



TUGAS AKHIR - SM 141501

ESTIMASI INFLASI WILAYAH KERJA KP_wBI MALANG MENGGUNAKAN ARIMA-FILTER KALMAN DAN VAR-FILTER KALMAN

**POPY FEBRITASARI
NRP 1212 100 056**

**Dosen Pembimbing
Prof. Dr. Erna Apriliani, M.Si
Dra. Nuri Wahyuningsih, M.Kes**

**JURUSAN MATEMATIKA
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2016**



FINAL PROJECT - SM 141501

***ESTIMATION OF INFLATION IN KPwBI
MALANG REGION USING ARIMA- KALMAN
FILTER AND VAR- KALMAN FILTER METHOD***

POPY FEBRITASARI
NRP 1212 100 056

Supervisors

Prof. Dr. Erna Apriliani, M.Si

Dra. Nuri Wahyuningsih, M.Kes

DEPARTMENT OF MATHEMATICS
Faculty of Mathematics and Natural Sciences
Institut Teknologi Sepuluh Nopember
Surabaya 2016

LEMBAR PENGESAHAN

**ESTIMASI INFLASI WILAYAH KERJA KPwBI MALANG
MENGUNAKAN ARIMA-FILTER KALMAN DAN VAR-
FILTER KALMAN
ESTIMATION OF INFLATION'S MODELS IN KPwBI
MALANG REGION WITH ARIMA-FILTER KALMAN
AND VAR-FILTER KALMAN METHOD**

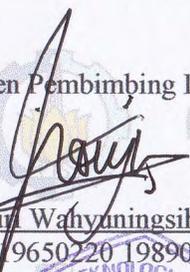
Diajukan Untuk Memenuhi Salah Satu Syarat
Untuk Memperoleh Gelar Sarjana Sains
pada
Bidang Studi Matematika Terapan
Program Studi S-1 Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember Surabaya
Oleh :

POPY FEBRITASARI
NRP. 1212 100 056

Dosen Pembimbing II

Menyetujui,

Dosen Pembimbing I


Dra. Nury Wahyuningsih, M.Kes
NIP. 19650220 198903 2 002


Prof. Dr. Erna Apriliani, M.Si
NIP. 19660414 199102 2 001

Mengetahui,
Ketua Jurusan Matematika
FMIPA ITS


Dr. Imam Mukhlash, S.Si, MT
NIP. 19700831 199403 1 003



ESTIMASI INFLASI WILAYAH KERJA KP_wBI MALANG MENGGUNAKAN ARIMA-FILTER KALMAN DAN VAR-FILTER KALMAN

Nama Mahasiswa : POPY FEBRITASARI
NRP : 1212 100 056
Jurusan : Matematika
Dosen Pembimbing : 1. Prof. Dr. Erna Apriliani, M.Si
2. Dra. Nuri Wahyuningsih, M.Kes

Abstrak

ARIMA Box-jenkins dan VAR adalah salah satu metode time series yang biasa digunakan untuk melakukan analisis data dan peramalan. Dalam kehidupan sehari-hari, kita sering menemukan data yang mempunyai keterkaitan dalam deret waktu. Data yang memiliki ketekaitn deret waktu merupakan data time series, dimana data tersebut selalu berubah-ubah setiap periode waktu dengan berbagai macam faktor. Untuk mendapatkan prediksi yang mempunyai tingkat error yang kecil, maka akan dilakukan perbandingan dua model yaitu Vector Autoregressive (VAR)-Filter Kalman dan model Autoregressive Integrated Moving Average (ARIMA)-Filter Kalman. Algoritma Filter Kalman akan diterapkan pada hasil ramalan pemodelan ARIMA dan VAR dengan pengambilan derajat polinomial kesatu, dua, dan tiga untuk memperbaiki prediksi 7 bulan ke depan. Hasil akhir menunjukan bahwa Filter Kalman mampu memperbaiki hasil estimasi ARIMA dan VAR. Dimana tingkat error ARIMA-Filter Kalman dan VAR-Filter Kalman lebih kecil dibandingkan dengan ARIMA dan VAR, yang ditunjukan melalui hasil simulasi berupa grafik dan diperjelas dengan nilai MAPE yang lebih kecil. Pengambilan derajat polinomial mempengaruhi hasil prediksi, semakin besar derajat polinomial maka semakin kecil error prediksi.

Kata Kunci : ARIMA, Filter Kalman, polinomial derajat, VAR.

ESTIMATION OF INFLATION IN KPwBI MALANG REGION WITH ARIMA- KALMAN FILTER AND VAR- KALMAN FILTER METHOD

Name : POPY FEBRITASARI
NRP : 1212 100 056
Departement : Matematika
Supervisors : 1. Prof. Dr. Erna Apriliani, M.Si
2. Dra. Nuri Wahyuningsih, M.Kes

Abstract

ARIMA Box-jenkins and VAR are time series's methods that can be used for analyzing data and forecasting. In our daily life, we had found data that have link with time. The data that have link with time is called time series data, and it always changes everytime for some reasons. To obtain an estimation that has smallest error, we compare two methods, that are Vector Autoregressive (VAR)-Kalman Filter and Autoregressive Integrated Moving Average (ARIMA)-Kalman Filter's model. Kalman Filter algorithm will be used in ARIMA's forecasting model and VAR's forecasting model with first to third polinomial degree for fix the estimate. The final project shows that Kalman Filter can be fixed the estimate of ARIMA's forecasting and VAR's forecasting. ARIMA-Kalman filter's and VAR-Kalman Filter's error is smaller than ARIMA's and VAR's forecasting. We can see the graph and MAPE on the simulation. The choice of polinomial degree has an effect to estimation results, bigger polinomial degree will produce smaller error.

Kata Kunci : *ARIMA, Kalman Filter, polinomial's degree, VAR*

KATA PENGANTAR

Segala Puji bagi Allah SWT Tuhan semesta alam yang telah memberikan karunia, rahmat dan anugerah-Nya sehingga penulis dapat menyelesaikan Tugas Akhir yang berjudul: **“Estimasi Inflasi Pada Wilayah Kerja KPwBI Malang Menggunakan ARIMA-Filter Kalman dan VAR-Filter Kalman”** yang merupakan salah satu persyaratan akademis dalam menyelesaikan Program Studi S-1 pada Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Institut Teknologi Sepuluh Nopember Surabaya.

Tugas Akhir ini dapat diselesaikan berkat kerjasama, bantuan, dan dukungan dari banyak pihak. Sehubungan dengan hal itu, penulis mengucapkan terima kasih kepada :

1. Dr. Imam Mukhlash, S.Si, MT selaku Ketua Jurusan Matematika FMIPA ITS.
2. Prof. Dr. Erna Apriliani, M.Si dosen pembimbing pertama Tugas Akhir atas segala bimbingan dan motivasi yang telah diberikan kepada penulis.
3. Dra. Nuri Wahyuningsih, M.Kes sebagai dosen pembimbing kedua Tugas Akhir atas segala bimbingan dan motivasi yang telah diberikan kepada penulis.
4. Drs. Chairul Imron, Ml.Komp selaku Koordinator Program Studi S1 Jurusan Matematika FMIPA ITS dan dosen penguji Tugas Akhir.
5. Endah Rokhmati M.P, Ph.D dan Dr. Dieky Adzkiya, S.Si, M.Si selaku dosen penguji Tugas Akhir.
6. Prof. DR. Tech. Mohammad Isa Irawan, MT selaku dosen wali penulis yang telah memberikan arahan akademik selama penulis menempuh pendidikan di Jurusan Matematika FMIPA ITS.
7. Kepala dan *staff* Kantor Perwakilan Bank Indonesia Kota Malang yang membantu penulis untuk mendapatkan data inflasi *month to month* Kota Malang dan Probolinggo.

8. Bapak dan Ibu dosen serta seluruh *staff* Tata Usaha dan Laboratorium Jurusan Matematika FMIPA-ITS.
9. Teman-Teman mahasiswa Jurusan Matematika ITS.

Penulis menyadari bahwa Tugas Akhir ini masih jauh dari kesempurnaan. Oleh karena itu, penulis mengharapkan saran dan kritik dari pembaca. Akhir kata, semoga Tugas Akhir ini bermanfaat bagi semua pihak yang berkepentingan.

Surabaya, 27 Januari 2016

Penulis

Special thanks to

Selama proses pembuatan Tugas Akhir ini, banyak pihak yang telah memberikan bantuan dan dukungan untuk penulis. Penulis mengucapkan terima kasih dan apresiasi secara khusus kepada:

1. Kedua orang tua Bapak Tri Priyo dan Ibu Dwi Ratna Rachmawati, yang selalu mendukung baik secara moril, materi maupun motivasi yang telah diberikan kepada penulis.
2. Kedua saudara kandung dan seluruh keluarga besar, yang selalu memberikan semangat, nasehat, serta motivasi kepada penulis.
3. Senior-senior 2011++ yang telah membantu proses pengerjaan Tugas Akhir.
4. Seluruh teman-teman angkatan 2012, terima kasih atas segala bentuk semangat dan dukungannya kepada penulis.
5. MAT12IKS dan HIMATIKA ITS sebagai keluarga kedua bagi penulis.
6. Sahabat dan teman-teman penulis di Malang, yang selalu memberikan dukungan dan hiburan.

Dan tentu saja masih banyak pihak lain yang turut andil dalam penyelesaian tugas akhir ini yang tidak bisa penulis sebutkan satu persatu. Semoga Allah membalas dengan balasan yang lebih baik bagi semua pihak yang telah membantu penulis. *Amin ya rabbal 'alamin.*

DAFTAR ISI

| | Hal. |
|--|-------|
| HALAMAN JUDUL | i |
| COVER | iii |
| LEMBAR PENGESAHAN | v |
| ABSTRAK | vii |
| ABSTRACT | ix |
| KATA PENGANTAR | xi |
| DAFTAR ISI | xv |
| DAFTAR TABEL | xix |
| DAFTAR GAMBAR | xxi |
| DAFTAR LAMPIRAN | xxv |
| DAFTAR NOTASI | xxvii |
| BAB I PENDAHULUAN | 1 |
| 1.1 Latar Belakang..... | 1 |
| 1.2 Rumusan Masalah..... | 3 |
| 1.3 Batasan Masalah..... | 3 |
| 1.4 Tujuan..... | 4 |
| 1.5 Manfaat..... | 4 |
| 1.6 Sistematika Penulisan | 5 |
| BAB II TINJAUAN PUSTAKA | 7 |
| 2.1 Inflasi..... | 7 |
| 2.2 Univariat <i>Time series</i> | 8 |
| 2.2.1 Stasioneritas Model Univariat <i>Time Series</i> | 8 |
| 2.2.2 Model <i>Autoregressive Integrated Moving Averages</i> (ARIMA)..... | 10 |
| 2.3 <i>Multivariate Time series</i> | 12 |
| 2.3.1 <i>Matrix Autocorrelation Function</i> (MACF)..... | 13 |
| 2.3.2 <i>Matrix Partial Autocorrelation Function</i> (MPACF) ... | 15 |
| 2.3.3 Model VAR (<i>Vector Autoregressive</i>) | 16 |
| 2.3.4 Penaksiran Parameter Model VAR..... | 17 |
| 2.3.5 Peramalan Model VAR..... | 19 |
| 2.4 Kalman Filter | 20 |

| | |
|---|----|
| 2.5 Penerapan Kalman Filter Pada Prediksi Pola Inflasi dari Hasil Prediksi ARIMA dan VAR | 21 |
| 2.6 Kriteria Pemilihan Terbaik | 22 |
| BAB III METODE PENELITIAN | 25 |
| 3.1 Tahap Penelitian | 25 |
| 3.2 Diagram Alir | 26 |
| BAB IV ANALISIS DAN PEMBAHASAN | 31 |
| 4.1 Variabel dan Data Penelitian | 31 |
| 4.2 Pemodelan ARIMA | 31 |
| 4.2.1 Model ARIMA Inflasi <i>month to month</i> Kota Malang di Z1. | 32 |
| 4.2.2 Model ARIMA Inflasi <i>month to month</i> Kota Probolinggo di Z2. | 44 |
| 4.3 Pemodelan <i>Vector Autoregressive</i> (VAR)..... | 56 |
| 4.3.1 Identifikasi Orde Model VAR..... | 57 |
| 4.3.2 Uji Normalitas..... | 59 |
| 4.3.3 Autocorrelation Test | 60 |
| 4.3.4 Uji Heterokedastisitas | 62 |
| 4.3.5 Uji Parameter | 64 |
| 4.3.6 Peramalan Model VAR..... | 66 |
| 4.4 Penerapan dan Simulasi ARIMA Filter Kalman Pada Data Inflasi <i>month to month</i> | 66 |
| 4.4.1 Penerapan dan Simulasi ARIMA Filter Kalman n = 2 Pada Data Inflasi <i>month to month</i> di Kota Malang | 67 |
| 4.4.2 Penerapan dan Simulasi ARIMA Filter Kalman n = 3 Pada Data Inflasi <i>month to month</i> Kota Malang..... | 70 |
| 4.4.3 Penerapan dan Simulasi ARIMA Filter Kalman n = 4 Pada Data Inflasi <i>month to month</i> Kota Malang | 73 |
| 4.4.4 Penerapan dan Simulasi ARIMA Filter Kalman n = 2 Pada Data Inflasi <i>month to month</i> di Kota Probolinggo | 76 |
| 4.4.5 Penerapan dan Simulasi ARIMA Filter Kalman n = 3 Pada Data Inflasi <i>month to month</i> Kota Probolinggo . | 77 |

| | |
|---|-----|
| 4.4.6 Penerapan dan Simulasi ARIMA Filter Kalman $n = 4$ Pada Data Inflasi <i>month to month</i> Kota Probolinggo.. | 79 |
| 4.5 Penerapan dan Simulasi VAR Filter Kalman Pada Data Inflasi <i>month to month</i> | 80 |
| 4.5.1 Penerapan dan Simulasi VAR Filter Kalman Pada Data Inflasi <i>month to month</i> di Kota Malang | 81 |
| 4.5.2 Penerapan dan Simulasi VAR Filter Kalman $n = 2$ Pada Data Inflasi <i>month to month</i> di Kota Probolinggo | 83 |
| 4.6 Perbandingan Model ARIMA, VAR, ARIMA-Filter Kalman dan VAR-Filter Kalman..... | 85 |
| BAB V KESIMPULAN DAN SARAN | 87 |
| 5.1 Kesimpulan..... | 87 |
| 5.2 Saran | 87 |
| DAFTAR PUSTAKA | 89 |
| LAMPIRAN | 91 |
| BIODATA | 109 |

DAFTAR GAMBAR

| | Hal |
|---|-----|
| Gambar 2.1 Contoh Plot MACF untuk 3 Data Time Series .. | 15 |
| Gambar 2.2 Contoh Plot MPACF untuk 3 Data Time Series | 16 |
| Gambar 3.1 Diagram Alir Pembagian Model <i>Time Series</i> | 26 |
| Gambar 3.2 Diagram Alir Penerapan ARIMA-Filter Kalman..... | 27 |
| Gambar 3.3 Diagram Alir Pembentukan Model VAR-Filter Kalman | 28 |
| Gambar 3.4 Diagram Alir Perbandingan Model ARIMA, VAR, ARIMA-Filter Kalman, dan VAR-Filter Kalman | 29 |
| Gambar 4.1 Plot Box-Cox Data Sebelum Transformasi | 33 |
| Gambar 4.2 Plot Box-Cox Data Sesudah Transformasi..... | 33 |
| Gambar 4.3 Plot <i>Time Series</i> $Z_1(t)$ Hasil Transformasi..... | 34 |
| Gambar 4.4 Plot <i>Time Series</i> $Z_1(t)$ Stasioner dalam <i>Mean</i> ... | 35 |
| Gambar 4.5 Plot ACF $Z_1(t)$ | 36 |
| Gambar 4.6 Plot PACF $Z_1(t)$ | 36 |
| Gambar 4.7 Residual Diagnostics Histogram-normality Test di $Z_1(t)$ | 42 |
| Gambar 4.8 Uji Signifikan ARIMA ($[1],0,[2]$)..... | 43 |
| Gambar 4.9 Plot Box-Cox Data Sebelum Transformasi | 45 |
| Gambar 4.10 Plot Box-Cox Data Sesudah Transformasi..... | 46 |
| Gambar 4.11 Plot <i>Time Series</i> $Z_2(t)$ Hasil Transformasi | 46 |
| Gambar 4.12 Plot <i>Time Series</i> $Z_2(t)$ Stasioner dalam <i>Mean</i> ... | 47 |
| Gambar 4.13 Plot ACF $Z_2(t)$ | 47 |
| Gambar 4.14 Plot PACF $Z_2(t)$ | 48 |

| | |
|---|----|
| Gambar 4.15 <i>Residual Diagnostics Histogram-normality Test</i> di $Z2(t)$ | 55 |
| Gambar 4.16 Uji Signifikan Parameter ARIMA ($[3],0,[3,6]$) . | 56 |
| Gambar 4.17 MACF Plot Data Inflasi Month to Month Kota Malang dan Probolinggo | 57 |
| Gambar 4.18 MPACF Plot Data Inflasi <i>Month to Month</i> Kota Malang dan Probolinggo | 58 |
| Gambar 4.19 Hasil <i>Lag Order Selection Criteria</i> | 59 |
| Gambar 4.20 Hasil Uji Normalitas..... | 60 |
| Gambar 4.21 Hasil Uji Autokorelasi Residual..... | 62 |
| Gambar 4.22 Hasil <i>White Heteroscedasticity Test</i> Redisual ... | 64 |
| Gambar 4.23 Hasil Simulasi Inflasi <i>month to month</i> Kota Malang pada ARIMA Filter Kalman $n = 2$ dengan (a) $Q = 0.1, R = 0.01,$ (b) $Q = R = 0.1$ | 69 |
| Gambar 4.24 Hasil Simulasi Inflasi <i>month to month</i> Kota Malang pada ARIMA Filter Kalman $n = 3$ dengan (a) $Q = 0.1, R = 0.01$ (b) $Q = R = 0.1$ | 72 |
| Gambar 4.25 Hasil Simulasi Inflasi <i>month to month</i> Kota Malang pada ARIMA Filter Kalman $n = 4$ dengan (a) $Q = 0.1, R = 0.01$ (b) $Q = R = 0.1$ | 75 |
| Gambar 4.26 Hasil Simulasi Inflasi <i>month to month</i> Kota Probolinggo pada ARIMA Filter Kalman $n = 2$ dengan (a) $Q = 0.1, R = 0.01$ (b) $Q = R = 0.1$ | 76 |
| Gambar 4.27 Hasil Simulasi Inflasi <i>month to month</i> Kota Probolinggo pada ARIMA Filter Kalman $n = 2$ | |

dengan (a) $Q = 0.1, R = 0.01$ (b) $Q = R = 0.1$
.....78

Gambar 4.28 Hasil Simulasi Inflasi *month to month* Kota
Probolinggo pada ARIMA Filter Kalman $n =$
4 dengan (a) $Q = 0.1, R = 0.001$ (b) $Q = 0.1,$
 $R = 0.1$ 80

Gambar 4.29 Hasil Simulasi Inflasi *month to month* Kota
Malang pada VAR Filter Kalman dengan $Q =$
0.1, $R = 0.01$ dan (a) polinomial 1 ($n = 2$), (b)
polinomial 2 $n = 3$, (c) polinomial 3 ($n = 4$) .. 82

Gambar 4.30 Hasil Simulasi Inflasi *month to month* Kota
Probolinggo pada VAR Filter Kalman dengan
 $Q = 0.1, R = 0.01$ dan (a) polinomial 1 ($n = 2$),
(b) polinomial 2 $n = 3$, (c) polinomial 3 ($n = 4$)
.....84

DAFTAR TABEL

| | Hal |
|---|-----|
| Tabel 2.1 Transformasi Box Cox | 9 |
| Tabel 2.2 Contoh Nilai MACF untuk 3 Data Time Series | 14 |
| Tabel 2.3 Contoh Nilai MPACF untuk 3 Data <i>Time Series</i> | 16 |
| Tabel 4.1 Deskripsi Data Inflasi <i>Month to Month</i> Kota Malang dan Probolinggo | 31 |
| Tabel 4.2 Estimasi Parameter Model ARIMA ([1,2],0[1,2]) | 35 |
| Tabel 4.3 Hasil Pengujian Asumsi Residual <i>White Noise</i> dan Berdistribusi Normal serta Nilai AIC dan SBC.... | 40 |
| Tabel 4.4 Hasil Pengujian Estimasi Parameter ARIMA ([1],0,[2]) | 41 |
| Tabel 4.5 Estimasi Parameter Model ARIMA ([2,3,22],0,[2,3,6]) | 48 |
| Tabel 4.6 Hasil Pengujian Asumsi Residual <i>White Noise</i> dan Berdistribusi Normal serta Nilai AIC dan SBC | 53 |
| Tabel 4.7 Hasil Pengujian Estimasi Parameter ARIMA ([3],0,[3,6])..... | 54 |
| Tabel 4.8 Hasil <i>Forecasting</i> ARIMA..... | 55 |
| Tabel 4.9 Hasil Estimasi Parameter Model VAR (3) Setelah Restrict | 65 |
| Tabel 4.10 Hasil <i>Forecasting</i> VAR (3)..... | 66 |
| Tabel 4.11 Hasil Perbandingan MAPE ARIMA, VAR, ARIMA Filter Kalman, dan VAR-Filter Kalman | 86 |

DAFTAR NOTASI

- p : orde dari AR
 q : orde dari MA
 ϕ_p : koefisien orde p
 θ_q : koefisien orde q
 B : *backward shift*
 Z_t : besarnya pengamatan (kejadian) pada waktu ke- t
 a_t : suatu proses *white noise* atau galat pada waktu ke- t
yang diasumsikan mempunyai *mean* 0 dan varian konstan σ_a^2
 n : jumlah data (observasi)
 $\hat{\rho}_k$: autokorelasi residual untuk lag ke- k
 \ln : natural log
 n : banyaknya pengamatan
 f : banyak parameter dalam model
 x_k : variabel keadaan berukuran $n \times 1$.
 u_k : vektor masukan deterministik berukuran $m \times 1$.
 z_k : vektor pengukuran/keluaran berukuran $p \times 1$.
 m_i : data ke- i
 ε_i : konstanta
 y_i^0 : selisih data aktual dan data prediksi ARIMA ke- i
 $a_{j,i}$: koefisien atau parameter yang harus diestimasi oleh
Filter Kalman, dengan $j = 0, 1, \dots, n-1$
 $(1 - B)^d$: orde *differencing* nonmusiman
 A, B, G, H : matriks-matriks konstan di dalam ukuran berkesesuaian
dimana $A = n \times n$, $B = n \times m$, $G = n \times l$, $H = p \times n$

DAFTAR LAMPIRAN

| | Hal | |
|-------------|---|-----|
| Lampiran 1 | Tabel Data Aktual Inflasi <i>Month to Month</i> Kota Malang dan Probolinggo..... | 93 |
| Lampiran 2 | Estimasi Parameter VAR (3) | 96 |
| Lampiran 3 | Coding MACF SAS..... | 97 |
| Lampiran 4 | Coding MPACF SAS..... | 98 |
| Lampiran 5 | Coding VAR(3) SAS..... | 99 |
| Lampiran 6 | Listing Program Filter Kalman = 2 | 100 |
| Lampiran 7 | Listing Program Filter Kalman $n = 3$ | 101 |
| Lampiran 8 | Listing Program Filter Kalman $n = 4$ | 104 |
| Lampiran 9 | Hasil Estimasi Parameter ARIMA di $Z_1(t)$ | 106 |
| Lampiran 10 | Hasil Estimasi Parameter ARIMA di $Z_2(t)$ | 107 |

BAB I

PENDAHULUAN

Pada bab ini dijelaskan tentang latar belakang permasalahan, rumusan masalah, batasan masalah, tujuan, manfaat, dan sistematika penulisan Tugas Akhir.

1.1 Latar Belakang

Bank Indonesia merupakan bank pusat yang mengatur segala kebijakan moneter di Indonesia. Bank Indonesia memiliki kantor perwakilan di beberapa provinsi, antara lain kantor perwakilan tingkat provinsi dan kantor perwakilan tingkat kota. Kantor perwakilan tingkat provinsi biasanya terletak pada ibukota provinsi tersebut. Namun tidak semua provinsi memiliki kantor perwakilan, sebab Bank Indonesia meletakkan kantor perwakilan pada provinsi yang dianggap memenuhi persyaratan. Hal ini juga berlaku pada kantor perwakilan tingkat kota, dimana tidak semua kota memiliki kantor perwakilan Bank Indonesia. Contohnya saja Provinsi Jawa Timur, memiliki kantor perwakilan tingkat provinsi di Surabaya dan memiliki beberapa kantor perwakilan tingkat kota yang dikoordinir, antara lain Kantor Perwakilan Bank Indonesia (KPwBI) Jawa Timur (Kota Malang, Kota Kediri dan Kota Jember), Bali (KPwBI Denpasar) dan Nusa Tenggara (KPwBI Mataram dan KPwBI Kupang). KPwBI Kota Malang terdiri atas wilayah kerja Kota Pasuruan, Kota Malang, Kota Probolinggo, Kabupaten Pasuruan, Kabupaten Malang, dan Kabupaten Probolinggo.

