



TUGAS AKHIR - SS 141501

**PERAMALAN HARGA GABAH KERING PANEN (GKP),
GABAH KERING GILING (GKG) DAN BERAS DI
TINGKAT PRODUSEN JAWA TIMUR DENGAN
PENDEKATAN METODE *UNIVARIATE* DAN
*MULTIVARIATE TIME SERIES***

**YUNAZ FIRDHANI
NRP 1313 105 017**

**Dosen Pembimbing
Dr. Brodjol Sutijo S.U, M.Si**

**Program Studi S1 Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2015**



FINAL PROJECT - SS 141501

**FORECASTING THE PRICE OF DRY HARVEST
GRAIN (DHG), DRY MILLED GRAIN (DMG)
AND MANUFACTURER OF RICE IN EAST JAVA
USING UNIVARIATE AND MULTIVARIATE TIME
SERIES METHOD**

YUNAZ FIRDHANI
NRP 1313 105 017

Supervisor
Dr. Brodjol Sutijo S.U, M.Si

Undergraduate Programme of Statistics
Faculty of Matematics and Natural Sciences
Institut Teknologi Sepuluh Nopember
Surabaya 2015

LEMBAR PENGESAHAN

PERAMALAN HARGA GABAH KERING PANEN (GKP), GABAH KERING GILING (GKG) DAN BERAS DI TINGKAT PRODUSEN JAWA TIMUR DENGAN PENDEKATAN METODE *UNIVARIATE* DAN *MULTIVARIATE TIME SERIES*

TUGAS AKHIR


Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada
Program Studi S-1 Jurusan Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :

YUNAZ FIRDHANI
NRP. 1313 105 017

Disetujui oleh Pembimbing Tugas Akhir :

Dr. Brodjol Sutijo S.U, M.Si
NIP. 19660125 199002 1 001



Mengetahui

Ketua Jurusan Statistika FMIPA-ITS


Dr. Muhammad Mashuri, MT.
NIP. 19620408 198701 1 001

SURABAYA, JULI 2015

**PERAMALAN HARGA GABAH KERING PANEN (GKP),
GABAH KERING GILING (GKG) DAN BERAS DI
TINGKAT PRODUSEN JAWA TIMUR DENGAN
PENDEKATAN METODE UNIVARIATE DAN
MULTIVARIATE TIME SERIES**

Nama Mahasiswa : Yunaz Firdhani
NRP : 1313 105 017
Jurusan : Statistika FMIPA-ITS
Dosen Pembimbing : Dr. Brodjol Sutijo S.U, M.Si

Abstrak

Indonesia merupakan salah satu Negara agraris, yang sebagian besar penduduknya berprofesi sebagai petani. Provinsi Jawa Timur merupakan salah satu provinsi lumbung padi nasional, yang selama ini selalu menjadi tulang punggung produksi beras nasional. Seiring dengan adanya suatu permasalahan masyarakat Indonesia, yakni selalu menjadikan beras sebagai bahan makanan pokok, sehingga kebutuhan akan beras selalu kontinyu, maka perlu dilakukan suatu estimasi peramalan terhadap harga beras, harga gabah kering panen (GKP) dan harga gabah kering giling (GKG). Untuk mengantisipasi terjadinya lonjakan harga yang drastis. Ada dugaan ketiga variabel tersebut saling berpengaruh, permasalahannya adalah bagaimana meramalkan ketiga variabel tersebut secara bersama-sama, maka pemodelan secara multivariat perlu mendapatkan pertimbangan yaitu dengan menggunakan model Vector Autoregressive (VAR). Selain itu metode Autoregressive Integrated Moving Average (ARIMA) juga digunakan dalam penelitian ini, yang selanjutnya akan dibandingkan dengan model VAR. Uji kausal Granger digunakan untuk mengetahui hubungan antar variabel. Hasil yang diperoleh adalah terdapat hubungan kausal dua arah antar harga GKG dan beras. Model peramalan terbaik berdasarkan kriteria out sample menghasilkan bahwa model VARIMA (6,1,0) merupakan model yang sesuai untuk meramalkan harga GKG. Sedangkan untuk harga GKP dan beras lebih sesuai jika menggunakan model ARIMA. Model ARIMA untuk harga GKP adalah ARIMA (0,1,[5,11]) (1,0,0)¹², sedangkan untuk harga beras adalah ARIMA (0,1,1)(1,0,1)¹².

Kata kunci : Harga, ARIMA, VAR, dan Granger Causality.

Halaman ini sengaja dikosongkan

FORECASTING THE PRICE OF DRY HARVEST GRAIN (DHG), DRY MILLED GRAIN (DMG) AND MANUFACTURER OF RICE IN EAST JAVA USING UNIVARIATE AND MULTIVARIATE TIME SERIES METHOD

Name of Student : Yunaz Firdhani
NRP : 1313 105 017
Department : Statistika FMIPA-ITS
Supervisor : Dr. Brodjol Sutijol S.U, M.Si

Abstract

Indonesia is one of the agricultural country, the majority of people work as farmers. East Java Province is one of the national granary province, which has always been the backbone of the national rice production. Along with the existence of a problem in Indonesian society, which always makes the rice as a staple food, so the demand for rice is always continuous, it is necessary to do an estimate of forecasting for price of rice, price of dry harvest grain (DHG) and price of dry milled grain (DMG). To anticipate the surge in prices. There are allegations that these three variables affect each other, the problem is how to predict these three variables together, then the multivariate modeling needs to get consideration, namely by using a Vector Autoregressive models (VAR). In addition the method Autoregressive Integrated Moving Average (ARIMA) is also used in this study, which will then be compared with the VAR model. Granger causality test is used to determine the relationship between variables. The result is a two-way causal relationship exists between the price variable of dry milled grain (DMG) and rice. The best forecasting model based on criteria out sample produce that model VARIMA (6,1,0) is an appropriate model to predict price of dry milled grain (DMG). While price of dry harvest grain (DHG) and rice are more appropriate if using ARIMA models . ARIMA models for the price of dry harvest grain (DHG) is ARIMA (0,1,[5,11]) (1,0,0)¹², while the price of rice is ARIMA (0,1,1)(1,0,1)¹².

Key words : Price, ARIMA, VAR, dan Granger Causality.

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Segala puji hanya milik Allah SWT, berkat limpahan dan rahmat-Nya penulis mampu menyelesaikan Tugas Akhir ini. Shalawat dan salam selalu tercurahkan kepada Rasulullah SAW. Tugas Akhir ini diajukan sebagai syarat untuk menyelesaikan studi Sarjana (S-1) di Jurusan Statistika dengan judul:

“Peramalan Harga Gabah Kering Panen (GKP), Gabah Kering Giling (GKG) Dan Beras Di Tingkat Produsen Jawa Timur Dengan Pendekatan Metode *Univariate* Dan *Multivariate Time Series*”.

Penyelesaian laporan Tugas Akhir ini tidak lepas dari bantuan, arahan, bimbingan, serta dukungan dari berbagai pihak. Dalam kesempatan ini penulis mengucapkan terima kasih yang sedalam-dalamnya kepada :

1. Kedua orang tua dan saudara tercinta yang telah memberikan dukungan, semangat, kasih sayang yang tak terbatas, serta doa yang tak lelah dipanjatkan agar penulis selalu diberikan kelancaran dan kemudahan dalam menyelesaikan Tugas Akhir ini.
2. Bapak Dr. Brodjol Sutijo Suprih Ulama, M.Si selaku dosen pembimbing atas semua bimbingan, waktu, semangat, perhatian, saran dan ilmu yang telah diberikan untuk membimbing penulis dalam menyelesaikan Tugas Akhir ini.
3. Bapak Ir. Dwiatmono Agus W., Mkom dan Dr.rer.pol. Heri Kuswanto, S.Si, M.Si selaku dosen penguji atas kritik, saran dan masukan demi perbaikan Tugas Akhir ini.
4. Ibu Dra. Wiwiek Setya Winahju M.S selaku dosen wali yang telah memberikan motivasi dan bimbingan selama proses perkuliahan.
5. Bapak Dr. Muhammad Mashuri, MT selaku Ketua Jurusan Statistika ITS.
6. Ibu Dra. Lucia Aridinanti, MT selaku Ketua Program Studi Sarjana Statistika ITS.

7. Seluruh Dosen Statistika ITS atas ilmu dan pengalaman yang dibagikan kepada penulis.
8. Segenap pihak yang tidak dapat penulis sebutkan satu persatu. Semoga dukungan serta doa yang diberikan kepada penulis mendapat balasan yang sesuai dari Allah SWT.

Penulis menyadari sepenuhnya bahwa laporan Tugas Akhir ini masih jauh dari sempurna, untuk itu kritik dan saran sangat penulis harapkan. Semoga penelitian ini bermanfaat bagi pembaca.

Surabaya, Juli 2015

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
LEMBAR PENGESAHAN	iii
ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xv
DAFTAR LAMPIRAN	xvii
BAB I PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Permasalahan	4
1.3 Tujuan Penelitian	5
1.4 Manfaat	5
1.5 Batasan Masalah	5
BAB II TINJAUAN PUSTAKA	
2.1 Analisis Deret Waktu.....	7
2.2 Model ARIMA.....	8
2.3 Identifikasi Model	8
2.3.1 Stasioneritas	9
2.3.2 ACF dan PACF	10
2.4 <i>Granger Causality Test</i>	12
2.5 Identifikasi Vektor <i>Time Series</i>	13
2.5.1 Fungsi Matriks Kovarian	13
2.5.2 MACF	15
2.5.3 MPACF	16
2.6 Model <i>Vector Autoregressive</i>	18
2.7 Estimasi dan Uji Signifikansi Parameter	20
2.8 Pemeriksaan Model (<i>Diagnostic Checking</i>).....	21
2.9 Peramalan Model VAR	22

2.10	Pemilihan Model Terbaik	22
2.11	Gabah	24
2.12	Beras	25
BAB III METODOLOGI PENELITIAN		
3.1	Sumber Data	27
3.2	Variabel Penelitian	27
3.3	Metode Analisis Data	27
3.4	Diagram Alir	29
BAB IV ANALISIS DAN PEMBAHASAN		
4.1	Karakteristik Data	31
4.2	Pemodelan Data Secara <i>Univariate</i> (ARIMA)	34
4.3	Pemodelan Data Secara <i>Multivariate</i> (VAR)	44
4.4	Model Peramalan Terbaik	55
4.5	Peramalan	56
BAB V KESIMPULAN DAN SARAN		
5.1.	Kesimpulan	59
5.2.	Saran	59
DAFTAR PUSTAKA		61
LAMPIRAN		63

DAFTAR TABEL

Tabel	Judul	Halaman
2.1	Kriteria Transformasi	9
2.2	Struktur ACF dan PACF	11
4.1	Statistik Deskriptif Dari Variabel	31
4.2	Matriks Korelasi Harga	33
4.3	Nilai Statistik Uji <i>Augmented Dickey-Fuller</i> Sebelum <i>Differencing</i>	37
4.4	Nilai Statistik Uji <i>Augmented Dickey-Fuller</i> Setelah <i>Differencing</i>	38
4.5	Estimasi Parameter Model ARIMA	39
4.6	<i>Diagnostic Check</i> Model ARIMA	39
4.7	Estimasi Parameter Model ARIMA Harga GKG dan Beras dengan <i>Outlier</i>	40
4.8	<i>Diagnostic Check</i> Model ARIMA dengan deteksi <i>Outlier</i>	42
4.9	Perbandingan Kebaikan Model ARIMA dan ARIMA dengan deteksi <i>Outlier</i>	43
4.10	Pengujian Kausalitas <i>Granger</i>	46
4.11	<i>Minimum Information Criterion</i>	48
4.12	Penaksiran Parameter Model VAR(6)	49
4.13	Signifikansi Parameter Model <i>Restrict</i> VAR(6)..	51
4.14	Uji Multivariat Normal	56
4.15	Kriteria <i>In Sample</i>	56
4.16	Kriteria <i>Out Sample</i>	57
4.17	Nilai Ramalan Harga GKP Periode Januari- Desember 2015	58
4.18	Nilai Ramalan Harga GKG Periode Januari- Desember 2015	59
4.19	Nilai Ramalan Harga Beras Periode Januari- Desember 2015	59

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

Gambar	Judul	Halaman
2.1	Plot MACF	16
2.2	Plot MPACF	18
2.3	Skema Konversi dan Rendemen.....	26
3.1	Diagram Alir Penelitian.....	30
4.1	<i>Time Series Plot</i> Tahun Data Ketiga Harga.....	32
4.2	<i>Time Series Plot</i>	34
4.3	Plot <i>Box-Cox</i>	35
4.4	Transformasi Plot <i>Box-Cox</i>	36
4.5	<i>Time Series Plot</i> hasil <i>differencing</i>	38
4.6	Plot Nilai Ramalan Model ARIMA dan Aktual Data <i>in sample</i>	43
4.7	Plot Nilai Ramalan Model ARIMA dan Aktual Data <i>out sample</i>	44
4.8	Skema MACF	47
4.9	Skema MPACF Setelah Dilakukan <i>Differencing</i>	48
4.10	Plot MACF Residual VAR(6)	55
4.11	Plot Nilai Ramalan Model VAR(6) dan Aktual Data <i>in sample</i>	56

Halaman ini sengaja dikosongkan

DAFTAR LAMPIRAN

Lampiran	Judul	Halaman
1	Data Harga GKP, GKG, dan Beras Tingkat Produsen Jawa Timur	65
2	Plot ACF Data Harga GKP, GKG, dan Beras	66
3	Plot ACF dan PACF Data Harga GKP, GKG, dan Beras Setelah <i>Differencing</i>	67
4	Program SAS ARIMA Data Harga Gabah Kering Panen (GKP).....	68
5	Output SAS ARIMA Data Harga Gabah Kering Panen (GKP).....	69
6	Program SAS ARIMA Data Harga Gabah Kering Giling (GKG)	70
7	Output SAS ARIMA Data Harga Gabah Kering. Giling (GKG).....	71
8	Program SAS ARIMA Data Harga Beras	72
9	Output SAS ARIMA Data Harga Beras	73
10	<i>Output</i> SAS model ARIMA dengan deteksi <i>Outlier</i>	74
11	Program SAS VAR (6) <i>restrict</i>	76

Halaman ini sengaja dikosongkan

BAB I

PENDAHULUAN

1.1 Latar Belakang

Sektor pertanian masih menjadi primadona perekonomian di Indonesia, meskipun telah terjadi transformasi struktur ekonomi, dimana perekonomian negara lebih ditopang pada sektor industri dan jasa. Selain dibutuhkan sebagai penyedia pangan nasional, sektor pertanian juga menyerap sebagian besar tenaga kerja. Kurang lebih 18% dari penduduk di Indonesia bekerja di sektor pertanian, sebagian besar dalam skala sangat kecil (ODA, 2014).

Provinsi Jawa Timur merupakan salah satu provinsi lumbung padi nasional, yang diamanahkan pemerintah pusat dapat memenuhi setengah dari total surplus beras nasional 10 juta ton pada tahun 2014. Dinas Pertanian Jatim mengakui jika selama ini Jatim selalu menjadi tulang punggung produksi beras nasional oleh pemerintah pusat (Nasional Republika, 2014). Fungsi Jawa Timur sebagai lumbung padi nasional mengharuskan provinsi ini untuk menyediakan surplus pangan, terutama beras, sebesar lima juta ton terhadap penyediaan beras nasional pada akhir tahun 2014.

Produksi padi sangat tergantung pada iklim dan cuaca. Cuaca yang tidak menentu tiap tahun akibat terimbas dari adanya *global warming*, turut berpengaruh terhadap musim panen padi, jagung, dan sejumlah komoditas lainnya (Morphi, 2012). Ironisnya musim kemarau panjang (El Nino) juga mempengaruhi produksi padi di beberapa kabupaten/kota di Jawa Timur. Sehingga hasil panen di sejumlah daerah mengalami penurunan antara Januari - April 2014 (Pertani, 2014). Hal tersebut menjadi faktor pemicu naik turunnya pasokan dan harga komoditas

sembako, termasuk beras, di sejumlah pasar. Menurut Bulog (2014), dibandingkan harga di awal tahun 2013, situasi harga gabah dan beras dalam negeri di awal tahun 2014 berada pada posisi yang relatif lebih tinggi, sampai dengan Juni 2014 selalu di atas Harga Pembelian Pemerintah (HPP) yang ditetapkan oleh Pemerintah.

Di Indonesia ketersediaan beras diatur oleh Perum BULOG. BULOG merupakan sebuah Perum yang berfungsi untuk penetapan kebijakan dan pembinaan di bidang manajemen logistik sesuai kebijakan umum pemerintah dan peraturan perundang-undangan yang berlaku, selain itu juga berfungsi untuk mengamankan harga dasar pembelian gabah, pendistribusian beras untuk masyarakat miskin. Seiring dengan adanya suatu permasalahan masyarakat Indonesia, yakni selalu menjadikan beras sebagai bahan makanan pokok, maka kelangkaan akan beras menyebabkan tingginya harga beras, sehingga bulog perlu mendapatkan informasi kapan biasanya harga akan naik, karena kebutuhan akan beras selalu menjadi prioritas, oleh karena itu perlu dilakukan suatu estimasi peramalan terhadap harga beras dan harga gabah. Metode yang sering digunakan untuk menyelesaikan data deret waktu seperti ini adalah model *Auto-regressive Integrated Moving Average* (ARIMA). Sehingga dalam penelitian ini akan dilakukan peramalan terhadap harga gabah kering giling (GKG), gabah kering panen (GKP) dan Beras di tingkat produsen Jawa Timur. Hal ini terjadi karena diduga ketiga variabel tersebut mempunyai hubungan yang erat dan saling berpengaruh. Secara teori ekonomi kenaikan harga gabah di tingkat produsen akan diikuti secara proposional oleh kenaikan harga beras tingkat produsen. Jatuhnya harga gabah lokal juga tak terlepas dari membanjirnya beras impor diberbagai daerah, dikarenakan harga beras impor lebih murah dibandingkan beras

lokal, yang akhirnya berpengaruh juga terhadap kenaikan harga gabah di tingkat produsen. Sehingga ketiga variabel harga GKG, GKP, dan beras saling berhubungan, maka pemodelan secara *multivariate* perlu mendapatkan pertimbangan yaitu dengan menggunakan model *Vector Autoregressive* (VAR).

