSA...	D(Y1 INSA...
CointEq1	-0.127076 (0.08662) [-1.46702]	0.349771 (0.21476) [1.62863]	-0.372997 (0.11750) [-3.17458]	0.375933 (0.10195) [3.68751]	0.285385 (0.08778) [3.25098]	-0.076494 (0.02065) [-3.70500]	-0.015063 (0.11507) [-0.13090]
D(X3_INSAMPLE(-1))	-0.096880 (0.26597) [-0.36425]	-0.524052 (0.65942) [-0.79471]	0.112316 (0.36076) [0.31133]	-1.247744 (0.31303) [-3.98608]	-0.252685 (0.26954) [-0.93748]	0.143892 (0.06339) [2.26983]	1.086282 (0.35332) [3.07449]
D(X3 INSAMPLE(-2))	-0.188637 (0.30270) [-0.62318]	-0.006411 (0.75050) [-0.00854]	0.663270 (0.41059) [1.61540]	-0.621468 (0.35626) [-1.74442]	0.007453 (0.30676) [0.02430]	0.157711 (0.07215) [2.18590]	1.070846 (0.40212) [2.66300]
D(X3 INSAMPLE(-3))	0.164037 (0.25036) [0.65521]	-0.783040 (0.62072) [-1.26149]	0.479799 (0.33959) [1.41287]	-0.377198 (0.29466) [-1.28013]	-0.060899 (0.25372) [-0.24002]	0.028411 (0.05967) [0.47612]	0.532286 (0.33259) [1.60045]
D(X1 INSAMPLE(-1))	-0.032372 (0.07392) [-0.43791]	-0.601235 (0.18328) [-3.28039]	-0.290426 (0.10027) [-2.89640]	0.221341 (0.08700) [2.54407]	0.163074 (0.07492) [2.17677]	-0.063017 (0.01762) [-3.57649]	-0.053523 (0.09820) [-0.54503]
D(X1 INSAMPLE(-2))	-0.019981 (0.06457) [-0.30944]	-0.452043 (0.16009) [-2.82964]	-0.206093 (0.08758) [-2.35306]	0.104251 (0.07600) [1.37181]	0.116771 (0.06544) [1.78447]	-0.046287 (0.01539) [-3.00751]	-0.032622 (0.08578) [-0.38031]
D(X1 INSAMPLE(-3))	-0.017481 (0.04842) [-0.36102]	-0.113096 (0.12005) [-0.94209]	-0.093880 (0.06568) [-1.42942]	0.082920 (0.05699) [1.45508]	0.023013 (0.04907) [0.46898]	-0.027889 (0.01154) [-2.41660]	-0.009153 (0.06432) [-0.14230]
D(X2 INSAMPLE(-1))	0.342751 (0.09371) [3.65744]	-0.011060 (0.23235) [-0.04760]	0.037983 (0.12711) [0.29881]	-0.678693 (0.11029) [-6.15347]	-0.387114 (0.09497) [-4.07612]	-0.001959 (0.02234) [-0.08769]	0.267176 (0.12449) [2.14612]
D(X2 INSAMPLE(-2))	0.311970 (0.10885) [2.86614]	-0.126568 (0.26987) [-0.46900]	-0.073141 (0.14764) [-0.49539]	-0.525224 (0.12811) [-4.09955]	-0.196632 (0.11031) [-1.78258]	0.057374 (0.02594) [2.21150]	0.133884 (0.14460) [0.92592]
D(X2 INSAMPLE(-3))	0.365281 (0.10306) [3.54429]	-0.318299 (0.25553) [-1.24567]	-0.514837 (0.13980) [-3.68280]	-0.110062 (0.12130) [-0.90738]	-0.442578 (0.10445) [-4.23742]	0.006587 (0.02456) [0.26815]	0.040866 (0.13691) [0.29849]
D(X4 INSAMPLE(-1))	-0.157031 (0.10918) [-1.43833]	0.254708 (0.27068) [0.94097]	-0.272089 (0.14809) [-1.83734]	-0.277272 (0.12849) [-2.15788]	0.375585 (0.11064) [3.39461]	-0.001242 (0.02602) [-0.04774]	0.309774 (0.14503) [2.13587]
D(X4 INSAMPLE(-2))	0.001876 (0.11597) [0.01618]	0.372042 (0.28754) [1.29389]	-0.193777 (0.15731) [-1.23183]	-0.188537 (0.13849) [-1.38130]	0.023287 (0.11753) [0.19813]	-0.038517 (0.02764) [-1.39343]	0.503870 (0.15406) [3.27055]
D(X4 INSAMPLE(-3))	-0.042737 (0.10974) [-0.38945]	-0.202970 (0.27207) [-0.74601]	-0.003271 (0.14885) [-0.02198]	-0.267935 (0.12915) [-2.07457]	0.172324 (0.11121) [1.54954]	-0.002532 (0.02616) [-0.09682]	0.441652 (0.14578) [3.02962]
D(X5 INSAMPLE(-1))	-0.050044 (0.22136) [-0.22607]	-0.475234 (0.54883) [-0.86590]	-0.036428 (0.30026) [-0.12132]	-0.679824 (0.26053) [-2.60941]	-0.370787 (0.22433) [-1.65284]	0.142852 (0.05276) [2.70750]	0.533865 (0.29407) [1.81546]
D(X5 INSAMPLE(-2))	-0.372406 (0.24383) [-1.52730]	0.018832 (0.60455) [0.03115]	0.623864 (0.33074) [1.88626]	-0.119421 (0.28698) [-0.41614]	0.004641 (0.24711) [0.01878]	0.113876 (0.05812) [1.95941]	0.458508 (0.32392) [1.41551]
D(X5 INSAMPLE(-3))	-0.244283 (0.20380) [-1.19862]	-0.290218 (0.50530) [-0.57435]	0.514272 (0.27644) [1.86031]	0.062828 (0.23986) [0.26193]	0.192326 (0.20654) [0.93118]	0.021518 (0.04858) [0.44296]	0.012219 (0.27074) [0.04513]
D(X6 INSAMPLE(-1))	-0.662492 (0.41477) [-1.59727]	0.847930 (1.02835) [0.82456]	0.019237 (0.56260) [0.03419]	0.776034 (0.48815) [1.58974]	1.303084 (0.42033) [3.10012]	0.814532 (0.09886) [8.23930]	0.416454 (0.55099) [0.75583]
D(X6 INSAMPLE(-2))	-0.190606 (0.55656) [-0.34247]	-0.159058 (1.37989) [-0.11527]	-0.121723 (0.75493) [-0.16124]	0.801564 (0.65503) [1.22371]	-0.533793 (0.56403) [-0.94640]	0.105277 (0.13266) [0.79361]	0.120662 (0.73935) [0.16320]
D(X6 INSAMPLE(-3))	0.457824 (0.40270) [1.13638]	-1.104188 (0.98444) [-1.10591]	0.163961 (0.54634) [0.29962]	-1.138312 (0.47385) [-2.40384]	0.016911 (0.40811) [0.04144]	-0.252949 (0.05698) [-2.63532]	-0.507389 (0.53497) [-0.94845]
D(Y1 INSAMPLE(-1))	-0.060795 (0.08199) [-0.74152]	-0.052772 (0.20327) [-0.25961]	0.168977 (0.11121) [1.51947]	-0.082141 (0.09649) [-0.85127]	0.181759 (0.08309) [2.18758]	-0.004263 (0.01954) [-0.21817]	-0.264570 (0.10891) [-2.42917]
D(Y1 INSAMPLE(-2))	-0.105733 (0.07047) [-1.50040]	0.066902 (0.17472) [0.38291]	0.104657 (0.09559) [1.09489]	0.198814 (0.08294) [2.39713]	0.090874 (0.07142) [1.27247]	0.008361 (0.01680) [0.49778]	-0.597900 (0.08381) [-6.38682]
D(Y1 INSAMPLE(-3))	-0.100503 (0.08276) [-1.21441]	-0.151378 (0.20519) [-0.73776]	0.055168 (0.11226) [0.49145]	-0.002120 (0.09740) [-0.02177]	0.121051 (0.08387) [1.44332]	0.039495 (0.01973) [2.00225]	-0.053097 (0.10994) [-0.48297]