Tugas pokok dari Bank Indonesia adalah menjaga kestabilan dan mengatur kebijakan moneter. Sehingga kantor-kantor perwakilan atau kantor cabang yang disebar di beberapa daerah tersebut juga memiliki peranan untuk menjaga kestabilan dan mengatur kebijakan moneter suatu daerah tersebut. Kebijakan moneter dipengaruhi oleh berbagai macam faktor. Salah satu faktor yang mempengaruhi adalah besarnya tingkat inflasi. Dalam

pengambilan beberapa keputusan atau penentuan kebijakan perlu adanya pertimbangan tingkat inflasi mendatang. Inflasi memiliki dampak besar terhadap perekonomian global yang disebut perekonomian makro [1]. Beberapa faktor yang mempengaruhi tingkat inflasi adalah indeks harga konsumtif (IHK), indeks harga saham global (IHSG), bunga bank, kurs dollar USA, dll. Hal tersebut merupakan faktor pengaruh inflasi secara global, dimana dalam KPwBI tiap daerah akan menganalisis faktor-faktor tersebut secara terperinci dalam lingkup daerah wilayah kerja. Karena banyak faktor yang mempengaruhi pergerakan tingkat inflasi, sehingga diperlukan adanya estimasi yang tepat yang mampu menjadi acuan masyarakat dan pemerintah dalam menentukan keputusan atau kebijakan. Pola tingkat inflasi dapat dilihat dari data *year of year* (yoy), *month to month* (mtm) sehingga dapat digunakan pendekatan *Vector Autoregressive* (VAR) dan *Autoregressive Integrated Moving Average* (ARIMA) Box-Jenkins seperti yang telah dilakukan oleh beberapa peneliti [2].

Bank Indonesia menggunakan perhitungan ARIMA dalam proses estimasi prediksi inflasi. Namun saat terlaksananya kerja praktek mahasiswa, digunakan metode Kalman Filter untuk mengestimasi prediksi inflasi pada bulan berikutnya dengan menggunakan asumsi noise sistem sebesar 0.1, state matriks adalah 1, matriks pengukuran sebesar 0.1, noise proses matriks sebesar 1, pertumbuhan data inflasi *month to month* dianggap konstan, kovarian *error* estimasi sebesar 0.1 dan nilai kovarian noise pengukuran sebesar 1. Dimana nilai estimasi diambil dari data terakhir ditambah dengan jumlah penambahan atau pengurangan dari data tahun lalu berdasarkan bulan yang sama atau moment yang sama. Hasil dari metode Kalman Filter yang diasumsikan tersebut mendekati hasil data sesungguhnya, sehingga dapat dikatakan baik jika digunakan untuk proses estimasi.

Laporan tengah singkat Damhuri Nasution dan Anton Hendranata, pada *focus group discussion* (FGD) metode statistika telah meneliti metode untuk mengestimasi inflasi dengan metode VAR, SVAR, dan ARIMA. Metode VAR sering digunakan sebagai metode estimasi dalam bidang ekonomi. Metode VAR dan ARIMA dapat digunakan untuk perhitungan *forecasting* saat penentuan prediksi tingkat inflasi dengan data *time series*. Hasil *Forecasting* dari metode VAR tidak akan digunakan begitu saja untuk menentukan prediksi tingkat inflasi, sebab nilai *forecasting* masih dalam kisaran yang memiliki *error* besar [3].

Tugas akhir akan membahas tentang metode VAR, ARIMA, estimasi Kalman Filter dan proyeksi inflasi *month to month* di daerah wilayah kerja Kantor Perwakilan Bank Indonesia (KPwBI) Malang. Kalman Filter digunakan sebagai alat bantu estimasi dikarenakan saat digunakan sebagai alat bantu estimasi pada penelitian prediksi cuaca [4] dan debit air sungai menghasilkan prediksi yang bagus dan memiliki nilai *error* yang relatif kecil [5]. Sehingga dalam tugas akhir ini akan dicoba menggunakan Filter Kalman dalam dunia perekonomian, khususnya dalam perhitungan inflasi.

1.2 Rumusan Masalah

Berdasarkan latar belakang permasalahan pada subbab 1.1, rumusan masalah yang ada dalam Tugas Akhir ini dapat dirumuskan sebagai berikut :

1. Bagaimana prediksi pola tingkat inflasi menggunakan metode ARIMA dan VAR
2. Bagaimana pola estimasi penghalusan *error* ARIMA dan VAR menggunakan metode estimasi Filter Kalman.

1.3 Batasan Masalah

Tugas Akhir ini memiliki banyak faktor yang mempengaruhi dalam penelitian, sehingga diberikan batasan masalah sebagai berikut :

1. Data inflasi merupakan data sekunder atas inflasi *month to month* (mtm) dari Kantor Perwakilan Bank Indonesia (KPwBI) Malang Bulan Januari 2010-September 2015.
2. Lokasi pengukuran yang digunakan dalam Tugas Akhir adalah Kota Malang dan Kota Probolinggo.
3. Polinomial derajat *error* residual ARIMA dan VAR yang diambil adalah 1 sampai 3.
4. Simulasi pemodelan menggunakan *software* Minitab, SAS, Microsoft Excel, Eviews, dan MatLab.

1.4 Tujuan

Tugas Akhir yang dibuat memiliki tujuan yang mendukung untuk melakukan penelitian. Adapun tujuan Tugas Akhir ini adalah sebagai berikut :

1. Mendapatkan model yang baik dari *forecasting* inflasi *month to month* wilayah kerja KPwBI Malang berdasarkan metode ARIMA dan VAR.
2. Mengetahui pengaruh tingkatan polinomial derajat *error* residual pada Filter Kalman terhadap hasil prediksi nilai *forecast* ARIMA dan VAR inflasi *month to month* wilayah kerja KPwBI Malang.

1.5 Manfaat

Pembuatan Tugas Akhir ini diharapkan memberikan manfaat sebagai berikut :

1. Dapat mengetahui akurasi pola inflasi *month to month* wilayah kerja KPwBI Malang menggunakan ARIMA dan VAR.
2. Dapat mengetahui pengaruh pemilihan derajat polinomial pada polinomial derajat *error* residual pada Filter Kalman terhadap hasil prediksi *forecast* ARIMA dan VAR inflasi *month to month* wilayah kerja KPwBI Malang.

3. Dapat menjadi informasi sebagai sarana pertimbangan pada KPwBI Malang dalam *forecasting* inflasi *month to month* wilayah kerja KPwBI Malang.

1.6 Sistematika Penulisan

Tugas Akhir ini terdiri atas lima (5) bab. Dimana secara garis besar, masing-masing bab berisikan:

BAB I PENDAHULUAN

Bab ini terdiri atas beberapa subbab, antara lain yaitu latar belakang, rumusan masalah, batasan masalah, tujuan penulisan, manfaat penulisan, dan sistematika penulisan Tugas Akhir.

BAB II TINJAUAN PUSTAKA

Bab ini ditulis untuk membahas tentang teori-teori dasar yang relevan untuk menyelesaikan permasalahan dan mendapatkan solusi atas permasalahan yang dibahas pada Tugas Akhir yang meliputi *forecasting* menggunakan ARIMA Box Jenkins, VAR, ARIMA Filter Kalman, dan VAR Filter Kalman.

BAB III METODE PENELITIAN

Bab ini berisi tentang tahapan atau langkah-langkah yang diambil dalam mencapai tujuan Tugas Akhir.

BAB IV ANALISIS DAN PEMBAHASAN

Bab ini membahas tentang proses pengolahan data dan penentuan model yang sesuai untuk *forecasting* inflasi *month to month* wilayah kerja KPwBI Malang pada dua titik yaitu Kota Malang dan Kota Probolinggo secara terperinci. *Forecasting* menggunakan metode ARIMA dan VAR, kemudian dilakukan penerapan Filter Kalman pada hasil *forecasting* ARIMA dan

VAR dengan pengambilan beberapa nilai *error* residual. Sehingga pada akhir akan didapatkan perbandingan antara data hasil peramalan dengan data aktual serta dilihat pengaruh dari polinomial derajat *error* residual yang digunakan tersebut.

BAB V PENUTUP

Bab ini merupakan bab terakhir dari penulisan Tugas Akhir yang berisi kesimpulan atas hasil penelitian dan saran untuk pengembangan penelitian lebih lanjut dari Tugas Akhir.

BAB II

TINJAUAN PUSTAKA

Pada bab ini dibahas teori-teori yang terkait dengan permasalahan dalam Tugas Akhir. Teori-teori yang dibahas antara lain : pengertian inflasi, pengertian dan bentuk umum model ARIMA dan VARIMA, pengertian dan bentuk umum Filter Kalman, dan implementasi polinomial *error* menggunakan Filter Kalman.

2.1 Inflasi

Inflasi adalah proses meningkatnya harga-harga secara umum dan terus-menerus (*continuous*) berkaitan dengan mekanisme pasar yang dapat disebabkan oleh berbagai faktor, antara lain, konsumsi masyarakat yang meningkat, berlebihnya likuiditas di pasar yang memicu konsumsi atau bahkan spekulasi, sampai termasuk juga akibat adanya ketidaklancaran distribusi barang.

Pengukuran tingkat inflasi terdapat dua pendekatan yang dapat digunakan, yaitu pendekatan univariat dan multivariat model. Pendekatan univariat lebih menekankan hanya pada aspek data *time series*, sedangkan pendekatan multivariat mencakup juga tambahan informasi seperti *output* riil dari variabel lain. Dari beberapa studi yang telah dilakukan, pendekatan univariat dengan menggunakan model *autoregressive (AR) time series* merupakan penelitian pada proses inflasi memungkinkan penggunaan model univariat. Namun demikian, model univariat tidak terlepas dari beberapa keterbatasan, salah satunya adalah bahwa model ini tidak dapat mengidentifikasi sumber penyebab dari *the observed persistence* inflasi sehingga terdapat kemungkinan pemicu potensial proses inflasi menjadi terabaikan [3].

2.2 Univariat *Time series*

Pemodelan *time series* dengan suatu variabel tanpa mempertimbangkan adanya pengaruh variabel lain biasa disebut dengan *univariate time series*. Identifikasi model *univariate time series* dilakukan berdasarkan pola *Autocorelation Function* (ACF) dan *Partial Autocorelation Function* (PACF) setelah data stasioner.

2.2.1 Stasioneritas Model Univariat *Time Series*

Stasioneritas artinya tidak terjadi pertumbuhan dan penurunan. Data dikatakan stasioner apabila pola data tersebut berada pada kesetimbangan di sekitar nilai rata-rata (*mean*) dan varian yang konstan selama waktu tertentu. *Time series* dikatakan stasioner apabila tidak terdapat unsur *trend* dan musiman dalam data, atau dapat dikatakan *mean* dan variannya tetap. Selain plot *time series*, kestasioneran dapat dilihat dari plot autokorelasi yang turun mendekati nol secara cepat, umumnya setelah lag kedua atau ketiga.

Kestasioneran data secara varian dapat dilihat dari Transformasi Box-Cox, dikatakan stasioner jika *rounded value*-nya bernilai 1. Apabila tidak stasioner dalam varian, maka dilakukan transformasi agar nilai varian menjadi konstan. Box dan Cox memperkenalkan transformasi pangkat (*power transformations*) dengan persamaan sebagai berikut [6]:

$$T(Z_t) = \frac{(Z_t^\lambda - 1)}{\lambda}, \lambda \neq 0$$

dengan λ disebut sebagai parameter transformasi. Dalam Transformasi Box-Cox akan diperoleh λ , dimana nantinya akan menentukan transformasi yang harus dilakukan. Khusus untuk $\lambda = 0$ dapat dinotasikan sebagai berikut:

$$\lim_{\lambda \rightarrow 0} T(Z_t) = \lim_{\lambda \rightarrow 0} Z_t^{(\lambda)}$$

$$\begin{aligned}
 &= \lim_{\lambda \rightarrow 0} \frac{(Z_t^\lambda - 1)}{\lambda} \\
 &= \ln(Z_t)
 \end{aligned}$$

Nilai λ beserta aturan Transformasi Box-Cox dapat dilihat pada Tabel 2.1.

Tabel 2.1 Transformasi Box-Cox

| Nilai λ | Transformasi |
|-----------------|--------------------------------|
| -1 | $\frac{1}{Z_t}$ |
| -0.5 | $\frac{1}{\sqrt{Z_t}}$ |
| 0 | $\ln Z_t$ |
| 0.5 | $\sqrt{Z_t}$ |
| 1 | Z_t (tidak ada transformasi) |

Ketidakstasioneran *mean* dapat diatasi dengan melakukan *differencing* (pembedaan). Perlu diingat bahwa Transformasi Box-Cox untuk melihat kestasioneran varian harus dilakukan sebelum melakukan *differencing*. Operator *shift* mundur (*backward shift*) sangat tepat untuk menggambarkan proses *differencing*. Penggunaan *backward shift* adalah sebagai berikut:

$$B^d Z_t = Z_{t-d} \tag{2.1}$$

dengan $d = 1, 2, \dots$ (biasanya 1 dan 2). Notasi B yang dipasang pada Z_t mempunyai pengaruh menggeser data satu waktu ke belakang. Sebagai contoh, apabila suatu *time series* nonstasioner maka data tersebut dapat dibuat mendekati stasioner dengan melakukan *differencing* orde pertama dari data.

2.2.2 Model *Autoregressive Integrated Moving Averages* (ARIMA)

Model *Autoregressive Integrated Moving Average* (ARIMA) telah dipelajari secara mendalam oleh George Box dan Gwilym Jenkins pada tahun 1967. Model diterapkan untuk analisis *time series*, peramalan, dan pengendalian. Model *Autoregressive* (AR) pertama kali diperkenalkan oleh Yule pada tahun 1926, kemudian dikembangkan oleh Walker. Sedangkan pada tahun 1937, model *Moving Average* (MA) pertama kali digunakan oleh Slutsky. Sedangkan Wold adalah orang pertama yang menghasilkan dasar-dasar teoritis dari proses kombinasi ARMA. Wold membentuk model ARMA yang dikembangkan untuk mencakup *time series* musiman dan pengembangan sederhana yang mencakup proses-proses nonstasioner (ARIMA).

Model AR(p) atau regresi diri dari orde p menyatakan bahwa nilai pengamatan pada periode ke- t (Z_t) merupakan hasil regresi dari nilai-nilai pengamatan sebelumnya selama p periode. Bentuk fungsi persamaannya adalah:

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + a_t$$

atau dapat ditulis

$$(1 - \phi_1 B - \dots - \phi_p B^p) \dot{Z}_t = a_t$$

$$\phi_p(B) \dot{Z}_t = a_t$$

Model AR(1), yaitu $p = 1$, $d = 0$, $q = 0$ dapat ditulis:

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + a_t$$

Model AR(2), yaitu $p = 2$, $d = 0$, $q = 0$ dapat ditulis:

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + a_t$$

Model MA (q) atau rata-rata bergerak orde q menyatakan bahwa nilai pengamatan pada periode ke- t (Z_t) dipengaruhi oleh q buah galat sebelumnya. Bentuk fungsi persamaan untuk model MA(q) adalah

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

atau dapat ditulis $\dot{Z}_t = \theta(B)a_t$ dimana

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

Model MA(1), yaitu $p = 0$, $d = 1$, $q = 0$ dapat ditulis:

$$\dot{Z}_t = a_t - \theta_1 a_{t-1}$$

Model MA(2), yaitu $p = 0$, $d = 2$, $q = 0$ dapat ditulis:

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

Model ARMA adalah gabungan dari model AR dengan MA. Bentuk fungsi persamaan untuk model ARMA(p, q) [4] adalah :

$$\phi_p(B)\dot{Z}_t = \theta_q(B)a_t$$

dimana

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

dan

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

Model ARMA (1,1), yaitu $p = 1$, $d = 1$, $q = 0$ dapat ditulis:

$$\dot{Z}_t - \phi_1 B \dot{Z}_t = a_t - \theta_1 a_{t-1}$$

atau

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} + \phi_1 \dot{Z}_{t-1}$$

Model ARIMA (p, d, q) diperkenalkan oleh Box dan Jenkins. Orde p menyatakan operator dari AR, orde d menyatakan hasil *differencing* (pembedaan), dan orde q menyatakan operator dari MA. Bentuk fungsi persamaan dari model ARIMA adalah:

$$\phi_p(B)(1 - B)^d \dot{Z}_t = \theta_q(B)a_t \tag{2.2}$$

dengan :

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

p : orde dari AR

q : orde dari MA

ϕ_p : koefisien orde p

θ_q : koefisien orde q

B : *backward shift*

$(1 - B)^d$: orde *differencing* nonmusiman

Z_t : besarnya pengamatan (kejadian) pada waktu ke- t

a_t : suatu proses *white noise* atau galat pada waktu ke- t yang diasumsikan mempunyai *mean* 0 dan varian konstan σ_a^2

2.3 *Multivariate Time series*

Data deret waktu yang tidak hanya terdiri dari beberapa variabel biasa disebut dengan data deret waktu multivariat atau *multivariate time series*. Pengidentifikasiannya dapat dilakukan dengan melihat pola *Matrix Autocorrelation Function* (MACF) dan *Matrix Partial Autocorrelation Function* (MPACF). Analisis *Time series* digunakan ketika data penelitian yang digunakan

terpaut oleh waktu, sehingga terdapat korelasi antara data kejadian saat ini dengan data dari satu periode sebelumnya. Artinya bahwa kejadian saat ini juga dipengaruhi oleh kejadian di satu periode waktu sebelumnya. Analisis *time series* yang hanya menggunakan satu data saja disebut sebagai *univariate time series*. Sedangkan pada kehidupan yang sebenarnya seringkali suatu variabel memiliki kaitan dengan beberapa variabel lainnya, sehingga dalam melakukan penelitian terdapat lebih dari satu variabel yang terlibat. Analisis dengan menggunakan banyak variabel ini disebut sebagai *multivariate time series*. Analisis *multivariate time series* pada umumnya digunakan untuk memodelkan dan menjelaskan interaksi serta pergerakan di antara sejumlah variabel *time series*.

Sama halnya dengan *univariate time series*, stasioneritas dari data *multivariate time series* juga dapat dilihat dari plot *Matrix Autocorrelation Function* (MACF) dan *Matrix Partial Autocorrelation Function* (MPACF) yang terbentuk. Plot MACF yang turun secara perlahan mengindikasikan bahwa data belum stasioner dalam rata-rata sehingga perlu dilakukan *differencing* untuk menstasionerkan data. Demikian juga saat data tidak stasioner dalam varians perlu dilakukan transformasi agar memperoleh data yang stasioner [7].

2.3.1 *Matrix Autocorrelation Function* (MACF)

Jika terdapat sebuah vektor *time series* dengan observasi sebanyak n , yaitu Z_1, Z_2, \dots, Z_n , maka persamaan matriks korelasi sampelnya adalah sebagai berikut [7]:

$$\hat{\rho}(k) = [\hat{\rho}_{ij}(k)]$$

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

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

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

Persamaan matriks korelasi sampel ini sangat berguna untuk menentukan orde dalam model *moving average* (MA). Akan tetapi bentuk matriks dan grafik akan semakin kompleks seiring dengan meningkatnya dimensi vektor. Untuk mengatasinya, Tiao dan Box (1981) dalam Wei (1994) memperkenalkan sebuah metode yang sesuai untuk meringkas penjelasan korelasi sampel, yaitu dengan menggunakan symbol (+), (-), dan (.) pada posisi (i, j) dari matriks korelasi sampel, dimana symbol (+) menotasikan nilai yang lebih besar dari 2 kali estimasi standar *error* dan menunjukkan adanya hubungan korelasi positif, (-) menotasikan nilai yang kurang dari - 2 kali estimasi standar *error* atau adanya hubungan korelasi negatif, sedangkan (.) menotasikan nilai yang berada di antara ± 2 kali estimasi standar *error* yang artinya tidak terdapat hubungan korelasi.

Sebagai contoh, pada Tabel 2.2 diberikan hasil perhitungan nilai-nilai MACF dari 3 data *time series* dengan masing-masing *series* terdiri dari 100 observasi.

Nilai-nilai MACF dalam Tabel 2.2 selanjutnya dinotasikan ke dalam bentuk simbol yang ditampilkan dalam Gambar 2.1.

Tabel 2.2 Contoh Nilai MACF untuk 3 Data *Time series*

| Lag | 0 | | | 1 | | | 2 | | |
|----------|-----|-----|-----|------|------|------|------|------|------|
| Variabel | y1 | y2 | y3 | y1 | y2 | y3 | y1 | y2 | y3 |
| y1 | 1 | 0.0 | 0.1 | - | 0.08 | - | 0.08 | 0.09 | 0.1 |
| y2 | 0.0 | 1 | 0.1 | - | -0.1 | - | - | - | - |
| y3 | 0.1 | 0.1 | 1 | 0.04 | 0.05 | 0.05 | 0.31 | 0.13 | 0.01 |
| | 1 | 4 | | 0.02 | - | - | - | 0.16 | - |
| | | | | | 0.11 | 0.07 | 0.03 | | 0.01 |

| Variable/ Lag | 0 | 1 | 2 | 3 | 4 | 5 | 6 |
|------------------|---|------------|------------|------------|------------|------------|------------|
| y1 | | +. | -. | +. | -. | +. | -. |
| y2 | | +. | -. | +. | -. | +. | -. |
| y3 | | +. | -. | +. | -. | +. | -. |

Gambar 2.1 Contoh Plot MACF untuk 3 Data *Time series*

2.3.2 Matrix Partial Autocorrelation Function (MPACF)

Persamaan autokorelasi parsial (PACF) dalam *univariate time series* sangat penting untuk menentukan orde dalam model AR. Generalisasi dari konsep PACF ke dalam bentuk vektor *time series* dilakukan oleh Tiao dan Box (1981) dalam Wei (1994), yang mendefinisikan matriks autoregresi parsial pada lag s dengan notasi $\mathcal{P}(s)$, sebagai koefisien matriks terakhir ketika data diterapkan ke dalam suatu proses *vector autoregressive* dari orde s . Persamaan untuk matriks autoregresi parsial adalah sebagai berikut [7]:

$$\mathcal{P}(s) = \begin{cases} \Gamma'(1)[\Gamma(0)]^{-1}, & s = 1 \\ \{\Gamma'(s) - c'(s)[A(s)]^{-1}b(s)\} \{\Gamma(0) - b'(s)[A(s)]^{-1}b(s)\}^{-1}, & s > 1 \end{cases}$$

Saat $s \geq 2$, maka nilai $A(s)$, $b(s)$, dan $c(s)$ adalah sebagai berikut:

$$A(s) = \begin{bmatrix} \Gamma(0) & \Gamma(1) & \dots & \Gamma'(s-2) \\ \Gamma(1) & \Gamma(0) & \dots & \Gamma'(s-3) \\ \vdots & \vdots & & \vdots \\ \Gamma(s-2) & \Gamma(s-3) & \dots & \Gamma(0) \end{bmatrix},$$

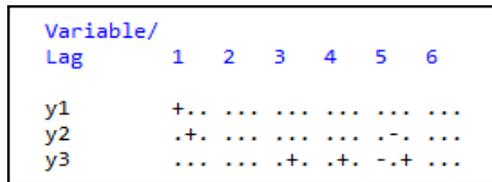
$$b(s) = \begin{bmatrix} \Gamma'(s-1) \\ \Gamma'(s-2) \\ \vdots \\ \Gamma'(1) \end{bmatrix}, c(s) = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(s-1) \end{bmatrix}.$$

Identifikasi data agar lebih mudah, maka diidentifikasi berdasarkan nilai MPACF, maka nilai-nilai MPACF juga dinotasikan dalam bentuk simbol (+), (-), dan (.) seperti pada

MACF. Contoh nilai-nilai hasil perhitungan MPACF ditampilkan dalam Tabel 2.3. Sedangkan bentuk simbol dari nilai-nilai MPACF pada Tabel 2.3 ditampilkan dalam Gambar 2.2.

Tabel 2.3 Contoh Nilai MPACF untuk 3 Data *Time series*

| Lag | 0 | | | 1 | | | 2 | | |
|----------|----------|----------|----------|-----------|----------|-----------|-----------|----------|-----------|
| Variabel | y1 | y2 | y3 | y1 | y2 | y3 | y1 | y2 | y3 |
| y1 | 0.3 3 | 0.0 9 | 0.0 7 | - 0.02 | 0.1 3 | 0.06 | 0.11 | 0.1 9 | 0.1 |
| y2 | 0 | 0.3 6 | 0.1 3 | 0.09 | 0.1 | - 0.03 | 0.04 | 0.0 4 | 0.1 |
| y3 | 0.0 7 | 0.1 9 | 0.1 5 | 0.18 | 0.1 8 | 0.11 | - 0.18 | 0.2 8 | - 0.07 |



Gambar 2.2 Contoh Plot MPACF untuk 3 Data *Time series*

Sama halnya dengan persamaan autokorelasi parsial pada kasus *univariate*, persamaan matriks *partial autoregression*, $\mathcal{P}(s)$, juga memiliki sifat *cut-off* untuk vektor proses AR.