Salah satu pemodelan *time series* yang bersifat *multivariate* adalah model *Vector Autoregressive* (VAR). Beberapa penelitian tentang aplikasi model VAR diantaranya dilakukan oleh Oktiningrum (2014) melalui persamaan model VAR, didapatkan model yang sesuai untuk meramalkan komoditas cabai merah dan cabai rawit di Surabaya adalah VARIMA (5,1,0), dan diketahui bahwa harga komoditas cabe merah dipengaruhi oleh harga komoditas cabe rawit, begitu pula sebaliknya pada wilayah Surabaya. Penelitian oleh Roshita (2013) melalui persamaan model VAR diketahui bahwa, Indeks Harga Saham Gabungan Indonesia dipengaruhi oleh indeks harga saham Amerika dan Jepang. Sedangkan indeks harga saham Amerika tidak dipengaruhi oleh indeks harga saham manapun, namun indeks harga saham Amerika mempengaruhi semua indeks harga saham yang lain. Indeks harga saham London dipengaruhi oleh indeks harga saham Amerika saja, begitu pula dengan indeks harga saham Jepang. Dengan menggunakan metode VAR dapat menangkap hubungan bahwa ada keterkaitan secara simultan. Model VAR telah dikembangkan untuk menjelaskan perilaku ekonomi dan keuangan yang dinamis berdasarkan deret waktu (Wei, 2006).

Penelitian mengenai harga beras pernah dilakukan oleh Zacky (2007), penelitian tersebut membahas peramalan dan faktor-faktor yang mempengaruhi fluktuasi harga beras di beberapa kota besar di pulau Jawa dan Bali, dengan kasus pengendalian harga beras pada Badan Ketahanan Pangan Nasional. Penelitian lain juga dilakukan oleh Morphi (2012)

melalui persamaan model ARIMA, untuk meramalkan harga beras produsen dan konsumen di Kabupaten Sidoarjo dan Banyuwangi. Didapatkan model yang sesuai untuk meramalkan harga beras Produsen adalah ARIMA (0,1,[3,11]) dan ARIMA (0,1,0) untuk masing-masing kabupaten Sidoarjo dan Banyuwangi. Sedangkan ramalan harga beras Konsumen untuk kabupaten Sidoarjo dan Banyuwangi yaitu ARIMA (0,1,[8]) dan ARIMA (0,1,0).

Berdasarkan uraian tersebut, dalam penelitian ini akan dikaji mengenai model peramalan yang sesuai untuk harga beras dan gabah pada wilayah Jawa Timur, dengan mengaplikasikan metode peramalan dengan membandingkan dua pendekatan yaitu metode ARIMA dan metode *Vector Autoregressive* (VAR). Hasil peramalan diharapkan dapat membantu Perum BULOG sebagai acuan dalam memantau setiap perkembangan harga dan mengantisipasi gejolak harga agar tetap stabil.

1.2 Permasalahan

Indonesia merupakan salah satu Negara agraris, yang sebagian besar penduduknya berprofesi sebagai petani. Provinsi Jawa Timur merupakan salah satu provinsi lumbung padi nasional, yang selama ini selalu menjadi tulang punggung produksi beras nasional. Seiring dengan adanya suatu permasalahan masyarakat Indonesia, yakni selalu menjadikan beras sebagai bahan makanan pokok, sehingga kebutuhan akan beras selalu kontinu, maka perlu dilakukan suatu estimasi peramalan terhadap harga beras, harga gabah kering panen (GKP) dan harga gabah kering giling (GKG). Untuk mengantisipasi terjadinya lonjakan harga yang drastis. Ada dugaan ketiga variabel tersebut saling berpengaruh, permasalahannya adalah bagaimana meramalkan ketiga variabel tersebut secara bersama-sama, maka pemodelan secara multivariat perlu mendapatkan pertimbangan yaitu dengan menggunakan model *Vector Autoregressive* (VAR).

Selain itu *metode Autoregressive Integrated Moving Average (ARIMA)* juga digunakan dalam penelitian ini, yang selanjutnya akan dibandingkan dengan model *Vector Autoregressive (VAR)*.

1.3 Tujuan Penelitian

Berdasarkan permasalahan di atas, tujuan penelitian ini adalah untuk mendapatkan model ramalan yang sesuai untuk meramalkan harga gabah kering panen (GKP), harga gabah kering giling (GKG) dan harga Beras di tingkat produsen Jawa Timur.

1.4 Manfaat

Diketahuinya adanya hubungan keterkaitan antara harga gabah kering giling (GKG), gabah kering panen (GKP) dan Beras di tingkat produsen Jawa Timur. Selain itu memberikan informasi berupa alternatif pemodelan ramalan harga gabah kering giling (GKG), gabah kering panen (GKP) dan Beras di tingkat produsen yang dapat digunakan sebagai bahan pertimbangan bagi Perum BULOG untuk menjaga stabilitas harga dan mengantisipasi terjadinya lonjakan harga yang drastis.

1.5 Batasan Masalah

Batasan masalah dalam penelitian ini adalah menggunakan data harga gabah kering giling (GKG), gabah kering panen (GKP) dan Beras tingkat produsen di Perum BULOG Divre Jatim dengan periode waktu bulanan. Model peramalan yang digunakan adalah ARIMA dan *Vector Autoregressive (VAR)*.

Halaman ini sengaja dikosongkan

BAB II LANDASAN TEORI

Pada penelitian ini terdapat 3 variabel dimana metode yang digunakan adalah *Autoregressive Integrated Moving Average* (ARIMA) dan *Vector Autoregressive* (VAR). Pada bagian ini akan dijelaskan secara ringkas beberapa metode dan beberapa teori yang mendukung untuk melakukan analisis ARIMA dan VAR.

2.1 Analisis Deret Waktu (*Time Series*)

Deret waktu (*time series*) merupakan serangkaian pengamatan obyek berdasarkan urutan waktu. Data penelitian yang digunakan tergantung oleh waktu, sehingga terdapat korelasi antara data/kejadian saat ini dengan data dari satu periode sebelumnya. Meskipun berhubungan erat dengan urutan waktu, tidak menutup kemungkinan memiliki hubungan erat dengan dimensi lain seperti ruang. *Time Series* diterapkan di dalam berbagai bidang, seperti pertanian, bisnis dan ilmu sosial (Wei, 2006).

Analisis *multivariate time series* merupakan suatu permodelan *time series* yang digunakan untuk memodelkan dan menjelaskan interaksi, serta pergerakan diantara variabel *time series*. Sama halnya dengan model *univariate time series* (ARIMA), model *multivariate time series* mempunyai beberapa tipe yaitu VAR (*Vector Autoregressive*), VMA (*Vector Moving Average*), VARMA (*Vector Autoregressive Moving Average*), VARI (*Vector Autoregressive Integrated*), VIMA (*Vector Integrated Moving Average*) dan VARIMA (*Vector Autoregressive Integrated Moving Average*). Prinsipnya, identifikasi pada model *time series* multivariat hampir sama dengan univariat. Hal pertama yang perlu dilakukan saat melakukan analisis *time series* adalah stasioneritas data. Pada

identifikasi stasioneritas *time series* multivariat dapat diperiksa dengan melihat plot *Matrix Autocorrelation Function* (MACF) dan *Matrix partial Autocorrelation Function* (MPACF) (Wei, 2006).

2.2 Model ARIMA

Model ARIMA digunakan untuk memodelkan data *time series*. Model ARIMA (p, d, q) yang dikenalkan oleh Box dan Jenkins dengan orde p dari AR, orde d merupakan *differencing*, dan orde q dari MA (Wei, 2006). Bentuk umum dari model ARIMA pada orde ke- p, q dengan proses *differencing* sebanyak d sebagai berikut :

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B)a_t \quad (2.1)$$

dimana fungsi polynomial orde p dari AR yang telah stasioner :

$$\phi_p(B) = (1 - \phi_1 B^1 - \phi_2 B^2 - \dots - \phi_p B^p) \quad (2.2)$$

dan fungsi polynomial dari orde q dari MA yang telah stasioner :

$$\theta_q(B) = (1 - \theta_1 B^1 - \theta_2 B^2 - \dots - \theta_q B^q) \quad (2.3)$$

Bentuk fungsi persamaan model ARIMA musiman adalah :

$$\Phi_P(B^s)(1-B^s)^D Z_t = \Theta_Q(B^s)a_t \quad (2.4)$$

Dengan: $\Phi_P(B^s) = (1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_P B^{Ps})$

orde P pada koefisien komponen AR musiman

$$\Theta_Q(B^s) = (1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs})$$

orde Q pada koefisien komponen MA musiman

Model ini dinotasikan dengan ARIMA (P, D, Q)^s yang mempunyai faktor musiman dalam pengamatan waktu ke- t .

2.3 Identifikasi Model

Pada tahap ini terdapat hal-hal yang harus diperhatikan yaitu kestasioneran data, fungsi autokorelasi dan fungsi autokorelasi parsial.

2.3.1 Stasioneritas

Salah satu asumsi dasar dalam analisis *time series* adalah stasioneritas dalam varians dan rata-rata. Dalam suatu data kemungkinan data tersebut tidak stasioner dalam mean atau varians. Jika vektor data tidak stasioner dalam varians maka dapat distabilkan dengan menggunakan transformasi yaitu transformasi Box-Cox (Wei, 2006). Nilai λ yang sering digunakan dalam transformasi *Box-Cox* sebagai berikut.

Tabel 2.1 Kriteria Transformasi Stasioneritas dalam Varians

Nilai Lambda	Jenis Transformasi
2	$Z_t^* = Z_t^2$
0,5	$Z_t^* = \sqrt{Z_t}$
0	$Z_t^* = \ln Z_t$
-0,5	$Z_t^* = \frac{1}{\sqrt{Z_t}}$
-1	$Z_t^* = \frac{1}{Z_t}$

Data dikatakan stasioner dalam *mean* bila berfluktuasi disekitar garis sejajar dengan sumbu waktu (t) atau disekitar suatu nilai mean yang konstan. Data yang tidak stasioner dalam *mean* perlu dilakukan proses pembedaan (*differencing*).

Differencing pertama :

$$Z_t^* = Z_t - Z_{t-1} = (1 - B)Z_t \quad (2.5)$$

Differencing orde kedua :

$$\begin{aligned} Z_t'' &= Z_t' - Z_{t-1}' \\ &= (Z_t - Z_{t-1}) - (Z_{t-1} - Z_{t-2}) \\ &= Z_t - 2Z_{t-1} + Z_{t-2} \\ &= (1 - 2B + B^2)Z_t = (1 - B)^2 Z_t \end{aligned} \quad (2.6)$$

Secara umum proses pembedaan *differencing* orde ke- d dapat ditulis seperti berikut (Makridarkis dkk, 1999) :

$$W_t = (1-B)^d Z_t \quad (2.7)$$

Selain menggunakan *time series plot* maupun plot autokorelasi, pengecekan kestasioneran terhadap *mean* secara inferensia juga dapat dilakukan menggunakan pengujian *Dickey Fuller*, dimana pengujian ini dilakukan dengan menguji akar-akar unit (*unit roots*). Data yang tidak stasioner dalam *mean* akan mempunyai akar-akar unit, sebaliknya data yang stasioner tidak mengandung akar-akar unit (Wei, 2006).

Hipotesis yang dipaparkan sebagai berikut.

$$H_0 : \phi = 1 \text{ (data mengandung unit root)}$$

$$H_1 : |\phi| < 1 \text{ (data tidak mengandung unit root)}$$

Statistik uji :

$$T_{hitung} = \frac{\hat{\phi} - 1}{S_{\hat{\phi}}} \quad (2.8)$$

dimana :

$S_{\hat{\phi}}$: Standart error dari $\hat{\phi}$

$\hat{\phi}$: Nilai taksiran dari ϕ

H_0 akan ditolak jika T memiliki nilai yang lebih besar dari nilai tabel *Dickey Fuller* dengan df adalah nilai (n, α) . Dengan n adalah jumlah pengamatan dan α adalah taraf signifikan.

2.3.2 Fungsi Autokorelasi (*Autocorrelation Function*) dan Fungsi Autokorelasi Parsial (*Partial Autocorrelation Function*)

Menghitung serta memeriksa sampel ACF dan PACF dari data awal untuk memastikan orde *differencing* yang dibutuhkan agar stasioner dalam *mean*. Jika sampel ACF turun secara lambat dan sampel PACF *cuts off* setelah lag 1, maka dibutuhkan

differencing dalam proses stasioner. *Differencing* awal yang dilakukan *differencing* dengan derajat satu $(1-B)Z_t$.

Umumnya untuk mengatasi ketidakstasioneran suatu *series* memungkinkan untuk mempertimbangkan orde *differencing* yang lebih tinggi $(1-B)^d Z_t$, untuk $d > 0$. Sebagian proses *differencing* orde yang digunakan adalah 0, 1 atau 2. Selanjutnya menghitung serta memeriksa orde p dan q melalui sampel ACF dan PACF dari *series* yang telah ditransformasi dan telah *differencing* dengan derajat yang sesuai untuk mengidentifikasi orde p dan q dimana p adalah orde tertinggi dalam polynomial AR dan q adalah orde tertinggi dari polynomial MA.

Pada umumnya orde p dan q yang diidentifikasi kurang dari sama dengan tiga. Untuk mengidentifikasi model ARIMA, idealnya membutuhkan minimum $n = 50$ observasi dan jumlah dari sampel lag- k ACF dan PACF adalah $\frac{n}{4}$.

Acuan yang sering digunakan untuk menentukan orde p , q , P , dan Q dapat dilihat pada Tabel 2.2 berikut ini.

Tabel 2.2 Struktur ACF dan PACF

Model	ACF	PACF
<i>Autoregressive</i> (p)	Turun eksponensial (<i>dies down</i>)	Terpotong setelah lag p (<i>cuts off after lag-p</i>)
<i>Moving Average</i> (q)	Terpotong setelah lag q (<i>cut off after</i> <i>lag-q</i>)	Turun eksponensial (<i>dies down</i>)
<i>Autoregressive</i> <i>Moving</i> <i>Average</i> (p,q)	Turun eksponensial (<i>dies down</i>) menuju nol setelah lag ($p-q$)	Turun eksponensial (<i>dies down</i>) menuju nol setelah lag ($p-q$)
AR(p) atau MA (q)	Terpotong setelah lag q (<i>cut off after</i> <i>lag-q</i>)	Terpotong setelah lag p (<i>cuts off after lag-p</i>)

(Sumber: Wei, 2006)

2.4 *Granger Causality Test*

Uji kausal *Granger* merupakan suatu metode analisis yang menjelaskan apakah suatu variabel mempunyai hubungan dua arah atau hanya satu arah saja. Uji kausal *Granger* melihat pengaruh masa lalu terhadap kondisi sekarang sehingga sesuai jika digunakan untuk data *time series*. Pada tahun 1969, uji hubungan kausal dikenalkan oleh Clive W. J Granger sehingga disebut *Granger Causality Test*. Secara umum bentuk model dari *Granger Causality* untuk 2 variabel menurut Gujarati (2004) yaitu.

$$Z_{1t} = \sum_{i=1}^m \Phi_i Z_{1t-i} + \sum_{j=1}^m \Phi_j Z_{2t-j} + a_{1t} \quad (2.9)$$

$$Z_{2t} = \sum_{i=1}^m \Phi_i Z_{1t-i} + \sum_{j=1}^m \Phi_j Z_{2t-j} + a_{2t} \quad (2.10)$$

dimana:

Z_{1t-i} : lag dari Z_{1t} , $i= 1, 2, \dots, m$

Z_{2t-j} : lag dari Z_{2t} , $j= 1, 2, \dots, m$

m : panjang lag

a_{1t}, a_{2t} : residual

Hipotesis untuk variabel Z_{1t}

$$H_0 : \sum_{i=1}^m \Phi_i = 0$$

$$H_1 : \sum_{i=1}^m \Phi_i \neq 0$$

Penentuan jumlah lag dapat menggunakan kriteria *Akaike's Information Criterion* (AIC) atau *Schwarz Information Criterion* (SIC) untuk menentukan pilihan (Gujarati, 2004).

Statistik uji yang digunakan pada kausal *Granger* adalah (Enders, 1995) :

$$\chi^2 = (T - c)(\log|\Sigma_r| - \log|\Sigma_u|) \quad (2.11)$$

dimana :

- T : jumlah observasi
 c : jumlah parameter yang diestimasi di model *unrestricted*
 $|\Sigma_r|$: determinan matrik varians kovarian dari residual model *restricted*
 $|\Sigma_u|$: determinan matrik varians kovarian dari residual model *unrestricted*

Tolak H_0 jika nilai statistik uji lebih besar dari $\chi^2_{(2n,1-\alpha)}$.

