

Implementation Vector Autoregressive (Var) On Rice Production and Rice Productivity Data in Indonesia

Penerapan Vector Autoregressive (Var) Pada Data Produksi Padi Dan Produktivitas Padi Di Indonesia

Putri Indi Rahayu¹, Muhammad Hidayatullah², Muh. Hijrah³

^{1,2,3}Universitas Sulawesi Barat, Indonesia

Email address: ¹⁾ putriindirahayu@unsulbar.ac.id ²⁾ muh.hidayatullah@unsulbar.ac.id

³⁾ muhhijrah@unsulbar.ac.id

Received: 2 January 2023; Accepted: 14 April 2023; Published: 5 May 2023

Abstract

Vector Autoregressive (VAR) is a statistical model used to analyze multivariate time series, especially in time series whose variables have a mutually influencing relationship with time. This study aims to determine the relationship between rice production and rice productivity in Indonesia. The data used in this study is secondary data on rice commodities based on rice production and rice productivity in Indonesia from January 2014 to December 2018. The Augmented Dickey-Fuller method in this study was used to conduct stationary test on the data. The ACF and PACF graphs show that rice commodity data based on rice production and rice productivity can be modeled using VAR. Based on the VAR(1) model, that rice production and rice productivity affect each other. The value of R² and Adjusted R² of each partial equation of the VAR model (1) tend to be small so that the diversity of each equation model cannot be explained by the variables of rice production and rice productivity in Indonesia.

Keywords: Vector Autoregressive, Agriculture, Indonesia

Abstrak

Vector Autoregressive (VAR) adalah suatu model statistik yang digunakan untuk menganalisis deret waktu multivariat, terutama pada deret waktu yang variabel-variabelnya memiliki hubungan yang saling mempengaruhi terhadap waktu. Penelitian ini bertujuan untuk mengetahui hubungan produksi padi dan produktivitas padi di Indonesia. Data yang digunakan pada penelitian ini adalah data sekunder komoditas beras berdasarkan produksi padi dan produktivitas padi di Indonesia dari bulan Januari 2014 sampai dengan Desember 2018. Metode Augmented Dickey-Fuller pada penelitian ini digunakan untuk melakukan uji stasioner pada data. Grafik ACF dan PACF menunjukkan bahwa data komoditas beras berdasarkan produksi padi dan produktivitas padi dapat dimodelkan dengan menggunakan VAR. Berdasarkan model VAR(1), bahwa produksi padi dan produktivitas padi saling mempengaruhi satu



sama lain. Nilai R² dan Adjusted R² tiap persamaan parsial model VAR (1) cenderung kecil sehingga keragaman model masing-masing persamaan belum dapat dijelaskan oleh variabel produksi padi dan produktivitas padi di Indonesia.

Kata kunci: Vector Autoregressive, Pertanian, Indonesia

1. PENDAHULUAN

Analisis deret waktu (time series) merupakan salah satu metode dengan tujuan untuk mengetahui peristiwa yang akan terjadi di masa depan berdasarkan data dan keadaan masa lalu. Dalam pengambilan keputusan meramalkan kejadian yang akan datang merupakan hal yang perlu dilakukan untuk mendukung diambilnya keputusan yang baik, dengan dasar dimana kejadian yang terjadi pada masa ini disebabkan oleh beberapa kejadian pada masa lalu, dengan kata lain analisis deret waktu dilakukan karena terdapat hubungan antara deret waktu pengamatan. Deret waktu merupakan kumpulan nilai observasi variabel pada waktu-waktu yang berbeda. Data deret waktu dikategorikan menurut interval waktu yang sama, baik dalam harian, mingguan, bulanan, kuartalan, ataupun tahunan [4]. Wei [11] menjelaskan bahwa berdasarkan jumlah variabel yang diamati, model deret waktu dapat dibagi menjadi dua, yaitu model deret waktu univariat dan model deret waktu multivariat.

Model deret waktu dibedakan menjadi univariat dan multivariat. Model Moving Average (MA), Autoregressive (AR) dan Autoregressive Moving Average (ARMA) merupakan model deret waktu univariat. Prediksi variabel Y pada model AR berdasarkan nilai Y sebelumnya, sedangkan model MA berdasarkan nilai residual sebelumnya. Notasi model AR untuk orde p adalah $AR_{(p)}$ dan model MA berorde q adalah $MA_{(q)}$. Gabungan model AR dan MA dimana prediksi Y berdasarkan nilai Y dan residual sebelumnya adalah ARMA dengan notasi $ARMA_{(p,q)}$ sedangkan salah satu model deret waktu multivariat adalah *Vector Autoregressive* (VAR) [2].