2.3.3 Model VAR (*Vector Autoregressive*)

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

Sebuah *multivariate* runtun waktu dikatakan sebuah VAR proses dari orde 1 atau VAR(1) jika mengikuti persamaan[8]:

$$\mathbf{Z}_t = \phi_0 + \Phi \mathbf{Z}_{t-1} + \mathbf{a}_t \quad (2.3)$$

Sehingga dalam bentuk matriks, persamaan model VAR(1) untuk data *time series* dengan 2 variabel dapat ditulis sebagai berikut.

$$\begin{bmatrix} Z_{1t} \\ Z_{2t} \end{bmatrix} = \begin{bmatrix} \phi_{10} \\ \phi_{20} \end{bmatrix} + \begin{bmatrix} \phi_{11} & \phi_{12} \\ \phi_{21} & \phi_{22} \end{bmatrix} \begin{bmatrix} Z_{1t-1} \\ Z_{2t-1} \end{bmatrix} + \begin{bmatrix} a_{1t} \\ a_{2t} \end{bmatrix}. \quad (2.4)$$

dengan ϕ_0 adalah vektor dengan dimensi k , Φ adalah matriks berukuran $k \times k$, dan $\{\mathbf{a}_t\}$ merupakan serangkaian vektor *random* yang berurutan dengan *mean nol*, dan matriks kovarians Σ . Dalam penerapannya, matriks kovarians Σ harus definit positif, sebaliknya, dimensi dari \mathbf{Z}_t dapat direduksi. Dalam literatur-literatur sering kali \mathbf{a}_t diasumsikan *multivariate normal*. Untuk persamaan model VAR dengan orde p atau VAR(p) dapat ditulis sebagai berikut [8].

$$\mathbf{Z}_t = \phi_0 + \Phi \mathbf{Z}_{t-1} + \dots + \Phi_p \mathbf{Z}_{t-p} + \mathbf{a}_t, \quad p > 0. \quad (2.5)$$

dengan operator *back-shift* B , persamaan (2.5) dapat ditulis menjadi

$$(\mathbf{I} - \Phi_1 B - \dots - \Phi_p B^p) \mathbf{Z}_t = \phi_0 + \mathbf{a}_t \quad (2.6)$$

dimana \mathbf{I} adalah matriks identitas berukuran $k \times k$.

Setelah data *time series* memenuhi syarat stasioneritas, tahap selanjutnya dalam pembentukan model VAR adalah mengidentifikasi model yang sesuai dan ordenya. Identifikasi model ini dapat dilakukan dengan memperhatikan pola matriks korelasi sampel (MACF) dan korelasi parsial (MPACF) yang terbentuk.

2.3.4 Penaksiran Parameter Model VAR

Setelah model dugaan dari data *time series* diperoleh, langkah selanjutnya ialah mengestimasi nilai parameter-parameter pada model tersebut. Salah satu metode estimasi yang dapat digunakan

adalah metode *maximum likelihood estimation* (MLE). Misalkan $\{\mathbf{Z}_t\}$ menyatakan suatu proses m -variati VAR(p), yaitu

$$\mathbf{Z}_t = \Phi_1 \mathbf{Z}_{t-1} + \dots + \Phi_p \mathbf{Z}_{t-p} + \boldsymbol{\varepsilon}_t \quad (2.7)$$

dengan $\{\boldsymbol{\varepsilon}_t\} \sim i.i.d.N(0, \Sigma)$.

Untuk memperoleh nilai estimasi dari parameter dalam proses m -variati VAR(p) pada persamaan (2.7) maka digunakan metode MLE dengan persamaan fungsi *likelihood* dari sampel $\{\mathbf{Z}_1, \dots, \mathbf{Z}_n\}$ adalah [9]

$$L(\boldsymbol{\Phi}, \boldsymbol{\Sigma}) = -\left(\frac{nm}{2}\right) \log(2\pi) + \left(\frac{n}{2}\right) \log|\boldsymbol{\Sigma}^{-1}| + \\ -\left(\frac{1}{2}\right) \sum_{t=1}^n \left[(\mathbf{Z}_t - \boldsymbol{\Phi}' \mathbf{Y}_t)' \boldsymbol{\Sigma}^{-1} (\mathbf{Z}_t - \boldsymbol{\Phi}' \mathbf{Y}_t) \right]$$

Dengan $\boldsymbol{\Phi}' = [\Phi_1 \quad \Phi_2 \quad \dots \quad \Phi_p]$ dan \mathbf{Y}_t merupakan vektor berukuran $mp \times 1$ sebagai berikut

$$\mathbf{Y}_t = \begin{bmatrix} \mathbf{Z}_{t-1} \\ \mathbf{Z}_{t-2} \\ \vdots \\ \mathbf{Z}_{t-p} \end{bmatrix}$$

Selanjutnya dengan metode *least square* yang meminimumkan jumlah kuadrat *error* diperoleh hasil persamaan untuk nilai estimasi parameter $\hat{\boldsymbol{\Phi}}$ yaitu [9]

$$\hat{\boldsymbol{\Phi}}' = \left[\sum_{t=1}^n \mathbf{Z}_t \mathbf{Y}_t' \right] \left[\sum_{t=1}^n \mathbf{Y}_t \mathbf{Y}_t' \right]^{-1}$$

Hasil penaksiran parameter dari metode *likelihood* ini selanjutnya masih perlu diuji untuk mengetahui signifikansinya

terhadap model dengan menggunakan statistik uji t . Hipotesis yang digunakan dalam pengujian ini adalah sebagai berikut:

$$H_0 : \Phi_i = 0$$

$$H_1 : \Phi_i \neq 0$$

dan perhitungan statistik uji sebagai berikut

$$t = \frac{\hat{\Phi}}{stdev(\Phi)}. \quad (2.8)$$

Statistik uji di atas kemudian dibandingkan dengan $t_{\alpha/2}$ yang diperoleh dari tabel distribusi t . Toleransi ketepatan (α) diasumsikan sebesar 5%, hipotesis awal akan ditolak jika nilai $|t| > t_{\alpha/2, (n-p-1)}$ dimana p menunjukkan jumlah parameter, yang berarti bahwa parameter telah signifikan.

Setelah estimasi parameter diperoleh, maka selanjutnya kecukupan dari kesesuaian model harus diperiksa dengan analisis diagnosa dari residual

$$\hat{\mathbf{a}}_t = \hat{\mathbf{Z}}_t - \hat{\Phi}_1 \hat{\mathbf{Z}}_{t-1} - \dots - \hat{\Phi}_p \hat{\mathbf{Z}}_{t-p}$$

dimana $\hat{\mathbf{Z}}_t$ digunakan untuk menotasikan \mathbf{Z}_t jika $\boldsymbol{\mu} = \mathbf{0}$ dan menotasikan $(\mathbf{Z}_t - \hat{\boldsymbol{\mu}})$ dengan $\boldsymbol{\mu}$ merupakan vektor rata-rata, dan $\hat{\Phi}_i$ adalah nilai taksiran dari parameter Φ_i . Suatu model *time series* dikatakan cukup jika residual model bersifat *white noise*. Maka dari itu matriks korelasi dari $\hat{\mathbf{a}}_t$ harus tidak signifikan dan tidak memiliki pola [7].

2.3.5 Peramalan Model VAR

Untuk sebuah model VAR(p), peramalan satu tahap ke depan pada waktu awal yang sama, yaitu h adalah [8]:

$$\mathbf{Z}_h(1) = \phi_0 + \sum_{i=1}^p \Phi_i \mathbf{Z}_{h+1-i}$$

dan *error* dari peramalan ini adalah

$$e_h(1) = a_{h+1}$$

Matriks kovarians dari nilai *error* peramalan ini adalah Σ . Jika Z_t memiliki stasioneritas yang lemah, maka peramalan sebanyak l tahap ke depan atau $Z_h(l)$ akan konvergen menuju vektor rata-rata μ sebagai peningkatan peramalan pada waktu l .

2.4 Kalman Filter

Kalman Filter adalah suatu metode estimasi yang optimal. Komponen dasar dari metode Kalman Filter adalah persamaan pengukuran dan persamaan transisi. Data pengukuran digunakan untuk memperbaiki hasil estimasi. Secara umum algoritma Kalman Filter untuk sistem dinamik linear waktu diskrit adalah :

Model sistem dan model pengukuran [10]:

$$x_{k+1} = A_k x_k + B_k u_k + G_k w_k \quad (2.9)$$

$$Z_k = H_k x_k + v_k \quad (2.10)$$

$$x_0 \sim (\bar{x}_0, P_{x_0}), \quad w_k \sim (0, Q_k), \quad v_k \sim (0, R_k)$$

Inisialisasi :

$$P(0) = P_{x_0}, \quad \hat{x}_0 = \bar{x}_0$$

Tahap Prediksi :

$$\text{Estimasi : } \hat{x}_{k+1}^- = A_k \hat{x}_k + B_k u_k \quad (2.11)$$

$$\text{Kovarians error : } P_{k+1}^- = A_k P_k A_k^T + G_k Q_k G_k^T \quad (2.12)$$

Tahap Koreksi :

Kalman gain :

$$K_{k+1} = P_{k+1}^- H_{k+1}^T (H_{k+1} P_{k+1}^- H_{k+1}^T + R_{k+1})^{-1} \quad (2.13)$$

kovarians error :

$$P_{k+1} = [I - K_{k+1} H_{k+1}] P_{k+1}^- \quad (2.14)$$

estimasi :

$$\hat{x}_{k+1} = \hat{x}_{k+1}^- + K_{k+1}[z_{k+1} - H_{k+1}\hat{x}_{k+1}^-] \quad (2.15)$$

dengan :

- x_k : variabel keadaan system pada waktu k yang nilai estimasi awalnya adalah \bar{x}_0 dan kovarian awal P_{x_0}
- u_k : variabel input deterministik pada waktu k
- w_k : *noise* pada pengukuran dengan *mean* sama dengan nol dan kovariansi Q_k
- z_k : variabel pengukuran
- H : matriks pengukuran
- v_k : *noise* pada pengukuran dengan *mean* sama dengan nol dan kovarian R_k

2.5 Penerapan Kalman Filter Pada Prediksi Pola Inflasi dari Hasil Prediksi ARIMA dan VAR

Kalman Filter berkaitan dengan pengembangan model peramalan statistik *autoregressive* yang *recursive* dalam mengintegrasikan data pengamatan terbaru ke dalam model untuk memperbaharui (*update*) prediksi sebelumnya dan melanjutkan prediksi ke periode yang akan datang. Sedangkan metode ARIMA dan VAR yang merupakan bagian dari *time series* untuk memprediksi karena dapat menghasilkan suatu model yang akurat yang mewakili pola masa lalu dan masa depan dari suatu data *time series*, di mana polanya bisa random, *seasonal*, *trend*, atau kombinasi pola-pola tersebut.

Pada tahapan ini, hasil model peramalan analisis *time series* dari pola inflasi di daerah wilayah kerja KPwBI Malang dapat dinyatakan sebagai parameter dan akan dilakukan pendekatan yang didasarkan pada koreksi dari bias prakiraan dalam penggunaan Kalman Filter. Selanjutnya akan difokuskan pada studi parameter. Diberikan polinomial [11] :

$$y_i^0 = a_{0,i} + a_{1,i}m_i + \dots + a_{n-1,i} m_i^{n-1} + \varepsilon_i$$

dengan:

y_i^0 : *error* dari selisih data aktual dan data prediksi ARIMA ke- i

$a_{j,i}$: koefisien atau parameter yang harus diestimasi oleh Kalman Filter, dengan $j = 0, 1, \dots, n-1$

m_i : data ke- i

ε_i : konstanta

2.6 Kriteria Pemilihan Terbaik

Pemilihan model terbaik dilakukan berdasar kriteria *in sample* dan *out-sample*. Kriteria *in-sample* yang akan digunakan yaitu *Akaike's Information Criterion* (AIC) dan *Schwart's Bayesian Criterion* (SBC). Sedangkan kriteria *out-sample* yang akan digunakan adalah *Root Mean Absolute Percentage Error* (MAPE).

Akaike's Information Criteria (AIC) merupakan salah satu kriteria pemilihan dalam penentuan model terbaik pada data *in-sample*. Model terbaik adalah model dengan AIC terkecil. Cara perhitungan AIC dalam [6] adalah:

$$AIC(p) = \ln \det(\Sigma_u(p)) + \frac{2}{p} k^2$$

Log adalah notasi logaritma natural, $\det(\cdot)$ merupakan notasi determinan, dan $\Sigma_u(p) = T^{-1} \sum_{t=1}^T \hat{u}_t \hat{u}_t'$ adalah matriks taksiran kovarian residual dari model VAR(p), T merupakan jumlah residual, dan K merupakan jumlah variabel.

SBC adalah suatu kriteria pemilihan model terbaik yang berdasarkan pada nilai terkecil. Kriteria SBC dapat dirumuskan sebagai berikut [6]:

$$SBC = n \ln \left(\frac{SSE}{n} \right) + f \ln n + n + n \ln(2\pi)$$

dengan:

\ln : natural log

SSE : *Sum Square Error*

n : banyaknya pengamatan

f : banyak parameter dalam model

Selain itu, pemilihan model terbaik juga dapat dilihat dengan menggunakan perhitungan nilai *Mean Absolute Percentage Error* (MAPE), yaitu ukuran kesalahan yang dihitung dengan mencari nilai tengah dari presentase absolut perbandingan kesalahan atau *error* dengan data aktualnya. Didefinisikan MAPE adalah sebagai berikut:

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} (100) \right| \quad (2.16)$$

dengan:

Z_t : nilai data ke- t

\hat{Z}_t : nilai peramalan ke- t

n : banyaknya data

BAB III

METODE PENELITIAN

Pada bab ini dijelaskan mengenai metode yang digunakan dalam Tugas Akhir agar proses pengerjaan dan penulisan dapat terstruktur dan dapat mencapai tujuan serta manfaat dilakukannya penelitian. Tahapan-tahapan penelitian digambarkan menggunakan diagram alir pada Gambar 3.1 sampai dengan Gambar 3.4.

3.1 Tahap Penelitian

Dalam melakukan penelitian pada Tugas Akhir ini, ada beberapa tahap yang akan dilakukan antara lain :

1. Studi literatur

Pada tahap ini dilakukan identifikasi permasalahan dan pengumpulan informasi tentang teori-teori yang menunjang penyelesaian Tugas Akhir ini seperti model ARIMA Box Jenkins, VAR, Filter Kalman dan lain-lain.

2. Pengumpulan data

Pengumpulan data dilakukan untuk mendapatkan data yang dibutuhkan untuk pengerjaan Tugas Akhir, yaitu data sekunder dari KpwBI Kota Malang.

3. Analisis data untuk mendapatkan model dan *forecasting* data menggunakan metode ARIMA Box-Jenkins dan VAR

Pada tahap ini dilakukan analisis data untuk mendapatkan model ARIMA dan VAR. Langkah pertama yang harus dipenuhi adalah data yang harus stasioner dalam *mean*. Langkah pertama dapat dilakukan dengan cara melihat grafik dari data. Jika data tersebut sudah stasioner maka nilai *mean* dan varian relatif konstan tiap periode. Langkah kedua adalah korelogram, yaitu analisis nilai *autocorrelation function* (ACF) dan *partial autocorrelation function* (PACF). Data stasioner ditandai dengan nilai autokorelasi dan autokorelasi parsial yang menurun secara *time lag*. Langkah ketiga adalah uji plot korelogram residual, jika sebaran data mendekati nilai nol dapat diartikan data stasioner dalam varian.

Langkah keempat dalam pengujian stasioneritas data adalah uji *unit root*, yaitu uji stasioneritas data menggunakan metode Dickey-Fuller Test (ADF) dengan bantuan program Eviews 7. Setelah data stasioner, maka akan didapatkan hasil ACF dan PACF data yang dapat digunakan untuk membuat suatu model *forecasting*. Setelah didapatkan model kemudian *forecasting* dapat dilakukan dengan menggunakan data *out-sample*. Proses pengolahan data menggunakan *software* Minitab, Microsoft Excel, Eviews dan SAS.

4. Implementasi dan simulasi data metode Filter Kalman

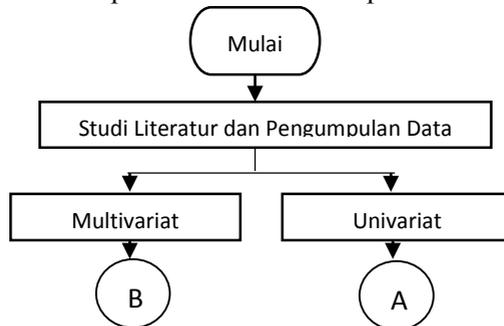
Pada tahap ini dilakukan implementasi simulasi Filter Kalman sebagai perbaikan *error* atas hasil *forecasting* ARIMA dan VAR dengan bantuan *software* MATLAB. Tahap ini sebagai dasar untuk menarik kesimpulan dari hasil penelitian Tugas Akhir.

5. Penarikan kesimpulan

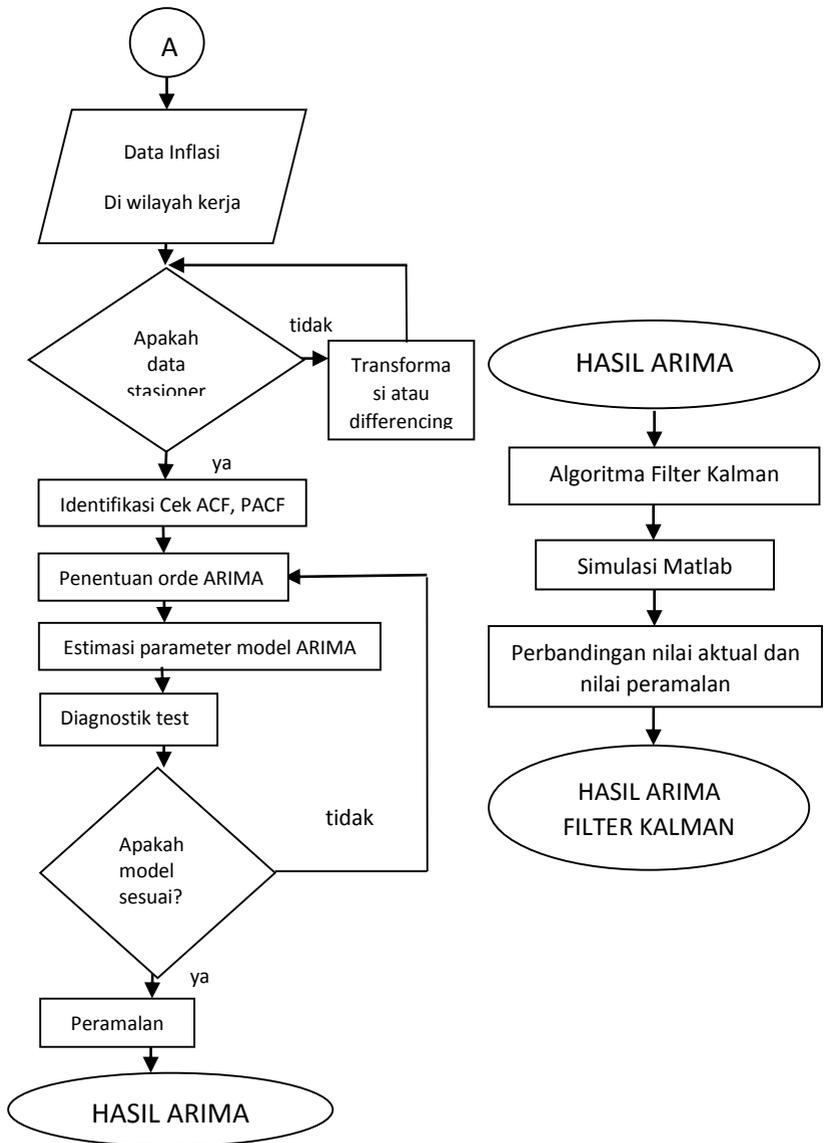
Pada tahap ini dilakukan penarikan kesimpulan dari hasil penelitian, dimana MAPE dianalisis melalui perbandingan hasil *forecasting* yang telah didapatkan dari hasil metode ARIMA, VAR, ARIMA-Filter Kalman, dan VAR-Filter Kalman.

3.2 Diagram Alir

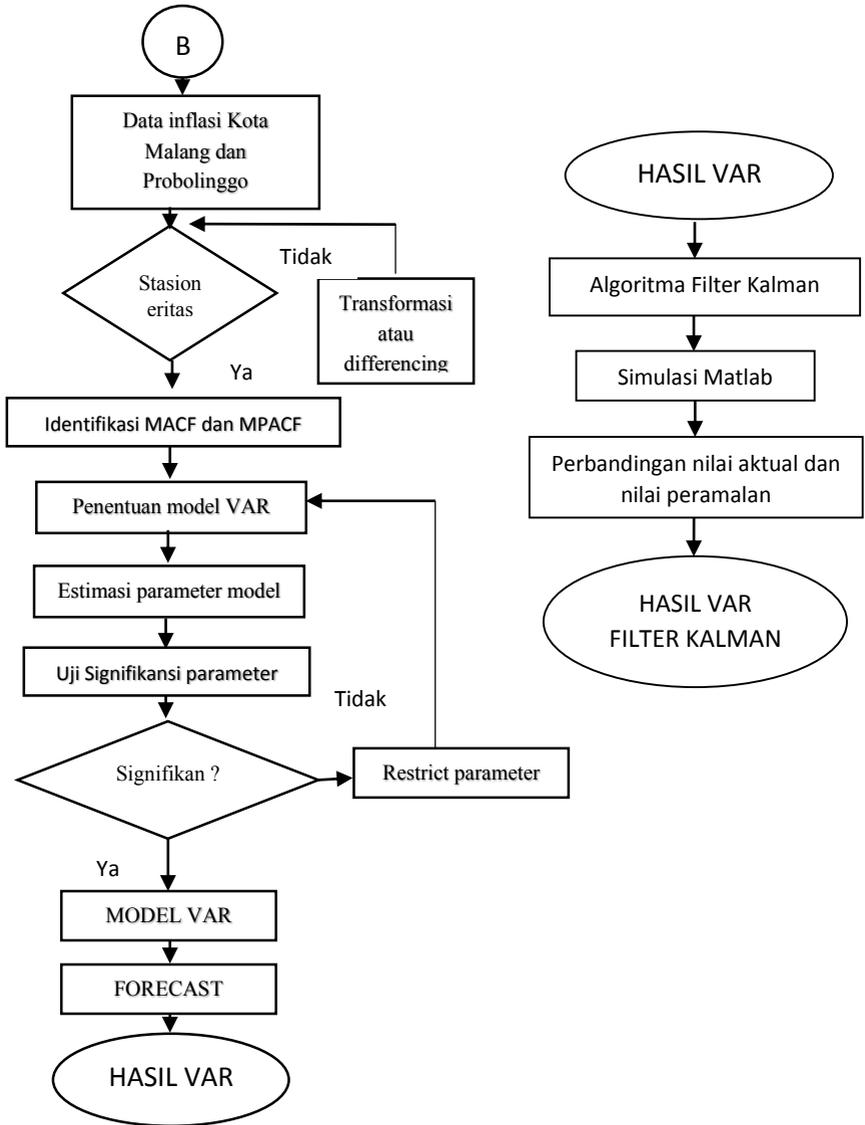
Tahapan-tahapan pembentukan dan *forecasting* menggunakan ARIMA, VAR, ARIMA-Filter Kalman, dan VAR-Filter Kalman yang digambarkan pada Gambar 3.1 sampai Gambar 3.4.



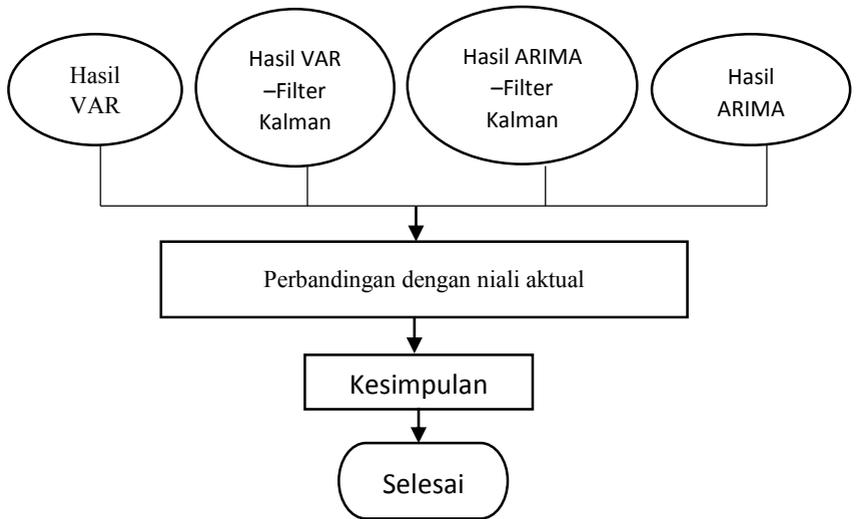
Gambar 3.1 Diagram alir pembagian model *time series*



Gambar 3.2 Diagram alir penerapan ARIMA-Filter Kalman



Gambar 3.3 Diagram alir pembentukan model VAR-Filter Kalman



Gambar 3.4 Diagram alir perbandingan model ARIMA, VAR, ARIMA-Filter Kalman, dan VAR- Filter Kalman

BAB IV ANALISIS DAN PEMBAHASAN

Pada bab ini dilakukan analisis dan pembahasan mengenai langkah-langkah dalam penerapan Filter Kalman dalam perbaikan estimasi inflasi *month to month* dengan metode ARIMA Box-Jenkins dan VAR.