2.5 Identifikasi Vektor *Time Series*

Pada prinsipnya, identifikasi dari model vektor *time series* mirip dengan model univariate *time series*. Diberikan vektor *time series* $\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_n$ identifikasi yang mendasari model dari penggunaan pola sampel Fungsi Matriks Autokorelasi (MACF) dan Fungsi Matriks Autokorelasi Parsial (MPACF).

2.5.1 Fungsi Matriks Kovarian

Jika $\mathbf{Z}_t = [Z_{1,t}, Z_{2,t}, \dots, Z_{m,t}]'$, $t = 0, \pm 1, \pm 2, \dots$ adalah vektor dari bilangan real berdimensi m dengan rata-rata $E(Z_{i,t}) = \mu_i$ adalah konstan untuk masing-masing $i=1, 2, \dots, m$ dan kovarian antara $Z_{i,t}$ dan $Z_{j,t+k}$ untuk semua $i, j = 1, 2, \dots, m$ yang di-dapatkan vektor rata-rata sebagai berikut.

$$\mathbf{E}(\mathbf{Z}_t) = \boldsymbol{\mu} = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_m \end{bmatrix} \quad (2.12)$$

dan matriks kovarian pada lag- k

$$\boldsymbol{\Gamma}(\mathbf{k}) = \text{Cov}(\mathbf{Z}_t, \mathbf{Z}_{t+k}) = \mathbf{E}[(\mathbf{Z}_t - \boldsymbol{\mu})(\mathbf{Z}_{t+k} - \boldsymbol{\mu})']$$

$$\begin{aligned}
&= E \begin{bmatrix} Z_{1,t} - \mu_1 \\ Z_{2,t} - \mu_2 \\ \vdots \\ Z_{m,t} - \mu_m \end{bmatrix} [Z_{1,t+k} - \mu_1, Z_{2,t+k} - \mu_2, \dots, Z_{m,t+k} - \mu_m] \\
&= \begin{bmatrix} \gamma_{11}(k) & \gamma_{12}(k) & \cdots & \gamma_{1m}(k) \\ \gamma_{21}(k) & \gamma_{22}(k) & \cdots & \gamma_{2m}(k) \\ \vdots & \vdots & \vdots & \vdots \\ \gamma_{m1}(k) & \gamma_{m1}(k) & \cdots & \gamma_{mm}(k) \end{bmatrix} = \mathbf{Cov}(\mathbf{Z}_{t+k}, \mathbf{Z}_t) \quad (2.13)
\end{aligned}$$

Dimana

$$\gamma_{ij}(k) = E(Z_{i,t} - \mu_i)(Z_{j,t+k} - \mu_j) = E(Z_{i,t-k} - \mu_i)(Z_{j,t} - \mu_j) \quad (2.14)$$

Untuk $k = 0, \pm 1, \pm 2, \dots$, $i, j = 1, 2, \dots, m$. Sebagai fungsi dari k , $\mathbf{\Gamma}(k)$ disebut fungsi matrik kovarian untuk proses vektor Z_t , untuk $i = j$, $\gamma_{ij}(k)$ adalah fungsi auto-kovarian untuk komponen ke- i proses $Z_{t,i}$ untuk $i \neq j$, $\gamma_{ij}(k)$ fungsi kovarian antara $Z_{t,i}$ dan $Z_{j,t}$. Matrik $\mathbf{\Gamma}(0)$ mudah dipahami sebagai proses matrik varian-kovarian (Wei, 2006).

$$\begin{aligned}
\mathbf{Var}(\mathbf{Z}_t) &= \mathbf{\Gamma}(0) = \mathbf{Cov}(\mathbf{Z}_t, \mathbf{Z}_{t+k}) \\
&= \mathbf{Cov}(\mathbf{Z}_t, \mathbf{Z}_t)
\end{aligned}$$

Catatan bahwa meskipun $\gamma_k = \gamma_{-k}$ untuk proses skalar (univariat), kesamaan itu tidak dibenarkan pada sebuah vektor (multivariat) (Hamilton, 1994). Contoh menggunakan deret waktu *bivariate* sebagai berikut.

$$\mathbf{\Gamma}(k) \neq \mathbf{\Gamma}(-k)$$

$$\mathbf{Cov}(\mathbf{Z}_t, \mathbf{Z}_{t+k}) \neq \mathbf{Cov}(\mathbf{Z}_t, \mathbf{Z}_{t-k})$$

$$\gamma_{ij}(k) = \mathbf{cov}(\mathbf{Z}_{i,t}, \mathbf{Z}_{j,t+k}) = \mathbf{cov}(\mathbf{Z}_{j,t+k}, \mathbf{Z}_{i,t}) = \mathbf{cov}(\mathbf{Z}_{j,t(-k)}, \mathbf{Z}_{i,t})$$

$$\gamma_{ij}(k) = \gamma_{ji}(-k)$$

Maka, didapatkan fungsi matrik kovarian *bivariate*.

$$\begin{aligned}\Gamma(k) &= \begin{bmatrix} \gamma_{11}(k) & \gamma_{12}(k) \\ \gamma_{21}(k) & \gamma_{22}(k) \end{bmatrix} = \begin{bmatrix} \gamma_{11}(-k) & \gamma_{21}(-k) \\ \gamma_{12}(-k) & \gamma_{22}(-k) \end{bmatrix} \\ &= \Gamma'(-k)\end{aligned}\quad (2.15)$$

Sehingga pada deret waktu *bivariate*, fungsi matrik kovarian pada lag ke-k sama dengan *transpose* fungsi matriks kovarian pada lag $(-k)$, $\Gamma(k) = \Gamma'(-k)$.

2.5.2 Matrix Autocorrelation Function (MACF)

Jika terdapat sebuah vektor *time series* dengan observasi sebanyak n , yaitu Z_1, Z_2, \dots, Z_n , jadi sampel fungsi korelasi dapat dinyatakan sebagai berikut (Wei, 2006).

$$\hat{\rho}(k) = \left[\hat{\rho}_{ij}(k) \right], \quad (2.16)$$

dimana $\hat{\rho}_{ij}(k)$ merupakan korelasi silang sampel untuk komponen *series* ke- i dan ke- j yang dinyatakan dalam persamaan berikut,

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Z_{i,t} - \bar{Z}_i)(Z_{j,t+k} - \bar{Z}_j)}{\left[\sum_{t=1}^n (Z_{i,t} - \bar{Z}_i)^2 \sum_{t=1}^n (Z_{j,t} - \bar{Z}_j)^2 \right]^{1/2}} = \frac{\gamma_k}{\gamma_0} \quad (2.17)$$

dan \bar{Z}_i dan \bar{Z}_j merupakan rata-rata sampel dari komponen *series* yang bersesuaian.

Persamaan matriks korelasi sampel ini sangat berguna untuk menentukan orde dalam *moving average* (MA). Akan tetapi bentuk matriks dan grafik akan semakin kompleks seiring meningkatnya dimensi vektor. Berikut adalah contoh pola MACF pada output *software* SAS yang ditunjukkan pada Gambar 2.1

Schematic Representation of Cross Correlations																			
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
z1		++	.+	+	+
z2		+++	+	+
z3		+

+ is > 2*std error, - is < -2*std error, . is between

Gambar 2.1 Plot MACF

Box dan Tiao (1981) dalam Wei (2006) memperkenalkan sebuah metode koefisien untuk meringkas sampel korelasi. Metode ini menggunakan symbol (+), (-), dan (.) pada baris ke- i dan kolom ke- j pada matrik sampel korelasi, dimana telah ditunjukkan pada Gambar 2.1.

- 1) Simbol (+) menunjukkan bahwa nilai $\hat{\rho}_{ij}(k)$ lebih besar dari 2 kali nilai estimasi *standard error* (SE), yang artinya bahwa komponen (i, j) memiliki korelasi positif.
- 2) Simbol (-) menunjukkan bahwa nilai $\hat{\rho}_{ij}(k)$ lebih kecil dari -2 kali nilai estimasi *standard error* (SE), yang artinya bahwa komponen (i, j) memiliki korelasi negative.
- 3) Simbol (.) menunjukkan bahwa nilai $\hat{\rho}_{ij}(k)$ yang terletak diantara -2 sampai 2 dari nilai estimasi *standard error* (SE), artinya bahwa komponen (i, j) memiliki korelasi.

2.5.3 Fungsi Matriks Korelasi Parsial (MPACF)

Dalam *univariate time series*, fungsi autokorelasi parsial dapat digunakan untuk mengidentifikasi orde dari model AR(p), dimana $\Phi_{kk} = 0$ untuk $|k| > p$, begitu pula dengan matriks korelasi parsial secara *multivariate*. *Partial lag correlation matrix* digunakan untuk mengidentifikasi model vektor AR(p).

$$\begin{aligned} \mathbf{u}_{s-1,t+s} &= \mathbf{Z}_{t+s} - \boldsymbol{\alpha}_{s-1,1} \mathbf{Z}_{t+s-1} - \dots - \boldsymbol{\alpha}_{s-1,s-1} \mathbf{Z}_{t+1} \\ &= \begin{cases} \mathbf{Z}_{t+s} - \sum_{k=1}^{s-1} \boldsymbol{\alpha}_{s-1,k} \mathbf{Z}_{t+s-k}, & s \geq 2, \\ \mathbf{Z}_{t+1}, & s = 1, \end{cases} \end{aligned} \quad (2.18)$$

dan

$$\mathbf{v}_{s-1,t} = \mathbf{Z}_t - \boldsymbol{\beta}_{s-1,1} \mathbf{Z}_{t+1} - \dots - \boldsymbol{\beta}_{s-1,s-1} \mathbf{Z}_{t+s-1} \quad (2.19)$$

$$= \begin{cases} \mathbf{Z}_t - \sum_{k=1}^{s-1} \boldsymbol{\beta}_{s-1,k} \mathbf{Z}_{t+k}, & s \geq 2, \\ \mathbf{Z}_t, & s = 1. \end{cases} \quad (2.20)$$

Kovarian antara $\mathbf{v}_{s-1,t}$, $\mathbf{u}_{s-1,t+s}$ adalah

$$\begin{aligned} \text{Cov}(\mathbf{v}_{s-1,t}, \mathbf{u}_{s-1,t+s}) &= E[(Z_t - \beta(s)Z_{t+1})(Z_{t+s} - \alpha(s)Z_{t+1})'] \\ &= \Gamma(s) - \mathbf{b}'(s)[\mathbf{A}(s)]^{-1}\mathbf{c}(s) \\ &= \Gamma(s) - \mathbf{b}'(s)\boldsymbol{\alpha}'(s). \end{aligned}$$

$\mathbf{V}_{\mathbf{u}(s)}$ adalah $\text{var}(\mathbf{u}_{s-1,t+s})$, $\mathbf{V}_{\mathbf{v}(s)}$ adalah $\text{var}(\mathbf{v}_{s-1,t+s})$, dan $\mathbf{V}_{\mathbf{vu}(s)}$ adalah $\text{cov}(\mathbf{v}_{s-1,t}, \mathbf{u}_{s-1,t+s})$. Heyse dan Wei (1985a, b) dalam buku Wei (2006) mendefinisikan *partial lag autocorrelation matrix* pada lag s sebagai berikut.

$$\mathbf{P}(s) = [\mathbf{D}_v(s)]^{-1} \mathbf{V}_{vu}(s) [\mathbf{D}_u(s)]^{-1}, \quad (2.21)$$

dengan $\mathbf{D}_v(s)$ adalah diagonal matrik dimana elemen diagonal ke- i adalah akar elemen diagonal ke- i dari $\mathbf{V}_{\mathbf{v}(s)}$ dan $\mathbf{D}_u(s)$ didefinisikan sama dengan $\mathbf{V}_{\mathbf{u}(s)}$. Menggunakan persamaan Quenouille (1957, p. 41) dan Hannan (1970, p. 400) bahwa elemen $\hat{P}(s)$ dinotasikan $\hat{P}_{ij}(s)$.

Schematic Representation of Partial Cross Correlations	
	Variable
/Lag	1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18
z1	... -+ -.. -.. -..+. .+. ..+ ...
z2	-+ .-.. -.. ..+ ... -.. ... -.. -.. -..
z3 -..+ +.. -.. -+ +.-
	+ is > 2*std error, - is < -2*std error, . is between

Gambar 2.2 Plot MPACF

Berdasarkan Gambar 3.2 simbol (+) menjelaskan bahwa untuk nilai $\hat{P}_{ij}(s)$ lebih besar dari $2/\sqrt{n}$, simbol (-) untuk nilai lebih kecil dari $-2/\sqrt{n}$, dan simbol (.) untuk nilai antara $-2/\sqrt{n}$ dan $2/\sqrt{n}$.

2.6 Model *Vector Autoregressive*

Salah satu pemodelan dalam analisis *time series* yang bersifat *multivariate* adalah model *Vector Autoregressive* (VAR). Dalam melakukan pemodelan *time series*, sebelum mengidentifikasi model yang sesuai untuk data *time series*, data tersebut haruslah stasioner terlebih dahulu, baik dalam *mean* maupun varians. Jika data *time series* tidak stasioner terhadap varians maka perlu dilakukan transformasi *Box-cox* sedangkan jika data tidak stasioner dalam *mean* maka perlu dilakukan *differencing* pada data tersebut (Wei, 2006).

Persamaan untuk model VAR(1) pada 3 variabel dapat juga dituliskan dengan bentuk sebagai berikut.

$$Z_{1t} = c_1 + \phi_{11}Z_{1,t(t-1)} + \phi_{12}Z_{2,t(t-1)} + \phi_{13}Z_{3,t(t-1)} + a_{1t}$$

$$Z_{2t} = c_2 + \phi_{21}Z_{1,t(t-1)} + \phi_{22}Z_{2,t(t-1)} + \phi_{23}Z_{3,t(t-1)} + a_{2t}$$

$$Z_{3t} = c_3 + \phi_{31}Z_{1,t(t-1)} + \phi_{32}Z_{2,t(t-1)} + \phi_{33}Z_{3,t(t-1)} + a_{3t}$$

Keterangan :

Z_{1t} : variabel pertama pada pengamatan waktu ke-t

Z_{2t} : variabel kedua pada pengamatan waktu ke-t

Z_{3t} : variabel ketiga pada pengamatan waktu ke-t

- c : konstanta
 ϕ_{11} : koefisien pada persamaan pertama (Z_{1t}) variabel $Z_{1,t}$
 ϕ_{12} : koefisien pada persamaan pertama (Z_{1t}) variabel $Z_{2,t}$
 ϕ_{13} : koefisien pada persamaan pertama (Z_{1t}) variabel $Z_{3,t}$
 ϕ_{21} : koefisien pada persamaan kedua (Z_{2t}) variabel $Z_{1,t}$
 ϕ_{22} : koefisien pada persamaan kedua (Z_{2t}) variabel $Z_{2,t}$
 ϕ_{23} : koefisien pada persamaan kedua (Z_{2t}) variabel $Z_{3,t}$
 ϕ_{31} : koefisien pada persamaan ketiga (Z_{3t}) variabel $Z_{1,t}$
 ϕ_{32} : koefisien pada persamaan ketiga (Z_{3t}) variabel $Z_{2,t}$
 ϕ_{33} : koefisien pada persamaan ketiga (Z_{3t}) variabel $Z_{3,t}$
 a_{1t} : error pada persamaan pertama (Z_{1t}) pada waktu ke- t
 a_{2t} : error pada persamaan kedua (Z_{2t}) pada waktu ke- t
 a_{3t} : error pada persamaan ketiga (Z_{3t}) pada waktu ke- t
 t : indeks waktu

Dapat juga ditulis persamaan dalam bentuk matriks sebagai berikut.

$$\begin{bmatrix} Z_{1t} \\ Z_{2t} \\ Z_{3t} \end{bmatrix} = \begin{bmatrix} c_1 \\ c_2 \\ c_3 \end{bmatrix} + \begin{bmatrix} \phi_{11} & \phi_{12} & \phi_{13} \\ \phi_{21} & \phi_{22} & \phi_{23} \\ \phi_{31} & \phi_{32} & \phi_{33} \end{bmatrix} \begin{bmatrix} Z_{1,t(t-1)} \\ Z_{2,t(t-1)} \\ Z_{3,t(t-1)} \end{bmatrix} + \begin{bmatrix} a_{1t} \\ a_{2t} \\ a_{3t} \end{bmatrix}$$

Secara umum persamaan model VAR (p) dapat ditulis sebagai berikut.

$$\dot{Z}_t = \Phi_1 \dot{Z}_{t-1} + \dots + \Phi_p \dot{Z}_{t-p} + a_t \quad (2.22)$$

Keterangan :

\dot{Z}_t = vektor variabel Z pada waktu ke- t

Φ_1 = matrik koefisien parameter pada ke-1

Φ_p = matrik koefisien parameter pada ke- p ($p = 1, 2, \dots, p$)

a_t = vektor nilai residual pada waktu ke- t ($t = 1, 2, \dots, h$)

2.7 Estimasi dan Uji Signifikansi Parameter

Setelah dilakukan identifikasi model dan diketahui orde dari *vector autoregressive*, maka langkah selanjutnya adalah melakukan estimasi parameter model *vector autoregressive*. Salah satu metode estimasi yang dapat digunakan adalah metode *Least Square*. Menurut (Cryer & Chan, 2008) metode ini bekerja dengan cara meminimumkan jumlah kuadrat error (S_c).