Pendekatan model VAR akan diterapkan jika struktur model yang ada membuat setiap variabel fungsi sebagai variabel endogen yang merupakan fungsi dari nilai-nilai seluruh variabel yang ada pada sistem sehingga pemodelan VAR tidak perlu menentukan variabel endogen dan variabel eksogen [10]. Beberapa penelitian terkait dengan model VAR adalah (Usman dkk 2020) menggunakan model *Vector Autoregressive* (VAR) untuk meramalkan factor-faktor yang mempengaruhi inflasi di provinsi Gorontalo. Hasil yang diperoleh menunjukkan bahwa model VAR (1) mempunyai kemampuan peramalan yang sangat baik dan diketahui juga sektor inflasi dipengaruhi oleh sektor makanan satu bulan sebelumnya, serta sektor makanan jadi, minuman dan tembakau. Selanjutnya (Putri dkk 2021) menggunakan model *Vector Autoregressive* (VAR) untuk penerapan pada data perkembangan harga eceran beras di tiga ibukota provinsi wilayah pulau jawa. Hasil yang diperoleh model terbaik untuk rata-rata harga beras eceran bulanan di tiga ibukota provinsi pulau jawa adalah VAR (1,1) artinya model VAR orde 1 dengan proses *differencing* pertama. Model ibu kota DKI Jakarta memiliki tingkat signifikansi model tertinggi dengan variabel yang signifikan mempengaruhi adalah selisih rata-rata harga beras eceran bulanan antara periode $ke -t$ dengan periode sebelumnya pada ibu kota DKI Jakarta dan Banten.

Salah satu penerapan model VAR dapat diaplikasikan pada data komoditas beras berdasarkan Produksi Padi (PP) dan Produktivitas Padi (PRP). Padi (*Oryza sativa L.*) merupakan salah satu komoditas pertanian terpenting dalam rantai pasok pertanian. Lebih banyak orang makan beras daripada tanaman lainnya, menjadikan beras sebagai tanaman pangan dunia yang paling signifikan. Asia menghasilkan > 90% dari beras giling dunia, sedangkan untuk sebagian besar penduduk di Asia Tenggara, beras merupakan sumber nutrisi utama [7]. Komoditas beras merupakan komoditas paling penting di Indonesia karena perannya sebagai makanan pokok yang mayoritas setiap

penduduk Indonesia mengkonsumsinya setiap hari sebagai asupan karbohidrat. Tidak hanya itu beras juga merupakan komoditas strategis yang dominan dalam ekonomi Indonesia karena berkaitan erat dengan kebijakan moneter dan menyangkut masalah sosial politik [1].

Mengingat beras merupakan komoditas strategis dan politis maka pemenuhan ketersediaan beras dalam negeri harus selalu terpenuhi. Dalam perkembangannya untuk memenuhi kebutuhan tersebut banyak sekali hal-hal yang mempengaruhi kestabilan ketersediaan dan harga beras ini. Mulai dari kondisi iklim, sistem logistik dan keadaan pasar domestic serta keadaan pasar beras secara internasional.

Hal ini merupakan tantangan nyata bagi Negara untuk terus menjaga stabilitas ketersediaan beras dan keterjangkauan harganya di pasar. Tantangan lainnya menurut Sumaryanto [8] dalam meningkatkan ketersediaan beras adalah pertumbuhan luas panen yang terbatas karena peningkatan luas panen pertanian sangat terbatas mengingat banyaknya konversi lahan pertanian menjadi lahan non pertanian, degradasi sumber daya air dan irigasi, turunnya tingkat kesuburan tanah, dan adanya gejala penurunan produktivitas.

Berdasarkan keterangan diatas, maka diperlukan suatu analisis penerapan model VAR dalam pemodelan komoditas beras berdasarkan produksi padi dan produktivitas padi di Indonesia dengan tujuan untuk mengetahui pemodelan produksi padi dan produktivitas padi di Indonesia menggunakan model Vector Autoregressive (VAR). Hal ini didukung dari hasil penelitian Hossain yang mengatakan bahwa model VAR lebih baik daripada ARIMA untuk meramalkan produksi biji-bijian [3]. Hasil analisis ini diharapkan dapat dijadikan bahan penyusun yang perlu dipertimbangkan oleh pemerintah untuk terus menjaga stabilitas ketersediaan beras dan keterjangkauan harga di pasar.

2. METODE PENELITIAN

Data yang digunakan dalam analisis ini adalah data sekunder mengenai komoditas beras berdasarkan produksi padi dan produktivitas padi di Indonesia, secara bulanan mulai dari bulan Januari 2014 sampai dengan Desember 2018. Data tersebut merupakan data yang dipublikasikan oleh kementerian pertanian [5].

Menurut Wei [11] deret waktu merupakan suatu pengamatan yang tersusun berdasarkan urutan waktu kejadian dengan interval waktu yang sama. Metode deret waktu merupakan salah satu analisis yang mempelajari data deret waktu, baik dari segi teori maupun membuat peramalan. Wei [10] menjelaskan bahwa berdasarkan jumlah variabel yang diamati, model deret waktu dapat dibagi menjadi dua, yaitu:

1. Model deret waktu univariat adalah model deret waktu yang melibatkan satu variabel runtun waktu.
2. Model deret waktu multivariat adalah model deret waktu yang melibatkan lebih dari satu variabel runtun waktu. Deret waktu multivariat merupakan deret waktu yang terdiri dari beberapa variabel yang pada umumnya digunakan untuk memodelkan dan menjelaskan interaksi serta pergerakan diantara sejumlah variabel deret waktu.