Vector Error Correction Estimates							
Date: 05/04/26 Time: 00:29							
Sample (adjusted): 2015M05 2023M12							
Included observations: 104 after adjustments							
Standard errors in () & t-statistics in []							
Cointegrating Eq:	CointEq1						
X4_INSAMPLE(-1)	1.000000						
X1_INSAMPLE(-1)	0.919274 (0.14099) [6.52003]						
X2_INSAMPLE(-1)	-0.753384 (0.20553) [-3.66565]						
X3_INSAMPLE(-1)	-1.079398 (0.34367) [-3.14082]						
X5_INSAMPLE(-1)	-0.606116 (0.32594) [-1.85959]						
X6_INSAMPLE(-1)	-0.316963 (0.09723) [-3.25977]						
Y1_INSAMPLE(-1)	0.015453 (0.10399) [0.14860]						
C	-0.076445						
Error Correction:	D(X4_INSA...	D(X1_INSA...	D(X2_INSA...	D(X3_INSA...	D(X5_INSA...	D(X6_INSA...	D(Y1_INSA...
CointEq1	-0.348281 (0.09445) [-3.68751]	-0.324043 (0.19897) [-1.62863]	0.345561 (0.10885) [3.17458]	0.117728 (0.08025) [1.46702]	-0.264393 (0.08133) [-3.25098]	0.070867 (0.01913) [3.70500]	0.013955 (0.10661) [0.13090]
D(X4_INSAMPLE(-1))	-0.277272 (0.12849) [-2.15788]	0.254708 (0.27068) [0.94097]	-0.272089 (0.14809) [-1.83734]	-0.157031 (0.10918) [-1.43833]	0.375585 (0.11064) [3.39461]	-0.001242 (0.02602) [-0.04774]	0.309774 (0.14503) [2.13587]
D(X4_INSAMPLE(-2))	-0.188537 (0.13649) [-1.38130]	0.372042 (0.28754) [1.29389]	-0.193777 (0.15731) [-1.23183]	0.001876 (0.11597) [0.01618]	0.023287 (0.11753) [0.19813]	-0.038517 (0.02764) [-1.39343]	0.503870 (0.15406) [3.27055]
D(X4_INSAMPLE(-3))	-0.267935 (0.12915) [-2.07457]	-0.202970 (0.27207) [-0.74601]	-0.003271 (0.14885) [-0.02198]	-0.042737 (0.10974) [-0.38945]	0.172324 (0.11121) [1.54954]	-0.002532 (0.02616) [-0.09682]	0.441652 (0.14578) [3.02962]
D(X1_INSAMPLE(-1))	0.221341 (0.08700) [2.54407]	-0.601235 (0.18328) [-3.28039]	-0.290426 (0.10027) [-2.89640]	-0.032372 (0.07392) [-0.43791]	0.163074 (0.07492) [2.17677]	-0.063017 (0.01762) [-3.57649]	-0.053523 (0.09820) [-0.54503]
D(X1_INSAMPLE(-2))	0.104251 (0.07600) [1.37181]	-0.452043 (0.16009) [-2.82964]	-0.206093 (0.08758) [-2.35306]	-0.019981 (0.06457) [-0.30944]	0.116771 (0.06544) [1.78447]	-0.046287 (0.01539) [-3.00751]	-0.032622 (0.08578) [-0.38031]
D(X1_INSAMPLE(-3))	0.082920 (0.05699) [1.45508]	-0.113096 (0.12005) [-0.94209]	-0.093880 (0.06568) [-1.42942]	-0.017481 (0.04842) [-0.36102]	0.023013 (0.04907) [0.46898]	-0.027889 (0.01154) [-2.41660]	-0.009153 (0.06432) [-0.14230]
D(X2_INSAMPLE(-1))	-0.678693 (0.11029) [-6.15347]	-0.011060 (0.23235) [-0.04760]	0.037983 (0.12711) [0.29881]	0.342751 (0.09371) [3.65744]	-0.387114 (0.09497) [-4.07612]	-0.001959 (0.02234) [-0.08769]	0.267176 (0.12449) [2.14612]
D(X2_INSAMPLE(-2))	-0.525224 (0.12811) [-4.09965]	-0.126568 (0.26987) [-0.46900]	-0.073141 (0.14764) [-0.49539]	0.311970 (0.10885) [2.86614]	-0.196632 (0.11031) [-1.78258]	0.057374 (0.02594) [2.21150]	0.133884 (0.14460) [0.92592]
D(X2_INSAMPLE(-3))	-0.110062 (0.12130) [-0.90738]	-0.318299 (0.25553) [-1.24567]	-0.514837 (0.13980) [-3.68280]	0.365281 (0.10306) [3.54429]	-0.442578 (0.10445) [-4.23742]	0.006587 (0.02456) [0.26815]	0.040866 (0.13691) [0.29849]
D(X3_INSAMPLE(-1))	-1.247744 (0.31303) [-3.98608]	-0.524052 (0.65942) [-0.79471]	0.112316 (0.36076) [0.31133]	-0.096880 (0.26597) [-0.36425]	-0.252685 (0.26954) [-0.93748]	0.143892 (0.06339) [2.26983]	1.086282 (0.35332) [3.07449]
D(X3_INSAMPLE(-2))	-0.621468 (0.36626) [-1.74442]	-0.008411 (0.75050) [-0.00854]	0.683270 (0.41059) [1.61540]	-0.189637 (0.30270) [-0.62318]	0.007453 (0.30676) [0.02430]	0.157711 (0.07215) [2.18590]	1.070846 (0.40212) [2.66300]
D(X3_INSAMPLE(-3))	-0.377198 (0.29466) [-1.28013]	-0.783040 (0.62072) [-1.26149]	0.479799 (0.33959) [1.41287]	0.164037 (0.25036) [0.65321]	-0.060899 (0.25372) [-0.24002]	0.028411 (0.05967) [0.47612]	0.532286 (0.33259) [1.60045]
D(X5_INSAMPLE(-1))	-0.679824 (0.26053) [-2.60941]	-0.475234 (0.54883) [-0.86590]	-0.036428 (0.30026) [-0.12132]	-0.050044 (0.22136) [-0.22607]	-0.370787 (0.22433) [-1.65284]	0.142852 (0.05276) [2.70750]	0.533865 (0.29407) [1.81546]
D(X5_INSAMPLE(-2))	-0.119421 (0.28698) [-0.41614]	0.018832 (0.60455) [0.03115]	0.623864 (0.33074) [1.88626]	-0.372406 (0.24383) [-1.52730]	0.004641 (0.24711) [0.01878]	0.113876 (0.05812) [1.95941]	0.458508 (0.32392) [1.41551]
D(X5_INSAMPLE(-3))	0.062828 (0.23986) [0.26193]	-0.290218 (0.50530) [-0.57435]	0.514272 (0.27644) [1.86031]	-0.244283 (0.20380) [-1.19862]	0.192326 (0.20654) [0.93118]	0.021518 (0.04858) [0.44296]	0.012219 (0.27074) [0.04513]
D(X6_INSAMPLE(-1))	0.776034 (0.48815) [1.58974]	0.847930 (1.02835) [0.82456]	0.019237 (0.56260) [0.03419]	-0.662492 (0.41477) [-1.59727]	1.303084 (0.42033) [3.10012]	0.814532 (0.09886) [8.23930]	0.416454 (0.55099) [0.75583]
D(X6_INSAMPLE(-2))	0.801564 (0.65503) [1.22371]	-0.159058 (1.37989) [-0.11527]	-0.121723 (0.75493) [-0.16124]	-0.190606 (0.55656) [-0.34247]	-0.533793 (0.56403) [-0.94640]	0.105277 (0.13266) [0.79361]	0.120662 (0.73935) [0.16320]
D(X6_INSAMPLE(-3))	-1.139312 (0.47395) [-2.40384]	-1.104188 (0.98444) [-1.10591]	0.163961 (0.54634) [0.29962]	0.457624 (0.40270) [1.13638]	0.016911 (0.40811) [0.04144]	-0.252949 (0.05698) [-2.63532]	-0.507389 (0.53487) [-0.94845]
D(Y1_INSAMPLE(-1))	-0.082141 (0.09649) [-0.85127]	-0.052772 (0.20327) [-0.25861]	0.168977 (0.11121) [1.51947]	-0.060795 (0.11121) [-0.74152]	0.181759 (0.08309) [2.18758]	-0.004263 (0.01954) [-0.21817]	-0.264570 (0.10891) [-2.42917]
D(Y1_INSAMPLE(-2))	0.198814 (0.08294) [2.39713]	0.066902 (0.17472) [0.38291]	0.104657 (0.09559) [1.09489]	-0.105733 (0.07047) [-1.50040]	0.090874 (0.07142) [1.27247]	0.008361 (0.01680) [0.49778]	-0.597900 (0.08381) [-6.38682]
D(Y1_INSAMPLE(-3))	-0.002120 (0.09740) [-0.02177]	-0.151378 (0.20519) [-0.73776]	0.055168 (0.11226) [0.49145]	-0.100503 (0.08276) [-1.21441]	0.121051 (0.08387) [1.44332]	0.039495 (0.01973) [2.00225]	-0.053097 (0.10994) [-0.48297]