Hipotesis :

$$H_0 : \Phi_k = 0 \text{ untuk semua } k, k=1,2, \dots, p$$

$$H_0 : \Phi_k \neq 0 \text{ untuk setiap } k$$

$$Z_t = \tau + \Phi_1 Z_{t-1} + \dots + \Phi_p Z_{t-p} + a_t \quad (2.23)$$

τ merupakan vektor konstanta. Jika terdapat n observasi, untuk $t = p+1, \dots, n$, sedangkan p adalah orde dari VAR diperoleh:

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e} \quad (2.24)$$

dimana

$$\mathbf{Y} = \begin{bmatrix} Z_{p+1} \\ \vdots \\ Z_n \end{bmatrix}, \mathbf{X} = \begin{bmatrix} 1 & Z_p & \dots & Z_1 \\ \vdots & \vdots & & \vdots \\ 1 & Z_{n-1} & \dots & Z_{n-p} \end{bmatrix}, \boldsymbol{\beta} = \begin{bmatrix} \tau \\ \Phi_1 \\ \vdots \\ \Phi_p \end{bmatrix},$$

$$\text{dan } \mathbf{e} = \begin{bmatrix} a_{t,p+1} \\ a_{t,p+2} \\ \vdots \\ a_{t,n} \end{bmatrix} \quad (2.25)$$

Maka, penaksir koefisien regresi dengan pendekatan OLS untuk $\hat{\boldsymbol{\beta}}$ dan $\hat{\boldsymbol{\Sigma}}$ adalah sebagai berikut :

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}\mathbf{X})^{-1}\mathbf{X}\mathbf{Y} \quad (2.26)$$

$$\hat{\boldsymbol{\Sigma}} = \frac{(\mathbf{Y}-\mathbf{X}\hat{\boldsymbol{\beta}})'(\mathbf{Y}-\mathbf{X}\hat{\boldsymbol{\beta}})}{N} \quad (2.27)$$

2.8 Pemeriksaan Model (*Diagnostic Checking*)

Pemeriksaan model (*diagnostic checking*) pada *vector autoregressive* terdiri dari beberapa langkah seperti berikut.

1. Uji *Multivariate* Normal Residual

Hipotesis yang digunakan untuk pengujian multivariat normal adalah sebagai berikut:

$H_0 = X_1, X_2, \dots, X_n$ berdistribusi multivariat normal

$H_1 = X_1, X_2, \dots, X_n$ tidak berdistribusi multivariat normal

Statistik uji yang digunakan adalah Shapiro Wilk Test dengan rumus penghitungan sebagai berikut (Shapiro&Wilk, 1965):

$$W = \frac{\left(\sum_{i=1}^n \alpha_i X_i \right)^2}{\sum_{i=1}^n (X_i - \bar{X})^2}, \quad (2.28)$$

dimana :

X_i = Observasi ke-i

\bar{X} = Rata-rata observasi ke-i

koefisien α_i dinyatakan sebagai berikut:

$$\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_n] = \mathbf{m}' \mathbf{V}^{-1} \left[\mathbf{m}' \mathbf{V}^{-1} \mathbf{V}^{-1} \mathbf{m} \right]^{-\frac{1}{2}},$$

dimana $\mathbf{m} = E[X_{(1)}, X_{(2)}, \dots, X_{(n)}]$ dan $\mathbf{V} = [\text{cov}(X_{(i)}, X_{(j)})]$

tolak H_0 jika W memiliki nilai yang lebih kecil dari nilai koefisien Shapiro Wilk α_{n-i+1} .

2. *White Noise*

Setelah diperoleh model dengan semua parameter telah signifikan, selanjutnya dilakukan cek diagnose, yaitu pengujian *White-Noise* (Wei, 2006). Residual dikatakan *White-Noise* jika memenuhi dua sifat yaitu identik (mempunyai varians yang konstan) dan independen (antar residual tidak saling berkorelasi) dengan *mean nol*. Untuk menguji asumsi ini dapat dilakukan dengan menggunakan uji *Ljung-Box*. Hipotesis yang digunakan dalam pengujian ini adalah sebagai berikut.

$$\begin{aligned} H_0 &= \rho_1 = \rho_2 = \rho_3 = \dots = \rho_k = 0 \\ H_1 &= \rho_j \neq 0 \end{aligned}$$

Statistik uji yang digunakan oleh pengujian ini adalah *Ljung-Box* seperti pada persamaan berikut (Wei, 2006).

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2 \quad (2.29)$$

dengan n adalah banyak pengamatan dan $\hat{\rho}_k$ menunjukkan MACF residual pada lag ke- k . Tolak H_0 jika nilai $Q > \chi_{(1/\alpha); df=K-m}^2$ dengan m adalah banyaknya parameter atau dengan menggunakan *p-value*, yakni tolak H_0 jika *p-value* $< \alpha$.

2.9 Peramalan Model VAR

Untuk sebuah model VAR (p), peramalan k tahap kedepan pada waktu awal yang sama yaitu (Tsay, 2002).

$$Z_h(k) = \phi_0 + \sum_{t=1}^p \Phi Z_{k+k-t} \quad (2.30)$$

Sedangkan untuk peramalan 1 tahap kedepan dirumuskan sebagai berikut.

$$Z_h(1) = \phi_0 + \sum_{t=1}^p \Phi Z_{k+1-t} \quad (2.31)$$

Untuk menghasilkan peramalan 1 tahap kedepan, setiap data terbaru dimasukkan dalam model dan hanya untuk meramalkan data pada $t+1$.

2.10 Pemilihan Model Terbaik

Untuk menentukan model terbaik dari beberapa model terpilih dapat digunakan kriteria *in-sample* dan kriteria *out-sample*. Beberapa kriteria *in-sample* antara lain AIC (*Akaike's Information Criterion*) dan, sedangkan kriteria *out-sample* meliputi *Mean Absolute*

Percentage Error (MAPE) dan *Root Mean Square Error* (RMSE). Berikut adalah penjelasan rumusan kriteria model terbaik.

1. *AIC (Akaike's Information Criterion)*

Diasumsikan suatu model statistik dengan M parameter sebagai penduga dari data. Penaksiran kualitas dari model dugaan dapat menggunakan AIC dengan perumusan sebagai berikut.

$$AIC(p) = \ln |\hat{\Sigma}| + \frac{2pm^2}{n} \quad (2.32)$$

Model VAR(p) dengan order ke- p dengan ukuran sampel n , sedangkan m adalah derajat bebas dalam model dan $|\hat{\Sigma}|$ adalah estimasi matriks varians kovarian.

2. *MAPE (Mean Absolute Percentage Error)*

MAPE dihitung dengan menggunakan kesalahan absolut dibagi dengan nilai observasi pada tiap periode. Kemudian, merata-rata kesalahan persentase absolut tersebut. Pendekatan ini berguna ketika ukuran atau besar variabel ramalan itu penting dalam mengevaluasi ketepatan ramalan.

Untuk mengetahui besarnya nilai MAPE digunakan rumus sebagai berikut :

$$MAPE_{\text{outsample}} = \frac{1}{n} \sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{Z_t} \times 100\% \quad (2.33)$$

dan

$$MAPE_{\text{in sample}} = \frac{1}{n-p} \sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{Z_t} \times 100\% \quad (2.34)$$

3. *RMSE (Root Mean Square Error)*

RMSE adalah suatu pengukuran akurasi yang baik, tetapi hanya untuk membandingkan error peramalan dari model yang berbeda untuk variabel yang khusus dengan variabel yang lain sebagai skala dependen (Hyndman, 2006). Perumusan kriteria RMSE

diperoleh dari akar *Mean Square Error* (MSE) yang dinyatakan sebagai berikut.

$$\text{RMSE}_{\text{outsample}} = \sqrt{\frac{\sum_{t=1}^n (Z_t - \hat{Z}_t)^2}{n}} \quad (2.35)$$

dan

$$\text{RMSE}_{\text{in sample}} = \sqrt{\frac{\sum_{t=1}^n (Z_t - \hat{Z}_t)^2}{n - p}} \quad (2.36)$$

dengan n merupakan banyak ramalan yang dilakukan dan p merupakan banyak parameter yang ditaksir.

2.11 Gabah

Padi/gabah/beras merupakan komoditas vital bagi Indonesia, sehingga pemerintah memberlakukan regulasi harga dalam perdagangan gabah. Muncullah istilah-istilah khusus yang mengacu pada kualitas gabah sebagai referensi penentuan harga (Albertdin, 2010).

- i. Gabah Kering Panen (GKP) adalah hasil tanaman padi yang telah dilepas dari tangkainya dengan cara perontokkan, dikeringkan, dan dibersihkan yang memiliki kadar air maksimum 25%, butir hampa/kotoran maksimum 10%, butir kuning/rusak maksimum 3%, butir hijau/mengapur maksimum 10% dan butir merah maksimum 3%.
- ii. Gabah Kering Giling (GKG) adalah hasil tanaman padi yang telah dilepas dari tangkainya dengan cara perontokkan, dikeringkan, dan dibersihkan yang memiliki kadar air maksimum 14%, butir hampa/kotoran maksimum 3%, butir kuning/rusak maksimum 3%, butir hijau/mengapur maksimum 5% dan butir merah maksimum 3%.

Mekanisme penentuan harga gabah kering panen (GKP) dan gabah kering giling (GKG) adalah sebagai berikut (Asran, 2015).

- Kondisi awal dari bahan gabah kering panen (GKP) kemudian dilakukan konversi dari GKP ke GKG sebesar 80,64%, dari kondisi awal GKP susut pasca panen setelah adanya perlakuan (perontokan, pembersihan, jemur, dan pengangkutan) sebesar 10,82%. Berdasarkan inpres (instruksi presiden) No. 5 / 2015 dengan harga GKP sebesar Rp 3.750/kg, setelah dilakukan konversi dan rendemen maka didapatkan harga GKG sebesar Rp 4.650/kg, dengan perhitungan harga GKP dibagi dengan nilai konversi dari bahan awal GKP ke GKG ($\text{Rp } 3.750 / 80,64\% = \text{Rp } 4.650$).


2.12 Beras

Beras adalah hasil utama dari proses penggilingan gabah, hasil tanaman padi yang seluruh lapisan sekamnya terkelupas, atau sebagian lembaga dan katul telah dipisahkan (Albertdin, 2010).

Mekanisme penentuan harga beras berdasarkan harga gabah kering panen (GKP) dan gabah kering giling (GKG) sebagai berikut (Asran, 2015).

- Kondisi awal dari bahan gabah kering panen (GKP) kemudian dilakukan konversi dari GKP ke beras sebesar 50,68%, jika dilakukan konversi dari bahan GKG ke beras yaitu sebesar 63,69%. Dari kondisi awal GKG susut pasca penggilingan sebesar 3,25%. Berdasarkan inpres (instruksi presiden) No. 5 / 2015 setelah dilakukan konversi dan rendemen maka didapatkan harga beras sebesar Rp 7.300/kg, dengan perhitungan harga GKP dibagi dengan nilai konversi dari bahan awal GKP ke beras ($\text{Rp } 3.750 / 50,68\% = \text{Rp } 7.300$). Jika perhitungan harga beras berdasarkan konversi dan rendemen dari GKG maka perhitungannya menjadi, harga GKG dibagi dengan nilai konversi dari bahan awal GKG ke beras ($\text{Rp } 4.650 / 63,69\% = \text{Rp } 7.300$).

Berikut merupakan skema konversi dan rendemen harga gabah kering panen (GKP) gabah kering giling (GKG) dan beras berdasarkan inpres (instruksi presiden) No. 5 / 2015.



Gambar 2.3 Skema Konversi dan Rendemen

BAB III

METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder, dalam bentuk data bulanan yang diperoleh dari database Perum BULOG Divre Jatim pada bagian Analisa Harga dan Pasar (GASAR), yakni data harga gabah kering panen (GKP), gabah kering giling (GKG) dan beras, dengan periode waktu bulan Januari 2001 sampai Desember 2014 dengan jumlah data setiap variabel sebanyak 168 data. Data dibagi menjadi data *in sample* sejumlah 156 data mulai Januari 2001- Desember 2013 dan *out sample* sejumlah 12 data terakhir, mulai bulan Januari – Desember 2014.

3.2 Variabel Penelitian

Terdapat 3 variabel yang akan digunakan pada penelitian ini. Variabel tersebut sebagai berikut :

$Z_{1,t}$ = Harga jual gabah kering panen (GKP) tingkat produsen (Rp).

$Z_{2,t}$ = Harga jual gabah kering giling (GKG) tingkat produsen (Rp).

$Z_{3,t}$ = Harga jual beras tingkat produsen (Rp).

3.3 Metode Analisis Data

Analisis yang digunakan adalah model *univariate* dan *multivariate time series* yaitu ARIMA dan VAR. Kedua metode tersebut akan digunakan untuk memodelkan ke tiga variabel yang akan digunakan. Dari permodelan tersebut akan dibandingkan mana model yang paling baik untuk peramalan harga GKP, GKG, dan beras.

Langkah-langkah analisis dalam penelitian ini adalah sebagai berikut:

1. Menganalisis statistika deskriptif pada masing-masing variabel data harga gabah kering panen (GKP), gabah kering giling (GKG) dan beras di tingkat produsen.

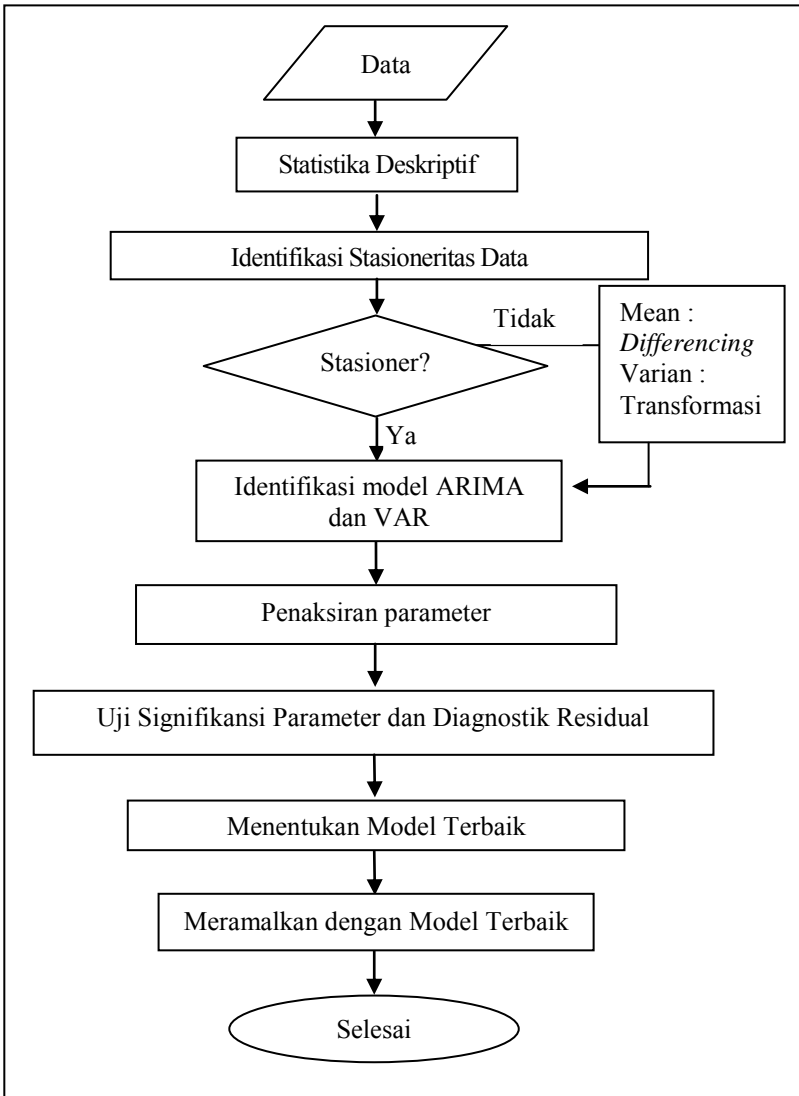
2. Pemodelan menggunakan ARIMA
 - a. Identifikasi model ARIMA menggunakan plot ACF dan PACF dari data *in sample*.
 - b. Estimasi dan uji signifikansi parameter.
 - c. Melakukan uji asumsi residual model.
 - d. Melakukan peramalan dan membandingkannya dengan data aktual.
 - e. Menghitung nilai RMSE in sample dan out sample.

3. Pemodelan menggunakan VAR
 - a. Melakukan *Granger Causality Test*.
 - b. Identifikasi kestasioneran
Identifikasi kestasioneran data, jika belum stasioner terhadap varian perlu dilakukan transformasi Box-Cox dan jika belum stasioner terhadap *mean* maka perlu dilakukan *differencing*.
 - c. Membuat plot MACF (*Matrix Autocorrelation Function*) dan MPACF (*Matrix Partial Autocorrelation Function*). Kestasioneran dapat dilihat dari data awal, data dikatakan belum stasioner terhadap mean apabila nilai MACF turun lambat menuju nol secara signifikan.
 - d. Membuat plot MACF dan MPACF berdasarkan data yang telah stasioner (*differencing* atau transformasi Box-Cox).
 - e. Model VAR adalah model untuk multivariate time series. Model VAR awal dapat diduga dengan melihat nilai AIC terkecil. *Lag* yang memuat nilai AIC terkecil digunakan sebagai penentuan orde pada model VAR.
 - f. Penaksiran parameter
Model VAR awal (langkah 3(e)) apabila tidak memuat parameter yang signifikan yaitu kurang dari $\alpha = 5\%$ sehingga dilakukan proses *backward* yaitu prosedur eliminasi langkah mundur untuk menentukan parameter mana yang signifikan. Proses tersebut dilakukan terus-menerus hingga semua parameter signifikan. Penaksiran

- parameter yang digunakan adalah dengan meminimumkan jumlah kuadrat *error* yaitu metode *Least Square*.
- g. Uji Diagnostik Residual
Asumsi yang harus dipenuhi pada model VAR adalah residual berdistribusi *multivariate normal* dan *white noise*.
 - h. Melakukan peramalan ketiga variabel harga (GKP, GKG, dan beras) dan membandingkannya dengan data aktual.
 - i. Menghitung nilai RMSE *in sample* dan *out sample*.
4. Memilih model yang paling sesuai dari kedua metode yang digunakan di atas untuk meramalkan data harga gabah kering panen (GKP), gabah kering giling (GKG) dan beras ditingkat produsen Jawa Timur.