Beberapa teknik seperti pemodelan simulasi dan penginderaan jauh sebagian besar digunakan untuk peramalan hasil panen dan areal. Namun terkadang, peramalan dibutuhkan jauh sebelum panen tanaman atau bahkan sebelum penanaman tanaman [9]. Pemodelan deret waktu dengan menggunakan *Vector Autoregressive* (VAR) adalah salah satu metode peramalan untuk data deret waktu multivariat yang sering digunakan karena mudah dan fleksibel jika dibandingkan dengan metode lainnya. Pada metode VAR, variabel eksogen dan endogen tidak dapat dibedakan secara apriori. Model VAR menjadikan semua variabel bersifat endogen. Tahapan dalam pemodelan *Vector Autoregressive* (VAR) dalam analisis ini adalah sebagai berikut :

1. Korelasi

Untuk menerapkan model VAR terlebih dahulu akan dilihat korelasi variabel- variabel yang akan dilibatkan dalam analisis dengan menggunakan rumus sebagai berikut [11]:

$$r = \frac{n \sum xy - \sum x \sum y}{\sqrt{n \sum x^2 - (\sum x)^2} \sqrt{n \sum y^2 - (\sum y)^2}} \quad 2.1$$

dengan :

n = ukuran sampel

x = nilai variabel bebas

y = nilai variabel terikat

2. Stasioneritas Data

Kestasioneran data merupakan kondisi yang diperlukan dalam analisis regresi deret waktu karena dapat memperkecil kekeliruan model, sehingga jika data tidak stasioner, maka harus dilakukan transformasi stasioneritas melalui proses diferensi, jika trendnya linier, sedangkan jika tidak linier, maka transformasinya harus dilakukan dulu transformasi linieritas trend melalui proses logaritma natural jika trendnya eksponensial, dan proses pembobotan (penghalusan eksponensial sederhana) jika bentuknya yang lain, yang selanjutnya proses diferensi pada data hasil proses linieritas. Bentuk kestasioneran ada dua, yaitu stasioner kuat (*strickly stationer*), atau stasioner orde pertama (*primary stationer*) dan stasioner lemah (*weakly stationer*), atau stasioner orde kedua (*secondary stationer*). sedangkan, ketidakstasioner data diklasifikasikan atas tiga bentuk yaitu :

- a. Tidak stasioner dalam rata-rata, jika trend tidak datar (tidak sejajar sumbu waktu) dan data tersebar pada “pita” yang meliputi secara seimbang trendnya.
- b. Tidak stasioner dalam varians, jika trend datar atau hampir datar tapi data tersebar membangun pola melebar atau menyempit yang meliputi secara seimbang trendnya (pola terompet).
- c. Tidak stasioner dalam rata-rata dan varians, jika trend tidak datar dan data membangun pola terompet.

Kestasioneran dalam rata-rata dapat diidentifikasi secara visual, tahap pertama dapat dilakukan pada peta data atas waktu menggunakan plot *time series*, karena biasanya “mudah”, dan jika belum mendapatkan kejelasan, maka tahap berikutnya ditelaah pada gambar *Autocorrelation Function* (ACF) dengan *Partial Autocorrelation Function* (PACF) yang akan dijelaskan selanjutnya. Jika telaahan kestasioneran dalam rata-rata secara “visual” kurang meyakinkan, maka pengujian hipotesis statistis untuk kestasioneran data perlu dilakukan menggunakan Augmented Dickey-Fuller Test [11].

Hipotesis : $H_0: \gamma = 0$ (data bersifat tidak stasioner)
 $H_1: \gamma < 0$ (data bersifat stasioner)

Statistik uji : Augmented Dickey-Fuller Test

$$\tau = \frac{\hat{\gamma}}{se(\hat{\gamma})} \quad 2.2$$

Kriteria Uji :

Tolak H_0 jika $p - value < \alpha$, terima dalam hal lainnya

dengan :

$\hat{\gamma}$ = penaksir kuadrat terkecil dari γ

$se(\hat{y}) =$ standar error dari \hat{y}

Kestasioneran varians dalam model deret waktu dapat dilakukan secara visual dengan menggunakan plot *time series* dengan melihat pola data apakah melebar atau menyempit, sedangkan pengujian stasioner varians dapat dijelaskan dalam bentuk plot *Box-Cox*. Menurut Mulyaningsih [6] jika nilai batas bawah dan batas atas lambda (λ) plot *Box-Cox* dari data deret waktu melalui nilai satu, maka dapat dikatakan bahwa data deret waktu tersebut sudah stasioner dalam varians. Jika varians tidak stasioner dapat diatasi dengan menggunakan transformasi *Box-Cox* pada data deret waktu tersebut.

3. Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF)

Visualisasi ACF dan PACF menggunakan korelogram (*correlogram*) yang dapat digunakan untuk melihat signifikansi autokorelasi dan kestasioneran data. Terlihat pada gambar ACF untuk melihat kestasioneran data adalah jika data tidak stasioner maka gambarnya akan membangun pola:

- Menurun, jika data tidak stasioner dalam rata-rata hitung (trend naik atau turun),
- Alternating*, jika data tidak stasioner dalam varians.
- Gelombang, jika data tidak stasioner dalam rata-rata hitung dan varians.