Vector Error Correction Estimates							
Date: 05/04/26 Time: 00:30							
Sample (adjusted): 2015M05 2023M12							
Included observations: 104 after adjustments							
Standard errors in () & t-statistics in []							
Cointegrating Eq:		CointEq1					
X5_INSAMPLE(-1)		1.000000					
X1_INSAMPLE(-1)		-1.516665 (0.22846) [-6.63879]					
X2_INSAMPLE(-1)		1.242971 (0.34437) [3.60940]					
X3_INSAMPLE(-1)		1.780844 (0.31853) [5.59078]					
X4_INSAMPLE(-1)		-1.649850 (0.34303) [-4.80963]					
X6_INSAMPLE(-1)		0.522942 (0.16256) [3.21688]					
Y1_INSAMPLE(-1)		-0.025495 (0.17839) [-0.14291]					
C		0.126123					
Error Correction:							
	D(X5_INSA...	D(X1_INSA...	D(X2_INSA...	D(X3_INSA...	D(X4_INSA...	D(X6_INSA...	D(Y1_INSA...
CointEq1	0.160253 (0.04929) [3.25098]	0.196407 (0.12060) [1.62863]	-0.209450 (0.06598) [-3.17458]	-0.071357 (0.04864) [-1.46702]	0.211098 (0.05725) [3.68751]	-0.042954 (0.01159) [-3.70500]	-0.008458 (0.06462) [-0.13090]
D(X5_INSAMPLE(-1))	-0.370787 (0.22433) [-1.65284]	-0.475234 (0.54883) [-0.86590]	-0.036428 (0.30026) [-0.12132]	-0.050044 (0.22136) [-0.22607]	-0.679824 (0.26053) [-2.60941]	0.142852 (0.05276) [2.70750]	0.533865 (0.29407) [1.81546]
D(X5_INSAMPLE(-2))	0.004641 (0.24711) [0.01878]	0.018832 (0.60455) [0.03115]	0.623864 (0.33074) [1.88626]	-0.372406 (0.24383) [-1.52730]	-0.119421 (0.28698) [-0.41614]	0.113876 (0.05812) [1.95941]	0.458508 (0.32392) [1.41551]
D(X5_INSAMPLE(-3))	0.192326 (0.20654) [0.93118]	-0.290218 (0.50530) [-0.57435]	0.514272 (0.27644) [1.86031]	-0.244283 (0.20380) [-1.19862]	0.062828 (0.23986) [0.26193]	0.021518 (0.04858) [0.44296]	0.012219 (0.27074) [0.04513]
D(X1_INSAMPLE(-1))	0.163074 (0.07492) [2.17677]	-0.601235 (0.18328) [-3.28039]	-0.290426 (0.10027) [-2.89640]	-0.032372 (0.07392) [-0.43791]	0.221341 (0.08700) [2.54407]	-0.063017 (0.01762) [-3.57649]	-0.053523 (0.09820) [-0.54503]
D(X1_INSAMPLE(-2))	0.116771 (0.06544) [1.78447]	-0.452043 (0.16009) [-2.82964]	-0.206093 (0.08758) [-2.35306]	-0.019981 (0.06457) [-0.30944]	0.104251 (0.07600) [1.37181]	-0.046287 (0.01539) [-3.00751]	-0.032622 (0.08578) [-0.38031]
D(X1_INSAMPLE(-3))	0.023013 (0.04907) [0.46898]	-0.113096 (0.12005) [-0.94209]	-0.093880 (0.06568) [-1.42942]	-0.017481 (0.04842) [-0.36102]	0.082920 (0.05699) [1.45508]	-0.027889 (0.01154) [-2.41660]	-0.009153 (0.06432) [-0.14230]
D(X2_INSAMPLE(-1))	-0.387114 (0.09497) [-4.07612]	-0.011060 (0.23235) [-0.04760]	0.037983 (0.12711) [0.29881]	0.342751 (0.09371) [3.65744]	-0.678693 (0.11029) [-6.15347]	-0.001959 (0.02234) [-0.08769]	0.267176 (0.12449) [2.14612]
D(X2_INSAMPLE(-2))	-0.196632 (0.11031) [-1.78258]	-0.126568 (0.26987) [-0.46900]	-0.073141 (0.14764) [-0.49539]	0.311970 (0.10885) [2.86614]	-0.525224 (0.12811) [-4.09995]	0.057374 (0.02594) [2.21150]	0.133884 (0.14460) [0.92592]
D(X2_INSAMPLE(-3))	-0.442578 (0.10445) [-4.23742]	-0.318299 (0.25553) [-1.24567]	-0.514837 (0.13980) [-3.68280]	0.365281 (0.10306) [3.54429]	-0.110062 (0.12130) [-0.90738]	0.006587 (0.02456) [0.26815]	0.040866 (0.13691) [0.29849]
D(X3_INSAMPLE(-1))	-0.252685 (0.26954) [-0.93748]	-0.524052 (0.65942) [-0.79471]	0.112316 (0.36076) [0.31133]	-0.096880 (0.26597) [-0.36425]	-1.247744 (0.31303) [-3.98608]	0.143892 (0.06339) [2.26983]	1.086282 (0.35332) [3.07449]
D(X3_INSAMPLE(-2))	0.007453 (0.30876) [0.02430]	-0.008411 (0.75050) [-0.00854]	0.663270 (0.41059) [1.61540]	-0.188637 (0.30270) [-0.62318]	-0.621468 (0.35626) [-1.74442]	0.157711 (0.07215) [2.18590]	1.070846 (0.40212) [2.66300]
D(X3_INSAMPLE(-3))	-0.060899 (0.25372) [-0.24002]	-0.783040 (0.62072) [-1.26149]	0.479799 (0.33959) [1.41287]	0.164037 (0.25036) [0.65321]	-0.377198 (0.29466) [-1.28013]	0.028411 (0.05967) [0.47612]	0.532286 (0.33259) [1.60045]
D(X4_INSAMPLE(-1))	0.375585 (0.11064) [3.39461]	0.254708 (0.27068) [0.94097]	-0.272089 (0.14809) [-1.83734]	-0.157031 (0.10918) [-1.43633]	-0.277272 (0.12849) [-2.15789]	-0.001242 (0.02602) [-0.04774]	0.309774 (0.14503) [2.13567]
D(X4_INSAMPLE(-2))	0.023287 (0.11753) [0.19813]	0.372042 (0.28754) [1.29389]	-0.193777 (0.15731) [-1.23183]	0.001876 (0.11597) [0.01618]	-0.188537 (0.13649) [-1.36130]	-0.038517 (0.02764) [-1.39343]	0.503870 (0.15406) [3.27056]
D(X4_INSAMPLE(-3))	0.172324 (0.11121) [1.54954]	-0.202970 (0.27207) [-0.74601]	-0.003271 (0.14885) [-0.02198]	-0.042737 (0.10974) [-0.38945]	-0.267935 (0.12915) [-2.07457]	-0.002532 (0.02616) [-0.09682]	0.441652 (0.14578) [3.02962]
D(X6_INSAMPLE(-1))	1.303084 (0.42033) [3.10012]	0.847930 (1.02835) [0.82456]	0.019237 (0.56260) [0.03419]	-0.662492 (0.41477) [-1.59727]	0.776034 (0.48815) [1.58974]	0.814532 (0.09886) [8.23930]	0.416454 (0.55099) [0.75583]
D(X6_INSAMPLE(-2))	-0.533793 (0.56403) [-0.94640]	-0.159058 (1.37989) [-0.11527]	-0.121723 (0.75493) [-0.16124]	-0.190606 (0.55656) [-0.34247]	0.801564 (0.65503) [1.22371]	0.105277 (0.13266) [0.79361]	0.120662 (0.73935) [0.16320]
D(X6_INSAMPLE(-3))	0.016911 (0.40811) [0.04144]	-1.104188 (0.98844) [-1.10591]	0.163961 (0.54634) [0.29962]	0.457624 (0.40270) [1.13638]	-1.136312 (0.47395) [-2.40384]	-0.252949 (0.05698) [-2.63532]	-0.507389 (0.53487) [-0.94845]
D(Y1_INSAMPLE(-1))	0.181759 (0.08309) [2.18758]	-0.052772 (0.20327) [-0.25861]	0.168977 (0.11121) [1.51947]	-0.060795 (0.11121) [-0.74152]	-0.082141 (0.09649) [-0.85127]	-0.004263 (0.01954) [-0.21817]	-0.264570 (0.10891) [-2.42917]
D(Y1_INSAMPLE(-2))	0.090874 (0.07142) [1.27247]	0.066902 (0.17472) [0.38291]	0.104657 (0.09559) [1.09489]	-0.105733 (0.07047) [-1.50040]	0.198814 (0.08294) [2.39713]	0.008361 (0.01680) [0.49778]	-0.597900 (0.08361) [-6.38682]
D(Y1_INSAMPLE(-3))	0.121051 (0.08387) [1.44332]	-0.151378 (0.20519) [-0.73776]	0.055168 (0.11226) [0.49145]	-0.100503 (0.08276) [-1.21441]	-0.002120 (0.09740) [-0.02177]	0.039495 (0.01973) [2.00225]	-0.053097 (0.10994) [-0.48297]