4.1 Variabel dan Data Penelitian

Tugas akhir ini menggunakan data bulanan inflasi wilayah kerja KPwBI Malang di dua wilayah yaitu Kota Malang dan Kota Probolinggo. Data yang digunakan sebanyak 68 data di setiap lokasi yang diperoleh dari Kantor Perwakilan Bank Indonesia (KPwBI) Kota Malang. Data yang diperoleh kemudian dibagi menjadi dua yaitu data *in-sample* dan data *out-sample*. Data *in-sample* yang digunakan sebanyak 60 data (Januari 2010- Desember 2013), sedangkan data *out-sample* sebanyak 8 data. Data *in-sample* digunakan untuk membentuk model dan data *out-sample* digunakan untuk mengecek ketepatan model. Variabel yang digunakan pada penelitian ini yaitu data inflasi *month to month* di dua wilayah yaitu Kota Malang $Z1(t)$ dan Kota Probolinggo $Z2(t)$. Deskripsi dari ke dua data inflasi *month to month* ini secara umum ditampilkan dalam Tabel 4.1.

Tabel 4.1 Deskripsi Data Inflasi *Month to Month* Kota Malang dan Probolinggo

| Variabel | Mean | StdDev | Max | Min |
|----------|----------|----------|------|------|
| $Z1(t)$ | 1.556042 | 0.695355 | 4.49 | 0.43 |
| $Z2(t)$ | 1.495 | 0.753 | 4.13 | 0.18 |

4.2 Pemodelan ARIMA

Pada tahap ini akan dilakukan analisis data untuk membentuk model ARIMA di masing-masing wilayah kerja KpwBI Malang.

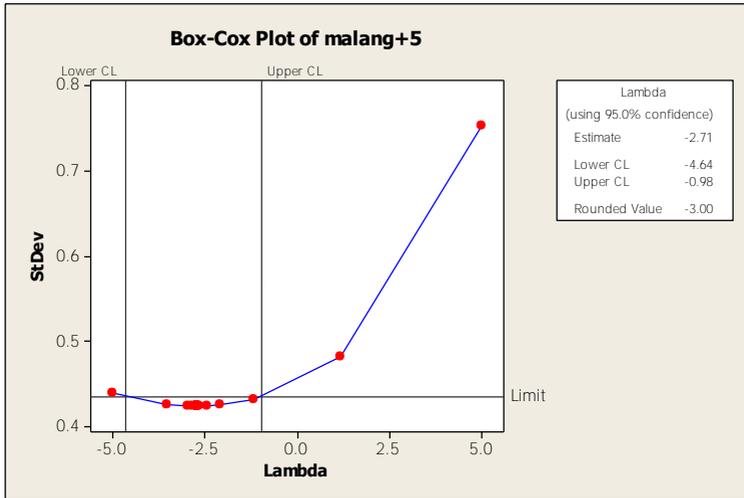
4.2.1 Model ARIMA Inflasi *month to month* Kota Malang di Z1.

Data inflasi *month to month* Kota Malang pada umumnya terdiri dari beberapa data positif dan beberapa data negatif. Dalam proses analisis model ARIMA menggunakan minitab, hendaknya data yang digunakan merupakan data yang positif, sehingga pada Tugas Akhir ini akan dilakukan penggeseran titik nol ke titik 5 dengan cara menambahkan setiap data dengan konstanta 5. Selanjutnya akan dilakukan identifikasi stasioneritas data inflasi *month to month*. Kestasioneritasan data merupakan langkah pertama dalam pembentukan model ARIMA karena syarat pembentukan model analisis *time series* adalah dengan mengasumsikan bahwa data dalam keadaan stasioner. *Time series* dikatakan stasioner apabila tidak terdapat perubahan kecenderungan, baik dalam *mean* maupun varians. Dengan kata lain, *time series* stasioner apabila relatif tidak terjadi kenaikan ataupun penurunan nilai secara tajam pada data.

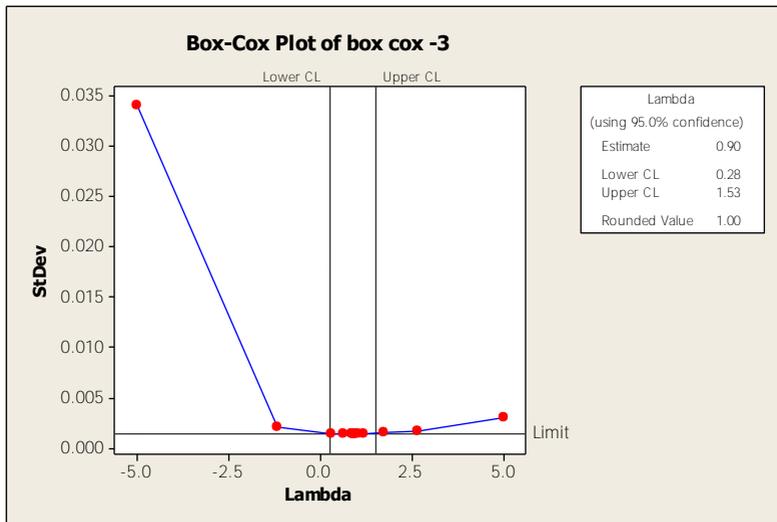
Identifikasi stasioner dalam varian dilakukan dengan cara melihat hasil Transformasi Box-Cox dimana data dikatakan stasioner apabila *rounded value* dari data adalah 1. Plot Box-Cox data sebelum transformasi dapat dilihat pada Gambar 4.1.

Gambar 4.1 menunjukkan nilai *lambda* dengan nilai kepercayaan 95% berada diantara -4.64 dan -0.98, dengan nilai *estimate* sebesar -2.71 dan *rounded value* sebesar -3.00. Hal ini berarti data belum stasioner terhadap varians karena *rounded value*-nya tidak sama dengan 1. Sehingga data tersebut perlu distasionerkan dengan menggunakan Transformasi Box-Cox sehingga didapat *rounded value* sama dengan 1. Data yang sudah stasioner dalam varians dapat dilihat pada Gambar 4.2.

Gambar 4.2 menunjukkan *rounded value*-nya sebesar 1 sehingga dapat dikatakan bahwa data sudah stasioner dalam varians. Setelah melihat kestasioneran dalam varians, selanjutnya akan dilihat apakah data telah stasioner dalam *mean*. Kestasioneran dalam *mean* dapat dilihat dari plot *time series* data tersebut. Hasil plot dapat dilihat pada Gambar 4.3.



Gambar 4.1 Plot Box-Cox Data Sebelum Transformasi.



Gambar 4.2 Plot Box-Cox Data Sesudah Transformasi.

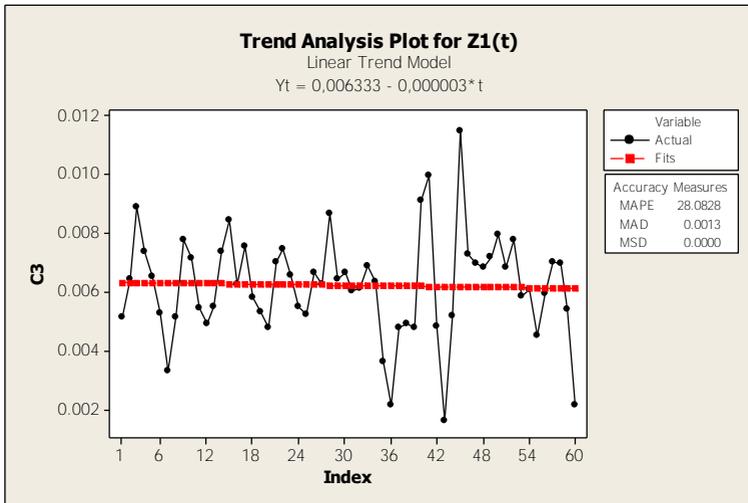


Gambar 4.3 Plot *Time series* $Z_1(t)$ Hasil Transformasi

Gambar 4.3 secara visual dapat diketahui bahwa data sudah memiliki pola yang teratur dan tidak terlalu fluktuatif, sehingga data tersebut dapat dikategorikan ke dalam data yang stasioner dalam *mean*. Sehingga tidak perlu adanya *pen-differencing-an*. Kestasioneritasan dalam *mean* juga dapat di cek melalui plot trend linear pada Gambar 4.4.

Dari Gambar 4.4 secara visual dapat diketahui bahwa data telah stasioner dalam *mean*. Hal tersebut diketahui dari plot rata-rata deret pengamatan yang berfluktuasi di sekitar nilai tengah dan trend sudah mendekati sumbu horizontal. Karena data telah stasioner terhadap *mean* dan varians, maka akan di lanjutkan dengan identifikasi model ARIMA melalui pengecekan pola ACF dan PACF. Pola ACF dapat dilihat pada Gambar 4.5 dan pola PACF pada Gambar 4.6.

Terlihat pada Gambar 4.5 plot dari ACF keluar pada lag ke-1 dan ke-2. Sedangkan pada Gambar 4.6 plot dari PACF keluar pada lag ke-1, 2, 8, dan 20. Sehingga dugaan model sementara untuk data $Z_1(t)$ adalah ARIMA $([1,2,8,20],0,2)$.

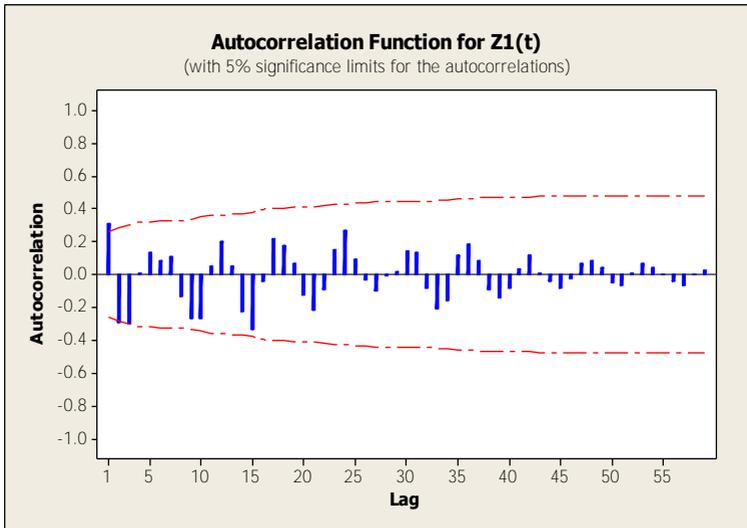


Gambar 4.4 Plot *Time series* $Z_1(t)$ Stasioner Dalam Mean

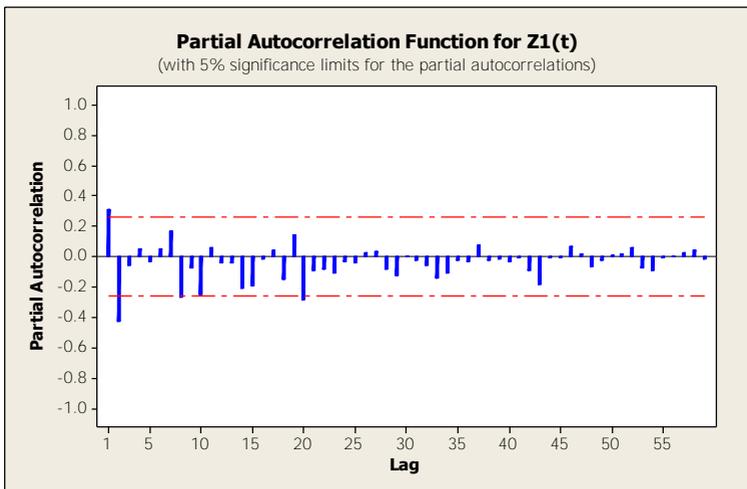
Selanjutnya akan dilakukan estimasi parameter dan uji kesignifikanan parameter untuk model sementara. Pengujian ini dilakukan dengan menggunakan *software Eviews*. Hasilnya dapat dilihat pada Tabel 4.2.

Tabel 4.2 Estimasi Parameter Model ARIMA $([1,2,8,20],0,2)$

| Parameter | Koefisien | SE | t-stat. | P-value |
|---------------------|-----------|----------|-----------|---------|
| AR(1)= ϕ_1 | 0.833372 | 0.306959 | 2.714928 | 0.0103 |
| AR(2)= ϕ_2 | 0.078018 | 0.314670 | 0.247936 | 0.8057 |
| AR(8)= ϕ_8 | -0.079838 | 0.114772 | -0.695620 | 0.4914 |
| AR(20)= ϕ_{20} | 0.165937 | 0.113827 | 1.457798 | 0.1541 |
| MA(1)= θ_1 | -0.326845 | 0.237943 | -1.373630 | 0.1785 |
| MA(2)= θ_2 | -0.604553 | 0.227483 | -2.657580 | 0.0119 |



Gambar 4.5 Plot ACF Z1(t)



Gambar 4.6 Plot PACF Z1(t)

Uji kesignifikanan parameter menggunakan uji-*tstudent*.

1. Menguji parameter AR(1) = ϕ_1

Hipotesis:

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

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

Statistik uji:

$$\begin{aligned} t_{hitung} &= \frac{\widehat{\phi}_1}{\text{st. dev}(\phi_1)} \\ &= \frac{0.833372}{0.306959} \\ &= 2.714928 \end{aligned}$$

$$\begin{aligned} t_{tabel} &= t_{0,025;60} \\ &= 2.00030 \end{aligned}$$

dengan $\alpha = 0.05$, karena $|t_{hitung}| > t_{0,025;60}$ maka H_0 diterima artinya parameter signifikan.

2. Menguji parameter AR(2) = ϕ_2

Hipotesis:

$H_0 : \phi_2 = 0$ (parameter model tidak signifikan)

$H_1 : \phi_2 \neq 0$ (parameter model signifikan)

Statistik uji:

$$\begin{aligned} t_{hitung} &= \frac{\widehat{\phi}_2}{\text{st. dev}(\phi_2)} \\ &= \frac{0.078018}{0.314670} \\ &= 0.247936 \end{aligned}$$

$$\begin{aligned} t_{tabel} &= t_{0,025;60} \\ &= 2.00030 \end{aligned}$$

Dengan $\alpha = 0.05$, karena $|t_{hitung}| < t_{0,025;60}$ maka H_0 ditolak artinya parameter tidak signifikan.

3. Menguji parameter $AR(8) = \phi_8$

Hipotesis:

$H_0 : \phi_8 = 0$ (parameter model tidak signifikan)

$H_1 : \phi_8 \neq 0$ (parameter model signifikan)

Statistik uji:

$$\begin{aligned} t_{hitung} &= \frac{\widehat{\phi}_8}{st. dev(\phi_8)} \\ &= \frac{-0.079838}{0.114772} \\ &= -0.695620 \end{aligned}$$

$$\begin{aligned} t_{tabel} &= t_{0,025;60} \\ &= 2.00030 \end{aligned}$$

Dengan $\alpha = 0.05$, karena $|t_{hitung}| < t_{0,025;60}$ maka H_0 ditolak artinya parameter tidak signifikan.

4. Menguji parameter $AR(20) = \phi_{20}$

Hipotesis:

$H_0 : \phi_{20} = 0$ (parameter model tidak signifikan)

$H_1 : \phi_{20} \neq 0$ (parameter model signifikan)

Statistik uji:

$$\begin{aligned} t_{hitung} &= \frac{\widehat{\phi}_{20}}{st. dev(\phi_{20})} \\ &= \frac{0.165937}{0.113827} \\ &= 1.457798 \end{aligned}$$

$$t_{tabel} = t_{0,025;60}$$

$$= 2.00030$$

Dengan $\alpha = 0.05$, karena $|t_{hitung}| < t_{0,025;60}$ maka H_0 ditolak artinya parameter tidak signifikan.

5. Menguji parameter MA(1) = θ_1

Hipotesis:

$H_0 : \theta_1 = 0$ (parameter model tidak signifikan)

$H_1 : \theta_1 \neq 0$ (parameter model signifikan)

Statistik uji:

$$\begin{aligned} t_{hitung} &= \frac{\widehat{\theta}_1}{st. dev(\theta_1)} \\ &= \frac{-0.326845}{0.237943} \\ &= -1.373630 \end{aligned}$$

$$\begin{aligned} t_{tabel} &= t_{0,025;60} \\ &= 2.00030 \end{aligned}$$

Dengan $\alpha = 0.05$, karena $|t_{hitung}| < t_{0,025;60}$ maka H_0 ditolak artinya parameter tidak signifikan.

6. Menguji parameter MA(2) = θ_2

Hipotesis:

$H_0 : \theta_2 = 0$ (parameter model tidak signifikan)

$H_1 : \theta_2 \neq 0$ (parameter model signifikan)

Statistik uji:

$$\begin{aligned} t_{hitung} &= \frac{\widehat{\theta}_2}{st. dev(\theta_2)} \\ &= \frac{-0.604553}{0.227483} \\ &= -2.657580 \end{aligned}$$

$$t_{tabel} = t_{0,025;60} \\ = 2.00030$$

Dengan $\alpha = 0.05$, karena $|t_{hitung}| > t_{0,025;60}$ maka H_0 diterima artinya parameter signifikan.

ARIMA ([1,2,8,20],0,2) bukan model yang signifikan untuk forecasting sebab terdapat parameter yang tidak signifikan, Tahapan selanjutnya dari model ARIMA Box-Jenkins adalah dengan melakukan *overfitting*. Model yang dihasilkan dari hasil *overfitting* dijadikan model alternatif yang kemudian dicari model yang terbaik diantara model-model yang lain. Adapun model-model alternatif yang diujikan adalah sebagai berikut:

1. ARIMA ([1],0,[2])
2. ARIMA (0,0,[2])
3. ARIMA ([1],0,0)

Saat memilih satu model terbaik, dipilih model ARIMA yang memenuhi semua asumsi, yaitu parameter signifikan, residualnya memenuhi asumsi *white noise* dan berdistribusi normal, serta memiliki nilai AIC dan SBC terkecil. Hasil pengujian dapat dilihat pada Tabel 4.3.

Tabel 4.3 Hasil Pengujian Asumsi Residual *White Noise* dan Berdistribusi Normal serta nilai AIC dan SBC

| Model | Uji Signifikan | Uji Asumsi <i>White Noise</i> | Uji Asumsi Normal | AIC | SBC |
|-------------------|----------------|-------------------------------|-------------------|----------|----------|
| ARIMA ([1],0,[2]) | Signifikan | <i>White noise</i> | Normal | -9.76363 | -9.69320 |
| ARIMA (0,0,[2]) | Signifikan | White noise | Normal | -7.48203 | -7.44712 |
| ARIMA ([1],0,0) | Signifikan | White noise | Normal | -9.59754 | -9.56233 |

Berdasarkan Tabel 4.3 terlihat bahwa model ARIMA ([1],0,[2]) memenuhi semua asumsi, yaitu parameter signifikan, residual *white noise* dan berdistribusi normal, serta memiliki nilai AIC dan SBC terkecil. Sehingga ARIMA ([1],0,[2]) merupakan model yang terbaik. Uji signifikansi parameter ARIMA (1,0,[2]) dapat dilihat pada Tabel 4.4 dan hasil uji signifikansi parameter model pada proses *overfitting* dapat dilihat pada Lampiran 9.

Tabel 4.4 Hasil Uji Signifikansi Parameter ARIMA ([1],0,[2])

| Model | Parameter | <i>p-value</i> | Signifikan/tidak |
|----------------------|------------|----------------|------------------|
| ARIMA ([1],0,[2]) | ϕ_1 | 0.000 | Signifikan |
| | θ_2 | 0.000 | Signifikan |

Selanjutnya asumsi yang harus dipenuhi adalah residual bersifat *white noise* dan berdistribusi normal. Pengujian asumsi *white noise* untuk ARIMA (1,0,[2]) dapat dilakukan dengan menggunakan uji Ljung-Box sebagai berikut :

Hipotesis:

$$H_0 : \rho_1 = \dots = \rho_{12} = 0$$

$$H_1 : \text{minimal ada satu } \rho_j \neq 0, \text{ dengan } j = 1, 2, \dots, 12$$

Statistik Uji:

Untuk k (lag maksimum) = 12, maka:

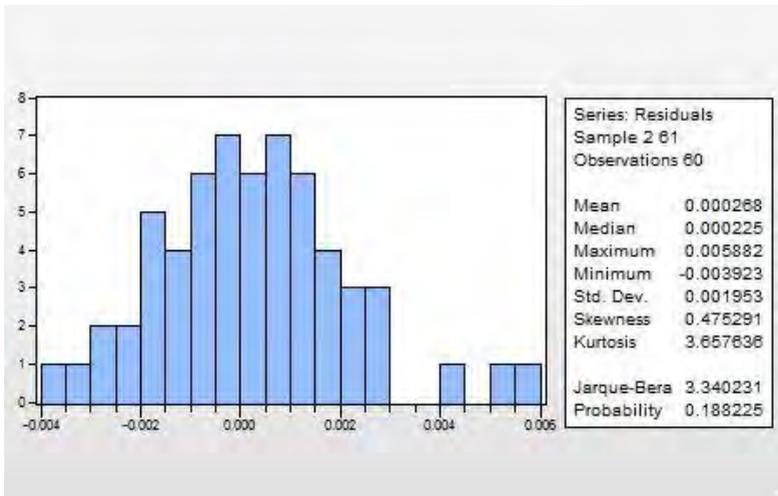
$$Q = n(n+2) \sum_{k=1}^{12} \frac{\hat{\rho}_k^2}{n-k}, \hat{\rho}_k \text{ autokorelasi residual lag } -k$$

$$\begin{aligned}
Q &= 60(60 + 2) \left(\frac{(-0.148)^2}{60 - 1} + \frac{(-0.265)^2}{60 - 2} + \frac{(-0.244)^2}{60 - 3} + \frac{(0.090)^2}{60 - 4} \right. \\
&\quad + \frac{(0.128)^2}{60 - 5} + \frac{(-0.086)^2}{60 - 6} + \frac{(-0.218)^2}{60 - 7} \\
&\quad + \frac{(-0.134)^2}{60 - 8} + \frac{(-0.040)^2}{60 - 9} + \frac{(-0.235)^2}{60 - 10} \\
&\quad \left. + \frac{(0.125)^2}{60 - 11} + \frac{(0.181)^2}{60 - 12} \right) \\
&= 60(62)(0.006585) \\
&= 24.49723
\end{aligned}$$

Dengan tabel Distribusi Chi-Square diperoleh:

$$\chi^2_{(0,05;12-2-1)} = 16.9$$

dengan $\alpha = 0.05$, karena $Q > \chi^2_{(0,05;12-2-1)}$ maka H_0 diterima artinya residual bersifat *white noise*. Atau dengan menggunakan P-value yang terdapat pada *Eviews*, karena P-value $< \alpha = 0.05$ maka H_0 diterima artinya residual bersifat *white noise*.



Gambar 4.7 Residual Diagnostics Histogram-nomality Test di $Z1(t)$

| Dependent Variable: MALANG | | | | |
|---|-------------|-----------------------|-------------|-----------|
| Method: Least Squares | | | | |
| Date: 01/19/16 Time: 21:46 | | | | |
| Sample (adjusted): 2 60 | | | | |
| Included observations: 59 after adjustments | | | | |
| Convergence achieved after 15 iterations | | | | |
| MA Backcast: 0 1 | | | | |
| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
| AR(1) | 0.980221 | 0.021468 | 45.65959 | 0.0000 |
| MA(2) | -0.443340 | 2.83E-05 | -15646.77 | 0.0000 |
| R-squared | -0.031743 | Mean dependent var | | 0.006247 |
| Adjusted R-squared | -0.049844 | S.D. dependent var | | 0.001761 |
| S.E. of regression | 0.001805 | Akaike info criterion | | -9.763629 |
| Sum squared resid | 0.000186 | Schwarz criterion | | -9.693204 |
| Log likelihood | 290.0271 | Hannan-Quinn criter. | | -9.736138 |
| Durbin-Watson stat | 2.360434 | | | |
| Inverted AR Roots | .98 | | | |
| Inverted MA Roots | .67 | -.67 | | |

Gambar 4.8 Estimasi parameter ARIMA ([1],0,[2])

Uji asumsi residual berdistribusi normal menggunakan histogram *normality test* pada minitab, dapat dilihat melalui nilai *p-value*. Jika nilai *p-value* lebih besar dari nilai alpha, maka residual tersebut berdistribusi normal. Pada Gambar 4.7, *p-value* = 0.188225 lebih besar dari alpha = 0.05 sehingga dapat disimpulkan bahwa residual berdistribusi normal.