Konsepsi autokorelasi setara (identik) dengan korelasi pearson untuk data bivariat. Deskripsinya adalah jika dimiliki sampel data deret waktu x_1, x_2, \dots, x_n dan dapat dibangun pasangan nilai $(X_1, X), (X_2, X_{k+2}), \dots, (X_n, X_{k+n})$, autokorelasi lag-k, dari sampel data deret waktu adalah [11]:

$$r = \frac{\sum_{t=1}^{n-k} (X_t - \bar{X})(X_{t+k} - \bar{X})}{\sqrt{\sum_{t=1}^n (X_t - \bar{X})^2}} \quad 2.3$$

dengan :

$X_t =$ pengamatan pada waktu ke t

$\bar{X} =$ rata-rata data ke t

$X_{t+k} =$ data waktu X_{t+k}

karena r_k merupakan fungsi atas k , maka hubungan autokorelasi dengan lagnya dinamakan **Fungsi Autokorelasi (autocorrelation function, ACF)**, berdasarkan persamaan (2.3) dapat dituliskan bentuk ACF sebagai berikut :

$$\rho^{(k)} = \frac{\sum_{t=1}^{n-k} (X_t - \bar{X})(X_{t+k} - \bar{X})}{\sqrt{\sum_{t=1}^n (X_t - \bar{X})^2}} \quad 2.4$$

Konsepsi lain pada autokorelasi adalah **autokorelasi parsial (partial autocorrelation)**, yaitu korelasi antara X_t dengan X_{t+k} , dengan mengabaikan ketidakbebasan $X_{t+1}, X_{t+2}, \dots, X_{t+k-1}$, sehingga X_t dianggap sebagai konstanta, $X_t = x_t, t = t + 1, t + 2, \dots, t + k - 1$. Autokorelasi parsial X_t dengan X_{t+k} didefinisikan sebagai korelasi bersyarat:

$$\rho_{kk} = kor(X_t, X_{t+k}, X_{t+1} = X_{t+1}, X_{t+2} = X_{t+2}, \dots, X_{t+k-1} = X_{t+k-1}) \quad 2.5$$

Seperti halnya autokorelasi yang merupakan fungsi atas lagnya, yang hubungannya dinamakan fungsi autokorelasi (ACF), autokorelasi parsial juga merupakan fungsi atas lagnya, dan hubungannya dinamakan Fungsi Autokorelasi Parsial (*partial autocorrelation function, PACF*). Gambar dari ACF dan PACF (korelogram) untuk menelaah signifikansi autokorelasi adalah jika gambar ACF membangun sebuah histogram yang menurun (pola eksponensial), maka autokorelasi signifikans atau data berautokorelasi, dan jika diikuti oleh gambar PACF yang histogramnya

langsung terpotong pada lag-2, maka data tidak stasioner, dan dapat distasionerkan melalui proses diferensi. Jika hasil telaahan secara “visual” tidak cukup menyakinkan, maka dapat dilakukan pengujian hipotesis statistis untuk keberartian autokorelasi [11].

4. Model *Autoregressive* (AR)

Model *Autoregressive* (AR) adalah suatu model yang menggambarkan bahwa nilai dari proses saat ini (Z_t) masih berhubungan dengan nilai atau data masa lalu. Misalkan nilai Z pada waktu t dinyatakan sebagai kombinasi linear dari nilai-nilai Z pada waktu sebelumnya ditambah error seperti pada persamaan berikut:

$$Z_t = \phi_1 Z(t-1) + \phi_2 Z(t-2) + \dots + \phi_p Z(t-p) + \varepsilon(t) \quad 2.6$$

Ekuivalen dengan

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Z_t = \varepsilon(t) \quad 2.7$$

atau

$$\phi_p(B) Z(t) = \varepsilon(t) \quad 2.8$$

dengan :

ϕ_p = parameter model AR orde p

B = operator backshift

$\varepsilon(t)$ = nilai galat pada saat t

dimana

$$\phi_p(B) = 1 - \sum_{j=1}^p \phi_j B^j, \text{ dan } 1 + \sum_{j=1}^p |\phi_j| < \infty \quad 2.9$$

Untuk kestasioneran, akar dari $1 - \phi_1 B = 0$ harus terletak diluar lingkaran satuan, artinya bahwa apabila $|\phi_j| < 1$ maka proses sudah dikatakan stasioner [11].

5. Model *Vector Autoregressive* (VAR)

Untuk suatu sistem sederhana dengan dua peubah (*bivariate model*) dengan kelambanan satu, model simultan yang dibentuk adalah sebagai berikut:

$$Z_1(t) = \phi_{11} Z_1(t-1) + \phi_{12} Z_2(t-1) + \varepsilon_1(t) \quad 2.10$$

$$Z_2(t) = \phi_{21} Z_1(t-1) + \phi_{22} Z_2(t-1) + \varepsilon_2(t) \quad 2.11$$

dengan asumsi: (1) $Z_1(t)$ dan $Z_2(t)$ stasioner, (2) $\varepsilon_1(t)$ dan $\varepsilon_2(t)$ adalah error dengan simpangan baku $\sigma^2_{Z_1}$ dan $\sigma^2_{Z_2}$, (3) $\varepsilon_1(t)$ dan $\varepsilon_2(t)$ tidak berkorelasi. Kedua persamaan diatas memiliki struktur timbal balik (feedback) karena $Z_1(t)$ dan $Z_2(t)$ saling memberikan pengaruh satu sama lain. Persamaan ini merupakan persamaan VAR struktural. Dengan menggunakan aljabar matriks, kedua sistem diatas dapat dituliskan sebagai berikut:

$$\begin{bmatrix} Z_1(t) \\ Z_2(t) \end{bmatrix} = \begin{bmatrix} \phi_{11} & \phi_{12} \\ \phi_{21} & \phi_{22} \end{bmatrix} \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \end{bmatrix} + \begin{bmatrix} \varepsilon_1(t) \\ \varepsilon_2(t) \end{bmatrix} \quad 2.12$$