3.4 Diagram Alir

Diagram alir merupakan runtutan proses dalam langkah-langkah penelitian yang ditampilkan dalam bentuk diagram. Diagram alir mendapatkan model ARIMA dan VAR selengkapnya disajikan pada gambar 3.1 sebagai berikut.



Gambar 3.1 Diagram Alir Penelitian

BAB IV ANALISIS DAN PEMBAHASAN

Bagian ini menjelaskan hasil analisis peramalan ke tiga variabel penelitian yang akan digunakan yaitu harga GKG, GKP dan beras, Sebelum dilakukan analisis menggunakan metode ARIMA dan *Vector Autoregressive* (VAR), dilakukan deskripsi data untuk mengetahui gambaran umum karakteristik dari ke tiga variabel tersebut.

4.1 Karakteristik Data


Harga GKG, GKP, dan beras di Provinsi Jawa Timur adalah data yang diukur dalam waktu bulanan. Analisis deskriptif dilakukan untuk mengetahui karakteristik pola data yang akan digunakan sebagai informasi pada analisis selanjutnya. Hasil analisa dari statistika deskriptif ke tiga variabel tersebut ditampilkan dalam tabel 4.1.

Tabel 4.1 Deskriptif Data Harga GKP, GKG dan Beras Januari 2001-Desember 2014 (Rupiah)

Variabel	N	Mean	St. Dev	Varian	Min.	Maks.
GKP	168	2385.7	1036.5	1074345.1	1017.8	4412.1
GKG	168	2902.8	1175.1	1380819	1302.6	5035.6
Beras	168	4377	1863	3468942	1911	7745

Tabel 4.1 menunjukkan bahwa nilai rata-rata untuk harga GKP, GKG, dan beras masing-masing yaitu Rp 2.386, Rp 2.902, dan Rp 4.377/kg. Beras mempunyai rata-rata harga paling tinggi, yaitu sebesar Rp 4.377, dikarenakan komoditas beras merupakan hasil padi akhir yang siap untuk dikonsumsi dan dipasarkan kepada masyarakat. Ukuran penyebaran data, bisa diketahui dari nilai standar deviasi data. Persebaran data harga GKP, GKG dan beras cenderung besar masing-masing yaitu 1037, 1175, dan 1863.

Nilai minimum untuk harga gabah kering panen (GKP), gabah kering giling (GKG), dan beras tingkat produsen Jawa Timur masing-masing sebesar Rp 1.018, Rp 1.303, dan Rp 1.911 pada bulan maret 2001 karena pada saat itu pasokan beras yang cukup melimpah dan masih ditambah masa panen yang sudah terjadi di berbagai daerah Jatim. Nilai maksimum pada harga beras sebesar Rp 7.745 pada bulan januari 2014, harga gabah kering panen (GKP) sebesar Rp 4.412, dan harga gabah kering giling (GKG) sebesar Rp 5.036 yang terjadi pada bulan desember 2014. Selanjutnya untuk nilai keragaman tertinggi terdapat pada variabel harga beras yaitu sebesar 3.468.942. Hal ini disebabkan karena sepanjang tahun harga beras selalu mengalami kenaikan, selain itu juga karena beras merupakan proses akhir padi yang siap untuk dipasarkan dan dikonsumsi.



Gambar 4.1 Time Series Plot Pertahun Data Harga (a) GKP, (b) GKG, (c) Beras Januari 2001-Desember 2014

Gambar 4.1 menunjukkan bahwa *time series plot* rata-rata pertahun data harga gabah kering panen (GKP) (a) berdasarkan bulan Januari 2001 sampai Desember 2014 menunjukkan terjadinya kenaikan disetiap tahunnya, meskipun terdapat beberapa penurunan namun tidak signifikan. Gambar (b) menunjukkan *time series plot* harga gabah kering giling (GKG) di tingkat produsen yang juga mengalami kenaikan secara perlahan. Selain itu juga terjadi kenaikan rata-rata pertahun harga beras (c) di tingkat produsen Jawa Timur.

Untuk mengetahui ada atau tidaknya hubungan antar variabel tanpa terikat oleh hubungan waktu. Digunakan nilai korelasi harga GKP, GKG, dan beras akan disajikan pada Tabel 4.2.

Tabel 4.2 Matriks Korelasi Harga GKP, GKG dan Beras

Harga	GKP	GKG
GKG	0,997 0,000	
Beras	0,996 0,000	0,997 0,000


Tabel 4.2 menunjukkan bahwa hasil nilai korelasi dan *p-value* masing-masing variabel dari harga GKP, GKG, dan beras. Diketahui, pada nilai kritis yaitu tolak H_0 jika *p-value* < α yang memberi kesimpulan bahwa variabel tersebut mempunyai hubungan linier. Nilai korelasi pada setiap variabel mempunyai *p-value* sebesar 0,000 yang berarti lebih kecil dari 0,05. Sehingga dapat disimpulkan bahwa ke tiga variabel tersebut (harga GKP, GKG, dan beras) mempunyai hubungan linier satu sama lain.

Pada matriks korelasi harga GKP terhadap GKG dan beras mempunyai hubungan yang positif masing-masing yaitu 0,997 dan 0,996. Hal tersebut menunjukkan bahwa harga GKP akan menambah harga GKG dan beras atau sebaliknya. Sedangkan korelasi harga GKG dan beras mempunyai hubungan yang positif yaitu 0,997. Hal tersebut menunjukkan bahwa ketiga harga tersebut (GKP, GKG, dan beras) saling berhubungan satu sama lain.

4.2 Pemodelan Data Secara *Univariate* (ARIMA)

Pada subbab ini peramalan yang dilakukan adalah secara *univariate* (ARIMA) yaitu peramalan untuk masing-masing harga GKP, GKG, dan beras. Selanjutnya akan dilihat modelnya, apakah mengandung musiman atau tidak. Untuk membentuk model dilakukan dengan menggunakan data *training* (*in sample*) yaitu data mulai tahun 2001-2013. Sedangkan untuk pengujian ketepatan ramalan digunakan data *testing* (*out sample*), yaitu data mulai bulan Januari – Desember 2014.


Untuk mendapatkan model ARIMA, langkah pertama yang harus dilakukan yaitu identifikasi model. Pengecekan awal untuk melihat kestasioneran data dari ke tiga variabel diidentifikasi melalui plot *time series*, grafik pergerakan data harga GKP, GKG dan beras disajikan dalam bentuk plot *time series* pada Gambar 4.2.



Gambar 4.2 *Time Series Plot* : (a) GKP, (b) GKG, dan (c) Beras

Gambar 4.2 menunjukkan bahwa pola data dari data harga GKP (a), GKG (b), dan beras (c) cenderung tidak stasioner dalam mean, data mempunyai pola yang fluktuatif dan tidak beraturan. Hal tersebut menunjukkan bahwa data belum stasioner baik dalam *mean* maupun varians dimana titik-titik pengamatan mengalami kenaikan dan penurunan yang tajam. Agar memperjelas pendugaan stasioner terhadap *mean*, dapat dilihat dari lag ACF yang tertera di lampiran, sedangkan pada varians digunakan plot Box-Cox.


Berikut ini merupakan plot Box-Cox untuk ke tiga data tersebut yang tersaji pada gambar 4.3.



Gambar 4.3 Plot *Box-Cox* : (a) GKP, (b) GKG, dan (c) Beras

Gambar 4.3 dapat ditunjukkan bahwa ke tiga variabel harga GKP, GKG, dan beras belum stasioner dalam varians karena nilai λ tidak sama dengan 1, batas atas dan batas bawah belum melewati angka 1. Maka untuk mengatasi hal tersebut dilakukan

transformasi *Box-Cox*. Berikut ini merupakan hasil transformasi untuk ke tiga variabel tersebut



Gambar 4.4 Transformasi Plot *Box-Cox* : (a) GKP, (b) GKG, dan (c) Beras

Gambar 4.4 menunjukkan bahwa *rounded-value* yang dihasilkan pada data harga gabah kering panen (GKP) sebesar 1 dan terdapat batas atas dan batas bawah masing-masing sebesar -1,66 dan 3,49, yang berarti bahwa data harga GKP sudah stasioner terhadap varians. *Rounded-value* yang dihasilkan *Box-Cox transformation* pada data gabah kering giling (GKG) sebesar 3 tetapi batas atas dan bawah sudah melewati angka 1, batas atas yang bertanda (*) dan batas bawah sebesar -0,07 mengartikan bahwa batsannya dipositif tidak terhingga yang telah melewati angka 1, ini menunjukkan bahwa data harga gabah kering giling (GKG) sudah stasioner terhadap varians. Selanjutnya untuk data

harga beras memiliki rounded value sebesar 0,5 tetapi batas bawah dan atas telah melewati 1 yaitu -0,15 dan 1,28 sehingga disimpulkan telah stasioner dalam varians.

Setelah dilakukan pengujian menggunakan transformasi *Box-Cox* yaitu cara untuk mengatasi kestasioneran data pada varians, langkah selanjutnya mengatasi kestasioneran dalam *mean*. Apabila data tidak stasioner terhadap *mean*, perlu dilakukan *differencing*. Plot hasil *differencing* untuk mengatasi ketidakstasioneran dalam *mean* tertera dalam lampiran. Setelah diuji secara visual, agar lebih yakin maka dilakukan uji secara inferensia yaitu *Augmented Dickey-Fuller* atau dikenal dengan *unit root test* sebagai berikut.

Hipotesis :

$H_0 : \beta = 0$ (data mengandung *unit root*)

$H_1 : \beta < 0$ (data tidak mengandung *unit root*)

Taraf signifikan $\alpha = 5\%$

Tabel 4.3 Nilai Statistik Uji *Augmented Dickey-Fuller* Sebelum *Differencing*

Harga	τ_{hitung}	p_value
GKP	-2,79	0,2042
GKG	-2,86	0,1777
Beras	-2,42	0,3653

Tabel 4.3 menjelaskan bahwa dengan menggunakan $\alpha=5\%$, maka diperoleh keputusan gagal tolak H_0 karena $p_value > \alpha$, sehingga dapat disimpulkan bahwa data harga GKP, GKG, dan beras mengandung *unit root* yang artinya tidak stasioner terhadap *mean*.


Setelah diketahui dengan pengujian secara inferensia yaitu *Augmented Dickey-Fuller test* dapat dipastikan bahwa data tidak stasioner terhadap *mean*. Selanjutnya akan dilakukan proses *differencing*. Berikut ini adalah hasil *Augmented Dickey-Fuller* dengan menggunakan data hasil *differencing*.

Tabel 4.4 Nilai Statistik Uji Augmented Dickey-Fuller Setelah Differencing

Harga	τ_{hitung}	p_value
GKP	-10,22	<0,0001
GKG	-11,98	<0,0001
Beras	-8,47	<0,0001

Tabel 4.4 menjelaskan bahwa data harga GKP, GKG, dan beras setelah melalui proses *differencing* didapatkan hasil telah stasioner terhadap mean atau data tidak mengandung *unit root*, karena nilai p_value masing-masing variabel sebesar <0,0001 kurang dari $\alpha=5\%$.

Setelah dilakukan *differencing*, maka plot *time series* ditunjukkan pada gambar 4.5.



Gambar 4.5 Time Series Plot hasil differencing : (a) GKP, (b) GKG, dan (c) Beras

Gambar 4.5 menunjukkan bahwa plot *time series* untuk harga (a) GKP, (b) GKG dan (c) beras sudah stasioner dalam varians maupun *mean* dimana titik-titik pengamatan mendekati nilai konstan. Setelah ke tiga variabel dinyatakan stasioner terhadap varian dan *mean*, maka dilakukan pemodelan untuk ke tiga harga GKP, GKG, dan beras, sehingga diperoleh model dugaan ke tiga variabel tersebut seperti pada Tabel 4.5.

Tabel 4.5 Estimasi Parameter Model ARIMA

Harga	Model	Parameter	Estimasi	p_value
GKP	ARIMA (0,1,[5,11]) (1,0,0) ¹²	θ_5	0,32785	<0,0001
		θ_{11}	-0,35737	< 0,0001
		1	0,24049	0,0039
GKG	ARIMA (0,1,0)(1,0,1) ¹²	1	0,89393	< 0,0001
		1	0,67187	< 0,0001
Beras	ARIMA (0,1,1)(1,0,1) ¹²	θ_1	-0,42949	< 0,0001
		1	1,00000	< 0,0001
		1	0,89351	< 0,0001

Tabel 4.5 menjelaskan bahwa parameter model ARIMA untuk ke tiga harga GKP, GKG, dan beras telah signifikan pada model, dilihat dari p_value pada estimasi parameter kurang dari $\alpha(5\%)$. Setelah parameter signifikan kemudian dilakukan pengecekan asumsi residual *white noise* dan normalitas.

Tabel 4.6 Diagnostic Check Model ARIMA

Harga	Model	Cek Residual White Noise			Cek Normalitas	
		Lag	Chi-Square	P_value	D	p_value
GKP	ARIMA (0,1,[5,11]) (1,0,0) ¹²	6	5,34	0,1486	0,061225	>0,1500
		12	8,18	0,5157		
		18	13,21	0,5859		
		24	25,19	0,2392		

Tabel 4.6 *Diagnostic Check Model ARIMA (lanjutan)*

Harga	Model	Cek Residual White Noise			Cek Normalitas	
		Lag	Chi-Square	P_value	D	p_value
GKG	ARIMA (0,1,0)(1,0,1) ¹²	6	3,06	0,5473	0,081999	0,0118
		12	7,98	0,6306		
		18	12,05	0,7407		
		24	15,47	0,8413		
Beras	ARIMA (0,1,1)(1,0,1) ¹²	6	4,45	0,2165	0,098365	<0,0100
		12	13,86	0,1273		
		18	19,05	0,2116		
		24	30,51	0,2576		

Tabel 4.6 menunjukkan bahwa residual dari seluruh model *white noise*, hal ini dilihat dari *p_value* lebih dari $\alpha=0,05$. Tetapi hanya model ARIMA (0,1,[5,11]) (1,0,0)¹² yang menghasilkan residual normal (*p_value*>0,05). Ketidaknormalan residual pada data harga GKG dan beras diakibatkan adanya *outlier*, sehingga perlu dilakukan deteksi *outlier*. Ditemukan terdapat 11 *outlier* pada data harga GKG dan 26 *outlier* pada data harga beras dengan dua tipe *outlier*, yaitu *shift* dan *additive*. Dengan adanya *outlier*, perlu diestimasi ulang nilai parameter dan pengujian diagnostik. Nilai estimasi dan signifikansi parameter ARIMA dengan deteksi *outlier* seperti ditunjukkan pada tabel 4.7.

Tabel 4.7 Estimasi Parameter Model ARIMA Harga GKG dan Beras dengan *Outlier*

Harga	Parameter	Estimasi	S. Error	P_value	Tipe <i>Outlier</i>
GKG	1	0,72238	0,13142	< 0,0001	-
	1	0,92583	0,08556	< 0,0001	-
	ω_1	-0,09395	0,03295	0,0050	ao122
	ω_2	-0,08197	0,03221	0,0119	ao31

Tabel 4.7 Estimasi Parameter Model ARIMA Harga GKG dan Beras dengan *Outlier* (lanjutan)

Harga	Parameter	Estimasi	S. Error	p_value	Tipe <i>Outlier</i>
Beras	θ_1	-0,78989	0,05606	< 0,0001	-
	μ_1	0,70688	0,10826	< 0,0001	-
	σ_1	1,0000	0,05155	< 0,0001	-
	ω_1	2,36427	0,46268	<0,0001	ls74
	ω_2	-2,26485	0,38666	<0,0001	ls122
	ω_3	-2,29801	0,38783	<0,0001	ls76
	ω_4	2,84801	0,50181	<0,0001	ls127
	ω_5	-2,13522	0,46296	<0,0001	ao60
	ω_6	16,8273	0,31431	<0,0001	ao13
	ω_7	1,50349	0,40303	0,0003	ls109
	ω_8	1,85150	0,51686	0,0005	ls126
	ω_9	1,54591	0,31626	<0,0001	ls51
	ω_{10}	1,36469	0,39379	0,0007	ls58
	ω_{11}	-1,32450	0,35333	0,0003	ls69
	ω_{12}	-1,39439	0,39549	0,0006	ao107
	ω_{13}	1,39965	0,42724	0,0013	ls72
	ω_{14}	-1,40988	0,35564	0,0001	ao119
ω_{15}	0,90693	0,40327	0,0261	ls62	
ω_{16}	1,25227	0,32318	0,0002	ls98	

Tabel 4.7 menjelaskan bahwa semua parameter dan *outlier* signifikan terhadap model dengan tipe *outlier* yaitu *shift* dan *additive*. *Additive outlier* merupakan pencilan yang hanya merubah *output* sistem tanpa adanya pengaruh berkelanjutan pada data deret waktu sebelumnya atau sesudahnya, dalam kasus ini sebagian besar *outlier tipe additive* dikarenakan adanya bulan paceklik, tetapi akan terjadi musim panen kembali (baru) pada

bulan berikutnya. Sedangkan *level shift outlier* merupakan modifikasi intervensi dan pencilan yang mempengaruhi hingga akhir pengamatan, memberikan suatu perubahan yang tiba-tiba dan permanen. Dalam hal ini *tipe outlier shift* yang pengaruhnya berdampak cukup besar terhadap kenaikan harga beras, terjadi pada bulan februari 2007 karena pada bulan tersebut terindikasi kekurangan suplai beras di pasar. Pada sisi lain stok yang dimiliki pemerintah pun makin terbatas karena stok tahun lalu sebagian besar sudah digunakan untuk Raskin 2007 yang dipercepat penyalurannya sejak Desember 2006, sementara pengadaan gabah/beras tahun ini (2007) belum dapat dilaksanakan karena tertundanya musim tanam akibat kendala iklim.