Vector Error Correction Estimates Date: 05/04/26 Time: 00:31 Sample (adjusted): 2015M05 2023M12 Included observations: 104 after adjustments Standard errors in () & t-statistics in []							
Cointegrating Eq:	CointEq1						
X6 INSAMPLE(-1)	1.000000						
X1 INSAMPLE(-1)	-2.900255 (0.45565) [-6.36505]						
X2 INSAMPLE(-1)	2.376882 (0.60660) [3.91835]						
X3 INSAMPLE(-1)	3.405433 (1.09210) [3.11825]						
X4 INSAMPLE(-1)	-3.154939 (0.66546) [-4.74097]						
X5 INSAMPLE(-1)	1.912258 (1.05712) [1.80863]						
Y1 INSAMPLE(-1)	-0.048752 (0.31733) [-0.15363]						
C	0.241179						
Error Correction:	D(X6 INSA...	D(X1 INSA...	D(X2 INSA...	D(X3 INSA...	D(X4 INSA...	D(X5 INSA...	D(Y1 INSA...
CointEq1	-0.022462 (0.00606) [-3.70500]	0.102710 (0.06307) [1.62863]	-0.109530 (0.03450) [-3.17458]	-0.037316 (0.02544) [-1.46702]	0.110392 (0.02994) [3.68751]	0.083803 (0.02578) [3.25098]	-0.004423 (0.03379) [-0.13090]
D(X6 INSAMPLE(-1))	0.814532 (0.09886) [8.23930]	0.847930 (1.02835) [0.82456]	0.019237 (0.56260) [0.03419]	-0.662492 (0.41477) [-1.59727]	0.776034 (0.48815) [1.58974]	1.303084 (0.42033) [3.10012]	0.416454 (0.55099) [0.75583]
D(X6 INSAMPLE(-2))	0.105277 (0.13266) [0.79361]	-0.159058 (1.37989) [-0.11527]	-0.121723 (0.75493) [-0.16124]	-0.190606 (0.55656) [-0.34247]	0.801564 (0.65503) [1.22371]	-0.533793 (0.56403) [-0.94640]	0.120662 (0.73935) [0.16320]
D(X6 INSAMPLE(-3))	-0.252949 (0.09598) [-2.63532]	-1.104188 (0.96844) [-1.10591]	0.163661 (0.54624) [0.29962]	0.457624 (0.40270) [1.13638]	-1.139312 (0.47395) [-2.40384]	0.016911 (0.40811) [0.04144]	-0.507389 (0.09820) [-0.94845]
D(X1 INSAMPLE(-1))	-0.063017 (0.01762) [-3.57649]	-0.601235 (0.18328) [-3.28039]	-0.290426 (0.10027) [-2.89640]	-0.032372 (0.07392) [-0.43791]	0.221341 (0.08700) [2.54407]	0.163074 (0.07492) [2.17677]	-0.053523 (0.09820) [-0.54503]
D(X1 INSAMPLE(-2))	-0.046287 (0.01539) [-3.00751]	-0.452043 (0.16009) [-2.82964]	-0.206093 (0.08758) [-2.35306]	-0.019981 (0.06457) [-0.30944]	0.104251 (0.07600) [1.37181]	0.116771 (0.08544) [1.78447]	-0.032622 (0.08578) [-0.38031]
D(X1 INSAMPLE(-3))	-0.027889 (0.01154) [-2.41660]	-0.113096 (0.12005) [-0.94209]	-0.093880 (0.06568) [-1.42942]	-0.017481 (0.04842) [-0.36102]	0.082920 (0.05699) [1.45508]	0.023013 (0.04907) [0.46898]	-0.009153 (0.06432) [-0.14230]
D(X2 INSAMPLE(-1))	-0.001959 (0.02234) [-0.08769]	-0.011060 (0.23235) [-0.04760]	0.037983 (0.12711) [0.29881]	0.342751 (0.09371) [3.65744]	-0.678693 (0.11029) [-6.15347]	-0.387114 (0.09497) [-4.07612]	0.267176 (0.12449) [2.14612]
D(X2 INSAMPLE(-2))	0.057374 (0.02594) [2.21150]	-0.126568 (0.26987) [-0.46900]	-0.073141 (0.14764) [-0.49539]	0.311970 (0.10885) [2.86614]	-0.525224 (0.12811) [-4.09995]	-0.196632 (0.11031) [-1.78258]	0.133884 (0.14460) [0.92592]
D(X2 INSAMPLE(-3))	0.006587 (0.02456) [0.26815]	-0.318299 (0.25553) [-1.24567]	-0.514837 (0.13980) [-3.68280]	0.365281 (0.10306) [3.54429]	-0.110062 (0.12130) [-0.90738]	-0.442578 (0.10445) [-4.23742]	0.040866 (0.13691) [0.29849]
D(X3 INSAMPLE(-1))	0.143892 (0.06339) [2.26983]	-0.524052 (0.65942) [-0.79471]	0.112316 (0.36076) [0.31133]	-0.096880 (0.26597) [-0.36425]	-1.247744 (0.31303) [-3.98608]	-0.252685 (0.26954) [-0.93748]	1.086282 (0.35332) [3.07449]
D(X3 INSAMPLE(-2))	0.157711 (0.07215) [2.18590]	-0.008411 (0.75050) [-0.00854]	0.663270 (0.41059) [1.61540]	-0.188637 (0.30270) [-0.62318]	-0.621468 (0.35626) [-1.74442]	0.007453 (0.30676) [0.02430]	1.070846 (0.40212) [2.66300]
D(X3 INSAMPLE(-3))	0.028411 (0.05967) [0.47612]	-0.783040 (0.62072) [-1.26149]	0.479799 (0.33959) [1.41287]	0.164037 (0.25036) [0.65321]	-0.377198 (0.29466) [-1.28013]	-0.060899 (0.25372) [-0.24002]	0.532286 (0.33259) [1.60045]
D(X4 INSAMPLE(-1))	-0.001242 (0.02602) [-0.04774]	0.254708 (0.27068) [0.94097]	-0.272089 (0.14809) [-1.83734]	-0.157031 (0.10918) [-1.43633]	-0.277272 (0.12849) [-2.15789]	0.375585 (0.11064) [3.39461]	0.309774 (0.14503) [2.13567]
D(X4 INSAMPLE(-2))	-0.038517 (0.02764) [-1.39343]	0.372042 (0.28754) [1.29389]	-0.193777 (0.15731) [-1.23183]	0.001876 (0.11597) [0.01618]	-0.188537 (0.13649) [-1.38130]	0.023287 (0.11753) [0.19813]	0.503870 (0.15406) [3.27056]
D(X4 INSAMPLE(-3))	-0.002532 (0.02616) [-0.09682]	-0.202970 (0.27207) [-0.74601]	-0.003271 (0.14885) [-0.02198]	-0.042737 (0.10974) [-0.38945]	-0.267935 (0.12915) [-2.07457]	0.172324 (0.11121) [1.54954]	0.441652 (0.14578) [3.02962]
D(X5 INSAMPLE(-1))	0.142852 (0.05276) [2.70750]	-0.475234 (0.54883) [-0.86590]	-0.036428 (0.30026) [-0.12132]	-0.050044 (0.22136) [-0.22607]	-0.679824 (0.26053) [-2.60941]	-0.370787 (0.22433) [-1.65284]	0.533865 (0.29407) [1.81546]
D(X5 INSAMPLE(-2))	0.113876 (0.05812) [1.95941]	0.018832 (0.60455) [0.03115]	0.623864 (0.33074) [1.88626]	-0.372406 (0.24383) [-1.52730]	-0.119421 (0.28698) [-0.41614]	0.004641 (0.24711) [0.01878]	0.458508 (0.32392) [1.41551]
D(X5 INSAMPLE(-3))	0.021518 (0.04858) [0.44296]	-0.290218 (0.50530) [-0.57435]	0.514272 (0.27644) [1.86031]	-0.244283 (0.20380) [-1.19862]	0.062828 (0.23896) [0.26193]	0.192326 (0.20854) [0.93118]	0.012219 (0.27074) [0.04513]
D(Y1 INSAMPLE(-1))	-0.004263 (0.01954) [-0.21817]	-0.052772 (0.20327) [-0.25961]	0.168977 (0.11121) [1.51947]	-0.060795 (0.08199) [-0.74152]	-0.082141 (0.09649) [-0.85127]	0.181759 (0.08309) [2.18758]	-0.264570 (0.10891) [-2.42917]
D(Y1 INSAMPLE(-2))	0.008361 (0.01680) [0.49778]	0.066902 (0.17472) [0.38291]	0.104657 (0.09559) [1.09489]	-0.105733 (0.07047) [-1.50040]	0.198814 (0.08294) [2.39713]	0.090874 (0.07142) [1.27247]	-0.597900 (0.08381) [-6.38682]
D(Y1 INSAMPLE(-3))	0.039495 (0.01973) [2.00225]	-0.151378 (0.20519) [-0.73776]	0.055168 (0.11226) [0.49145]	-0.100503 (0.08276) [-1.21441]	-0.002120 (0.09740) [-0.02177]	0.121051 (0.08387) [1.44332]	-0.053097 (0.10994) [-0.48297]