Karena peubah-peubah endogen dalam persamaan VAR hanya terdiri dari beda lag semua peubah endogen, kesimultanan bukan suatu persoalan dan pendugaan *Ordinary Least Square* atau metode kuadrat terkecil menghasilkan dugaan yang konsisten [11].

6. Diagnostik Model

a. Uji *Multivariate White Noise Residual*

Hipotesis :

H_0 : $E(\varepsilon_t \varepsilon_{t-1}) = 0$ atau model sudah memenuhi *multivariate white noise*

H_1 : minimal ada satu $E(\varepsilon_t \varepsilon_{t-1}) \neq 0$, atau model belum memenuhi *multivariate white noise*, dengan $I=3,4,\dots,10$

Statistik Uji : Pormanteau Test

$$Q = T = (T + 2) \sum_{h=1}^h \frac{\hat{r}_h^2}{T - h} \quad 2.13$$

dengan:

T = banyaknya sisaan

\hat{r}_h = autokorelasi antar sisaan

h = lag

Kriteria Uji :

Statistik Q untuk model VAR mengikuti sebaran *Chi-Square* dengan derajat bebas $n^2(h-p)$, dimana n = banyaknya peubah dalam VAR, p = orde VAR, h = lag (Eviews, 2002). Jika nilai $p - value > \alpha$ maka tidak tolak H_0 atau model memenuhi syarat *multivariate white noise* [11].

b. Uji *Residual Berdistribusi Multivariate Normal*

Hipotesis :

H_0 : residual berdistribusi normal multivariat residual

H_1 : residual tidak berdistribusi normal multivariat normal residual

Statistik Uji : Multivariat Jarque-Berra (MJB) Test

$$JB = n \frac{(\sqrt{b_1})^2}{6} + \frac{(b_2 - 3)^2}{24} \quad 2.14$$

dengan:

b_1 = kemencengan

b_2 = kurtosis

Kriteria Uji :

Kondisi hipotesis no *Jarque Berra* (JB) memiliki derajat bebas 2. Jika nilai $p - value > \alpha$ maka terima H_0 atau model memenuhi syarat *multivariate normal* [11].

3. HASIL DAN PEMBAHASAN

3.1 Analisis Deskriptif

Sebelum masuk dalam tahap analisis, eksplorasi data secara univariat dilakukan untuk melihat gambaran dari data yang digunakan dalam analisis ini bisa dilihat pada Gambar 3.1 berikut:

Deskriptif Data Produksi Padi						
Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	SD
627	239671	841883	2274767	2488594	13633701	3404615
Deskriptif Data Produktivitas Padi						
Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	SD
19.33	40.22	47.23	45.78	52.15	62.14	9.654356

Gambar 3.1 Deskriptif Data

Analisis awal menunjukkan bahwa rata-rata produksi padi sebesar 22.747,67, dimana rentang nilainya antara 6.27-136.337,01, serta simpangan baku sebesar 34.046,15. Rata-rata produktivitas padi sebesar 45.78, dimana rentang nilainya antara 19.33-62.14, serta simpangan baku sebesar 9.654,356.

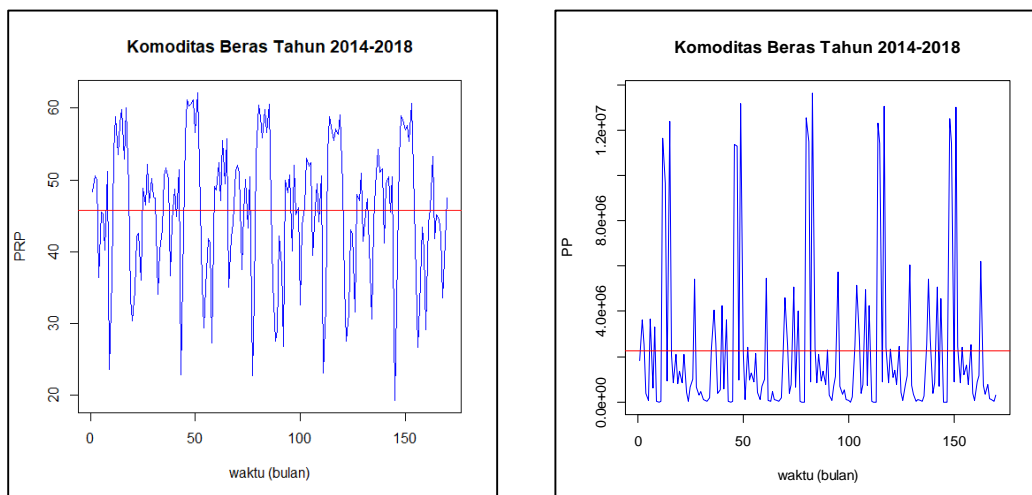
Korelasi Pearson
0.5299061

Gambar 3.2 Korelasi

Berdasarkan Gambar 3.2 menunjukkan bahwa nilai korelasi sebesar 0.5299061 sehingga dapat disimpulkan bahwa antar lokasi saling berkorelasi. Oleh karena itu, penerapan model VAR dapat dilanjutkan.