Hal ini dilihat dari semua *p_value* yang kurang dari 0,05. Selanjutnya model ARIMA dengan deteksi *outlier* diuji residual *white noise* dan berdistribusi normal sebagai berikut:

Tabel 4.8 *Diagnostic Check Model ARIMA dengan Outlier*

Harga	ARIMA <i>Outlier</i>	Cek Residual <i>White Noise</i>			Cek Normalitas	
		Lag	Chi-Square	<i>p_value</i>	D	<i>p_value</i>
GKG	(0,1,0)(1,0,1) ¹²	6	2,20	0,6999	0,070431	0,0592
		12	9,05	0,5277		
		18	12,68	0,6958		
		24	17,06	0,7602		
		6	1,49	0,6855		
Beras	(0,1,1)(1,0,1) ¹²	12	4,15	0,9013	0,059926	>0,150
		18	11,41	0,7231		
		24	16,39	0,7475		


Tabel 4.8 menjelaskan bahwa hasil pengujian *Ljung Box* model ARIMA dengan deteksi *outlier* pada data harga GKG, dan beras telah *white noise* karena nilai *p_value* > $\alpha(5\%)$. Setelah residual memenuhi asumsi *white noise*, kemudian dilakukan pengecekan terhadap kenormalan residual. Hasil yang didapatkan adalah residual model untuk harga GKG dan beras telah berdistribusi normal karena *p_value* > $\alpha(5\%)$.


Tabel 4.9 Perbandingan Kebaikan Model ARIMA dan ARIMA dengan Deteksi *Outlier*

Harga	Kriteria	ARIMA	ARIMA (<i>Outlier</i>)
GKP	AIC	-563,933	-
	SBC	-554,803	-
GKG	AIC	-598,248	-608,526
	SBC	-592,161	-596,352
Beras	AIC	382,4079	261,2897
	SBC	391,5381	319,1148

Model terbaik dipilih berdasarkan nilai AIC dan SBC terkecil. Tabel 4.9 digunakan untuk perbandingan kriteria kebaikan model *in sample* model ARIMA dan ARIMA dengan deteksi *outlier* pada data harga GKG dan beras, didapatkan hasil bahwa nilai AIC dan SBC menunjukkan model ARIMA dengan deteksi *outlier* lebih kecil.



Pola data dan pola hasil ramalan harga dengan data *in sample* yang dihasilkan oleh model ARIMA terbaik disajikan pada Gambar 4.6.






Gambar 4.6 Plot Nilai Ramalan Model ARIMA dan Aktual Data *in sample* Harga (a) GKP, (b) GKG, (c) Beras

Gambar 4.6 menunjukkan bahwa nilai ramalan yang dihasilkan oleh model ARIMA tidak berbeda jauh dengan nilai aktualnya. Selanjutnya akan diketahui pola data dan pola hasil ramalan harga dengan data *out sample* yang dihasilkan oleh model ARIMA terbaik disajikan pada Gambar 4.7.





Gambar 4.7 Plot Nilai Ramalan Model ARIMA dan Aktual Data *out sample* Harga (a) GKP, (b) GKG, (c) Beras

Gambar 4.7 menunjukkan pola data dan pola hasil ramalan data dengan *out sample*. Jika dibandingkan dengan ramalan pada data *in sample* (Gambar 4.6), untuk nilai ramalan pada data *in sample* terlihat lebih baik, karena data yang digunakan untuk mendapatkan hasil ramalan pada data *in sample* adalah data aktual, sehingga *error* yang dihasilkan menjadi lebih kecil dibandingkan dengan hasil ramalan pada *out sample* yang berasal dari hasil ramalan di waktu sebelumnya.

4.3 Granger Causality Test

Granger Causality Test digunakan untuk mengetahui hubungan antar variabel apakah terdapat hubungan searah atau kausal (dua arah). Sebelum dilakukan uji *Granger*, data harus memenuhi asumsi yaitu kestasioneran data untuk masing-masing variabel. Berdasarkan pembahasan sebelumnya, sudah dilakukan uji stasioneritas dalam varians maupun *mean* yaitu dilakukan transformasi kemudian *differencing*. Berikut ini merupakan hasil pengujian kausalitas *Granger* antara variabel harga GKP, GKG, dan beras. Uji hubungan kausal *Granger* yang dilakukan terhadap ketiga harga tersebut adalah sebagai berikut.

1. Hipotesis :

H_0 : harga GKP mempengaruhi harga GKG dan beras, tetapi tidak sebaliknya.

- H_1 : harga GKP berpengaruh signifikan terhadap harga GKG dan beras, begitu juga sebaliknya
2. Hipotesis :
- H_0 : harga GKG mempengaruhi harga GKP dan beras, tetapi tidak sebaliknya.
- H_1 : harga GKG berpengaruh signifikan terhadap harga GKP dan beras, begitu juga sebaliknya
3. Hipotesis :
- H_0 : harga beras mempengaruhi harga GKP dan GKG, tetapi tidak sebaliknya.
- H_1 : harga beras berpengaruh signifikan terhadap harga GKP dan GKG, begitu juga sebaliknya

Taraf signifikan : $\alpha = 5\%$

Pengujian hipotesis di atas menggunakan statistik uji Chi-Square seperti disajikan pada tabel 4.10.

Tabel 4.10 Pengujian Kausalitas *Granger*

Test	DF	Chi-Square	p_value
1	12	8,45	0,7488
2	12	41,35	<0,0001
3	12	26,01	0,0107

Berdasarkan tabel 4.10 dengan menggunakan tingkat signifikansi 5%, didapatkan keputusan gagal tolak H_0 pada kausal (1) yang artinya bahwa pada kausal (1) harga GKP mempengaruhi harga GKG dan beras, tetapi tidak sebaliknya, dan H_0 ditolak pada kausal (2) dan kausal (3), yang artinya bahwa pada kausal (2) harga GKG berpengaruh secara signifikan terhadap harga GKP dan beras, untuk kausal (3) berarti bahwa harga beras berpengaruh secara signifikan terhadap harga GKP dan GKG.

4.4 Pemodelan Data Secara *Multivariate* (VAR)

Secara umum peramalan harga GKP, GKG, dan beras dengan menggunakan metode VAR melalui 4 tahap, yaitu pendugaan model awal, penaksiran parameter, uji diagnostik,

menentukan model VAR akhir. Langkah pengerjaan VAR (*Vector Autoregressive*) sama dengan ARIMA, hanya bedanya berupa matriks. Apabila pada ARIMA menggunakan ACF dan PACF, pada VAR (*Vector Autoregressive*) menggunakan MACF dan MPACF. Seperti yang diketahui sebelumnya, bahwa variabel Z_{1t} , Z_{2t} dan Z_{3t} belum stasioner terhadap varians (lihat Gambar 4.3), karena pemodelan selanjutnya menggunakan pemodelan secara *multi-variate* (VAR), sehingga dilakukan transformasi dengan jenis transformasi yang sama yaitu menggunakan \ln untuk ke tiga data harga GKP, GKG, dan beras. Berikut ini merupakan skema MACF dan MPACF ketiga harga tersebut.

(a)		Schematic Representation of Cross Correlations												
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12	
GKP	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	
GKG	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	
BRS	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	

+ is $> 2 \cdot \text{std error}$, - is $< -2 \cdot \text{std error}$, . is between

(b)		Schematic Representation of Cross Correlations												
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12	
GKP	+++	+++	+++	
GKG	+++	..++	+++	
BRS	+++	..+	+++	+++	

+ is $> 2 \cdot \text{std error}$, - is $< -2 \cdot \text{std error}$, . is between

Gambar 4.8 Skema MACF (a) Sebelum Dilakukan *Differencing*
(b) Setelah Dilakukan *Differencing*

Gambar 4.8(a) menunjukkan bahwa skema matriks (MACF) belum stasioner dalam *mean* karena titik-titik pengamatan dari semua lag keluar dari batas atas (+). Untuk mengatasi ketidak-stasioneran tersebut maka dilakukan *differencing* 1. Setelah di-

lakukan *differencing*, skema matriks (MACF) pada Gambar 4.8(b) menunjukkan bahwa skema MACF sudah stasioner dalam *mean*. Hal ini ditunjukkan oleh munculnya simbol (+) dan (-) hanya pada lag-lag tertentu.

Setelah data stasioner, langkah selanjutnya yaitu menduga model awal VAR. Penentuan orde VAR dilakukan menggunakan plot matriks korelasi parsial (MPACF) sebagai berikut:

Schematic Representation of Partial Cross Correlations												
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12
GKP	..++	...	-..	..++
GKG	..+	..-	+..+	...
BRS	..+	-..	+.	+..

+ is > 2*std error, - is < -2*std error, . is between

Gambar 4.9 Skema MPACF Setelah Dilakukan *Differencing*

Plot MPACF pada Gambar 4.9 menunjukkan adanya simbol (+) atau (-) pada lag 1, 2, 3, 5, 6, dan 9. Diduga orde VAR memuat lag-lag tersebut. Selain menggunakan plot MPACF, penentuan orde VAR juga dapat dilakukan dengan melihat nilai AIC model sebagai berikut:

Tabel 4.11 *Minimum Information Criterion*

Lag	MA 0	MA 1
AR 1	-22.00484	-21,91511
AR 2	-21.98825	-21,88986
AR 3	-22.03932	-21,9407
AR 4	-21.92146	-21,84417
AR 5	-21.97288	-21,97013
AR 6	-22.14251*	-22,08124

Tabel 4.11 menunjukkan orde yang sesuai dalam model VAR. Pada tabel tersebut ditunjukkan bahwa nilai AIC terkecil model VAR terletak di MA(0) dan AR(6). Sehingga model yang terpilih dari data ketiga harga yang diperoleh adalah VAR (6).

Setelah didapatkan model tersebut, langkah selanjutnya dilakukan penaksiran parameter, untuk menentukan parameter yang akan digunakan dalam model. Hasil penaksiran parameter ditampilkan pada Tabel 4.12.

Tabel 4.12 Penaksiran Parameter Model VAR(6)

<i>Equation</i>	<i>Parameter</i>	<i>Estimate</i>	<i>Std Error</i>	<i>t value</i>	<i>p value</i>	<i>Variabel</i>
GKP	$\phi_{1\ 1}$	0,24032	0,15471	1,55	0,1227	GKP(t-1)
	$\phi_{1\ 2}$	0,02523	0,21015	0,12	0,9046	GKG(t-1)
	$\phi_{1\ 3}$	-0,01205	0,27764	-0,04	0,9654	BRS(t-1)
	$\phi_{2\ 1}$	0,09574	0,1503	0,64	0,5253	GKP(t-2)
	$\phi_{2\ 2}$	-0,13236	0,21271	-0,62	0,5348	GKG(t-2)
	$\phi_{2\ 3}$	-0,27018	0,26712	-1,01	0,3137	BRS(t-2)
	$\phi_{3\ 1}$	0,24297	0,15033	1,62	0,1084	GKP(t-3)
	$\phi_{3\ 2}$	-0,22496	0,21518	-1,05	0,2977	GKG(t-3)
	$\phi_{3\ 3}$	0,02321	0,26619	0,09	0,9307	BRS(t-3)
	$\phi_{4\ 1}$	0,09713	0,15359	0,63	0,5282	GKP(t-4)
	$\phi_{4\ 2}$	-0,12174	0,21359	-0,57	0,5697	GKG(t-4)
	$\phi_{4\ 3}$	0,10796	0,26536	0,41	0,6848	BRS(t-4)
	$\phi_{5\ 1}$	-0,22449	0,14911	-1,51	0,1346	GKP(t-5)
	$\phi_{5\ 2}$	0,01383	0,20786	0,07	0,947	GKG(t-5)
	$\phi_{5\ 3}$	0,0547	0,26525	0,21	0,8369	BRS(t-5)
	$\phi_{6\ 1}$	-0,17102	0,14758	-1,16	0,2486	GKP(t-6)
	$\phi_{6\ 2}$	-0,06762	0,19741	-0,34	0,7325	GKG(t-6)
	$\phi_{6\ 3}$	0,296	0,22716	1,3	0,1948	BRS(t-6)

Tabel 4.12 Penaksiran Parameter Model VAR(6) (Lanjutan)

Equation	Parameter	Estimate	Std Error	t value	p_value	Variabel
GKG	$\phi_{1\ 1}$	0,26515	0,12087	2,19	0,03	GKP(t-1)
	$\phi_{1\ 2}$	-0,307	0,16419	-1,87	0,0637	GKG(t-1)
	$\phi_{1\ 3}$	0,10677	0,21691	0,49	0,6234	BRS(t-1)
	$\phi_{2\ 1}$	0,09832	0,11743	0,84	0,404	GKP(t-2)
	$\phi_{2\ 2}$	-0,22196	0,16618	-1,34	0,184	GKG(t-2)
	$\phi_{2\ 3}$	0,07043	0,20869	0,34	0,7363	BRS(t-2)
	$\phi_{3\ 1}$	0,16452	0,11745	1,4	0,1636	GKP(t-3)
	$\phi_{3\ 2}$	-0,31032	0,16811	-1,85	0,0672	GKG(t-3)
	$\phi_{3\ 3}$	0,24211	0,20797	1,16	0,2465	BRS(t-3)
	$\phi_{4\ 1}$	0,0906	0,11999	0,76	0,4516	GKP(t-4)
	$\phi_{4\ 2}$	-0,17395	0,16687	-1,04	0,2991	GKG(t-4)
	$\phi_{4\ 3}$	0,10845	0,20732	0,52	0,6018	BRS(t-4)
	$\phi_{5\ 1}$	0,2295	0,1165	1,97	0,0509	GKP(t-5)
	$\phi_{5\ 2}$	-0,26873	0,1624	-1,65	0,1004	GKG(t-5)
	$\phi_{5\ 3}$	0,04062	0,20723	0,2	0,8449	BRS(t-5)
	$\phi_{6\ 1}$	-0,01726	0,1153	-0,15	0,8812	GKP(t-6)
	$\phi_{6\ 2}$	-0,03766	0,15423	-0,24	0,8075	GKG(t-6)
	$\phi_{6\ 3}$	0,1997	0,17747	1,13	0,2626	BRS(t-6)
Beras	$\phi_{1\ 1}$	0,1603	0,10375	1,55	0,1247	GKP(t-1)
	$\phi_{1\ 2}$	0,04483	0,14093	0,32	0,7509	GKG(t-1)
	$\phi_{1\ 3}$	0,0993	0,18619	0,53	0,5947	BRS(t-1)
	$\phi_{2\ 1}$	0,03761	0,1008	0,37	0,7097	GKP(t-2)
	$\phi_{2\ 2}$	-0,12585	0,14265	-0,88	0,3793	GKG(t-2)
	$\phi_{2\ 3}$	-0,05686	0,17913	-0,32	0,7514	BRS(t-2)
	$\phi_{3\ 1}$	0,13174	0,10081	1,31	0,1936	GKP(t-3)
	$\phi_{3\ 2}$	-0,06057	0,1443	-0,42	0,6754	GKG(t-3)
	$\phi_{3\ 3}$	-0,00803	0,17851	-0,04	0,9642	BRS(t-3)

Tabel 4.12 Penaksiran Parameter Model VAR(6) (Lanjutan)

Equation	Parameter	Estimate	Std Error	t value	p_value	Variabel
	$\phi_{4\ 1}$	0,08981	0,103	0,87	0,3848	GKP(t-4)
	$\phi_{4\ 2}$	0,00567	0,14323	0,04	0,9685	GKG(t-4)
	$\phi_{4\ 3}$	-0,14454	0,17796	-0,81	0,4182	BRS(t-4)
Beras	$\phi_{5\ 1}$	0,13631	0,1	1,36	0,1752	GKP(t-5)
	$\phi_{5\ 2}$	-0,08624	0,1394	-0,62	0,5372	GKG(t-5)
	$\phi_{5\ 3}$	0,00040119	0,17788	0	0,9982	BRS(t-5)
	$\phi_{6\ 1}$	0,17246	0,09897	1,74	0,0838	GKP(t-6)
	$\phi_{6\ 2}$	0,00311	0,13239	0,02	0,9813	GKG(t-6)
	$\phi_{6\ 3}$	-0,06327	0,15234	-0,42	0,6786	BRS(t-6)

Tabel 4.12 menunjukkan bahwa belum ada parameter pada model VAR dugaan awal secara signifikan berpengaruh pada model. Hal ini dapat dilihat dari tabel tersebut terdapat *p_value* yang lebih dari α yaitu 0,05. Sehingga untuk mengatasinya, perlu dilakukan pembatasan atau *restrict* pada parameter yang tidak signifikan untuk mendapatkan parameter yang signifikan terhadap model. Hasil penaksiran parameter model *restrict* untuk model VAR(6) terlihat pada Tabel 4.13.