Lampiran 13. Uji Portmanteau

VEC Residual Portmanteau Tests for Autocorrelations Null Hypothesis: No residual autocorrelations up to lag h Date: 05/05/26 Time: 20:27 Sample: 2015M01 2023M12 Included observations: 102					
Lags	Q-Stat	Prob.*	Adj Q-Stat	Prob.*	df
1	24.71673	---	24.96145	---	---
2	54.35030	---	55.18770	---	---
3	82.42047	---	84.10847	---	---
4	111.55160	---	114.42860	---	---
5	162.45960	0.1823	167.96080	0.2015	91
6	213.56330	0.2541	222.25840	0.2768	140
7	261.74120	0.3125	273.98630	0.3357	189
8	305.07600	0.4012	321.00920	0.4289	238
*Test is valid only for lags larger than the VAR lag order. df is degrees of freedom for (approximate) chi-square distribution after adjustment for VEC estimation (Bruggemann, et al. 2005)					

Lampiran 14. Hasil Impulse Response Function

Response of D(X1 INSAMPLE):							
Period	D(X1 INS...	D(X2 INS...	D(X3 INS...	D(X4 INS...	D(X5 INS...	D(X6 INS...	D(Y1 INS...
1	1.206639 (0.08407)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)
2	-1.039767 (0.15364)	0.172900 (0.12651)	-0.013759 (0.12530)	0.096558 (0.13030)	0.029909 (0.11871)	0.104817 (0.13021)	-0.042046 (0.11982)
3	-0.005328 (0.17615)	-0.138765 (0.16854)	-0.001523 (0.16304)	0.076980 (0.17360)	0.138840 (0.16389)	-0.056736 (0.16918)	0.019120 (0.15616)
4	0.338341 (0.17549)	-0.056222 (0.16247)	-0.085613 (0.16389)	-0.281063 (0.16636)	-0.110169 (0.15581)	-0.141207 (0.16126)	-0.007094 (0.14902)
5	-0.145903 (0.18177)	0.237107 (0.16408)	0.224950 (0.17127)	0.215335 (0.16412)	0.089278 (0.15653)	-0.006652 (0.14109)	0.015957 (0.14447)
6	0.083523 (0.18332)	-0.158265 (0.14850)	-0.140261 (0.15686)	-0.059365 (0.16173)	-0.087213 (0.15265)	0.037889 (0.10182)	0.022657 (0.13356)
7	-0.080459 (0.15544)	0.120441 (0.11783)	0.067658 (0.13316)	-0.054619 (0.13009)	0.089463 (0.12793)	-0.016347 (0.09441)	-0.068349 (0.11528)
8	0.061684 (0.12860)	-0.069903 (0.11170)	0.046618 (0.12116)	0.096739 (0.11083)	-0.022459 (0.11219)	-0.003704 (0.08317)	0.015041 (0.11120)
9	0.021368 (0.12352)	0.064614 (0.10458)	-0.039718 (0.10557)	-0.015365 (0.10188)	-0.085966 (0.10310)	-0.008373 (0.06675)	-0.048631 (0.08550)
10	-0.064978 (0.10106)	-0.022224 (0.09146)	0.002359 (0.08629)	-0.032607 (0.08987)	0.007506 (0.08622)	-0.009124 (0.05574)	0.034392 (0.07056)
11	0.026178 (0.08309)	-0.000567 (0.07603)	0.008949 (0.07354)	0.032844 (0.07988)	0.049505 (0.07389)	0.021299 (0.04752)	0.005113 (0.06036)
12	0.012260 (0.07362)	0.007721 (0.06653)	-0.033918 (0.06643)	-0.026927 (0.07264)	-0.046396 (0.06644)	-0.006026 (0.03992)	-0.048259 (0.05080)
Response of D(X2 INSAMPLE):							
Period	D(X1 INS...	D(X2 INS...	D(X3 INS...	D(X4 INS...	D(X5 INS...	D(X6 INS...	D(Y1 INS...
1	0.106266 (0.06254)	0.630253 (0.04391)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)
2	-0.020879 (0.07571)	-0.146831 (0.07075)	-0.033722 (0.06965)	0.075988 (0.07203)	-0.197889 (0.06462)	0.056911 (0.06920)	0.060401 (0.06359)
3	-0.033578 (0.07758)	-0.110880 (0.06914)	0.047414 (0.06900)	-0.025216 (0.07338)	0.136349 (0.06791)	0.051572 (0.07002)	-0.071488 (0.06555)
4	-0.052247 (0.08269)	-0.355761 (0.07316)	-0.058993 (0.06982)	0.120874 (0.07026)	-0.028285 (0.06730)	-0.030410 (0.07032)	-0.017314 (0.06146)
5	-0.017668 (0.08452)	0.010613 (0.07333)	-0.044679 (0.07711)	0.027345 (0.07742)	-0.010646 (0.07371)	-0.009023 (0.06976)	-0.042851 (0.07002)
6	-0.086773 (0.08544)	0.048144 (0.07187)	-0.073448 (0.05884)	-0.149881 (0.07546)	-0.020091 (0.06274)	0.028469 (0.06616)	0.043182 (0.06038)
7	0.055292 (0.06694)	0.227208 (0.07344)	0.086649 (0.05556)	-0.083281 (0.06529)	0.163403 (0.05934)	0.061402 (0.06568)	0.090861 (0.04847)
8	0.094184 (0.06356)	0.037394 (0.07195)	0.011737 (0.05602)	-0.042406 (0.06604)	-0.003969 (0.05800)	0.033635 (0.05804)	0.023569 (0.05310)
9	0.015947 (0.06153)	-0.052211 (0.07131)	0.016200 (0.05241)	0.155219 (0.06317)	-0.043702 (0.05236)	0.003303 (0.05264)	-0.016495 (0.04712)
10	-0.056603 (0.05815)	-0.235406 (0.06946)	-0.014101 (0.04880)	0.088958 (0.05643)	-0.085616 (0.05343)	-0.028974 (0.04999)	0.001506 (0.04289)
11	-0.072759 (0.05838)	-0.070656 (0.07056)	0.035510 (0.04643)	0.015969 (0.05896)	0.014286 (0.05098)	-0.009503 (0.04751)	-0.022839 (0.04665)
12	0.019878 (0.05422)	0.105191 (0.06971)	-0.032576 (0.03891)	-0.095432 (0.05664)	0.009777 (0.04334)	-0.005012 (0.04437)	-0.022209 (0.04202)
Response of D(X3 INSAMPLE):							
Period	D(X1 INS...	D(X2 INS...	D(X3 INS...	D(X4 INS...	D(X5 INS...	D(X6 INS...	D(Y1 INS...
1	0.032925 (0.04546)	-0.253035 (0.04184)	0.385143 (0.02683)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)
2	0.109641 (0.05872)	0.269514 (0.05209)	-0.043910 (0.04826)	-0.036095 (0.05007)	-0.012158 (0.04565)	-0.034042 (0.05006)	-0.050783 (0.04600)
3	0.025383 (0.06713)	0.167294 (0.06128)	-0.054657 (0.05988)	0.104549 (0.06259)	-0.216995 (0.05687)	-0.065339 (0.05683)	-0.049941 (0.05276)
4	0.015626 (0.06762)	0.055442 (0.06076)	0.062836 (0.06220)	-0.028770 (0.06294)	-0.064701 (0.05920)	0.000991 (0.06234)	-0.046717 (0.05679)
5	-0.005609 (0.06656)	-0.055398 (0.05718)	-0.080072 (0.06014)	0.043267 (0.05960)	-0.064084 (0.05688)	-0.034611 (0.05139)	-0.044534 (0.05254)
6	-0.030162 (0.06457)	-0.064569 (0.05230)	-0.063007 (0.05020)	0.004459 (0.05620)	0.028123 (0.05263)	-0.055229 (0.04682)	-0.046887 (0.04766)
7	-0.076921 (0.05167)	-0.114587 (0.04793)	-0.122279 (0.04392)	-0.015613 (0.04349)	0.011508 (0.04527)	-0.003901 (0.04351)	-0.021985 (0.04212)
8	-0.016996 (0.04710)	0.014389 (0.04740)	-0.040846 (0.04213)	-0.057413 (0.04330)	0.075296 (0.04282)	-0.007818 (0.04382)	0.031045 (0.03845)
9	-0.036629 (0.04332)	0.018885 (0.04669)	-0.001119 (0.04018)	-0.065237 (0.04128)	0.110881 (0.04257)	0.040203 (0.04137)	0.061492 (0.03403)
10	0.027731 (0.03897)	0.052402 (0.04550)	0.031954 (0.03918)	-0.008347 (0.03882)	0.087986 (0.04075)	0.047897 (0.04055)	0.057275 (0.03289)
11	0.034364 (0.03622)	-0.028031 (0.03969)	0.038933 (0.03593)	0.014310 (0.03561)	0.001693 (0.03945)	0.027111 (0.03725)	0.036391 (0.03206)
12	-0.013409 (0.03442)	-0.051904 (0.03999)	0.070185 (0.03391)	0.082395 (0.03303)	-0.013724 (0.03689)	0.027827 (0.03442)	0.006815 (0.02743)
Response of D(X4 INSAMPLE):							
Period	D(X1 INS...	D(X2 INS...	D(X3 INS...	D(X4 INS...	D(X5 INS...	D(X6 INS...	D(Y1 INS...
1	-0.152481 (0.05333)	-0.004606 (0.05226)	-0.284298 (0.04836)	0.447713 (0.03119)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)
2	-0.100548 (0.07123)	-0.234000 (0.06555)	-0.060546 (0.06309)	-0.257758 (0.06258)	-0.085562 (0.05445)	0.028881 (0.05947)	-0.007717 (0.05479)
3	-0.083317 (0.08195)	-0.118005 (0.07507)	0.112250 (0.07430)	-0.129550 (0.07706)	0.301844 (0.06893)	0.041509 (0.06895)	0.105695 (0.06408)
4	0.141897 (0.08465)	0.136782 (0.07577)	0.010547 (0.07671)	-0.059887 (0.07829)	0.162035 (0.07311)	0.018755 (0.07650)	0.017999 (0.06912)
5	0.014755 (0.08508)	0.120389 (0.07275)	0.044254 (0.07649)	-0.019051 (0.07640)	-0.056747 (0.07355)	0.005025 (0.06836)	0.019253 (0.06861)
6	0.065238 (0.08411)	0.022640 (0.06865)	0.056158 (0.06650)	0.106919 (0.07349)	-0.065434 (0.06777)	0.009819 (0.06126)	0.090276 (0.06178)
7	-0.033380 (0.07028)	-0.081278 (0.06444)	0.126981 (0.05760)	0.045489 (0.06224)	-0.031509 (0.06017)	-0.013227 (0.05625)	-0.015753 (0.05655)
8	0.001348 (0.06178)	-0.007617 (0.06177)	0.019381 (0.05140)	0.079608 (0.05655)	-0.037788 (0.05424)	-0.002141 (0.04993)	-0.076767 (0.05152)
9	0.053958 (0.05473)	0.034456 (0.06043)	-0.070052 (0.04826)	-0.009357 (0.05210)	-0.128622 (0.05147)	-0.048079 (0.04368)	-0.074565 (0.04323)
10	-0.032026 (0.04842)	0.053193 (0.05640)	0.031421 (0.04482)	-0.060575 (0.04732)	-0.012532 (0.04864)	-0.017285 (0.03938)	-0.031722 (0.04018)
11	0.018214 (0.04494)	0.054791 (0.05090)	-0.037293 (0.04049)	-0.033248 (0.04440)	0.024056 (0.04482)	-0.018522 (0.03512)	0.013521 (0.03786)
12	0.016333 (0.04049)	0.031456 (0.04814)	-0.066492 (0.03786)	-0.007354 (0.04197)	-0.002902 (0.04145)	-0.032384 (0.03254)	-0.010346 (0.03399)