Berdasarkan persamaan (2.1), diperoleh persamaan model sebagai berikut:

$$Z_t = \phi_1 Z_{t-1} - \theta_2 a_{t-2} + a_t$$

$$Z_t = 0.980221 Z_{t-2} + 0.443340 a_{t-2} + a_t$$

dimana $Z_t = \frac{1}{(Z1(t)+5)^3}$

Kemudian, akan dilakukan peramalan untuk 7 bulan ke depan dengan *software Eviews*. Hasil prediksi ini nantinya akan diolah

lebih lanjut dengan algoritma Filter Kalman untuk memperbaiki hasil estimasi prediksi ARIMA. Hasil *forecasting* dapat dilihat pada Tabel 4.8.

4.2.2 Model ARIMA Inflasi *month to month* Kota Probolinggo di Z2.

Data inflasi *month to month* Kota Probolinggo pada umumnya terdiri dari atas beberapa data positif dan beberapa data negatif. Dalam proses analisis model ARIMA menggunakan minitab, hendaknya data yang digunakan merupakan data yang positif, sehingga pada Tugas Akhir ini akan dilakukan penggeseran titik nol ke titik 5 dengan cara menambahkan setiap data dengan konstanta 5. Selanjutnya akan dilakukan identifikasi stasioneritas data inflasi *month to month*. Kestasioneritasan data merupakan langkah pertama dalam pembentukan model ARIMA karena syarat pembentukan model analisis *time series* adalah dengan mengasumsikan bahwa data dalam keadaan stasioner. *Time series* dikatakan stasioner apabila tidak terdapat perubahan kecenderungan, baik dalam *mean* maupun varians. Dengan kata lain, *time series* stasioner apabila relatif tidak terjadi kenaikan ataupun penurunan nilai secara tajam pada data.

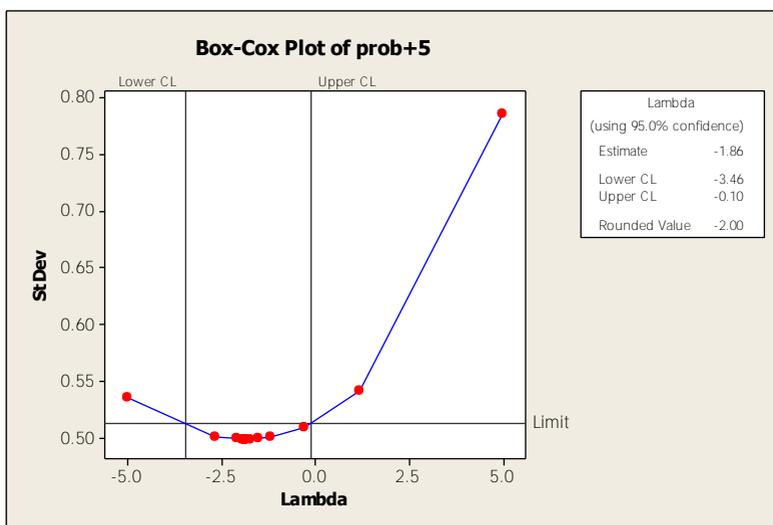
Identifikasi stasioner dalam varian dilakukan dengan cara melihat hasil Transformasi Box-Cox dimana dikatakan stasioner apabila *rounded value* dari data adalah 1. Plot Box-Cox data sebelum transformasi dapat dilihat pada Gambar 4.9.

Berdasarkan Gambar 4.9 didapatkan nilai *lambda* dengan nilai kepercayaan 95% berada diantara -3.46 dan -0.10, dengan nilai *estimate* sebesar -1.86 dan *rounded value* sebesar -2.00. Hal ini berarti data belum stasioner terhadap varians karena *rounded value*-nya tidak sama dengan 1. Sehingga data tersebut perlu distasionerkan dengan menggunakan Transformasi Box-Cox sehingga didapat *rounded value* sama dengan 1. Data yang sudah stasioner dalam varians dapat dilihat pada Gambar 4.10.

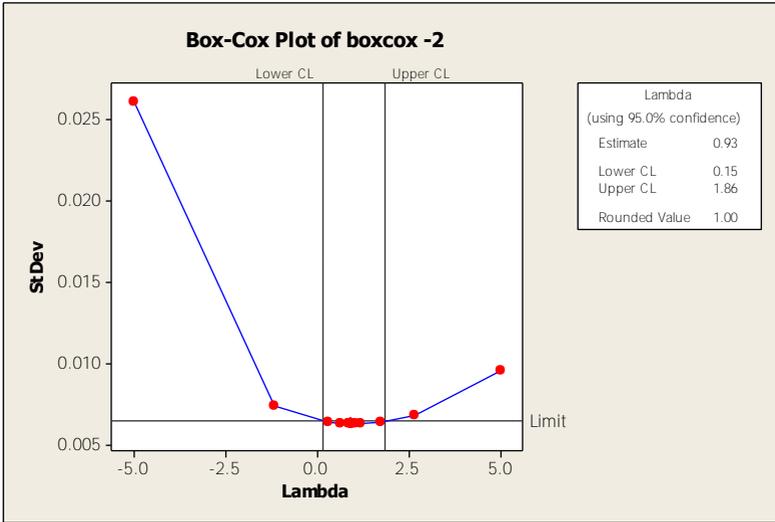
Berdasarkan Gambar 4.10, *rounded value*-nya sebesar 1 sehingga dapat dikatakan bahwa data sudah stasioner dalam

varians. Setelah melihat kestasioneran dalam varians, selanjutnya akan dilihat apakah data telah stasioner dalam *mean*. Kestasioneran dalam *mean* dapat dilihat dari plot *time series* data tersebut. Hasil plot dapat dilihat pada Gambar 4.11.

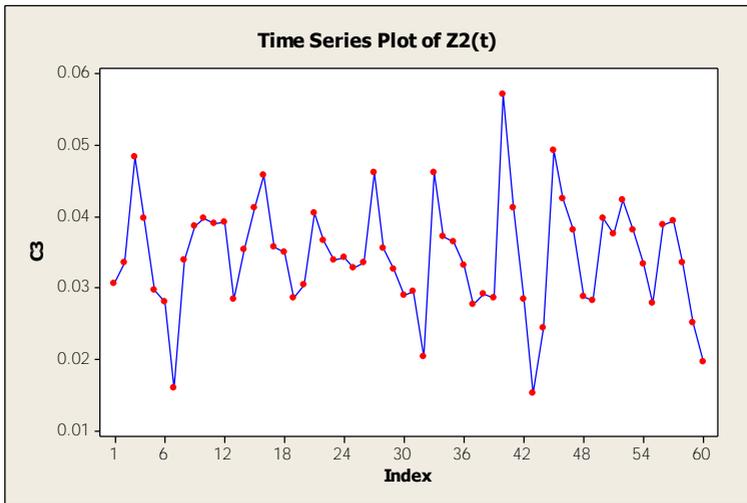
Gambar 4.11 secara visual dapat diketahui bahwa data sudah memiliki pola yang teratur dan tidak terlalu fluktuatif, sehingga data tersebut dapat dikategorikan ke dalam data yang stasioner dalam *mean*. Sehingga tidak perlu adanya *pen-differencing-an*. Kestasioneritasan dalam *mean* juga dapat di cek melalui plot trend linear pada Gambar 4.12.



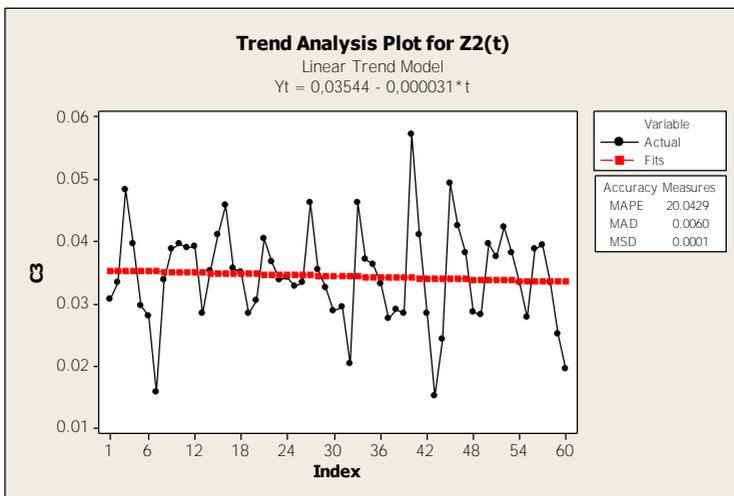
Gambar 4.9 Plot Box-Cox Data Sebelum Transformasi.



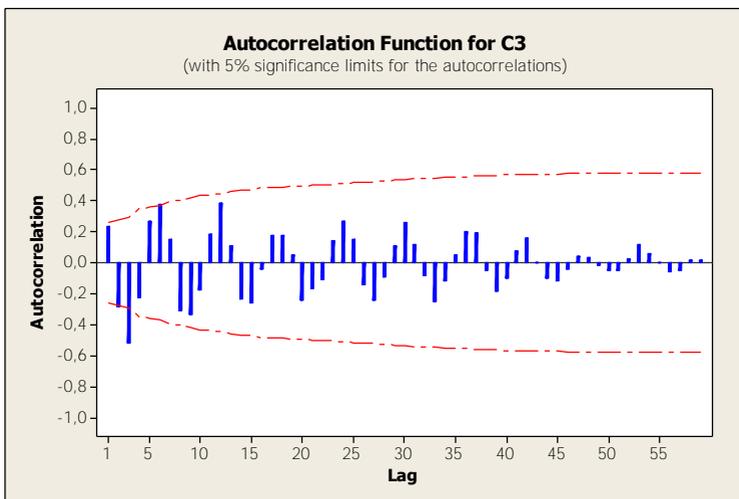
Gambar 4.10 Plot Box-Cox Data Sesudah Transformasi.



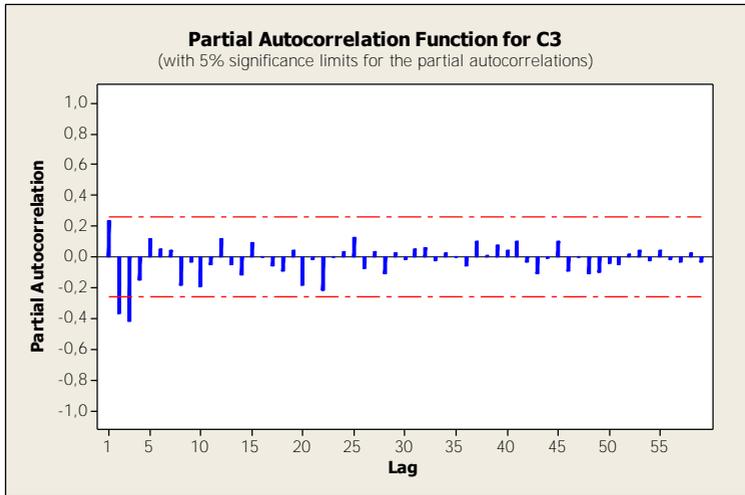
Gambar 4.11 Plot *Time series* Z2(t) Hasil Transformasi



Gambar 4.12 Plot *Time series* Z2(t) Stasioner Dalam Mean



Gambar 4.13 Plot ACF Z2(t)



Gambar 4.14 Plot PACF Z2(t)

Terlihat pada Gambar 4.13 plot dari ACF keluar pada lag ke-2, 3, dan ke-6. Sedangkan pada Gambar 4.14 plot dari PACF keluar pada lag ke-2, 3, dan ke-22. Sehingga dugaan model sementara untuk data Z2(t) adalah ARIMA ([2,3,22],0,[2,3,6]).

Tabel 4.5 Estimasi Parameter Model ARIMA ([2,3,22],0,[2,3,6])

| Parameter | Koefisien | SE | t-stat. | P-value |
|---------------------|-----------|----------|-----------|---------|
| AR(2)= ϕ_2 | 0.191119 | 0.049652 | 3.849165 | 0.0005 |
| AR(3)= ϕ_3 | 0.711031 | 0.060361 | 11.77972 | 0.0000 |
| AR(22)= ϕ_{22} | 0.078350 | 0.058184 | 1.346596 | 0.1873 |
| MA(2)= θ_2 | -0.288572 | 0.179572 | -1.606997 | 0.1176 |
| MA(3)= θ_3 | -2.373872 | 0.298725 | -7.946678 | 0.0000 |
| MA(6)= θ_6 | 1.081490 | 0.255925 | 4.25814 | 0.0002 |

Selanjutnya akan dilakukan estimasi parameter dan uji kesignifikanan parameter untuk model sementara. Pengujian ini dilakukan dengan menggunakan *software Eviews*. Hasilnya dapat dilihat pada Tabel 4.5.

Uji kesignifikanan parameter menggunakan uji-*t student*.

1. Menguji parameter $AR(2) = \phi_2$

Hipotesis:

$H_0 : \phi_2 = 0$ (parameter model tidak signifikan)

$H_1 : \phi_2 \neq 0$ (parameter model signifikan)

Statistik uji:

$$\begin{aligned} t_{hitung} &= \frac{\widehat{\phi}_2}{st. dev(\phi_2)} \\ &= \frac{0.191119}{0.049652} \\ &= 3.849165 \end{aligned}$$

$$\begin{aligned} t_{tabel} &= t_{0,025;60} \\ &= 2.00030 \end{aligned}$$

dengan $\alpha = 0.05$, karena $|t_{hitung}| > t_{0,025;60}$ maka H_0 diterima artinya parameter signifikan.

2. Menguji parameter $AR(3) = \phi_3$

Hipotesis:

$H_0 : \phi_3 = 0$ (parameter model tidak signifikan)

$H_1 : \phi_3 \neq 0$ (parameter model signifikan)

Statistik uji:

$$\begin{aligned} t_{hitung} &= \frac{\widehat{\phi}_3}{st. dev(\phi_3)} \\ &= \frac{0.711031}{0.060361} \\ &= 11.77972 \end{aligned}$$

$$t_{tabel} = t_{0,025;60}$$

$$= 2.00030$$

dengan $\alpha = 0.05$, karena $|t_{hitung}| > t_{0,025;60}$ maka H_0 diterima artinya parameter signifikan.

3. Menguji parameter AR(2) = ϕ_{22}

Hipotesis:

$H_0 : \phi_{22} = 0$ (parameter model tidak signifikan)

$H_1 : \phi_{22} \neq 0$ (parameter model signifikan)

Statistik uji:

$$t_{hitung} = \frac{\widehat{\phi}_{22}}{st. dev(\phi_{22})}$$

$$= \frac{0.078350}{0.058184}$$

$$= 1.346596$$

$$t_{tabel} = t_{0,025;60}$$

$$= 2.00030$$

dengan $\alpha = 0.05$, karena $|t_{hitung}| < t_{0,025;60}$ maka H_0 ditolak artinya parameter tidak signifikan.

4. Menguji parameter MA(2) = θ_2

Hipotesis:

$H_0 : \theta_2 = 0$ (parameter model tidak signifikan)

$H_1 : \theta_2 \neq 0$ (parameter model signifikan)

Statistik uji:

$$t_{hitung} = \frac{\widehat{\theta}_2}{st. dev(\theta_2)}$$

$$= \frac{-0.288572}{0.179572}$$

$$= -1.606997$$

$$t_{tabel} = t_{0,025;60}$$

$$= 2.00030$$

dengan $\alpha = 0.05$, karena $|t_{hitung}| < t_{0,025;60}$ maka H_0 ditolak artinya parameter tidak signifikan.

5. Menguji parameter MA(3) = θ_3

Hipotesis:

$H_0 : \theta_3 = 0$ (parameter model tidak signifikan)

$H_1 : \theta_3 \neq 0$ (parameter model signifikan)

Statistik uji:

$$t_{hitung} = \frac{\widehat{\theta}_3}{st. dev(\theta_3)}$$

$$= \frac{-2.373872}{0.298725}$$

$$= -7.946678$$

$$t_{tabel} = t_{0,025;60}$$

$$= 2.00030$$

dengan $\alpha = 0.05$, karena $|t_{hitung}| > t_{0,025;60}$ maka H_0 diterima artinya parameter signifikan.

6. Menguji parameter MA(6) = θ_6

Hipotesis:

$H_0 : \theta_6 = 0$ (parameter model tidak signifikan)

$H_1 : \theta_6 \neq 0$ (parameter model signifikan)

Statistik uji:

$$t_{hitung} = \frac{\widehat{\theta}_6}{st. dev(\theta_6)}$$

$$= \frac{1.081490}{0.255925}$$

$$= 4.25814$$

$$\begin{aligned}
 t_{tabel} &= t_{0,025;60} \\
 &= 2.00030
 \end{aligned}$$

dengan $\alpha = 0.05$, karena $|t_{hitung}| < t_{0,025;60}$ maka H_0 ditolak artinya parameter tidak signifikan.

Pengujian parameter model ARIMA ([2,3,22],0,[2,3,6]) menghasilkan dugaan model ARIMA tersebut tidak signifikan. Tahapan selanjutnya dari model ARIMA Box-Jenkins adalah dengan melakukan *overfitting*. Model yang dihasilkan dari hasil *overfitting* dijadikan model alternatif yang kemudian dicari model yang terbaik diantara model-model yang lain. Adapun model-model alternatif yang diujikan adalah sebagai berikut:

1. ARIMA ([2,3],0,[3])
2. ARIMA ([2,3],0,[6])
3. ARIMA ([2],0,[3,6])
4. ARIMA ([3],0,[3,6])
5. ARIMA ([2],0,[3])
6. ARIMA ([2],0,[6])
7. ARIMA ([3],0,[3])
8. ARIMA ([3],0,[6])

Pemilihan model terbaik dilakukan dengan memilih model ARIMA yang memenuhi semua asumsi, yaitu parameter signifikan, residualnya memenuhi asumsi *white noise* dan berdistribusi normal, serta memiliki nilai AIC dan SBC terkecil. Hasil pengujian dapat dilihat pada Tabel 4.6.

Tabel 4.6 terlihat bahwa model ARIMA ([3],0,[3,6]) memenuhi semua asumsi, yaitu parameter signifikan, residual *white noise* dan berdistribusi normal, serta memiliki nilai AIC dan SBC terkecil. Sehingga ARIMA ([3],0,[3,6]) merupakan model yang terbaik. Uji signifikan ARIMA ([3],0,[3,6]) terdapat pada Tabel 4.7 dan hasil uji signifikansi parameter model pada proses *overfitting* dapat dilihat pada Lampiran 10.

Tabel 4.6 Hasil Pengujian Asumsi Residual *White Noise* dan Berdistribusi Normal serta nilai AIC dan SBC

| Model | Uji Signifikan | Uji Asumsi <i>White Noise</i> | Uji Asumsi Normal | AIC | SBC |
|---------------------|------------------|-------------------------------|-------------------|----------|---------|
| ARIMA ([2,3],0,[3]) | Tidak signifikan | <i>White noise</i> | Normal | -6.68164 | -6.7161 |
| ARIMA ([2,3],0,[6]) | Signifikan | <i>White noise</i> | Normal | -6.15587 | -6.0493 |
| ARIMA ([2],0,[3,6]) | Signifikan | <i>White noise</i> | Normal | -6.29601 | -6.1904 |
| ARIMA ([3],0,[3,6]) | Signifikan | <i>White noise</i> | Normal | -7.02371 | -6.9171 |
| ARIMA ([2],0,[3]) | Signifikan | <i>White noise</i> | Normal | -6.12956 | -6.0591 |
| ARIMA ([2],0,[6]) | Signifikan | <i>White noise</i> | Normal | -6.06898 | -5.9985 |
| ARIMA ([3],0,[3]) | Signifikan | <i>White noise</i> | Normal | -6.68082 | -6.6098 |
| ARIMA ([3],0,[6]) | Signifikan | <i>White noise</i> | Normal | -5.95655 | -5.8855 |

Selanjutnya asumsi yang harus dipenuhi adalah residual bersifat *white noise* dan berdistribusi normal. Pengujian asumsi *white noise* untuk ARIMA ([3],0,[3,6]) dapat dilakukan dengan menggunakan uji Ljung-Box sebagai berikut :

Hipotesis:

$$H_0 : \rho_1 = \dots = \rho_{12} = 0$$

$$H_1 : \text{minimal ada satu } \rho_j \neq 0, \text{ dengan } j = 1, 2, \dots, 12$$

Statistik Uji:

Untuk k (lag maksimum) = 12, maka:

$$Q = n(n+2) \sum_{k=1}^{12} \frac{\hat{\rho}_k^2}{n-k}, \hat{\rho}_k \text{ autokorelasi residual lag } -k$$

$$Q = 60(60+2) \left(\frac{(0.069)^2}{60-1} + \frac{(-0.180)^2}{60-2} + \frac{(-0.045)^2}{60-3} \right. \\ \left. + \frac{(-0.089)^2}{60-4} + \frac{(0.124)^2}{60-5} + \frac{(0.222)^2}{60-6} \right. \\ \left. + \frac{(0.062)^2}{60-7} + \frac{(-0.255)^2}{60-8} + \frac{(-0.193)^2}{60-9} \right. \\ \left. + \frac{(-0.078)^2}{60-10} + \frac{(0.037)^2}{60-11} + \frac{(0.155)^2}{60-12} \right)$$

$$= 60(62)(0.004712)$$

$$= 17.52879$$

dengan tabel Distribusi Chi-Square diperoleh:

$$\chi^2_{(0,05;12-2-1)} = 16.9$$

dengan $\alpha = 0.05$, karena $Q > \chi^2_{(0,05;6-2-1)}$ maka H_0 diterima artinya residual bersifat *white noise*. Atau dengan menggunakan P-value yang terdapat pada *Eviews 6*, karena $P\text{-value} < \alpha = 0.05$ maka H_0 diterima artinya residual bersifat *white noise*.

Tabel 4.7 Hasil Uji Signifikansi Parameter ARIMA ([3],0,[3,6])

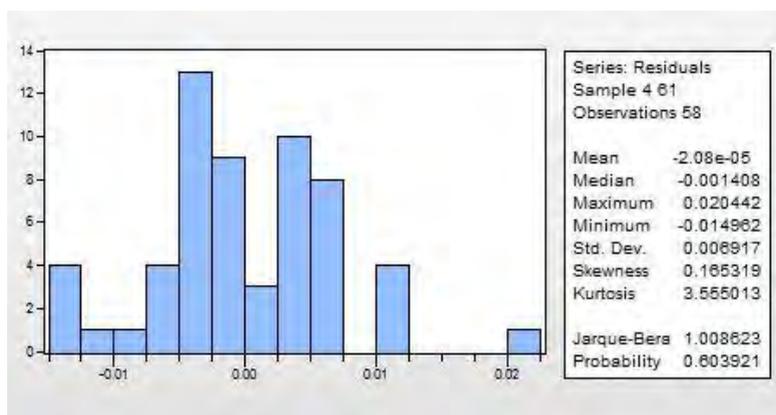
| Model | Parameter | P-value | Signifikan/tidak |
|------------------------|------------|---------|------------------|
| ARIMA ([3],0,[3,6]) | ϕ_3 | 0.0000 | Signifikan |
| | θ_3 | 0.0000 | Signifikan |
| | θ_6 | 0.0000 | Signifikan |

Pengujian asumsi residual berdistribusi normal menggunakan histogram *normality test* pada *minitab*, dapat dilihat melalui nilai

p-value. Jika nilai *p-value* lebih besar dari nilai alpha, maka residual tersebut berdistribusi normal. Pada Gambar 4.15, *p-value* = 0.603921 dimana lebih besar dari $\alpha = 0.05$.