Tabel 4.13 Signifikansi Parameter Model *Restrict* VAR(6)

Equation	Parameter	Estimate	Std Error	t value	p_value	Variabel
GKP	$\phi_{1\ 1}$	0,239	0,07894	3,03	0,003	GKP(t-1)
	$\phi_{5\ 1}$	-0,19314	0,04621	-4,18	0,0001	GKP(t-5)
GKG	$\phi_{1\ 1}$	0,28478	0,0755	3,77	0,0002	GKP(t-1)
	$\phi_{1\ 2}$	-0,21216	0,10271	-2,07	0,0408	GKG(t-1)
	$\phi_{3\ 3}$	0,19486	0,05726	3,4	0,0009	BRS(t-3)
Beras	$\phi_{1\ 1}$	0,20961	0,05385	3,89	0,0002	GKP(t-1)
	$\phi_{1\ 2}$	0,05139	0,03127	1,64	0,1026	GKG(t-1)
	$\phi_{2\ 2}$	-0,08575	0,03839	-2,23	0,0272	GKG(t-2)
	$\phi_{3\ 1}$	0,10498	0,03299	3,18	0,0018	GKP(t-3)

Tabel 4.13 Signifikansi Parameter Model *Restrict VAR(6)*
(lanjutan)

Equation	Parameter	Estimate	Std Error	t value	p_value	Variabel
	$\phi_{3\ 3}$	-0,0472	0,01363	-3,46	0,0007	BRS(t-3)
Beras	$\phi_{4\ 1}$	0,11255	0,04799	2,35	0,0205	GKP(t-4)
	$\phi_{4\ 3}$	-0,16256	0,07986	-2,04	0,0438	BRS(t-4)
	$\phi_{6\ 1}$	0,1291	0,03048	4,24	0,0001	GKP(t-6)

Tabel 4.13 diketahui bahwa data ketiga harga GKP, GKG, dan beras cenderung dipengaruhi oleh ketiga harga itu sendiri pada waktu sebelumnya. Untuk harga beras yang tidak dipengaruhi secara signifikan oleh harga GKG (t-1) pada bulan sebelumnya karena $p_value > \alpha(5\%)$. Hal tersebut dianggap kurang relevan jika dibandingkan dengan keadaan sebenarnya, karena pada umumnya pembentukan harga beras dipengaruhi oleh kondisi harga gabah kering panen (GKP), dan gabah kering giling (GKG) pada waktu sebelumnya. Sehingga dalam penelitian ini diputuskan untuk tetap menggunakan persamaan beras pada variabel GKG (t-1) pada model.

Setelah terpilih model VARIMA (6,1,0) untuk harga GKP, GKG, dan beras, selanjutnya dilakukan permodelan dengan parameter yang telah di-*restrict* sebelumnya sebagai berikut:

$$\begin{aligned}
 1 &= \begin{bmatrix} 0,239 & 0 & 0 \\ 0,285 & -0,212 & 0 \\ 0,21 & 0,051 & 0 \end{bmatrix} & 2 &= \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & -0,086 & 0 \end{bmatrix} \\
 3 &= \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0,195 \\ 0,105 & 0 & -0,047 \end{bmatrix} & 4 &= \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0,113 & 0 & -0,163 \end{bmatrix} \\
 5 &= \begin{bmatrix} -0,193 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} & 6 &= \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0,129 & 0 & 0 \end{bmatrix}
 \end{aligned}$$

Parameter-parameter tersebut dimasukkan ke dalam persamaan bentuk umum model VARI (6,1) dari ketiga variabel yaitu harga GKP, GKG, dan beras. Perlu diingat, sebelumnya model telah dilakukan transformasi ln dan proses *differencing* orde 1, sehingga modelnya sebagai berikut:

$$(1 - {}_1B - {}_2B^2 - {}_3B^3 - {}_4B^4 - {}_5B^5 - {}_6B^6)(1 - B)Z_t^* = a_t$$

dimana $Z_t^* = \ln Z_t$, sehingga modelnya jika ditulis dalam matriks sebagai berikut.

$$\begin{aligned} \begin{bmatrix} Z_{1,t}^* \\ Z_{2,t}^* \\ Z_{3,t}^* \end{bmatrix} &= \begin{bmatrix} Z_{1,t-1}^* \\ Z_{2,t-1}^* \\ Z_{3,t-1}^* \end{bmatrix} + \begin{bmatrix} 0,239 & 0 & 0 \\ 0,285 & -0,212 & 0 \\ 0,21 & 0,051 & 0 \end{bmatrix} \begin{bmatrix} Z_{1,t-1}^* \\ Z_{2,t-1}^* \\ Z_{3,t-1}^* \end{bmatrix} - \begin{bmatrix} 0,239 & 0 & 0 \\ 0,285 & -0,212 & 0 \\ 0,21 & 0,051 & 0 \end{bmatrix} \begin{bmatrix} Z_{1,t-2}^* \\ Z_{2,t-2}^* \\ Z_{3,t-2}^* \end{bmatrix} \\ &+ \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & -0,086 & 0 \end{bmatrix} \begin{bmatrix} Z_{1,t-2}^* \\ Z_{2,t-2}^* \\ Z_{3,t-2}^* \end{bmatrix} - \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & -0,086 & 0 \end{bmatrix} \begin{bmatrix} Z_{1,t-3}^* \\ Z_{2,t-3}^* \\ Z_{3,t-3}^* \end{bmatrix} \\ &+ \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0,195 \\ 0,105 & 0 & -0,047 \end{bmatrix} \begin{bmatrix} Z_{1,t-3}^* \\ Z_{2,t-3}^* \\ Z_{3,t-3}^* \end{bmatrix} - \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0,195 \\ 0,105 & 0 & -0,047 \end{bmatrix} \begin{bmatrix} Z_{1,t-4}^* \\ Z_{2,t-4}^* \\ Z_{3,t-4}^* \end{bmatrix} \\ &+ \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0,113 & 0 & -0,163 \end{bmatrix} \begin{bmatrix} Z_{1,t-4}^* \\ Z_{2,t-4}^* \\ Z_{3,t-4}^* \end{bmatrix} - \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0,113 & 0 & -0,163 \end{bmatrix} \begin{bmatrix} Z_{1,t-5}^* \\ Z_{2,t-5}^* \\ Z_{3,t-5}^* \end{bmatrix} \\ &+ \begin{bmatrix} -0,193 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} Z_{1,t-5}^* \\ Z_{2,t-5}^* \\ Z_{3,t-5}^* \end{bmatrix} - \begin{bmatrix} -0,193 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} Z_{1,t-6}^* \\ Z_{2,t-6}^* \\ Z_{3,t-6}^* \end{bmatrix} \\ &+ \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0,129 & 0 & 0 \end{bmatrix} \begin{bmatrix} Z_{1,t-6}^* \\ Z_{2,t-6}^* \\ Z_{3,t-6}^* \end{bmatrix} - \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0,129 & 0 & 0 \end{bmatrix} \begin{bmatrix} Z_{1,t-7}^* \\ Z_{2,t-7}^* \\ Z_{3,t-7}^* \end{bmatrix} + \begin{bmatrix} a_{1t} \\ a_{2t} \\ a_{3t} \end{bmatrix} \end{aligned}$$

Persamaan untuk model VARIMA (6,1,0) di atas dapat juga dituliskan dengan bentuk sebagai berikut:

$$\begin{aligned}\ln Z_{1,t} &= \ln Z_{1,t-1} + 0,239 \ln Z_{1,t-1} - 0,239 \ln Z_{1,t-2} - 0,193 \ln Z_{1,t-5} \\ &\quad + 0,193 \ln Z_{1,t-6} + a_{1t} \\ &= 1,239 \ln Z_{1,t-1} - 0,239 \ln Z_{1,t-2} - 0,193 \ln Z_{1,t-5} + 0,193 \ln Z_{1,t-6} + a_{1t}\end{aligned}$$

Berdasarkan model dari harga GKP di atas dapat dijelaskan bahwa harga GKP dipengaruhi oleh harga GKP pada waktu sebulan yang lalu, 2 bulan yang lalu, 5 bulan yang lalu dan 6 bulan yang lalu.

$$\begin{aligned}\ln Z_{2,t} &= \ln Z_{2,t-1} + 0,285 \ln Z_{1,t-1} - 0,212 \ln Z_{2,t-1} - 0,285 \ln Z_{1,t-2} + 0,212 \ln Z_{2,t-2} \\ &\quad + 0,195 \ln Z_{3,t-3} - 0,195 \ln Z_{3,t-4} + a_{2t} \\ &= 0,285 \ln Z_{1,t-1} + 0,788 \ln Z_{2,t-1} - 0,285 \ln Z_{1,t-2} + 0,212 \ln Z_{2,t-2} \\ &\quad + 0,195 \ln Z_{3,t-3} - 0,195 \ln Z_{3,t-4} + a_{2t}\end{aligned}$$

Berdasarkan model dari harga GKG di atas dapat dijelaskan bahwa harga GKG dipengaruhi oleh harga GKG pada waktu sebulan yang lalu, dan 2 bulan yang lalu. Selain itu, juga dipengaruhi oleh variabel harga GKP pada waktu sebulan yang lalu, 2 bulan yang lalu, dan dipengaruhi juga oleh harga beras pada waktu 3 bulan yang lalu dan 4 bulan yang lalu.

$$\begin{aligned}\ln Z_{3,t} &= \ln Z_{3,t-1} + 0,210 \ln Z_{1,t-1} + 0,051 \ln Z_{2,t-1} - 0,210 \ln Z_{1,t-2} - 0,051 \ln Z_{2,t-2} \\ &\quad - 0,086 \ln Z_{2,t-2} + 0,086 \ln Z_{2,t-3} + 0,105 \ln Z_{1,t-3} - 0,047 \ln Z_{3,t-3} \\ &\quad - 0,105 \ln Z_{1,t-4} + 0,047 \ln Z_{3,t-4} + 0,113 \ln Z_{1,t-4} - 0,163 \ln Z_{3,t-4} \\ &\quad - 0,113 \ln Z_{1,t-5} + 0,163 \ln Z_{3,t-5} + 0,129 \ln Z_{1,t-6} - 0,129 \ln Z_{1,t-7} + a_{3t} \\ &= \ln Z_{3,t-1} + 0,210 \ln Z_{1,t-1} + 0,051 \ln Z_{2,t-1} - 0,210 \ln Z_{1,t-2} + 0,137 \ln Z_{2,t-2} \\ &\quad + 0,086 \ln Z_{2,t-3} + 0,105 \ln Z_{1,t-3} - 0,047 \ln Z_{3,t-3} + 0,008 \ln Z_{1,t-4} \\ &\quad + 0,047 \ln Z_{3,t-4} - 0,163 \ln Z_{3,t-4} - 0,113 \ln Z_{1,t-5} + 0,163 \ln Z_{3,t-5} \\ &\quad + 0,129 \ln Z_{1,t-6} - 0,129 \ln Z_{1,t-7} + a_{3t}\end{aligned}$$

Berdasarkan model dari harga beras di atas dapat dijelaskan bahwa harga beras dipengaruhi oleh harga beras itu sendiri pada waktu sebulan yang lalu, 3 bulan yang lalu, 4 bulan yang lalu, dan 5 bulan yang lalu. Selain itu, juga dipengaruhi oleh variabel harga

GKP pada waktu 1, 2, 3, 4, 5, 6 bulan yang lalu dan 7 bulan yang lalu, dan dipengaruhi juga oleh harga GKG pada waktu sebulan yang lalu, 2 bulan yang lalu dan 3 bulan yang lalu.

Selanjutnya dilakukan pengecekan residual terhadap asumsi *white noise*. Berdasarkan plot korelasi silang (MACF) residual model VAR (6) (Gambar 4.10) terlihat bahwa hampir semua lag residual signifikan atau nilainya berada pada batas kendali ± 2 kali standar error. Residual dikatakan memenuhi asumsi *white noise* jika lag-lag residual berada pada batas kendali. Sehingga didapatkan kesimpulan bahwa residual VAR (6) memenuhi asumsi *white noise* atau antar residual tidak memiliki korelasi.

Schematic Representation of Residual Cross Correlations													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
GKP	+++
GKG	+++
BRS	+++

+ is > 2*std error, - is < -2*std error, . is between

Gambar 4.10 Plot MACF Residual VAR(6)


Setelah residual model memenuhi asumsi *white noise*, selanjutnya dilakukan pengujian asumsi kenormalan residual dengan menggunakan uji Shapiro-Wilk sebagai berikut.

Tabel 4.14 Uji Multivariat Normal

Test	W	p_value
<i>Shapiro Wilk</i>	0,9920	0,5567

Tabel 4.14 menjelaskan bahwa residual data telah memenuhi asumsi kenormalan (multivariat normal), dilihat dari nilai *p_value* lebih dari α yaitu sebesar $0,5567 > 0,05$.

Untuk melihat hasil pola data dari ketiga harga dan hasil ramalan VAR(6) dengan menggunakan data *in sample* disajikan pada Gambar 4.11.



Gambar 4.11 Plot Nilai Ramalan Model VAR(6) dan Aktual Data *in sample* Harga (a) GKP, (b) GKG, (c) Beras

Berdasarkan Gambar 4.11 menunjukkan bahwa nilai ramalan untuk model VAR (6) hampir berimpitan dengan nilai aktualnya.

4.5 Model Peramalan Terbaik

Hasil pemodelan dengan VAR dan ARIMA menghasilkan nilai RMSE dan MAPE untuk data *in sample* maupun *out sample* sebagai berikut.

Tabel 4.15 Kriteria *In Sample*

Harga	Kriteria	VAR	ARIMA
GKP	MAPE	0,0307	0,0304
	RMSE	95,7679	90,7119

Tabel 4.15 Kriteria *In Sample*(Lanjutan)

Harga	Kriteria	VAR	ARIMA
GKG	MAPE	0,0252	0,0249
	RMSE	94,3341	85,7018
Beras	MAPE	0,0201	0,0183
	RMSE	112,14	98,4341

Tabel 4.15 berdasarkan kriteria *in sample* diketahui bahwa dari kedua model peramalan yang digunakan pada data harga GKP, GKG, dan beras memiliki nilai RMSE dan MAPE *in sample* terkecil untuk model ARIMA.

Tabel 4.16 Kriteria *Out Sample*

Harga	Kriteria	VAR	ARIMA
GKP	MAPE	0,0459	0,0257
	RMSE	219,1987	141,1286
GKG	MAPE	0,0338	0,0399
	RMSE	182,3783	220,9638
Beras	MAPE	0,0287	0,02057
	RMSE	242,6594	175,7375

Selain menggunakan kriteria RMSE dan MAPE *in sample* digunakan juga kriteria RMSE dan MAPE *out sample*. Hasil pada Tabel 4.16 menunjukkan bahwa harga GKG memiliki nilai RMSE dan MAPE *out sample* terkecil untuk model VAR. Sedangkan harga GKP dan beras memiliki nilai RMSE dan MAPE *out sample* terkecil untuk model ARIMA.

4.6 Peramalan (*Forecasting*)

Berdasarkan kriteria RMSE dan MAPE data *out sample*, yang menunjukkan bahwa harga GKG memiliki nilai RMSE dan MAPE terkecil untuk model VAR. Sedangkan harga GKP dan beras memiliki nilai RMSE dan MAPE terkecil untuk model ARIMA. Oleh karena itu, peramalan untuk harga GKP dan beras

menggunakan model ARIMA, sedangkan harga GKG menggunakan model VARI (6,1).

Tabel 4.17 Nilai Ramalan Harga GKP
Periode Januari-Desember 2015

Bulan	Harga GKP
Januari	4456,2998
Februari	4446,2970
Maret	4265,7533
April	4174,3533
Mei	4193,3798
Juni	4207,0209
Juli	4200,2403
Agustus	4154,9033
September	4236,7043
Oktober	4390,4998
Nopember	4465,3372
Desember	4478,8509

Tabel 4.17 menjelaskan bahwa harga gabah kering panen (GKP) selama 1 tahun ke depan yaitu pada bulan Januari-Desember 2015 akan terus mengalami kenaikan. Harga GKP paling tinggi terjadi pada bulan Nopember 2015, sedangkan pada bulan April 2015 harga GKP paling rendah. Harga GKP mengalami penurunan pada bulan Februari 2015, namun akan naik kembali pada bulan Juni 2015 dan akan terus naik sampai pada bulan Nopember 2015, lalu mengalami penurunan kembali pada bulan Desember 2015.

Tabel 4.18 Nilai Ramalan Harga GKG
Periode Januari-Desember 2015

Bulan	Harga GKG
Januari	5072,296
Februari	5096,275
Maret	5100,739
April	5082,629
Mei	5068,857
Juni	5062,974
Juli	5063,539
Agustus	5062,817
September	5064,296
Oktober	5066,906
Nopember	5067,443
Desember	5067,419

Berdasarkan Tabel 4.18 sama seperti harga GKP, harga gabah kering giling (GKG) selama 1 tahun ke depan yaitu pada bulan Januari-Desember 2015 juga akan terus mengalami kenaikan. Harga GKG akan mengalami terus penurunan mulai bulan April 2015, namun akan naik kembali pada bulan September 2015.