3.2 Stasioneritas Data

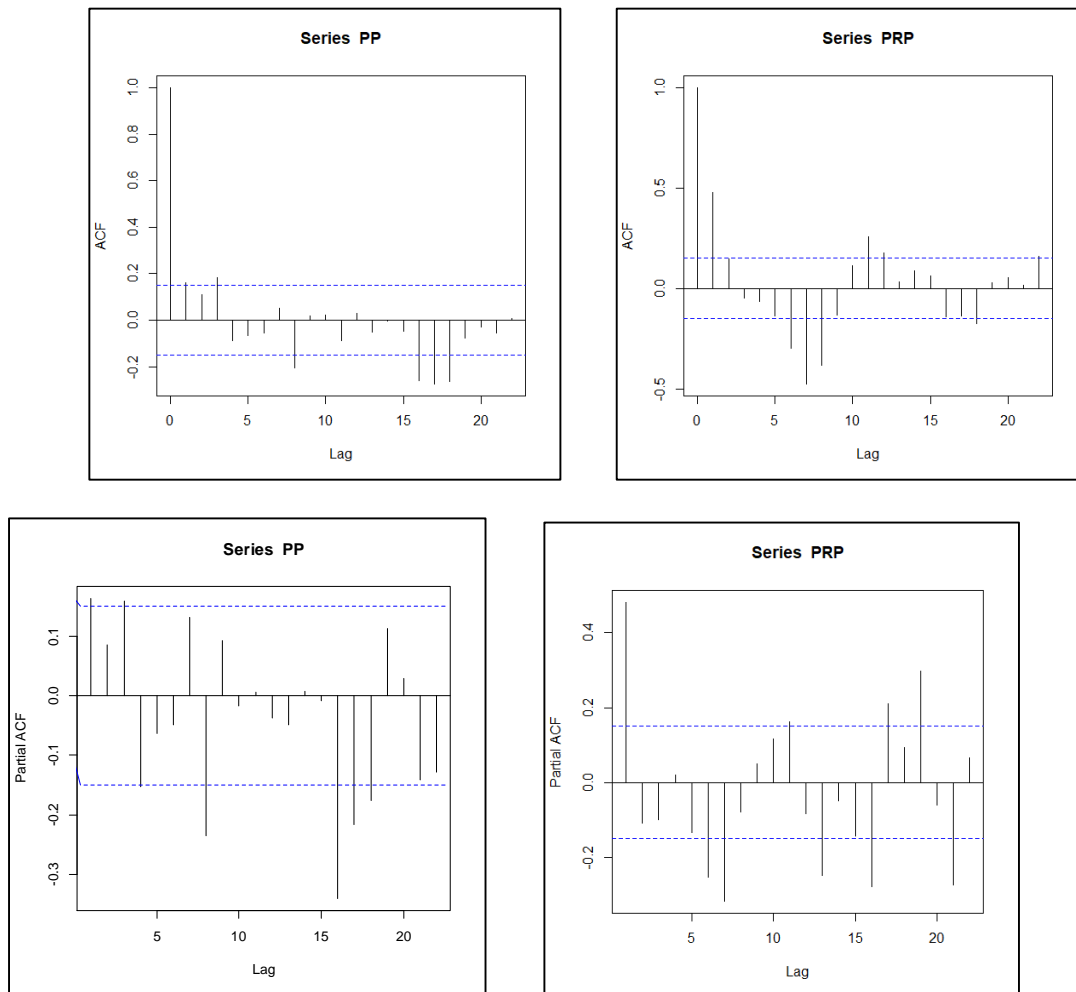
Berikut hasil stasioneritas data komoditas beras untuk variabel produksi padi dan produktivitas padi :

**Gambar 3.3** Komoditas Beras berdasarkan Produksi Padi dan Produktivitas Padi

3.3 ACF dan PACF

Berikut hasil plot ACF dan PACF dari produksi padi dan produktivitas padi yang didapatkan :

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
Putri Indi Rahayu, Muhammad Hidayatullah, Muh. Hijrah



Gambar 3.4 Kolerogram (ACF dan PACF)

Berdasarkan Gambar 3.3 menunjukkan bahwa grafik ACF produksi padi dan produktivitas padi dari lag 1 hingga seterusnya membentuk pola sinus *damped* dan pada grafik PACF produksi padi dan produktivitas padi terlihat pada lag ke-1 memotong garis sehingga dapat dikatakan bahwa data signifikan pada lag ke-1. Hal ini menunjukkan bahwa data komoditas beras berdasarkan produksi padi dan produktivitas padi dapat dimodelkan dengan menggunakan VAR(1).