Tabel 4.8 Hasil *Forecasting* ARIMA di Malang dan Probolinggo

| T | Malang | Probolinggo |
|------|----------|-------------|
| 62 | -0.04 | 0.17 |
| 63 | -0.37 | -0.11 |
| 64 | 0.59 | 0.74 |
| 65 | 0.34 | 0.75 |
| 66 | 0.57 | 0.37 |
| 67 | 0.40 | 0.54 |
| 68 | 0.67 | 0.36 |
| MAPE | 19.27087 | 10.09112 |



Gambar 4.15 *Residual Diagnostics Histogram-nomality Test* di Z2

Berdasarkan persamaan (2.1), diperoleh persamaan model sebagai berikut:

$$Z_t = \phi_3 Z_{t-3} - \theta_3 a_{t-3} - \theta_6 a_{t-6} + a_t$$

$$Z_t = 0.998970 Z_{t-3} + 1.489904 a_{t-3} - 0.607217 a_{t-6} + a_t$$

$$\text{dimana } Z_t = \frac{1}{(Z_2(t)+5)^2}$$

| Dependent Variable: PROB | | | | |
|---|-------------|-----------------------|-------------|----------|
| Method: Least Squares | | | | |
| Date: 01/20/16 Time: 14:58 | | | | |
| Sample (adjusted): 4 61 | | | | |
| Included observations: 58 after adjustments | | | | |
| Convergence achieved after 16 iterations | | | | |
| MA Backcast: -2 3 | | | | |
| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
| AR(3) | 0.998970 | 0.003841 | 260.0609 | 0.0000 |
| MA(3) | -1.489904 | 0.080602 | -18.48474 | 0.0000 |
| MA(6) | 0.607217 | 0.083214 | 7.297067 | 0.0000 |
| R-squared | 0.229189 | Mean dependent var | 0.034478 | |
| Adjusted R-squared | 0.201159 | S.D. dependent var | 0.007878 | |
| S.E. of regression | 0.007041 | Akaike info criterion | -7.023711 | |
| Sum squared resid | 0.002727 | Schwarz criterion | -6.917137 | |
| Log likelihood | 206.6876 | Hannan-Quinn criter. | -6.982198 | |
| Durbin-Watson stat | 1.824823 | | | |
| Inverted AR Roots | 1.00 | -.50+.87i | -.50-.87i | |
| Inverted MA Roots | .92+.09i | .92-.09i | -38+.84i | -38-.84i |
| | -.54-.75i | -.54+.75i | | |

Gambar 4.16 Estimasi Parameter ARIMA ([3],0,[3,6])

Langkah akhir adalah melakukan peramalang untuk 7 bulan ke depan dengan *software Eviews*. Hasil prediksi ini nantinya akan diolah lebih lanjut dengan algoritma Filter Kalman untuk memperbaiki hasil estimasi prediksi ARIMA. Hasil estimasi dapat dilihat pada Tabel 4.8.

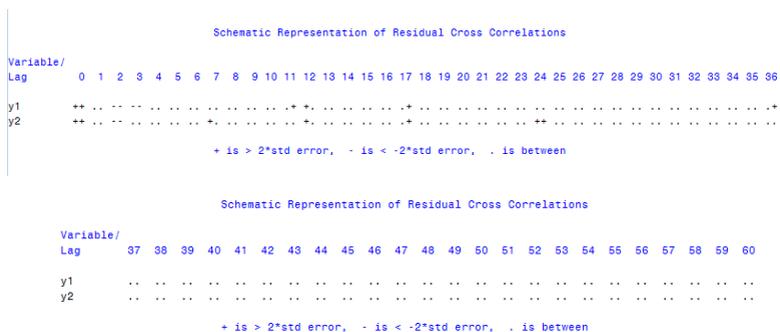
4.3 Pemodelan *Vector Autoregressive* (VAR)

Model terbaik pada *univariate time series* telah didapatkan, sehingga dapat dilakukan pemodelan *multivariate time series* menggunakan *Vector Autoregressive* (VAR). Pemodelan ini akan menjelaskan juga mengenai hubungan antar variabel satu dengan

variabel lainnya. Analisis pemodelan *vector autoregressive* (VAR) menggunakan skenario *in-sampel* dan *out-sampel*, yaitu membagi data menjadi data *in-sampel* sebagai data *training* dan data *out-sampel* sebagai data *testing*. Data *in-sampel* yang digunakan adalah data inflasi *month to month* Kota Malang dan Kota Probolinggo pada Januari 2011 hingga Desember 2014, dengan jumlah data sebanyak 60. Sedangkan data *out-sampel* menggunakan data inflasi *month to month* Kota Malang dan Kota Probolinggo Januari 2011 hingga Desember 2014, dengan jumlah data sebanyak 8 data.

4.3.1 Identifikasi Orde Model VAR

Langkah awal dalam pemodelan *time series* adalah melakukan identifikasi terhadap data inflasi *month to month* di kedua lokasi yang digunakan. Identifikasi data bertujuan untuk mengetahui kestasioneran data. Proses identifikasi stasioneritas terhadap data inflasi *month to month* di Kota Malang dan Probolinggo dilakukan secara visual dengan memperhatikan plot MACF yang terbentuk, seperti yang disajikan dalam Gambar 4.17.



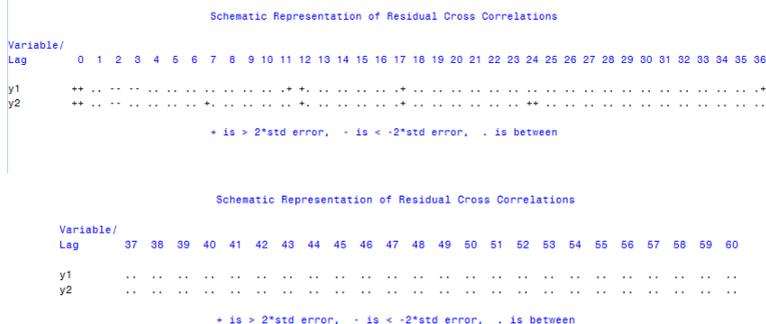
Gambar 4.17 MACF Plot Data Inflasi *month to month* Kota Malang dan Probolinggo

Banyaknya tanda titik yang muncul secara bersamaan dalam plot MACF pada Gambar 4.17 menunjukkan bahwa data stasioner. Karena data sudah stasioner, maka tidak perlu dilakukan

differencing. Menurut Gambar 4.17, data memiliki lag signifikan mulai lag awal hingga lag ketiga, sehingga dapat dikatakan bahwa model VMA dari data inflasi *month to month* adalah tiga.

Selanjutnya dilakukan identifikasi untuk menentukan orde dari model VAR yang akan dibentuk. Penentuan orde model ini dilakukan dengan melihat plot MPACF dari data yang sudah stasioner. Plot MPACF data curah hujan yang sudah stasioner ditampilkan dalam Gambar 4.18.

Model yang ingin dibentuk dalam analisis ini adalah model VAR, maka identifikasi orde model lebih ditekankan melalui plot MPACF-nya. Berdasarkan plot MPACF pada Gambar 4.18 terlihat bahwa nilai MPACF dari data inflasi *month to month* di kedua lokasi signifikan mulai dari lag pertama hingga lag ketiga. Ini mengindikasikan bahwa orde nonmusiman dari model VAR ini adalah tiga.



Gambar 4.18 MPACF Plot Data Inflasi *month to month* yang Sudah Stasioner

Keberadaan orde musiman dapat dilihat dari tanda yang muncul dari kedua data inflasi *month to month* pada lag ke-12 dan kelipatannya. Lag ke-12 pada Gambar 4.18 menunjukkan tanda positif yang artinya nilai MPACF pada lag tersebut berada diluar batas standar deviasi, atau dapat dikatakan signifikan. Sehingga dapat diambil kesimpulan bahwa data inflasi *month to month* tidak

mengandung unsur musiman. Sehingga diperoleh model dugaan, yaitu VAR (3).

Pemilihan lag juga dapat dilihat melalui VAR lag *selection* pada program *Eviews 6*. Pada Gambar 4.19, secara visual dapat dilihat bahwa lag terbaik menurut *Akaike Information Criterion* (AIC) dan *Final Prediction Error* (FPE) adalah lag ke-3. Sehingga model dugaan untuk VAR adalah VAR (3). Model dugaan VAR diasumsikan telah stasioner menurut MACF dan MPACF, kemudian perlu dilakukan uji normalitas, uji autokorelasi, uji multikolinieritas, dan uji heteroskedastisitas.

| VAR Lag Order Selection Criteria | | | | | | |
|--|----------|-----------|-----------|------------|------------|------------|
| Endogenous variables: TRANS_MLG TRANS_PROB | | | | | | |
| Exogenous variables: C | | | | | | |
| Date: 01/11/16 Time: 12:14 | | | | | | |
| Sample: 1 68 | | | | | | |
| Included observations: 56 | | | | | | |
| Lag | LogL | LR | FPE | AIC | SC | HQ |
| 0 | 486.8472 | NA | 1.03e-10 | -17.31597 | -17.24364* | -17.28793 |
| 1 | 489.0757 | 4.218075 | 1.10e-10 | -17.25270 | -17.03570 | -17.16857 |
| 2 | 500.5966 | 20.98459 | 8.43e-11 | -17.52131 | -17.15964 | -17.38109 |
| 3 | 507.5927 | 12.24310* | 7.59e-11* | -17.62831* | -17.12197 | -17.43200* |
| 4 | 510.2642 | 4.484274 | 7.98e-11 | -17.58086 | -16.92986 | -17.32847 |
| 5 | 514.1852 | 6.301648 | 8.04e-11 | -17.57804 | -16.78237 | -17.26956 |
| 6 | 515.8125 | 2.499107 | 8.82e-11 | -17.49330 | -16.55296 | -17.12874 |
| 7 | 517.3869 | 2.305365 | 9.71e-11 | -17.40668 | -16.32167 | -16.98602 |
| 8 | 522.3326 | 6.888647 | 9.50e-11 | -17.44045 | -16.21077 | -16.96371 |
| 9 | 523.0134 | 0.899663 | 1.09e-10 | -17.32191 | -15.94756 | -16.78908 |
| 10 | 527.3083 | 5.368613 | 1.10e-10 | -17.33244 | -15.81343 | -16.74352 |
| 11 | 529.5459 | 2.637135 | 1.20e-10 | -17.26950 | -15.60581 | -16.62449 |
| 12 | 537.7895 | 9.126884 | 1.07e-10 | -17.42105 | -15.61270 | -16.71996 |

* indicates lag order selected by the criterion
 LR: sequential modified LR test statistic (each test at 5% level)
 FPE: Final prediction error
 AIC: Akaike information criterion
 SC: Schwarz information criterion
 HQ: Hannan-Quinn information criterion

Gambar 4.19 Hasil *Lag Order Selection Criteria*

4.3.2 Uji Normalitas

Data yang digunakan diasumsikan normal, sehingga dalam proses pembentukan model VAR perlu dilakukan uji normalitas (*normality test*). Model dugaan yang didapatkan adalah VAR (3),

sehingga model yang akan diuji adalah model VAR (3) dengan 2 variabel data inflasi *month to month* (MTM).

Gambar 4.20 merupakan hasil uji normalitas dimana menunjukkan nilai *p-value* lebih dari nilai α (5% atau 0.05), sehingga dapat ditarik kesimpulan bahwa residual data berdistribusi normal. Jika uji stasioneritas dan uji normalitas sudah dipenuhi, maka data diasumsikan tidak memiliki data yang outliers atau yang memiliki penurunan dan kenaikan yang tajam.

| VAR Residual Normality Tests | | | | |
|--|-------------|----------|--------|--------|
| Orthogonalization: Cholesky (Lutkepohl) | | | | |
| Null Hypothesis: residuals are multivariate normal | | | | |
| Date: 01/11/16 Time: 12:14 | | | | |
| Sample: 1 68 | | | | |
| Included observations: 65 | | | | |
| Component | Skewness | Chi-sq | df | Prob. |
| 1 | -0.115400 | 0.144269 | 1 | 0.7041 |
| 2 | 0.282422 | 0.864091 | 1 | 0.3526 |
| Joint | | 1.008360 | 2 | 0.6040 |
| Component | Kurtosis | Chi-sq | df | Prob. |
| 1 | 2.837987 | 0.071089 | 1 | 0.7898 |
| 2 | 3.816992 | 1.807746 | 1 | 0.1788 |
| Joint | | 1.878835 | 2 | 0.3909 |
| Component | Jarque-Bera | df | Prob. | |
| 1 | 0.215357 | 2 | 0.8979 | |
| 2 | 2.671838 | 2 | 0.2629 | |
| Joint | 2.887195 | 4 | 0.5769 | |

Gambar 4.20 Hasil Uji Normalitas Jarque-Berra

4.3.3 Autocorrelation Test

Setelah didapatkan model VAR (3), maka akan dilakukan uji autokorelasi variabel. Tes autokorelasi menggunakan uji Durbin Watson untuk mendeteksi terjadinya autokorelasi pada nilai

residual dari sebuah analisis regresi. Tes autokorelasi terbagi menjadi dua, yaitu:

- Deteksi Autokorelasi Positif
 - Jika $d < dL$, maka terdapat autokorelasi positif
 - Jika $d > dU$, maka tidak terdapat autokorelasi positif
 - Jika $dL < d < dU$, maka pengujian tidak meyakinkan

- Deteksi autokorelasi Negatif
 - Jika $(4 - d) < dL$, maka terdapat autokorelasi negatif
 - Jika $(4 - d) > dL$, maka tidak terdapat autokorelasi negatif
 - Jika $dL < (4 - d) < dU$, maka pengujian tidak meyakinkan

Statistik uji :

$$d \text{ malang} = 1.892311$$

$$d \text{ probolinggo} = 2.137028$$

$$dL = 1.54853$$

$$dU = 1.61617$$

Deteksi autokorelasi positif di Malang :

$$d \text{ malang} > dU$$

$$1.892311 > 1.61617$$

Deteksi autokorelasi positif di Probolinggo :

$$d \text{ probolinggo} > dU$$

$$2.137028 > 1.61617$$

Deteksi autokorelasi negatif di Malang :

$$(4 - d \text{ malang}) > dL$$

$$(4 - 1.892311) > 1.54853$$

$$2.107689 > 1.54853$$

Deteksi autokorelasi negatif di Probolinggo :

$$(4 - d \text{ probolinggo}) > dL$$

$$(4 - 2.137028) > 1.54853$$

$$1.862972 > 1.54853$$

Berdasarkan hasil uji statistik menurut deteksi autokorelasi positif dan negatif, residual data tidak terdapat autokorelasi. Dimana pada Gambar 4.21, secara visual dapat dilihat bahwa nilai

Durbin Watson lebih dari nilai tabel Durbin Watson, maka residual data tidak terdapat autokorelasi.

| System: UNTITLED | | | | |
|---|-------------|--------------------|-------------|--------|
| Estimation Method: Least Squares | | | | |
| Date: 01/17/16 Time: 23:59 | | | | |
| Sample: 4 60 | | | | |
| Included observations: 57 | | | | |
| Total system (balanced) observations 114 | | | | |
| | Coefficient | Std. Error | t-Statistic | Prob. |
| C(1) | 0.330522 | 0.170226 | 1.941663 | 0.0550 |
| C(2) | 0.031547 | 0.034195 | 0.922571 | 0.3585 |
| C(3) | -0.227739 | 0.168931 | -1.348120 | 0.1807 |
| C(4) | -0.068542 | 0.034434 | -1.990560 | 0.0493 |
| C(5) | 0.121949 | 0.163410 | 0.746280 | 0.4572 |
| C(6) | -0.052948 | 0.036098 | -1.466795 | 0.1456 |
| C(7) | 0.007931 | 0.001667 | 4.757880 | 0.0000 |
| C(8) | 0.430522 | 0.766586 | 0.561610 | 0.5756 |
| C(9) | 0.137581 | 0.153990 | 0.893442 | 0.3738 |
| C(10) | -0.621497 | 0.760752 | -0.816951 | 0.4159 |
| C(11) | -0.176973 | 0.155066 | -1.141277 | 0.2565 |
| C(12) | 0.229997 | 0.735888 | 0.312544 | 0.7553 |
| C(13) | -0.451490 | 0.162560 | -2.777369 | 0.0065 |
| C(14) | 0.051255 | 0.007507 | 6.827679 | 0.0000 |
| Determinant residual covariance | | 5.07E-11 | | |
| Equation: TRANS_MLG = C(1)*TRANS_MLG(-1) + C(2)*TRANS_PROB(-1) + C(3)*TRANS_MLG(-2) + C(4)*TRANS_PROB(-2) + C(5)*TRANS_MLG(-3) + C(6)*TRANS_PROB(-3) + C(7) | | | | |
| Observations: 57 | | | | |
| R-squared | 0.383782 | Mean dependent var | 0.006197 | |
| Adjusted R-squared | 0.309835 | S.D. dependent var | 0.001757 | |
| S.E. of regression | 0.001459 | Sum squared resid | 0.000106 | |
| Durbin-Watson stat | 1.892311 | | | |
| Equation: TRANS_PROB = C(8)*TRANS_MLG(-1) + C(9)*TRANS_PROB(-1) + C(10)*TRANS_MLG(-2) + C(11)*TRANS_PROB(-2) + C(12)*TRANS_MLG(-3) + C(13)*TRANS_PROB(-3) + C(14) | | | | |
| Observations: 57 | | | | |
| R-squared | 0.375185 | Mean dependent var | 0.034321 | |
| Adjusted R-squared | 0.300207 | S.D. dependent var | 0.007857 | |
| S.E. of regression | 0.006572 | Sum squared resid | 0.002160 | |
| Durbin-Watson stat | 2.137028 | | | |

Gambar 4.21 Hasil Uji Autokorelasi Residual

4.3.4 Uji Heterokedastisitas

Heterokedastisitas terdapat didalam model yang menggunakan beberapa data dimana data tersebut menghimpun data yang mewakili berbagai ukuran. Jika suatu data memiliki heterokedastisitas, maka terdapat ketidaksamaan varians dari residual untuk semua variabel. Metode yang digunakan dalam

pengujian heterokedastisitas adalah *white heteroscedasticity test*. Uji hipotesis yang digunakan adalah:

Hipotesis :

H_0 : Tidak ada heteroskedastisitas

H_1 : Ada heteroskedastisitas

Statistik Uji :

1. Residual Z1(t)

$$nR^2 = (65)(0.234514) = 15.243$$

dengan nilai $\alpha = 0.05$, maka dapat diketahui berdasarkan tabel chi square $\chi_2^2 = 5.991$. Sehingga nilai nR^2 lebih besar dari nilai chi-square (χ_2^2), maka dapat disimpulkan bahwa H_0 diterima, sehingga Z1(t) memiliki varian yang konstan.

2. Residual Z2(t)

$$nR^2 = (65)(0.190867) = 12.40635$$

dengan nilai $\alpha = 0.05$, maka dapat diketahui berdasarkan tabel chi square $\chi_2^2 = 5.991$. Sehingga nilai nR^2 lebih besar dari nilai chi-square (χ_2^2), maka dapat disimpulkan bahwa H_0 diterima, sehingga Z2(t) memiliki varian yang konstan.

3. Residual Z1(t) dan Z2(t)

$$nR^2 = (65)(0.239483) = 15.56639$$

dengan nilai $\alpha = 0.05$, maka dapat diketahui berdasarkan tabel chi square $\chi_2^2 = 5.991$. Sehingga nilai nR^2 lebih besar dari nilai chi-square (χ_2^2), maka dapat disimpulkan bahwa H_0 diterima, sehingga Z1(t) dan Z2(t) memiliki varian yang konstan.

Uji heterokedastisitas dapat dilihat melalui nilai *p-value*. Jika nilai *p-value* lebih besar dari nilai alpha, maka H_0 diterima, sehingga dapat disimpulkan bahwa tidak ada heterokedastisitas. Gambar 4.22 secara visual dapat diketahui bahwa nilai *p-value* = 0.4878 lebih besar daripada nilai alpha = 0.05, sehingga dapat disimpulkan bahwa tidak terdapat heterokedastisitas di Z1(t) dan Z2(t).

| VAR Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares) | | | | | |
|---|-----------|----------|--------|------------|--------|
| Date: 01/11/16 Time: 12:18 | | | | | |
| Sample: 1 68 | | | | | |
| Included observations: 65 | | | | | |
| Joint test: | | | | | |
| Chi-sq | df | Prob. | | | |
| 35.59306 | 36 | 0.4878 | | | |
| Individual components: | | | | | |
| Dependent | R-squared | F(12,52) | Prob. | Chi-sq(12) | Prob. |
| res1*res1 | 0.234514 | 1.327555 | 0.2320 | 15.24338 | 0.2284 |
| res2*res2 | 0.190867 | 1.022191 | 0.4431 | 12.40634 | 0.4136 |
| res2*res1 | 0.239483 | 1.364544 | 0.2130 | 15.56639 | 0.2119 |

Gambar 4.22 Hasil *White Heteroscedasticity Test* Residual

4.3.5 Uji Parameter

Estimasi atau penaksiran parameter dilakukan terhadap model dugaan, yaitu VAR (3). Setelah parameter-parameter dari masing-masing model diestimasi, selanjutnya hasil estimasi parameter tersebut diuji signifikansinya. Pengujian signifikansi parameter ini menggunakan hipotesis uji dimana hipotesis awal menyatakan bahwa parameter tidak signifikan, dan hipotesis alternatifnya menyatakan bahwa parameter signifikan. Penarikan kesimpulan dapat dilakukan dengan membandingkan *p-value* dari hasil pengujian dengan nilai signifikansi (α) yang ditentukan peneliti sebesar 5% atau 0,05. Jika diperoleh *p-value* lebih kecil dari α maka hipotesis awal akan ditolak, sehingga kesimpulan yang diambil ialah parameter signifikan, dan begitu pula sebaliknya.

Hasil estimasi parameter dari model VAR (3) menunjukkan bahwa model tersebut memiliki 12 parameter. Akan tetapi, jika dilihat dari *p-value* masing-masing parameter ini dapat diketahui bahwa ternyata tidak semua parameter memiliki pengaruh yang

signifikan terhadap model. Hasil estimasi parameter dari model VAR (3) selengkapnya ditampilkan pada Lampiran 2.

Untuk mengatasi adanya variabel-variabel yang tidak signifikan pada model ini maka dilakukan *restrict* terhadap variabel-variabel tersebut. Perintah *restrict* dilakukan terhadap satu demi satu variabel yang tidak signifikan secara bertahap, dimulai dari variabel dengan *p-value* tertinggi, hingga semua variabel yang tidak di-*restrict* menunjukkan *p-value* yang lebih kecil dari nilai signifikansi ($\alpha=0,05$). Jika *p-value* dari masing-masing variabel sudah lebih besar dari nilai α maka dapat dikatakan bahwa variabel-variabel tersebut sudah signifikan terhadap model.

Tabel 4.9 Hasil Estimasi Parameter Model VAR (3) setelah restrict

| Lokasi | Parameter | Estimasi | Std Error | t-value | P-value | Variabel |
|------------------|--------------|----------|-----------|---------|---------|----------|
| Malang (y1) | ϕ_{111} | 0.34859 | 0.1507 | 2.31 | 0.0275 | y1(t-1) |
| | ϕ_{112} | 0.20902 | 0.0655 | 3.19 | 0.0032 | y2(t-1) |
| Probolinggo (y2) | ϕ_{122} | 0.55271 | 0.1526 | 3.62 | 0.0010 | y2(t-1) |
| | ϕ_{222} | 0.42133 | 0.1515 | 2.78 | 0.0091 | y2(t-2) |

Hasil estimasi parameter model VAR (3) setelah dilakukan *restrict* ditampilkan dalam Tabel 4.9, yang menunjukkan bahwa terdapat 4 parameter yang memiliki pengaruh signifikan terhadap model. Untuk keperluan penyusunan model, nilai-nilai koefisien parameter ini selanjutnya diubah ke dalam bentuk matriks. Matriks koefisien dari model VAR (3) adalah sebagai berikut:

$$\Phi_1 = \begin{bmatrix} 0.34859 & 0.20902 \\ 0 & 0.55271 \end{bmatrix}$$

$$\Phi_2 = \begin{bmatrix} 0 & 0 \\ 0 & 0.42133 \end{bmatrix}$$

Tabel 4.10 Hasil *Forecasting* Inflasi Menggunakan VAR di Malang dan Probolinggo

| T | Malang | Probolinggo |
|------|----------|-------------|
| 62 | 0.009511 | 0.045762 |
| 63 | 0.007404 | 0.040985 |
| 64 | 0.004143 | 0.026857 |
| 65 | 0.005706 | 0.02847 |
| 66 | 0.006075 | 0.03239 |
| 67 | 0.006573 | 0.0316 |
| 68 | 0.006172 | 0.037515 |
| MAPE | 13.6031 | 8.218826 |

4.3.6 Peramalan Model VAR

Setelah hasil estimasi dari parameter-parameter model diperoleh, tahap selanjutnya adalah melakukan peramalan dengan model VAR (3). Peramalan ini dilakukan pada data *in-sampel* pada *Eviews*. Nilai *p-value* dari parameter VAR (3) kurang dari 0.05. Oleh karena itu dapat ditarik kesimpulan bahwa parameter VAR (3) signifikan, sehingga dapat dilakukan *forecasting*. Hasil *forecasting* dapat dilihat pada Tabel 4.10.

4.4 Penerapan dan Simulasi ARIMA Filter Kalman Pada Data Inflasi *month to month*

MAPE ARIMA (1,0,[2]) pada inflasi di Kota Malang untuk 7 bulan kedepan sebesar 19,2787 dan ARIMA ([3],0,[3,6]) pada inflasi di Kota Probolinggo untuk 7 bulan berikutnya sebesar 10,09112. Nilai kedua MAPE tersebut sudah dapat diterima, namun masih kurang valid atau kurang kecil. Metode Filter Kalman merupakan metode estimasi dengan tahapan estimasi setiap satu langkah kedepan dilakukan koreksi dengan data actual, sehingga dapat diperkirakan bahwa nilai *error* dapat di minimalisir lagi. Penerapan Filter Kalman menggunakan besaran nilai kovarian *noise* sistem dan *noise* pengukuran. Pemilihan nilai kovarian

diasumsikan, sehingga untuk pemilihan beberapa nilai kovarian akan berpengaruh terhadap hasil estimasi.