Lampiran 15. Hasil Variance Decomposition

Variance Decomposition of D(X1 INSAMPLE):								
Period	S.E.	D(X1 INS...	D(X2 INS...	D(X3 INS...	D(X4 INS...	D(X5 INS...	D(X6 INS...	D(Y1 INS...
1	1.206339	100.0000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
2	1.609394	97.95161	1.154159	0.007309	0.359960	0.034537	0.424171	0.008254
3	1.624261	96.16783	1.862998	0.007264	0.578018	0.704572	0.538454	0.008086
4	1.689537	92.25152	1.819948	0.261673	0.237805	1.124038	1.187939	0.075975
5	1.748445	87.43314	3.550172	1.901302	4.599684	1.317570	1.118372	0.079762
6	1.768872	85.84511	4.278851	2.420331	4.617133	1.533272	1.141152	0.094550
7	1.778572	84.92134	4.681308	2.604062	4.650891	1.766769	1.134634	0.240992
8	1.784457	84.48166	4.803939	2.655164	4.914160	1.770976	1.127594	0.246510
9	1.789010	84.06645	4.909961	2.690954	4.896555	1.992875	1.124053	0.319150
10	1.790995	84.01181	4.914481	2.685165	4.918852	1.990216	1.124157	0.355317
11	1.792328	83.90827	4.907186	2.683667	4.945121	2.063546	1.136607	0.355602
12	1.794169	83.74082	4.898972	2.713901	4.957501	2.126184	1.135404	0.427221
Variance Decomposition of D(X2 INSAMPLE):								
Period	S.E.	D(X1 INS...	D(X2 INS...	D(X3 INS...	D(X4 INS...	D(X5 INS...	D(X6 INS...	D(Y1 INS...
1	0.639149	2.764279	97.23572	0.000000	0.000000	0.000000	0.000000	0.000000
2	0.695317	2.425892	86.62020	0.235208	1.194333	8.098936	0.669916	0.754612
3	0.725350	2.443555	81.93245	0.643412	1.218327	10.97650	1.121106	1.664755
4	0.821914	2.307109	82.54677	1.016271	1.311639	8.667235	1.010040	1.340936
5	0.825071	2.335343	81.93280	1.301749	1.397717	8.617681	1.014285	1.600429
6	0.849428	2.324882	77.62270	1.975824	1.634048	8.186503	1.069279	1.768403
7	0.910702	3.193271	73.75313	2.624161	6.169482	10.34129	1.384806	2.533982
8	0.918306	4.192510	72.70261	2.587220	6.280982	10.17261	1.496124	2.557945
9	0.934246	4.079810	70.55530	2.539421	8.828865	10.04727	1.447658	2.502580
10	0.973509	4.095416	70.82619	2.359696	8.966069	10.02661	1.420992	2.350525
11	0.979968	4.528258	70.41543	2.259997	8.874815	9.916118	1.411725	2.329055
12	0.991252	4.529103	69.94577	2.512313	9.600781	9.701376	1.382324	2.265631
Variance Decomposition of D(X3 INSAMPLE):								
Period	S.E.	D(X1 INS...	D(X2 INS...	D(X3 INS...	D(X4 INS...	D(X5 INS...	D(X6 INS...	D(Y1 INS...
1	0.462002	0.507872	29.98663	69.49550	0.000000	0.000000	0.000000	0.000000
2	0.552468	0.293684	44.77554	49.23087	0.426851	0.048426	0.379676	0.844945
3	0.633736	0.342316	40.99679	38.15800	0.304599	1.176103	1.351520	1.263158
4	0.645046	0.363190	40.31042	37.78050	1.319044	1.235829	1.304775	1.743778
5	0.659361	0.3225984	39.28508	37.63263	3.434822	1.277215	1.524271	1.252067
6	0.670720	0.319871	38.89249	37.25125	3.323886	12.51902	2.511509	2.263865
7	0.696232	0.310650	38.80315	37.65581	3.135040	11.64567	1.999488	2.459189
8	0.704907	0.254555	37.89562	37.07045	3.721721	12.50178	1.962878	2.592997
9	0.723567	0.294206	36.03434	35.18306	4.919399	14.21359	2.171658	3.183213
10	0.735477	0.294102	35.34880	34.20713	4.769965	15.17265	2.523466	3.663665
11	0.739744	0.464786	35.12099	34.12473	4.757271	15.01396	2.631274	3.886988
12	0.750212	4.372997	34.62633	34.05423	5.831656	14.63133	2.695936	3.787518
Variance Decomposition of D(X4 INSAMPLE):								
Period	S.E.	D(X1 INS...	D(X2 INS...	D(X3 INS...	D(X4 INS...	D(X5 INS...	D(X6 INS...	D(Y1 INS...
1	0.551855	7.634482	0.006966	26.53983	65.81872	0.000000	0.000000	0.000000
2	0.669126	7.450998	12.23446	18.87106	59.60879	1.635099	0.186293	0.013300
3	0.757876	6.694871	11.41265	15.12857	47.12239	16.35107	0.424783	1.866563
4	0.833192	6.342316	13.01821	14.47638	42.78089	18.56949	0.433219	1.720881
5	0.831929	8.763752	14.72392	14.32746	41.55708	18.48075	0.423942	1.723099
6	0.850874	8.965684	14.14633	14.13213	41.30604	18.25832	0.418591	1.727291
7	0.866785	8.787849	14.51102	15.76419	40.07891	17.72630	0.426652	2.705073
8	0.748480	8.626217	14.25131	15.52290	40.16865	17.58635	0.419392	3.425186
9	0.893836	8.628843	13.80218	15.48607	38.49485	18.91947	0.691138	3.977458
10	0.899388	8.649248	13.98179	15.41717	38.47382	18.70560	0.719553	4.052816
11	0.903235	8.616393	14.23092	15.45660	38.28229	18.61753	0.755486	4.040774
12	0.907044	8.576599	14.23191	15.86443	37.96800	18.46251	0.876627	4.019916
Variance Decomposition of D(X5 INSAMPLE):								
Period	S.E.	D(X1 INS...	D(X2 INS...	D(X3 INS...	D(X4 INS...	D(X5 INS...	D(X6 INS...	D(Y1 INS...
1	0.466905	0.030168	27.89145	36.71782	1.668796	33.69177	0.000000	0.000000