Tabel 4.19 Nilai Ramalan Harga Beras
Periode Januari-Desember 2015

Bulan	Harga Beras
Januari	7978,559
Februari	7801,544
Maret	7524,929
April	7395,609

Tabel 4.19 Nilai Ramalan Harga Beras
Periode Januari-Desember 2015 (Lanjutan)

Bulan	Harga Beras
Mei	7449,131
Juni	7551,790
Juli	7671,771
Agustus	7762,639
September	7796,269
Oktober	7908,053
Nopember	8030,082
Desember	8090,269

Tabel 4.19 menjelaskan bahwa kondisi harga beras selama 1 tahun ke depan yaitu pada bulan Januari-Desember 2015 akan terus mengalami kenaikan. Harga beras paling tinggi terjadi pada bulan Desember 2015, sedangkan harga beras paling rendah pada bulan April 2015. Harga beras mengalami penurunan pada bulan Februari 2015, namun akan naik kembali pada bulan Mei 2015 dan akan terus naik sampai pada bulan Desember 2015.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan pada bab sebelumnya, maka didapatkan kesimpulan sebagai berikut.

1. Model ARIMA terbaik untuk masing-masing harga GKP, GKG, beras adalah sebagai berikut:
 - a. Harga GKP : ARIMA (0,1,[5,11]) (1,0,0)¹²
 - b. Harga GKG : ARIMA (0,1,0)(1,0,1)¹²
 - c. Harga Beras : ARIMA (0,1,1)(1,0,1)¹²
2. Pemodelan menggunakan VAR didapatkan orde 6 pada AR setelah dilakukan *differencing* sehingga diperoleh model VARI(6,1).
3. Secara keseluruhan berdasarkan kriteria RMSE dan MAPE *out sample*, model VAR(6) merupakan model yang sesuai untuk meramalkan harga gabah kering giling (GKG). Sedangkan untuk harga gabah kering panen (GKP) dan beras lebih sesuai jika menggunakan model ARIMA.

5.2 Saran

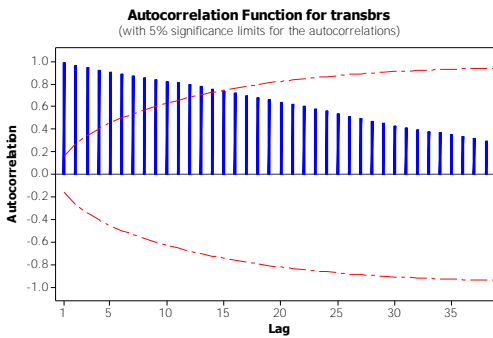

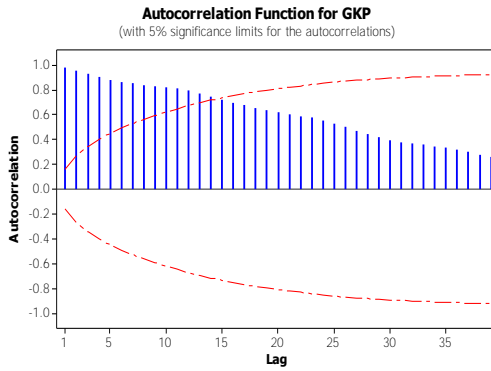
Data yang digunakan untuk penelitian selanjutnya diharapkan memiliki *series* yang lebih panjang agar pemodelan dengan VAR maupun ARIMA bisa menangkap orde yang lebih panjang sehingga ramalan yang dihasilkan bisa lebih baik.

Halaman ini sengaja dikosongkan

LAMPIRAN

Lampiran 1. Data Harga GKP, GKG, dan Beras Tingkat
Produsen Jawa Timur


No	Tahun	Bulan	Harga		
			GKP	GKG	Beras
1	2001	Januari	1017.76	1302.56	2057.54
2	2001	Februari	1093.76	1507.62	2067.23
3	2001	Maret	1054.41	1454.6	1990
4	2001	April	1057.96	1461.98	1910.73
5	2001	Mei	1062.63	1455.85	1918.71
6	2001	Juni	1088.55	1460.58	1962.77
7	2001	Juli	1088.41	1497.78	2010.57
8	2001	Agustus	1153.26	1503	2111.03
9	2001	September	1237.2	1522.78	2240.46
10	2001	Oktober	1288.19	1545.07	2348.23
11	2001	Nopember	1287.69	1584.93	2407.73
12	2001	Desember	1313.4	1688.33	2493.75
.
.
.
1	2014	Januari	4157.6923	4856.9231	7745.38
2	2014	Februari	4002.8846	4796.1538	7551.44
3	2014	Maret	3803.2692	4631.7308	7210.58
4	2014	April	3645.7692	4436.3462	7026.92
5	2014	Mei	3793.6538	4519.7115	7062.69
6	2014	Juni	3844.0385	4577.4038	7133.37
7	2014	Juli	3863.4615	4582.6923	7151.25
8	2014	Agustus	3860.0962	4644.2308	7263.4615
9	2014	September	3865.3846	4655.7692	7273.0769
10	2014	Oktober	4133.1538	4792.3846	7428.6923
11	2014	Nopember	4360.8654	4996.25	7629.6154
12	2014	Desember	4412.1154	5035.5769	7697.7885

Lampiran 2. Plot ACF Data Harga GKP, GKG, dan Beras

Lampiran 3. Plot ACF dan PACF Data Harga GKP, GKG, dan Beras Setelah *Differencing*


Autocorrelation Function for GKP

(with 5% significance limits for the autocorrelations)




Partial Autocorrelation Function for GKP

(with 5% significance limits for the partial autocorrelations)




Autocorrelation Function for GKG

(with 5% significance limits for the autocorrelations)




Partial Autocorrelation Function for GKG

(with 5% significance limits for the partial autocorrelations)




Autocorrelation Function for diffrs

(with 5% significance limits for the autocorrelations)



Partial Autocorrelation Function for diffrs

(with 5% significance limits for the partial autocorrelations)



Lampiran 4

Program SAS ARIMA Data Harga Gabah Kering Panen (GKP)

```
data harga;
input x;
datalines;
6.92536
6.99738
6.96074
6.96410
6.96850
6.99260
6.99247
.
.
.
8.19903
8.24724
8.26285
8.28322
8.30552
8.32230
8.30490
;

proc arima data=harga;
identify noprint var=x(1);
estimate noconstant p=(12) q=(5,11) method=cls;
run;
outlier maxnum=100 alpha=0.01;
run;
forecast lead=12 printall out=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 5

Output SAS Signifikansi Parameter dan Uji White Noise ARIMA Data Harga Gabah Kering Panen (GKP)

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.32785	0.07307	4.49	<.0001	5
MA1,2	-0.35737	0.07667	-4.66	<.0001	11
AR1,1	0.24049	0.08204	2.93	0.0039	12

Variance Estimate 0.00151
 Std Error Estimate 0.038865
 AIC -563.933
 SBC -554.803
 Number of Residuals 155

* AIC and SBC do not include log determinant.

Correlations of Parameter Estimates

Parameter	MA1,1	MA1,2	AR1,1
MA1,1	1.000	0.073	0.042
MA1,2	0.073	1.000	0.111
AR1,1	0.042	0.111	1.000

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.34	3	0.1486	0.168	-0.058	0.019	0.022	0.033	-0.016
12	8.18	9	0.5157	0.045	0.044	0.024	0.072	-0.068	-0.050
18	13.21	15	0.5859	-0.035	-0.088	-0.027	0.134	0.029	-0.014
24	25.19	21	0.2392	-0.053	-0.107	0.022	-0.052	0.075	0.205
30	32.68	27	0.2077	0.113	0.006	-0.040	-0.003	-0.128	-0.091

Lampiran 6

Program SAS ARIMA Data Harga Gabah Kering Giling (GKG)

```
data harga;
input x;
datalines;
7.17209
7.31829
7.28249
7.28755
7.28335
7.28659
7.31174
.
.
.
8.41119
8.44413
8.44628
8.46428
8.47941
8.48505
8.47557
;

proc arima data=harga;
identify noprint var=x(1);
estimate noconstant p=(12) q=(12) method=cls;
run;
outlier maxnum=100 alpha=0.01;
run;
forecast lead=12 printall out=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
```

Lampiran 7

Output SAS Signifikansi Parameter dan Uji White Noise ARIMA Data Harga Gabah Kering Giling (GKG)

The SAS System									
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	0.67187		0.13994	4.80	<.0001	12			
AR1,1	0.89393		0.09694	9.22	<.0001	12			
Variance Estimate				0.001218					
Std Error Estimate				0.034903					
AIC				-598.248					
SBC				-592.161					
Number of Residuals				155					
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	AR1,1							
MA1,1	1.000	0.895							
AR1,1	0.895	1.000							
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.06	4	0.5473	0.010	0.013	-0.037	0.022	-0.122	-0.042
12	7.98	10	0.6306	0.075	-0.079	-0.038	0.083	0.084	-0.045
18	12.05	16	0.7407	0.046	-0.042	-0.075	0.071	0.081	-0.047
24	15.47	22	0.8413	-0.032	0.002	0.041	-0.081	0.085	0.045
30	25.85	28	0.5813	-0.057	-0.061	0.069	-0.076	-0.180	0.063

Lampiran 8

Program SAS ARIMA Data Harga Beras

```
data harga;
input x;
datalines;
45.3601
45.4668
44.6094
43.7119
43.8031
44.3032
44.8394
.
.
.

83.0113
84.2159
84.6202
84.9377
85.4265
85.5665
85.6002
;

proc arima data=harga;
identify noprint var=x(1);
estimate noconstant p=(12) q=(1)(12) method=cls;
run;
outlier maxnum=100 alpha=0.01;
run;
forecast lead=12 printall out=out2;
run;
proc univariate data=out2 normal;
var residual;
```

Lampiran 9

Output SAS Signifikansi Parameter dan Uji White Noise ARIMA Data Harga Beras

The SAS System									
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	-0.42949		0.07658	-5.61	<.0001	1			
MA2,1	0.89351		0.16769	5.33	<.0001	12			
AR1,1	1.00000		0.11552	8.66	<.0001	12			
Variance Estimate				0.677128					
Std Error Estimate				0.822878					
AIC				382.4079					
SBC				391.5381					
Number of Residuals				155					
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Parameter	MA1,1	MA2,1	AR1,1						
MA1,1	1.000	-0.067	-0.019						
MA2,1	-0.067	1.000	0.974						
AR1,1	-0.019	0.974	1.000						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.45	3	0.2165	-0.004	-0.081	0.088	-0.022	-0.102	0.049
12	13.86	9	0.1273	0.009	-0.075	-0.070	0.098	0.189	0.002
18	19.05	15	0.2116	0.030	-0.095	-0.040	0.121	0.055	-0.025
24	24.76	21	0.2576	-0.021	-0.021	-0.006	-0.118	0.101	0.078
30	30.51	27	0.2919	-0.001	0.014	-0.028	0.078	-0.123	-0.087

Lampiran 10.*Output SAS model ARIMA dengan deteksi Outlier***1. Model ARIMA Harga GKG ARIMA (0,1,0)(1,0,1)¹² + ao1 +ao122+ ao31**

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1,1	0.72238	0.13142	5.50	<.0001	12	x	0
AR1,1	0.92583	0.08556	10.82	<.0001	12	x	0
NUM1	-0.09395	0.03295	-2.85	0.0050	0	ao122	0
NUM2	-0.08197	0.03221	-2.55	0.0119	0	ao31	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.20	4	0.6999	0.032	-0.011	0.009	0.028	-0.107	-0.005
12	9.05	10	0.5277	0.110	-0.057	-0.068	0.104	0.078	-0.064
18	12.68	16	0.6958	0.033	-0.036	-0.089	0.049	0.059	-0.067
24	17.06	22	0.7602	-0.032	0.016	0.022	-0.068	0.108	0.076
30	27.39	28	0.4972	-0.079	-0.070	0.112	-0.085	-0.129	0.080

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.971283	Pr < W	0.0025
Kolmogorov-Smirnov	D	0.070431	Pr > D	0.0592
Cramer-von Mises	W-Sq	0.165895	Pr > W-Sq	0.0158
Anderson-Darling	A-Sq	0.990806	Pr > A-Sq	0.0136

2. Model ARIMA Harga Beras ARIMA (0,1,1)(1,0,1)¹² + ls74
 ls122+ls76+ls127+ao60+ao13+ls109+ls126+ls51+ls58+ls69
 +ao107+ls72+ao119+ls62+ls98

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1,1	-0.78989	0.05606	-14.09	<.0001	1	x	0
MA2,1	0.70688	0.10826	6.53	<.0001	12	x	0
AR1,1	1.00000	0.05155	19.40	<.0001	12	x	0
NUM1	2.36427	0.46268	5.11	<.0001	0	ls74	0
NUM2	-2.26485	0.38666	-5.86	<.0001	0	ls122	0
NUM3	-2.29801	0.38783	-5.93	<.0001	0	ls76	0
NUM4	2.84801	0.50181	5.68	<.0001	0	ls127	0
NUM5	-2.13522	0.46296	-4.61	<.0001	0	ao60	0
NUM6	1.68273	0.31431	5.35	<.0001	0	ao13	0
NUM7	1.50349	0.40303	3.73	0.0003	0	ls109	0
NUM8	1.85150	0.51686	3.58	0.0005	0	ls126	0
NUM9	1.54591	0.31626	4.89	<.0001	0	ls51	0
NUM10	1.36469	0.39379	3.47	0.0007	0	ls58	0
NUM11	-1.32450	0.35333	-3.75	0.0003	0	ls69	0
NUM12	-1.39439	0.39549	-3.53	0.0006	0	ao107	0
NUM13	1.39965	0.42724	3.28	0.0013	0	ls72	0
NUM14	-1.40988	0.35564	-3.96	0.0001	0	ao119	0
NUM15	0.90693	0.40327	2.25	0.0261	0	ls62	0
NUM16	1.25227	0.32318	3.87	0.0002	0	ls98	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.49	3	0.6855	0.061	-0.010	0.022	0.011	-0.063	0.027
12	4.15	9	0.9013	-0.030	0.039	-0.086	0.070	0.022	-0.029
18	11.41	15	0.7231	-0.044	0.133	0.004	0.128	0.045	-0.061
24	16.39	21	0.7475	-0.102	-0.010	-0.034	-0.118	-0.003	0.044
30	23.29	27	0.6695	-0.115	-0.020	-0.085	0.075	-0.098	-0.015

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.97822	Pr < W	0.0148
Kolmogorov-Smirnov	D	0.059926	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.117551	Pr > W-Sq	0.0683
Anderson-Darling	A-Sq	0.84203	Pr > A-Sq	0.0305

Lampiran 11. Program SAS VAR (6) restrict

```

data harga;
  input GKP GKG BRS;
  datalines;
6.92536 7.17209 7.62927
6.99738 7.31829 7.63396
6.96074 7.28249 7.59589
6.96410 7.28755 7.55524
6.96850 7.28335 7.55941
6.99260 7.28659 7.58211
6.99247 7.31174 7.60617
.
.
.
.
.
8.19903 8.41119 8.83795
8.24724 8.44413 8.86677
8.26285 8.44628 8.87635
8.28322 8.46428 8.88384
8.30552 8.47941 8.89531
8.32230 8.48505 8.89859
8.30490 8.47557 8.89938
;

proc varmax data=harga printall;
model GKP GKG BRS/minic=(p=18) p=6 dftest dify(1) noint;
restrict
AR(5,3,3)=0, AR(6,3,2)=0, AR(3,3,3)=0, AR(5,1,3)=0, AR(4,3,2)=0
AR(4,1,2)=0, AR(1,1,3)=0, AR(6,1,2)=0, AR(6,2,1)=0, AR(5,2,3)=0
AR(1,1,2)=0, AR(5,1,2)=0, AR(3,1,3)=0, AR(4,1,1)=0, AR(2,3,3)=0
AR(2,1,1)=0, AR(2,3,1)=0, AR(3,3,2)=0, AR(3,1,1)=0, AR(2,1,3)=0
AR(2,2,3)=0, AR(4,2,3)=0, AR(4,1,3)=0, AR(1,3,2)=0, AR(6,3,3)=0
AR(1,2,3)=0, AR(6,2,2)=0, AR(6,1,3)=0, AR(6,1,1)=0, AR(5,3,2)=0
AR(3,1,2)=0, AR(5,3,1)=0, AR(2,2,2)=0, AR(2,2,1)=0, AR(2,1,2)=0
AR(4,2,2)=0, AR(4,2,1)=0, AR(1,3,3)=0, AR(3,2,1)=0, AR(5,2,2)=0
AR(6,2,3)=0, AR(3,2,2)=0, AR(5,2,1)=0;
output lead = 12 out=hasil;
run;

```

BIODATA PENULIS



Penulis dengan nama lengkap Yunaz Firdhani dilahirkan di Kediri pada tanggal 24 Juli 1991. Penulis merupakan anak kedua dari dua bersaudara. Penulis telah menempuh pendidikan formal yaitu SDN Mekikis II, SMPN 2 Kertosono, SMAN 1 Patianrowo. Setelah lulus dari SMAN 1 Patianrowo, penulis diterima di Jurusan Statistika FMIPA ITS untuk program Diploma III Statistika ITS dan melanjutkan program Lintas Jalur Sarjana pada tahun 2013 dengan NRP 1313105017. Jika terdapat kritik dan saran dapat dikirim melalui email penulis di yunaz.165@gmail.com