Polinomial derajat *error* digunakan untuk memperbaiki nilai MAPE dari ARIMA dengan cara menggunakan nilai selisih (y_i) dari hasil *forecast* ARIMA dan data aktual. Nilai dari y_i diasumsikan dengan hasil kali dari data aktual (m_i) dan data keadaan awal ditambahkan dengan *noise* pengukuran (v_k). Persamaan polinomial derajat *error* dengan hasil selisih tersebut digunakan untuk estimasi Filter Kalman sebagai pengukuran. Hasil pengukuran diberikan *noise* pengukuran dengan kovarian diasumsikan. Hasil pengukuran tersebut merupakan hasil akhir atas Filter Kalman. Penerapan dan simulasi pada data inflasi *month to month* Kota Malang dan Kota Probolinggo dengan ARIMA Filter Kalman polinomial 1 ($n = 2$), ARIMA Filter Kalman polinomial 2 ($n = 3$), dan ARIMA Filter Kalman polinomial 3 ($n = 4$). Kovarian *noise* sistem diasumsikan sebesar 0.1 dan kovarian *noise* pengukuran diasumsikan sebesar 0.1 dan 0.01.

4.4.1 Penerapan dan Simulasi ARIMA Filter Kalman $n = 2$ Pada Data Inflasi *month to month* di Kota Malang

Penerapan ARIMA Filter Kalman dengan menggunakan polinomial derajat 1 atau untuk $n= 2$ persamaan (2.5) menjadi:

$$y_i^0 = a_{0,i} + a_{1,i}m_i \text{ dengan } x(t_i) = \begin{bmatrix} a_{0,i} \\ a_{1,i} \end{bmatrix}, H_i = [1 \quad m_i]$$

Algoritma ARIMA Filter Kalman untuk $n = 2$ adalah sebagai berikut:

Model sistem[10]:

$$x_{k+1} = Ax_k + w_k$$

atau dapat ditulis

$$\begin{bmatrix} a_{0,i} \\ a_{0,i} \end{bmatrix}_{k+1} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} a_{0,i} \\ a_{1,i} \end{bmatrix}_k + w_k$$

Model umum pengukuran[10]:

$$z_k = Hx_k + v_k$$

atau dapat ditulis

$$y_i^0 = [1 \quad m_i] \begin{bmatrix} a_{0,i} \\ a_{1,i} \end{bmatrix}_k$$

diasumsikan nilai awal $Q = 0.1$

$$P_0 = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}, Q_k = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \cdot Q$$

Nilai awal $a_{0,i}$ dan $a_{1,i}$ di Malang $\hat{x}_0 = \begin{bmatrix} 0.6 \\ 0.2075 \end{bmatrix}$. Kemudian setelah itu masuk ke dalam Tahap prediksi[10]:

$$\hat{x}_{k+1}^- = A\hat{x}_k$$

$$P_{k+1}^- = AP_k A^T + GQ_k G^T$$

Tahap koreksi[10]:

Pada tahap koreksi melibatkan Kalman gain:

$$K_{k+1} = P_{k+1}^- H_{k+1}^T (H_{k+1} P_{k+1}^- H_{k+1}^T + R_k^{-1})^{-1}$$

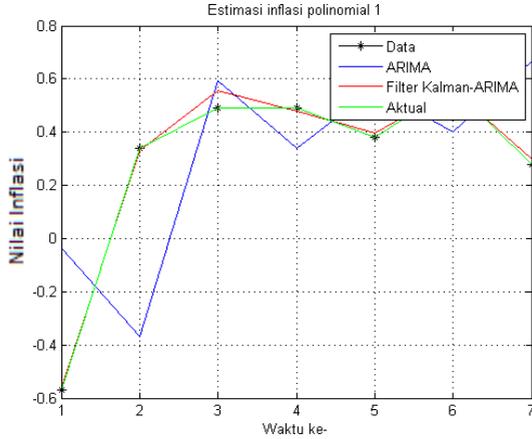
dengan $R = 0.1$ dan $R = 0.01$. Lalu \hat{x}_{k+1} diestimasi menggunakan nilai \hat{x}_{k+1}^- yang diperoleh dari tahap prediksi. z_{k+1} diasumsikan sama dengan y_i^0 yang diperoleh dari bias atau selisih antara data aktual dengan data prediksi ARIMA.

$$\hat{x}_{k+1} = \hat{x}_{k+1}^- + P_{k+1} H_{k+1}^T R_{k+1}^{-1} (z_{k+1} - H_{k+1} \hat{x}_{k+1}^-)$$

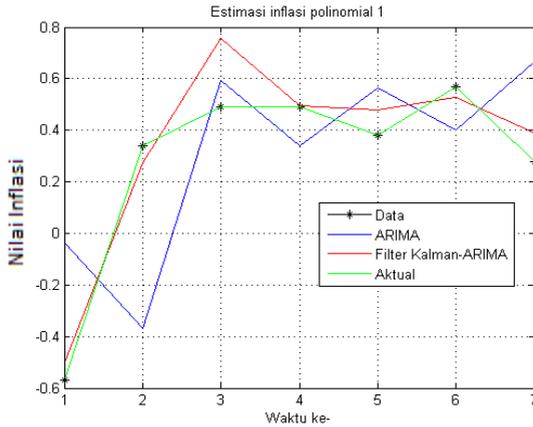
Kemudian, nilai P_{k+1} juga dicari dengan menggunakan nilai P_{k+1}^- yang telah dicari pada tahap prediksi.

$$P_{k+1} = [(P_{k+1}^-)^{-1} + H_{k+1}^T R_{k+1}^{-1} H_{k+1}]^{-1}$$

Hasil simulasi penerapan ARIMA Filter Kalman $n = 2$ pada inflasi *month to month* Kota Malang dengan menggunakan listing program pada Lampiran 6 dapat dilihat pada Gambar 4.23. Gambar 4.23(a) menunjukkan hasil simulasi ketika $Q = 0.1$ dan $R = 0.01$. Pada gambar terlihat bahwa grafik hasil peramalan ARIMA-Filter Kalman mendekati data aktual.



(a)



(b)

Gambar 4.23 Hasil Simulasi Inflasi *month to month* Kota Malang pada ARIMA Filter Kalman $n = 2$ dengan $\hat{x}_0 = [0.6 \quad 0.2075]^T$ dan (a) $Q = 0.1, R = 0.01$, (b) $Q = R = 0.1$

Ketika diberikan $Q = R = 0.1$, terlihat pada Gambar 4.23(b) bahwa dengan menggunakan algoritma ARIMA Filter Kalman hasil prediksi mendekati grafik data aktual namun jaraknya lebih

jauh dibandingkan saat $R = 0.01$. Tingkat akurasi dikatakan baik apabila nilai mutlak kesalahan mendekati nilai nol. Hasil MAPE dan CPU time dapat dilihat pada Tabel 4.11.

4.4.2 Penerapan dan Simulasi ARIMA Filter Kalman $n = 3$ Pada Data Inflasi month to month Kota Malang

Penerapan ARIMA Filter Kalman dengan menggunakan polinomial derajat 2 atau untuk $n = 3$ persamaan (2.5) menjadi:

$$y_i^0 = a_{0,i} + a_{1,i}m_i + a_{2,i}m_i^2 \text{ dengan } x(t_i) = \begin{bmatrix} a_{0,i} \\ a_{1,i} \\ a_{2,i} \end{bmatrix} \text{ dan}$$

$$H_i = [1 \quad m_i \quad m_i^2]$$

Algoritma ARIMA Filter Kalman untuk $n = 3$ adalah sebagai berikut:

Model sistem[10]:

$$x_{k+1} = Ax_k + w_k$$

atau dapat ditulis

$$\begin{bmatrix} a_{0,i} \\ a_{1,i} \\ a_{2,i} \end{bmatrix}_{k+1} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} a_{0,i} \\ a_{1,i} \\ a_{2,i} \end{bmatrix}_k + w_k$$

Model umum pengukuran[10]:

$$z_k = Hx_k + v_k$$

atau dapat ditulis

$$y_i^0 = [1 \quad m_i \quad m_i^2] \begin{bmatrix} a_{0,i} \\ a_{1,i} \\ a_{2,i} \end{bmatrix}_k$$

diasumsikan nilai awal $Q = 0.1$

$$P_0 = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, Q_k = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \cdot Q$$

Nilai awal $a_{0,i}$, $a_{0,i}$ dan $a_{2,i}$ di Malang $\hat{x}_0 = \begin{bmatrix} 0.6 \\ 0.2075 \\ 0.11 \end{bmatrix}$

Kemudian setelah itu masuk ke dalam Tahap prediksi[10]:

$$\hat{x}_{k+1}^- = A\hat{x}_k$$

$$P_{k+1}^- = AP_k A^T + GQ_k G^T$$

Tahap koreksi[10]:

Pada tahap koreksi melibatkan Kalman gain:

$$K_{k+1} = P_{k+1}^- H_k^T (H_{k+1} P_{k+1}^- H_k^T + R_k^{-1})^{-1}$$

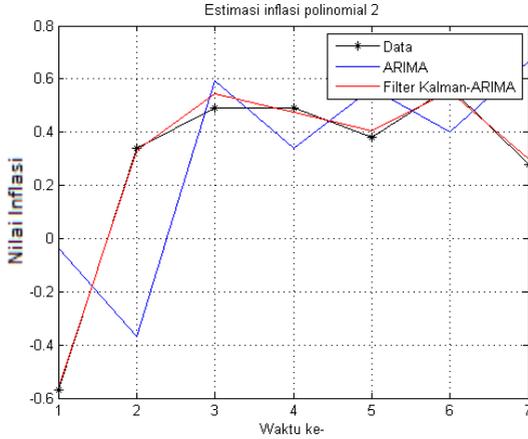
dengan $R = 0.01$ dan $R = 0.1$. Lalu \hat{x}_{k+1} diestimasi menggunakan nilai \hat{x}_{k+1}^- yang diperoleh dari tahap prediksi. z_{k+1} diasumsikan sama dengan y_i^0 yang diperoleh dari bias atau selisih antara data aktual dengan data prediksi ARIMA.

$$\hat{x}_{k+1} = \hat{x}_{k+1}^- + P_{k+1} H_{k+1}^T R_{k+1}^{-1} (z_{k+1} - H_{k+1} \hat{x}_{k+1}^-)$$

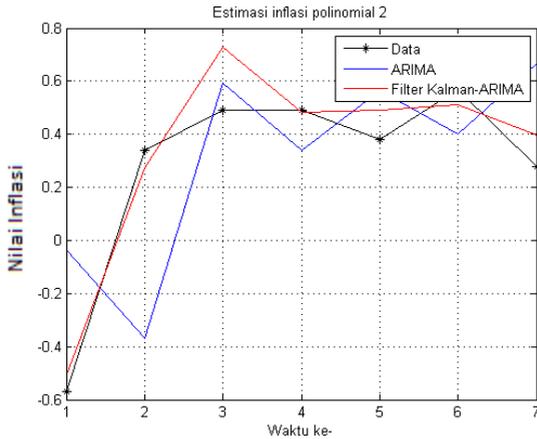
Kemudian, nilai P_{k+1} juga dicari dengan menggunakan nilai P_{k+1}^- yang telah dicari pada tahap prediksi.

$$P_{k+1} = [(P_{k+1}^-)^{-1} + H_{k+1}^T R_{k+1}^{-1} H_{k+1}]^{-1}$$

Hasil simulasi penerapan ARIMA Filter Kalman $n = 3$ pada inflasi *month to month* Kota Malang dengan menggunakan listing program pada Lampiran 7 dapat dilihat pada Gambar 4.24. Gambar 4.24(a) menunjukkan hasil simulasi ketika $Q = 0.1$ dan $R = 0.01$. Pada Gambar 4.24 terlihat bahwa grafik hasil peramalan ARIMA-Filter Kalman mendekati data aktual. Sedangkan ketika diberikan $Q = R = 0.1$, terlihat pada Gambar 4.24(b) bahwa dengan menggunakan algoritma ARIMA Filter Kalman hasil prediksi mendekati grafik data aktual namun jaraknya lebih jauh dibandingkan saat $R = 0.01$. Tingkat akurasi dikatakan baik apabila nilai mutlak kesalahan mendekati nilai nol. Hasil MAPE dan CPU time dapat dilihat pada Tabel 4.11.



(a)



(b)

Gambar 4.24 Hasil Simulasi Inflasi *month to month* Kota Malang pada ARIMA Filter Kalman $n = 3$ dengan $\hat{x}_0 = [0.6 \ 0.2075 \ 0.11]^T$ dan (a) $Q = 0.1, R = 0.01$ (b) $Q = R = 0.1$

4.4.3 Penerapan dan Simulasi ARIMA Filter Kalman n = 4 Pada Data Inflasi *month to month* Kota Malang

Penerapan ARIMA Filter Kalman dengan menggunakan polinomial derajat 3 atau untuk n= 4 persamaan (2.5) menjadi:

$$y_i^0 = a_{0,i} + a_{1,i}m_i + a_{2,i}m_i^2 + a_{3,i}m_i^3 \quad \text{dengan} \quad x(t_i) = \begin{bmatrix} a_{0,i} \\ a_{1,i} \\ a_{2,i} \\ a_{3,i} \end{bmatrix}$$

dan $H_i = [1 \quad m_i \quad m_i^2 \quad m_i^3]$

Algoritma ARIMA Filter Kalman untuk n = 4 adalah sebagai berikut:

Model sistem[10]:

$$x_{k+1} = Ax_k + w_k$$

atau dapat ditulis

$$\begin{bmatrix} a_{0,i} \\ a_{1,i} \\ a_{2,i} \\ a_{3,i} \end{bmatrix}_{k+1} = \begin{bmatrix} 1000 \\ 0100 \\ 0010 \\ 0001 \end{bmatrix} \begin{bmatrix} a_{0,i} \\ a_{1,i} \\ a_{2,i} \\ a_{3,i} \end{bmatrix}_k + w_k$$

Model umum pengukuran[10]:

$$z_k = Hx_k + v_k$$

atau dapat ditulis

$$y_i^0 = [1 \quad m_i \quad m_i^2 \quad m_i^3] \begin{bmatrix} a_{0,i} \\ a_{1,i} \\ a_{2,i} \\ a_{3,i} \end{bmatrix}_k$$

Diasumsikan nilai awal $Q = 0.1$

$$\text{Untuk } n = 4: P_0 = \begin{bmatrix} 1000 \\ 0100 \\ 0010 \\ 0001 \end{bmatrix}, Qk = \begin{bmatrix} 1000 \\ 0100 \\ 0010 \\ 0001 \end{bmatrix} \cdot Q$$

Nilai awal $a_{0,i}$, $a_{0,i}$, $a_{2,i}$, dan $a_{3,i}$ di Malang $\hat{x}_0 = \begin{bmatrix} 0.6 \\ 0.2075 \\ 0.11 \\ 0.12 \end{bmatrix}$

Kemudian setelah itu masuk ke dalam Tahap prediksi[10]:

$$\hat{x}_{k+1}^- = A\hat{x}_k$$

$$P_{k+1}^- = AP_k A^T + GQ_k G^T$$

Tahap koreksi[10]:

Pada tahap koreksi melibatkan Kalman gain:

$$K_{k+1} = P_{k+1}^- H_k^T (H_{k+1} P_{k+1}^- H_k^T + R_k^{-1})^{-1}$$

dengan $R = 0.01$ dan $R = 0.1$. Lalu \hat{x}_{k+1} diestimasi menggunakan nilai \hat{x}_{k+1}^- yang diperoleh dari tahap prediksi. z_{k+1} diasumsikan sama dengan y_i^0 yang diperoleh dari bias atau selisih antara data aktual dengan data prediksi ARIMA.

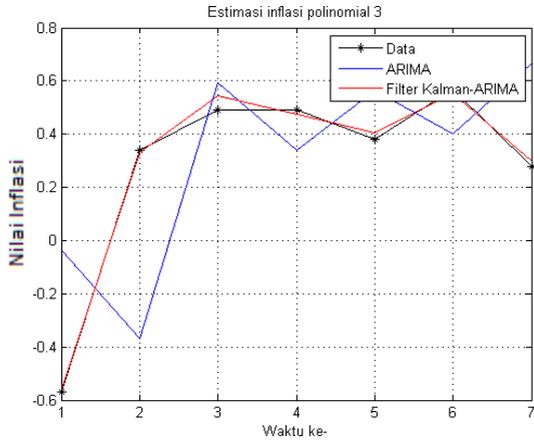
$$\hat{x}_{k+1} = \hat{x}_{k+1}^- + P_{k+1} H_{k+1}^T R_{k+1}^{-1} (z_{k+1} - H_{k+1} \hat{x}_{k+1}^-)$$

Kemudian, nilai P_{k+1} juga dicari dengan menggunakan nilai P_{k+1}^- yang telah dicari pada tahap prediksi.

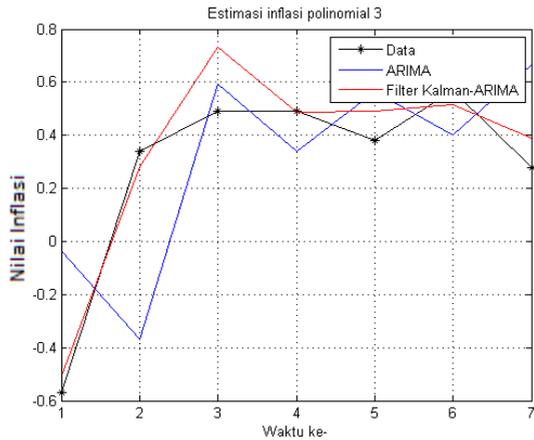
$$P_{k+1} = [(P_{k+1}^-)^{-1} + H_{k+1}^T R_{k+1}^{-1} H_{k+1}]^{-1}$$

Hasil simulasi penerapan ARIMA Filter Kalman $n = 4$ pada inflasi *month to month* Kota Malang dengan menggunakan listing program pada Lampiran 8 dapat dilihat pada Gambar 4.25.

Gambar 4.25(a) menunjukkan hasil simulasi ketika $Q = 0.1$ dan $R = 0.01$. Pada gambar terlihat bahwa grafik hasil peramalan ARIMA-Filter Kalman mendekati data aktual. Sedangkan ketika diberikan $Q = R = 0.1$, terlihat pada Gambar 4.25(b) bahwa dengan menggunakan algoritma ARIMA Filter Kalman hasil prediksi mendekati grafik data aktual namun jaraknya lebih jauh dibandingkan saat $R = 0.01$. Tingkat akurasi dikatakan baik apabila nilai mutlak kesalahan mendekati nilai nol. Hasil MAPE dan CPU time dapat dilihat pada Tabel 4.11.



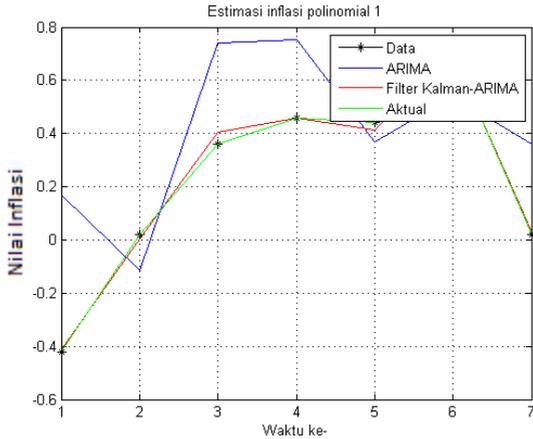
(a)



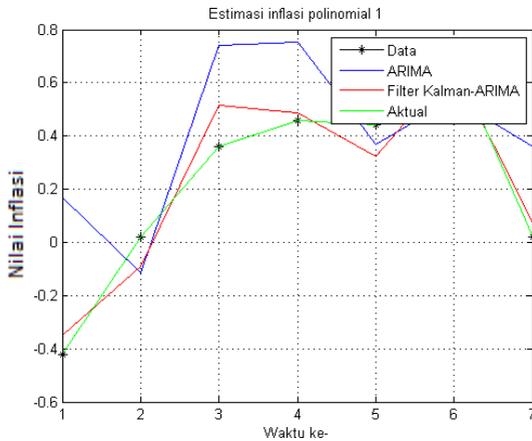
(b)

Gambar 4.25 Hasil Simulasi Inflasi *month to month* Kota Malang pada ARIMA Filter Kalman $n = 4$ dengan $\hat{x}_0 = [0.60 \ 0.2075 \ 0.11 \ 0.12]^T$ dan (a) $Q = 0.1, R = 0.01$ (b) $Q = R = 0.1$

4.4.4 Penerapan dan Simulasi ARIMA Filter Kalman $n = 2$ Pada Data Inflasi *month to month* di Kota Probolinggo



(a)



Gambar 4.26 Hasil Simulasi Inflasi *month to month* Kota Probolinggo pada ARIMA Filter Kalman $n = 2$ dengan $\hat{x}_0 = [0.424 \quad 0.042]^T$ dan (a) $Q = 0.1, R = 0.01$ (b) $Q = R = 0.1$

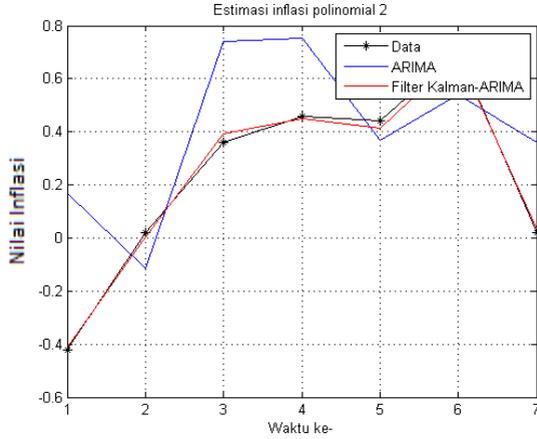
Penerapan Filter Kalman dalam perbaikan error ARIMA inflasi di Kota Probolinggo menggunakan penyelesaian dan langkah yang sama seperti subbab 4.4.1. Keadaan awal yang digunakan adalah hasil rata-rata dari data aktual, dimana $\hat{x}_0 = \begin{bmatrix} 0.424 \\ 0.042 \end{bmatrix}$.

Gambar 4.26(a) menunjukkan hasil simulasi ketika $Q = 0.1$ dan $R = 0.01$. Pada gambar terlihat bahwa grafik hasil peramalan ARIMA-Filter Kalman mendekati data aktual. Sedangkan ketika diberikan $Q = R = 0.1$, terlihat pada Gambar 4.26(b) bahwa dengan menggunakan algoritma ARIMA Filter Kalman hasil prediksi mendekati grafik data aktual namun jaraknya lebih jauh dibandingkan saat $R = 0.01$. Tingkat akurasi dikatakan baik apabila nilai mutlak kesalahan mendekati nilai nol. Hasil MAPE dan CPU time dapat dilihat pada Tabel 4.11.

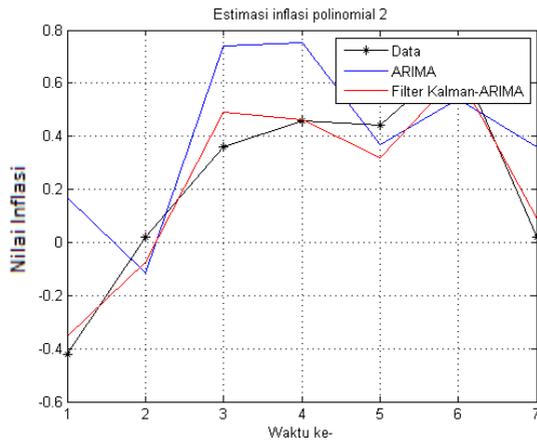
4.4.5 Penerapan dan Simulasi ARIMA Filter Kalman $n = 3$ Pada Data Inflasi month to month Kota Probolinggo

Penerapan Filter Kalman dalam perbaikan error ARIMA inflasi di Kota Probolinggo menggunakan penyelesaian dan langkah yang sama seperti subbab 4.4.2. Keadaan awal yang digunakan adalah hasil rata-rata dari data aktual, dimana $\hat{x}_0 = \begin{bmatrix} 0.424 \\ 0.042 \\ -0.194 \end{bmatrix}$.

Gambar 4.27(a) menunjukkan hasil simulasi ketika $Q = 0.1$ dan $R = 0.01$. Pada gambar terlihat bahwa grafik hasil peramalan ARIMA-Filter Kalman mendekati data aktual. Sedangkan ketika diberikan $Q = R = 0.1$, terlihat pada Gambar 4.27(b) bahwa dengan menggunakan algoritma ARIMA Filter Kalman hasil prediksi mendekati grafik data aktual namun jaraknya lebih jauh dibandingkan saat $R = 0.01$. Tingkat akurasi dikatakan baik apabila nilai mutlak kesalahan mendekati nilai nol. Hasil MAPE dan CPU time dapat dilihat pada Tabel 4.11.