2	0.581247	2.876048	41.33825	23.72707	3.875546	22.69453	2.314633	1.379282
3	0.641912	2.436429	36.43644	22.89365	7.848335	26.11866	1.905095	2.661388
4	0.667562	3.126743	35.42078	21.25922	9.046147	25.63335	2.628907	2.864864
5	0.701067	4.205167	35.10174	22.72327	8.843121	26.29267	2.692651	2.578951
6	0.716590	4.423397	34.22572	22.34856	8.368984	24.03774	1.692900	3.435305
7	0.744575	4.471866	35.57929	22.40228	8.897405	22.33453	2.945197	3.369434
8	0.760167	4.449945	34.91567	21.51187	8.742624	24.18613	2.851395	3.354224
9	0.774540	4.318556	33.73556	20.78111	9.342724	24.81775	3.119535	3.830764
10	0.788189	4.533540	33.07960	21.14362	9.029771	24.58308	3.384190	4.246202
11	0.793644	4.761748	32.75091	21.40803	9.018004	24.37671	3.390921	4.293684
12	0.804723	4.687728	31.99774	21.53659	10.30446	23.90211	3.348362	4.223003
Variance Decomposition of D(X6 INSAMPLE):								
Period	S.E.	D(X1 INS...	D(X2 INS...	D(X3 INS...	D(X4 INS...	D(X5 INS...	D(X6 INS...	D(Y1 INS...
1	0.118852	1.149310	1.415424	0.168339	0.372326	0.742287	96.15231	0.000000
2	0.163744	3.045792	5.020233	0.404846	3.791408	0.391374	87.14597	0.000374
3	0.202471	2.571646	8.095701	0.265129	2.602793	0.271591	85.50335	0.689611
4	0.226177	2.667817	11.62850	0.432403	2.334351	1.090742	77.93148	0.917413
5	0.239340	2.382788	12.60421	0.957193	2.342470	1.455789	75.18490	0.507264
6	0.247605	2.180682	13.78150	1.532275	2.408879	1.673368	72.65884	0.134273
7	0.251055	2.796777	14.23925	1.988720	2.389315	1.77854	71.50851	0.506971
8	0.252670	2.762474	14.55838	1.888429	2.751028	1.765438	70.61777	0.563737
9	0.253243	2.750001	14.49599	1.882864	2.773243	2.022221	70.32666	0.5749017
10	0.254355	2.920741	14.38897	1.961223	2.8811739	2.007319	70.15815	0.5751852
11	0.255133	2.921674	14.38870	1.973164	2.794642	1.995710	70.20926	0.5716852
12	0.255768	2.910600	14.32278	1.989819	2.780820	2.003426	70.30280	0.5960651
Variance Decomposition of D(Y1 INSAMPLE):								
Period	S.E.	D(X1 INS...	D(X2 INS...	D(X3 INS...	D(X4 INS...	D(X5 INS...	D(X6 INS...	D(Y1 INS...
1	0.583099	0.168639	0.203806	3.506046	2.942446	1.088170	0.094193	91.99742
2	0.613849	0.288053	0.507616	3.160383	6.246005	2.248760	1.148592	86.13059
3	0.705587	0.50347	0.384735	2.603293	6.092555	3.834437	2.159960	80.90297
4	0.737463	0.575449	0.426825	2.463402	8.943946	7.877324	2.562140	77.13550
5	0.794243	0.499608	1.059843	8.700531	12.67686	7.323921	2.241382	67.97886
6	0.846901	0.439414	9.455522	8.653886	11.70726	7.873943	2.024189	60.38279
7	0.915678	1.959826	9.418030	10.65150	11.85534	11.73182	2.149740	52.32374
8	0.938067	2.113284	12.15043	10.37210	11.34001	12.12724	2.081289	49.77014
9	0.967497	3.498474	13.57354	9.770827	10.67252	13.59106	1.957066	46.93690
10	0.976269	3.436395	13.44451	10.13070	10.68433	14.26467	2.004938	46.13445
11	0.983061	3.450174	13.86627	10.33978	10.66840	14.10669	1.993161	45.57554
12	0.987647	3.428911	13.96578	10.41325	10.63677	14.00298	2.037785	45.51542
Cholesky One S.D. (d.f. adjusted)								
Cholesky ordering: D(X1 INSAMPLE) D(X2 INSAMPLE) D(X3 INSAMPLE) D(X4 INSAMPLE) D(X5 INSAMPLE) D(X6 INSAMPLE) D(Y1 INSAMPLE)								

Lampiran 16. MAPE

Bulan-Tahun	Produksi padi	Produksi padi VECM	$\frac{ y_t - f_t }{y_t}$
Januari 2024	-0,54355019	-0.5342843	0.017046981
Februari 2024	-0,48459154	-0.4052448	0.163739425
Maret 2024	1,311245795	1.36608511	0.0418223
April 2024	2,757316192	2.67228950	0.030836758
Mei 2024	0,501080961	0.65497432	0.307122743
Juni 2024	0,118212357	0.29644466	1.507729881
Juli 2024	0,544942557	0.2443110	0.551675682
Agustus 2024	0,502424317	0.41226734	0.179443896
September 2024	0,12281007	0.34470840	1.806841491
Oktober 2024	-0,19742487	-0.21395445	0.083725926
November 2024	-0,21423912	-0.2426162	0.132455174
Desember 2024	-0,38134974	-0.386292488	0.012961194
MAPE			40.3%

Bulan-Tahun	Curah hujan	Curah hujan VECM	$\frac{ y_t - f_t }{y_t}$
Januari 2024	-0,0989	-0.09109928	0.078874823
Februari 2024	-0,08613	-0.046727117	0.457481516
Maret 2024	-0,10227	-0.157336822	0.538445507
April 2024	-0,10104	-0.192365291	0.90385284
Mei 2024	-0,12143	-0.131025402	0.079020028
Juni 2024	-0,11778	-0.165504383	0.40519938
Juli 2024	-0,12163	-0.0572845	0.529026556
Agustus 2024	-0,12068	-0.1282436	0.062674843
September 2024	-0,12126	-0.17185838	0.417271813
Oktober 2024	-0,11889	-0.16291703	0.370317352
November 2024	-0,1014	-0.13428859	0.324345069
Desember 2024	-0,08324	-0.039764254	0.522293921
MAPE			39.08%