3.4 Model VAR

Hasil estimasi model VAR (1) untuk produksi padi yang didapatkan sebagai berikut :

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
Putri Indi Rahayu, Muhammad Hidayatullah, Muh. Hijrah

```

Estimation results for equation PP:
=====
PP = PP.l1 + PRP.l1 + const

      Estimate Std. Error t value Pr(>|t|)
PP.l1 -8.471e-02  8.290e-02 -1.022 0.308360
PRP.l1 1.644e+05  2.921e+04  5.629 7.58e-08 ***
const -5.054e+06  1.269e+06 -3.982 0.000102 ***
---|
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 3106000 on 166 degrees of freedom
Multiple R-Squared:  0.1826,    Adjusted R-squared:  0.1727
F-statistic: 18.54 on 2 and 166 DF,  p-value: 5.414e-08

```

Gambar 3.5 Estimasi Produksi Padi

Hasil estimasi model VAR (1) untuk produktivitas padi yang didapatkan sebagai berikut :

```

Estimation results for equation PRP:
=====
PRP = PP.l1 + PRP.l1 + const

      Estimate Std. Error t value Pr(>|t|)
PP.l1 1.854e-09  2.280e-07  0.008  0.994
PRP.l1 4.803e-01  8.032e-02  5.980 1.33e-08 ***
const 2.378e+01  3.490e+00  6.813 1.68e-10 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 8.54 on 166 degrees of freedom
Multiple R-Squared:  0.231,    Adjusted R-squared:  0.2218
F-statistic: 24.94 on 2 and 166 DF,  p-value: 3.39e-10

Covariance matrix of residuals:
      PP  PRP
PP 9.645e+12 1.097e+07
PRP 1.097e+07 7.294e+01

Correlation matrix of residuals:
      PP  PRP
PP 1.0000 0.4135
PRP 0.4135 1.0000

```

Gambar 3.6 Estimasi Produktivitas Padi

Tabel 3.1 Model VAR (1)

Persamaan	Variabel	Koefisien	F- value	(df)	P-value(Simultan)
Produksi Padi	constanta	$-5.054 \cdot e^6$	18.54	2,166	$5.414 \cdot e^{-8}$
	PP _{t-1}	$-8.471 \cdot e^{-2}$			
	PRP _{t-1}	$1.644 \cdot e^5$			
Produktivitas Padi	constanta	$2.378 \cdot e^1$	24.94	2,166	$3.39 \cdot e^{-10}$
	PP _{t-1}	$1.854 \cdot e^{-9}$			
	PRP _{t-1}	$4.803 \cdot e^{-1}$			

Persamaan VAR (1) dapat ditulis sebagai berikut:

$$PP_t = -5.5054 \cdot e^6 - 8.471e^{-2} PP_{t-1} + 1.644 \cdot e^5 PRP_{t-1}$$

$$PRP_t = 2.378 \cdot e^1 + 1.854 \cdot e^{-9} PRP_{t-1} + 4.803 \cdot e^{-1} PP_{t-1}$$

dengan asumsi $\varepsilon_1(t), \varepsilon_2(t) \sim N(\mu, \sigma^2)$

Dengan menggunakan taraf signifikan 10%, diperoleh bahwa kedua persamaan signifikan secara simultan (uji-F). Dua persamaan diatas menunjukkan bahwa variabel yang diamati, yaitu produksi padi dan produktivitas padi di indonesia saling mempengaruhi satu sama lain.

Nilai R^2 dan *Adjusted R²* tiap persamaan parsial model VAR (1) cenderung kecil, yaitu 0.1826% dan 0.1727% untuk produksi padi serta 0.231% dan 0.2218% untuk produktivitas padi. Hal ini menunjukkan bahwa keragaman model masing-masing persamaan parsial belum dapat dijelaskan oleh variabel produksi padi dan produktivitas padi di indonesia, tetapi masih terdapat variabel lain diluar model yang lebih berpengaruh pada penelitian tersebut.

3.5 Diagnostik Model

Diagnostik model perlu dilakukan untuk mengetahui kelayakan model. Diagnostik model yang dilakukan adalah pemeriksaan asumsi *residual*. Model dikatakan layak jika antar residual saling bebas (*white noise*) dan ragam residual mengikuti sebaran normal.

a. Uji Multivariate White Noise Residual

Diagnostik model perlu dilakukan untuk mengetahui kelayakan model. Diagnostik model selanjutnya yang dilakukan adalah pemeriksaan residual berdistribusi multivariat normal.

Portmanteau Test (asymptotic)

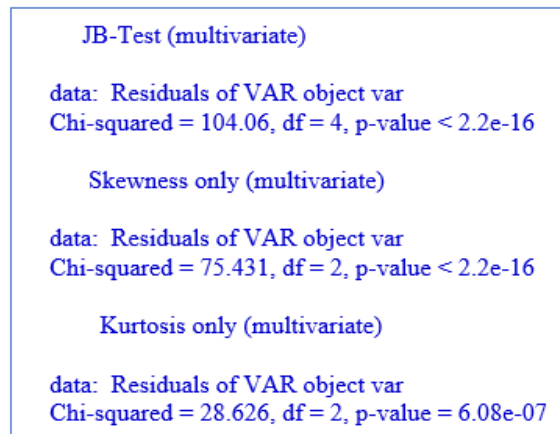
data: Residuals of VAR object var
Chi-squared = 164.36, df = 36, p-value < 2.2e-16

Gambar 3.7 Uji Multivariat White Noise Residual

Dengan taraf signifikansi 10%, hasil pengujian menggunakan Portmanteau Test menunjukkan bahwa H_0 ditolak ($P - value = 2.2 \cdot e^{-16} < 0.10$). Oleh karena itu, dapat disimpulkan bahwa model VAR(1) tidak memenuhi syarat *multivariate white noise*.

b. Uji Residual Berdistribusi Multivariat Normal

Diagnostik model perlu dilakukan untuk mengetahui kelayakan model. Diagnostik model selanjutnya yang dilakukan adalah pemeriksaan residual berdistribusi multivariat normal.