Bulan-Tahun	Suhu udara	Suhu udara VECM	$\frac{ y_t - f_t }{y_t}$
Januari 2024	0,878066	0.71963815	0.18042818
Februari 2024	0,698037	0.588296525	0.157212977
Maret 2024	1,102774	1.188580469	0.077809659
April 2024	1,515799	1.738874306	0.147166812
Mei 2024	1,871892	1.882860905	0.005859796
Juni 2024	0,758415	0.72087551	0.049497294
Juli 2024	-0,92779	-1.070612385	0.153938267
Agustus 2024	-0,86125	-0.748576975	0.130824993
September 2024	0,83216	0.81364509	0.022249219
Oktober 2024	2,114442	2.106107733	0.003941592

November 2024	1,617448	1.628744633	0.006984233
Desember 2024	-0,20207	-0.250002433	0.237207072
MAPE			9.78%

Bulan-Tahun	Kelembaban udara	Kelembaban udara VECM	$\frac{ y_t - f_t }{y_t}$
Januari 2024	0,397369	0.417254367	0.050042573
Februari 2024	0,784275	0.752862043	0.040053498
Maret 2024	0,573903	0.588841317	0.026029341
April 2024	0,641893	0.416310038	0.351433903
Mei 2024	-0,77714	-0.610247529	0.214752131
Juni 2024	-0,54383	-0.559011869	0.027916571
Juli 2024	-0,75965	-0.858785344	0.130501341
Agustus 2024	-1,17315	-1.139964415	0.028560585
September 2024	-1,46661	-1.408544834	0.039591416
Oktober 2024	-1,68526	-1.62819421	0.033861713
November 2024	0,003427	0.0105318456	2.073196849
Desember 2024	1,162351	1.139311107	0.019821803
MAPE			25.3%

Bulan-Tahun	Kecepatan angin	Kecepatan angin VECM	$\frac{ y_t - f_t }{y_t}$
Januari 2024	-0,55911	-0.4526187	0.19046574
Februari 2024	-0,84543	-0.90127727	0.066057829
Maret 2024	-0,10334	-0.464584794	3.495691833
April 2024	-0,78312	-0.580725941	0.25844578
Mei 2024	0,219836	0.328804747	0.495681995
Juni 2024	-0,06384	-0.061945519	0.029675454
Juli 2024	0,965633	0.960355146	0.005465693
Agustus 2024	1,338532	1.368647468	0.022498878
September 2024	1,117831	1.367737751	0.223241715
Oktober 2024	0,750181	0.69991934	0.066999377
November 2024	-0,75743	-0.674251558	0.109816672
Desember 2024	-0,56739	-0.811527244	0.430281189
MAPE			44.95%

Bulan-Tahun	Penyinaran matahari	Penyinaran matahari VECM	$\frac{ y_t - f_t }{y_t}$
Januari 2024	-1,03018	-1.505563943	0.461457166
Februari 2024	-0,83785	-0.821760927	0.019202808
Maret 2024	-0,93969	-0.951808075	0.012895822
April 2024	-0,55298	-0.416396016	0.246996246
Mei 2024	0,879811	0.73171125	0.168331323
Juni 2024	0,104003	0.130648107	0.256195562
Juli 2024	0,44935	0.342301809	0.238228977
Agustus 2024	0,742994	0.754442595	0.015386329
September 2024	0,616466	0.63876948	0.036179578
Oktober 2024	0,635977	0.73622704	0.15763155
November 2024	-0,24123	-0.38369542	0.590579198
Desember 2024	-1,937	-1.93507189	0.00099541
MAPE			18.37%

Bulan-Tahun	ONI	ONI VECM	$\frac{ y_t - f_t }{y_t}$
Januari 2024	1,754569	1.73801	0.009437645
Februari 2024	1,440942	1.41326	0.019211044
Maret 2024	1,022772	1.02703	0.004163196
April 2024	0,604603	0.8756	0.448223049
Mei 2024	0,290976	0.28667	0.014798471
Juni 2024	0,081891	0.084457	0.031334335
Juli 2024	-0,12719	-0.23619	0.856985612
Agustus 2024	-0,23174	-0.21567	0.069344956
September 2024	-0,33628	-0.38549	0.146336386
Oktober 2024	-0,44082	-0.49912	0.132253528
November 2024	-0,54536	-0.58785	0.077911838
Desember 2024	-0,6499	-0.59108	0.090506232
MAPE			15.84%

RIWAYAT HIDUP



Mohamad Iqbal Zakaria Putra lahir di Kabupaten Blitar pada 19 Juli 2003, biasa dipanggil Iqbal. Bertempat tinggal di Desa Tunjung, Kecamatan Udanawu, Kabupaten Blitar, Jawa Timur. Penulis memulai pendidikan pertama di TK Al-Hidayah Tunjung pada tahun 2006 dan lulus pada tahun 2009. Penulis melanjutkan pendidikan ke jenjang sekolah dasar di SD Negeri Tunjung 1 dan lulus pada tahun 2015. Setelah lulus sekolah dasar, penulis melanjutkan ke pendidikan jenjang menengah pertama di MTsN 1 Blitar dan lulus pada tahun 2018. Setelah itu, penulis melanjutkan pendidikan jenjang menengah atas di MA Ma'arif Udanawu dan dinyatakan lulus pada tahun 2021. Setelah lulus MA di tahun 2021, penulis melanjutkan pendidikan di salah satu Perguruan Tinggi yang ada di Kota Malang, Jawa Timur yaitu di Universitas Islam Negeri Maulana Malik Ibrahim Malang (UIN Malang). Penulis mengambil Program Studi Matematika, Fakultas Sains dan Teknologi di UIN Malang melalui jalur Seleksi Bersama Masuk Perguruan Tinggi Negeri (SBMPTN) pada tahun 2022. Salah satu mata kuliah wajib yang pernah diikuti oleh penulis adalah Praktik Kerja Lapangan (PKL) di Badan Pusat Statistik (BPS) Kabupaten Tulungagung. Penulis dapat dihubungi melalui email berikut: zakariaiqbal774@gmail.com.



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

BUKTI KONSULTASI SKRIPSI

Nama : Mohamad Iqbal Zakaria Putra
NIM : 220601110079
Fakultas / Jurusan : Sains dan Teknologi / Matematika
Judul Skripsi : Implementasi *Vector Error Correction Model* dalam
Menganalisis Produksi Padi Pasca El-Nino di Jawa Timur
Pembimbing I : Prof. Dr. Hj. Sri Harini, M.Si
Pembimbing II : Juhari, M.Si

No	Tanggal	Hal	Tanda Tangan
1.	2 September 2025	Konsultasi Bab I, II, dan III	1.
2.	4 September 2025	Konsultasi Bab I, II, dan III	2.
3.	10 September 2025	Konsultasi Bab I, II, dan III	3.
4.	23 September 2025	Konsultasi Bab I, II, dan III	4.
5.	1 Oktober 2025	Konsultasi Kajian Agama Bab I dan II	5.
6.	3 Oktober 2025	Konsultasi Bab I, II, dan III	6.
7.	14 Oktober 2025	Konsultasi Bab I, II, dan III	7.
8.	17 Oktober 2025	Konsultasi Bab I, II, dan III	8.
9.	20 Oktober 2025	ACC Bab I, II, dan III	9.
10.	20 Oktober 2025	ACC Kajian Agama Bab I dan II	10.
11.	21 Oktober 2025	ACC Seminar Proposal	11.
12.	11 Februari 2026	Konsultasi Revisi Seminar Proposal	12.
13.	5 Mei 2026	Konsultasi Bab IV dan V	13.
14.	11 Mei 2026	Konsultasi Kajian Agama Bab IV	14.
15.	21 Mei 2026	ACC Bab IV dan V	15.
16.	25 Mei 2026	ACC Kajian Agama Bab IV	16.



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

17.	29 Mei 2026	ACC Seminar Hasil	17.
18.	3 Juni 2026	Konsultasi Revisi Seminar Hasil	18.
19.	5 Juni 2026	Konsultasi Revisi Seminar Hasil	19.
20.	11 Juni 2026	ACC Sidang Skripsi	20.
21.	15 Juni 2026	ACC Keseluruhan	21.

Malang, 15 Juni 2026

Mengetahui,

Ketua Program Studi Matematika



Dr. Fachrur Rozi, M.Si.

NIP. 19800527 200801 1 012