Gambar 3.8 Uji Residual Berdistribusi Multivariat Normal

4. Simpulan

Pemodelan produksi padi dan produktivitas padi menggunakan model VAR(1) diperoleh hasil sebagai berikut:

$$PP_t = -5.5054 \cdot e^6 - 8.471e^{-2} PP_{t-1} + 1.644 \cdot e^5 PRP_{t-1}$$

$$PRP_t = 2.378 \cdot e^1 + 1.854 \cdot e^{-9} PRP_{t-1} + 4.803 \cdot e^{-1} PP_{t-1}$$

Dua persamaan diatas menunjukkan bahwa variabel yang diamati, yaitu produksi padi dan produktivitas padi saling mempengaruhi satu sama lain. Hasil diagnostik model terhadap residual menunjukkan bahwa model VAR(1) belum memenuhi asumsi multivariate white noise dan multivariate normal. Selanjutnya nilai R^2 dan Adjusted R^2 tiap persamaan model VAR(1) cenderung kecil. Hal ini menunjukkan keragaman model masing-masing persamaan secara parsial belum dapat dijelaskan oleh variabel produksi padi dan produktivitas padi, tetapi masih terdapat variabel lain diluar model yang lebih berpengaruh pada periode penelitian tersebut.

DAFTAR PUSTAKA

- [1] Adiratma E. R., 2004. Stop Tanam Padi?. Memikirkan Kondisi Petani Padi Indonesia dan Upaya Meningkatkan Kesejahteraannya. *Penebar Swadaya*, 116 hal.
- [2] Faradhila A., Kusanandar D., & Debatara N.N., 2018. Model Vector Autoregressive (VAR) dalam Meramal Produksi Kelapa Sawit PTPN XIII. *Buletin Ilmiah Math. Stat. dan Terapannya (Bimaster)*, Vol. 07, No. 2, 77-84.
- [3] Hossain M., Khanam M., & Akhter S., 2022. An Econometric Analysis to Forecast the Food Grain Production in Bangladesh by Using ARIMA and VAR Models. *Dhaka University Journal Science*, Vol. 70, No. 1, 8-13.
- [4] Juliodinata A. I., Ahmar A. S. & Tiro M. A., 2019. Metode Vector Autoregressive dalam Menganalisis Pengaruh Kurs Mata Uang, Inflasi, dan Suku Bunga Terhadap Indeks Harga Saham Gabungan. *Journal of Statistics and Its Application on Teaching and Research*, Vol. 1, No. 2, 13-21.

- [5] Kementerian Pertanian Republik Indonesia. <https://www.pertanian.go.id/home/?show=page&act=view&id=61>. [16 Maret 2019]
- [6] Mulyaningsih T., Ruchjana B. N., & Soemartini, 2013. Pendekatan Model Time Series untuk Pemodelan Inflasi Beberapa Kota di Jawa Tengah. Bandung: Universitas Padjadjaran. http://pustaka.unpad.ac.id/wp-content/uploads/2015/01/Makalah-Semnas_Tri-Mulyaningsih_140720131.pdf. [17 Maret 2019]
- [7] Rathod S., Chitikela G., & Bandumula N., 2022. Modeling and Forecasting of Rice Prices in India during the COVID-19 Lockdown Using Machine Learning Approaches. *Agronomy*, Vol. 12, No. 2133, 1-13.
- [7] Rathod S., Chitikela G., & Bandumula N., 2022. Modeling and Forecasting of Rice Prices in India during the COVID-19 Lockdown Using Machine Learning Approaches. *Agronomy*, Vol. 12, No. 2133, 1-13.
- [8] Sumaryanto, 2009. Diversifikasi Sebagai Salah Satu Pilar Ketahanan Pangan. *Forum Penelitian Agro Ekonomi*, Vol. 27, No. 2, 93-108.
- [9] Putri. Z. H. S., dkk., 2021. Model Vector Autoregressive Integrated (VARI) dan Penerapannya Pada Data Perkembangan Harga Eceran Beras Di Tiga Ibukota Provinsi Wilayah Pulau Jawa. *Pattimura Proceeding : Conference of Science and Technology*. Vol. 2014.
- [10] Usman H. H., Djakaria I., & Payu R. M. F., 2020. Pendekatan Model Vector Autoregressive (VAR) untuk meramalkan Faktor-Faktor yang Mempengaruhi Inflasi Di Provinsi Gorontalo. *Jambura Journal Of Probability and Statistics*, Vol. 1, No 1.
- [11] Wei, W. W. S., 2006. *Time Series Analysis*. Addison Wesley: New York.