(a)



(b)

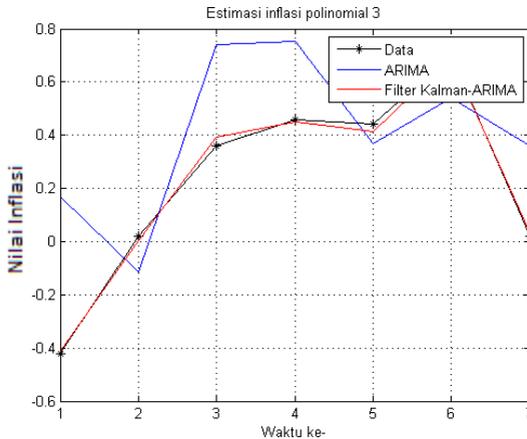
Gambar 4.27 Hasil Simulasi Inflasi *month to month* Kota Probolinggo pada ARIMA Filter Kalman $n = 3$ dengan $\hat{x}_0 = [0.424 \ 0.042 \ -0.194]^T$ dan (a) $Q = 0.1, R = 0.01$ (b) $Q = R = 0.1$

4.4.6 Penerapan dan Simulasi ARIMA Filter Kalman $n = 4$ Pada Data Inflasi *month to month* Kota Probolinggo

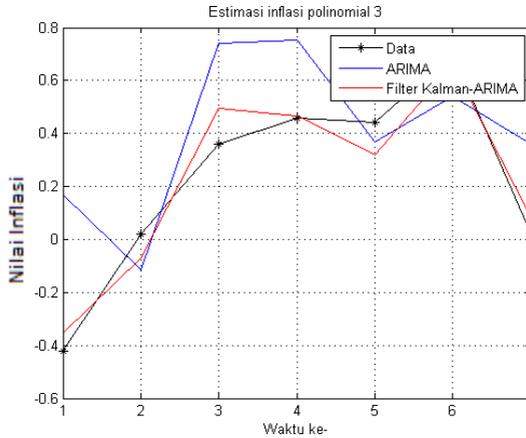
Penerapan Filter Kalman dalam perbaikan error ARIMA inflasi di Kota Probolinggo menggunakan penyelesaian dan langkah yang sama seperti subbab 4.4.3. Keadaan awal yang digunakan adalah

$$\hat{x}_0 = \begin{bmatrix} 0.424 \\ 0.042 \\ -0.194 \\ 0.338 \end{bmatrix}$$

Gambar 4.28(a) menunjukkan hasil simulasi ketika $Q = 0.1$ dan $R = 0.01$. Pada gambar terlihat bahwa grafik hasil peramalan ARIMA-Filter Kalman mendekati data aktual. Sedangkan ketika diberikan $Q = R = 0.1$, terlihat pada Gambar 4.28(b) bahwa dengan menggunakan algoritma ARIMA Filter Kalman hasil prediksi mendekati grafik data aktual namun jaraknya lebih jauh dibandingkan saat $R = 0.01$. Tingkat akurasi dikatakan baik apabila nilai mutlak kesalahan mendekati nilai nol. Hasil MAPE dan CPU time dapat dilihat pada Tabel 4.11.



(a)



(b)

Gambar 4.28 Hasil Simulasi Inflasi *month to month* Kota Probolinggo pada ARIMA Filter Kalman $n = 4$ dengan $\hat{x}_0 = [0.424 \ 0.042 \ -0.194 \ 0.338]^T$ dan (a) $Q = 0.1, R = 0.001$ (b) $Q = 0.1, R = 0.1$

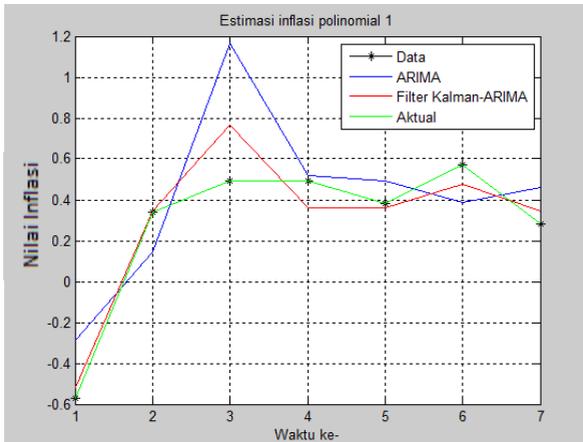
4.5 Penerapan dan Simulasi VAR Filter Kalman Pada Data Inflasi *month to month*

MAPE VAR(3) untuk inflasi di Malang sebesar 13.6031 dan di Probolinggo sebesar 8.218826. Nilai MAPE VAR(3) sudah rendah dan lebih baik jika dibandingkan dengan nilai MAPE dari ARIMA. Metode ARIMA dan VAR merupakan dua metode yang berbeda dan dianggap kurang tepat untuk dibandingkan sebab metode ARIMA merupakan univariat *time series* dengan pengolahan data 1 variabel sedangkan VAR merupakan multivariate *time series* dengan pengolahan data lebih dari 1 variabel. Perbandingan MAPE akan dilakukan dengan hasil VAR(3) yang diterapkan Filter Kalman menggunakan polinomial derajat *error* dengan kovarian yang diasumsikan. Tahap ini akan dilakukan penerapan dan simulasi pada data inflasi *month to month* Kota Malang dan Kota Probolinggo dengan VAR Filter Kalman

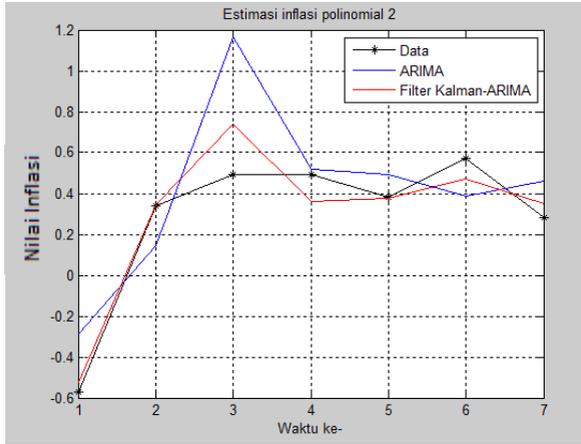
polinomial 1 ($n = 2$), VAR Filter Kalman polinomial 2 ($n = 3$), dan VAR Filter Kalman polinomial 3 ($n = 4$). Dimana langkah-langkah penerapan untuk polinomial 1 ($n = 2$) telah dibahas pada Subbab 4.4.1, untuk polinomial 2 ($n = 3$) telah dibahas pada Subbab 4.4.2 dan untuk polinomial 3 ($n = 4$) telah dibahas pada Subbab 4.4.3.

4.5.1 Penerapan dan Simulasi VAR Filter Kalman Pada Data Inflasi *month to month* di Kota Malang

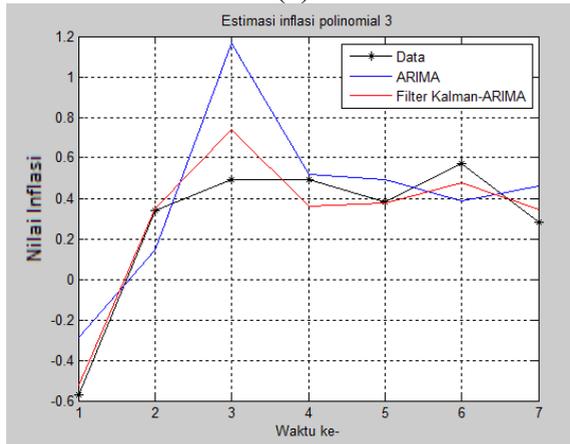
Penerapan Filter Kalman dalam estimasi VAR dengan keadaan awal $\hat{x}_0 = \begin{bmatrix} 0.6 \\ 0.2075 \\ 0.11 \\ 0.12 \end{bmatrix}$, dimana \hat{x}_0 diambil berdasarkan rata-rata data aktual dengan $Q = 0.1$, $R = 0.01$. Pada Gambar 4.29 diketahui bahwa pengambilan derajat polinomial berpengaruh pada ketepatan hasil estimasi.



(a)



(b)



(c)

Gambar 4.29 Hasil Simulasi Inflasi *month to month* Kota Malang pada VAR Filter Kalman dengan $Q = 0.1$, $R = 0.01$ dan (a) polinomial 1 ($n = 2$), (b) polinomial 2 ($n = 3$), (c) polinomial 3 ($n = 4$)

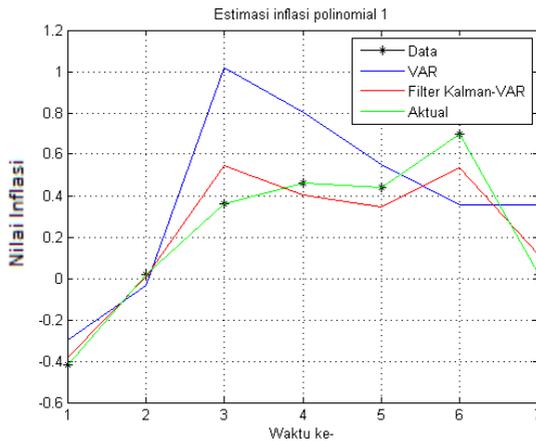
Tingkat akurasi dikatakan baik apabila nilai mutlak kesalahan mendekati nilai nol. Hasil MAPE dan CPU time dapat dilihat pada Tabel 4.11.

4.5.2 Penerapan dan Simulasi VAR Filter Kalman $n = 2$ Pada Data Inflasi *month to month* di Kota Probolinggo

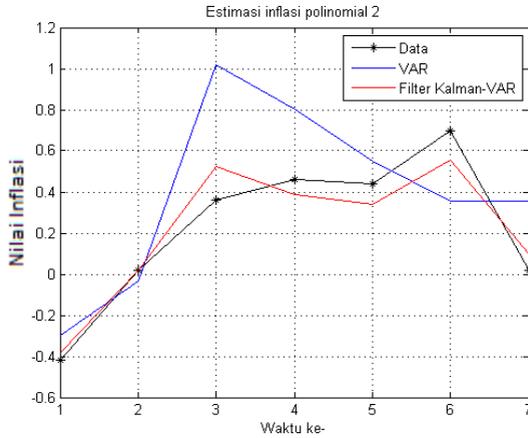
Penerapan Filter Kalman dalam estimasi VAR dengan

keadaan awal $\hat{x}_0 = \begin{bmatrix} 0.424 \\ 0.042 \\ -0.194 \\ 0.338 \end{bmatrix}$, dimana \hat{x}_0 diambil berdasarkan

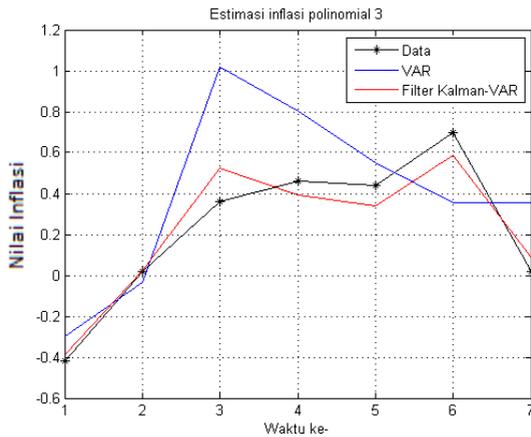
rata-rata data aktual dengan $Q = 0.1$, $R = 0.01$. Pada Gambar 4.29 diketahui bahwa pengambilan derajat polinomial berpengaruh pada ketepatan hasil estimasi.



(a)



(b)



(c)

Gambar 4.30 Hasil Simulasi Inflasi *month to month* Kota Probolinggo pada VAR Filter Kalman dengan $Q = 0.1$, $R = 0.01$ dan (a) polinomial 1 ($n = 2$), (b) polinomial 2 ($n = 3$), (c) polinomial 3 ($n = 4$)

Tingkat akurasi dikatakan baik apabila nilai mutlak kesalahan mendekati nilai nol. Hasil MAPE dan CPU time dapat dilihat pada Tabel 4.11.

4.6 Perbandingan Model ARIMA, VAR, ARIMA-Filter Kalman dan VAR-Filter Kalman

Forecasting merupakan suatu metode untuk memprediksi nilai pada waktu selanjutnya. Dimana dalam melakukan prediksi atau estimasi tentu akan terjadi kesalahan prediksi atau *error* estimasi. Berdasarkan simulasi ARIMA, VAR, ARIMA-Filter Kalman dan VAR-Filter Kalman memiliki nilai *error* estimasi masing-masing. Oleh karena itu, setelah dilakukan simulasi dengan berbagai macam model estimasi, akan dilakukan tahap evaluasi.

Tahap evaluasi dilakukan dengan cara membandingkan perhitungan akurasi hasil prediksi menggunakan MAPE, yaitu ukuran kesalahan yang dihitung dengan mencari nilai tengah presentasi absolut perbandingan kesalahan dengan data aktual, rumus perhitungan dapat dilihat pada persamaan 2.16. Hasil perhitungan MAPE untuk prediksi model ARIMA dan VAR disetiap lokasi dapat dilihat pada Tabel 4.8 dan Tabel 4.10, sedangkan untuk ARIMA Filter Kalman dan VAR-Filter Kalman dilihat pada Tabel 4.11.

Tabel 4.8, 4.10, dan 4.11 menunjukkan bahwa hasil MAPE lebih baik dengan jika dilakukan penerapan Filter Kalman. Hal ini dibuktikan dengan nilai MAPE yang bernilai kecil dan mendekati nilai dari data aktual. Selain itu juga dapat diamati, untuk setiap Q dan R yang diambil, nilai MAPEnya akan semakin menurun apabila derajat polinomialnya semakin tinggi. Jika semakin kecil nilai R dan semakin besar nilai Q , maka *error* estimasi akan semakin kecil atau MAPE semakin rendah.

Tabel 4.11 Hasil MAPE ARIMA, VAR, ARIMA-Filter Kalman, dan VAR-Filter Kalman

| MALANG | | | | |
|-----------------|----------|----------|-----------|-----------|
| ARIMA | | pol 1 | pol 2 | pol 3 |
| q=0.1 r=0.1 | MAPE | 9.892638 | 9.8923303 | 9.8923002 |
| | CPU time | 2,210401 | 2,6258 | 3,214133 |
| q=0.1 r=0.01 | MAPE | 2.7675 | 2.76745 | 2.7674 |
| | CPU time | 2,265131 | 2,768148 | 3,285697 |
| VAR | | pol 1 | pol 2 | pol 3 |
| q=0.1 r=0.1 | MAPE | 7.2644 | 7.2641 | 7.2641 |
| | CPU time | 2,282953 | 2,588835 | 3,348403 |
| q=0.1 r=0.01 | MAPE | 1.80645 | 1.8064 | 1.8063 |
| | CPU time | 2,253124 | 2,783111 | 3,2908 |
| PROBOLINGGO | | | | |
| ARIMA | | pol 1 | pol 2 | pol 3 |
| q=0.1 r=0.1 | MAPE | 4.6480 | 4.6436 | 4.6434 |
| | CPU time | 2,265829 | 2,887921 | 3,250456 |
| q=0.1 r=0.01 | MAPE | 1.0477 | 1.0464 | 1.0463 |
| | CPU time | 2,223796 | 2,77139 | 3,31175 |
| VAR | | pol 1 | pol 2 | pol 3 |
| q=0.1 r=0.1 | MAPE | 4.1081 | 4.1038 | 4.1036 |
| | CPU time | 2,24095 | 2,748382 | 3,29128 |
| q=0.1 r=0.01 | MAPE | 0.8820 | 0.8807 | 0.88061 |
| | CPU time | 2,270752 | 2,855789 | 3,37866 |

BAB V

KESIMPULAN DAN SARAN

Bab ini membahas mengenai kesimpulan dari penulisan Tugas Akhir dan saran yang bisa digunakan untuk pengembangan penelitian selanjutnya.

5.1 Kesimpulan

Berdasarkan dari seluruh proses pada bab 4, dapat diambil kesimpulan sebagai berikut:

1. Model ARIMA terbaik untuk data inflasi *month to month* di Malang adalah ARIMA([1],0,[2]), inflasi *month to month* di Probolinggo adalah ARIMA([3],0,[3,6]).
2. Model VAR terbaik untuk kedua data adalah VAR (3), dengan:
 - a. Inflasi *month to month* di Kota Malang
$$y_1(t) = 0.34859y_1(t - 1) + 0.20902y_2(t - 1)$$
 - b. Inflasi *month to month* di Kota Probolinggo
$$y_2(t) = 0.55271y_2(t - 1) + 0.42133y_2(t - 2)$$
3. Pada simulasi Filter Kalman derajat polinomial pertama, kedua, dan ketiga, dengan nilai awal yang sama untuk setiap Q dan R yang diambil, nilai MAPE akan semakin menurun apabila derajat polinomialnya semakin tinggi. Hasil prediksi terbaik apabila diambil $Q = 0.1$, $R = 0.0001$, dan derajat polinomial yang tinggi.

5.2 Saran

Untuk pengembangan penelitian selanjutnya, Filter Kalman dapat diterapkan untuk percabangan model ARIMA lain, seperti model SARIMA. Sedangkan untuk model VAR dapat digunakan metode VARIMA atau ARCH-GARCH.

LAMPIRAN 1

Tabel Data Aktual Inflasi *Month to Month*

| Periode | Malang | Probol inggo | Periode | Malang | Probol inggo |
|---------|--------|-----------------|---------|--------|-----------------|
| 10-Jan | 0.79 | 0.71 | 11-Nov | 0.34 | 0.43 |
| 10-Feb | 0.37 | 0.46 | 11-Dec | 0.67 | 0.4 |
| 10-Mar | -0.17 | -0.45 | 12-Jan | 0.76 | 0.52 |
| 10-Apr | 0.14 | 0.02 | 12-Feb | 0.31 | 0.46 |
| 10-May | 0.35 | 0.81 | 12-Mar | 0.43 | -0.35 |
| 10-Jun | 0.74 | 0.98 | 12-Apr | -0.13 | 0.3 |
| 10-Jul | 1.71 | 2.94 | 12-May | 0.37 | 0.54 |
| 10-Aug | 0.79 | 0.43 | 12-Jun | 0.31 | 0.88 |
| 10-Sep | 0.05 | 0.08 | 12-Jul | 0.49 | 0.82 |
| 10-Oct | 0.19 | 0.02 | 12-Aug | 0.47 | 2.01 |
| 10-Nov | 0.68 | 0.06 | 12-Sep | 0.26 | -0.35 |
| 10-Dec | 0.88 | 0.05 | 12-Oct | 0.4 | 0.19 |
| 11-Jan | 0.67 | 0.93 | 12-Nov | 1.51 | 0.24 |
| 11-Feb | 0.14 | 0.32 | 12-Dec | 2.72 | 0.49 |
| 11-Mar | -0.09 | -0.07 | 13-Jan | 0.94 | 1.02 |
| 11-Apr | 0.42 | -0.33 | 13-Feb | 0.88 | 0.86 |
| 11-May | 0.1 | 0.29 | 13-Mar | 0.93 | 0.92 |
| 11-Jun | 0.56 | 0.34 | 13-Apr | -0.21 | -0.82 |
| 11-Jul | 0.73 | 0.92 | 13-May | -0.35 | -0.07 |
| 11-Aug | 0.94 | 0.73 | 13-Jun | 0.91 | 0.93 |
| 11-Sep | 0.22 | -0.03 | 13-Jul | 3.49 | 3.13 |
| 11-Oct | 0.12 | 0.22 | 13-Aug | 0.77 | 1.41 |

Lanjutan Lampiran 1

| Periode | Malang aktual | Probolinggo |
|---------|------------------|-------------|
| 13-Oct | 0.16 | -0.15 |
| 13-Nov | 0.23 | 0.12 |
| 13-Dec | 0.27 | 0.9 |
| 14-Jan | 0.18 | 0.95 |
| 14-Feb | 0.01 | 0.02 |
| 14-Mar | 0.27 | 0.16 |
| 14-Apr | 0.05 | -0.14 |
| 14-May | 0.54 | 0.12 |
| 14-Jun | 0.48 | 0.47 |
| 14-Jul | 1.04 | 0.99 |
| 14-Aug | 0.52 | 0.07 |
| 14-Sep | 0.22 | 0.04 |
| 14-Oct | 0.23 | 0.46 |
| 14-Nov | 0.7 | 1.31 |
| 14-Dec | 2.72 | 2.15 |
| 15-Jan | 0.04 | -0.2 |
| 15-Feb | -0.57 | -0.42 |
| 15-Mar | 0.34 | 0.02 |
| 15-Apr | 0.49 | 0.36 |
| 15-May | 0.45 | 0.46 |
| 15-Jun | 0.38 | 0.44 |
| 15-Jul | 0.57 | 0.7 |
| 15-Aug | 0.28 | 0.02 |

LAMPIRAN 2

Uji Parameter VAR (3)

| | Parameter | Estimasi | SE | T | Prob | Var |
|-------------|--------------|----------|---------|-------|--------|---------|
| Malang | ϕ_{111} | 0.4817 | 0.21148 | 2.28 | 0.0298 | y1(t-1) |
| | ϕ_{112} | 0.2871 | 0.20095 | 1.43 | 0.163 | y2(t-1) |
| | ϕ_{211} | -0.2231 | 0.2152 | -1.04 | 0.3078 | y1(t-2) |
| | ϕ_{212} | -0.1809 | 0.2091 | -0.87 | 0.3935 | y2(t-2) |
| | ϕ_{311} | -0.12 | 0.20564 | -0.58 | 0.5637 | y1(t-3) |
| | ϕ_{312} | 0.16905 | 0.1989 | 0.85 | 0.4019 | y2(t-3) |
| Probolinggo | ϕ_{121} | 0.1903 | 0.23302 | 0.82 | 0.4203 | y1(t-1) |
| | ϕ_{122} | 0.5329 | 0.22142 | 2.41 | 0.0222 | y2(t-1) |
| | ϕ_{221} | -0.3531 | 0.23712 | -1.49 | 0.1466 | y1(t-2) |
| | ϕ_{222} | 0.4328 | 0.2304 | 1.49 | 0.1468 | y2(t-2) |
| | ϕ_{321} | -0.1056 | 0.22658 | -0.47 | 0.6446 | y1(t-3) |
| | ϕ_{322} | 0.18757 | 0.21915 | 0.86 | 0.3986 | y2(t-3) |

LAMPIRAN 3

Coding MACF SAS

```
data inflasi;
  input y1 y2;
datalines;
0.005151863    0.030670989
0.006457689    0.03354399
.....
.....
0.011502409    0.049382716
0.007278651    0.042512488
0.006990286    0.038146973
0.006832319    0.028727377
;
proc varmax data=inflasi;
model y1 y2 / p=1 lagmax=60
print=(corrypecorr);
run;
```

LAMPIRAN 4

Coding MPACF SAS

```
data inflasi;
  input y1 y2;
datalines;
0.005151863    0.030670989
0.006457689    0.03354399
.....
.....
0.011502409    0.049382716
0.007278651    0.042512488
0.006990286    0.038146973
0.006832319    0.028727377
;
proc varmax data=inflasi;
model y1 y2/ p=1 lagmax=60
print=(parcoef);
run;
```

LAMPIRAN 5

Coding VAR (3) SAS

```
data inflasi;
  input y1 y2;
datalines;
0.005151863    0.030670989
0.006457689    0.03354399
.....
.....
0.011502409    0.049382716
0.007278651    0.042512488
0.006990286    0.038146973
0.006832319    0.028727377
;
proc statespace data=inflasi;
var y1(1) y2(1);
run;
proc varmax data=inflasi;
model y1 y2/ p=3 dftest noint;
restrict
AR(1,2,1)=0, AR(3,1,2)=0, AR(3,1,1)=0, AR(2,1,2)=0,
AR(3,2,1)=0, AR(3,2,2)=0, AR(2,1,1)=0, AR(2,2,1)=0;
output lead=8;
run;
```

LAMPIRAN 6

Coding Filter Kalman (n=2)

```
clc
clear all

%Tahap inialisasi
n=input('Masukkan banyak data (maksimal 7):');
Q=input('Q : ');%System noise strength
R=input('R : ');%Nilai matrik error kovarian measurement
a00=input('a00 : ');
a10=input('a10 : ');
tic;
A=eye(2);%Nilai matrik dalam sistem
Qk=eye(2)*Q;%Nilai matrik error kovarian noise
Rk=R;%Nilai matrik error kovarian measurement
xtopi(:,1)=[a00 a10];%Nilai matrik x0 awal
%Nilai matrik error kovarian sistem awal
p(:,1)=[1,0];
p(:,2)=[0,1];

%Data yang diperlukan
a=xlsread('malang3.xlsx','Malang_aktual');%Data inflasi malang
b=xlsread('malang3.xlsx','Malang_forecast');%Data forecasting_malang
c=xlsread('malang3.xlsx','Data_bias');%Data bias_malang
H=[ones(7,1),a];
%Tahap Prediksi dan Koreksi
for i = 1:n
    %Prediksi
    xf(:,i)=A*xtopi(:,i);
    ptopi=[p(1,2*i-1) p(1,2*i); p(2,2*i-1) p(2,2*i)];
    pf=A*ptopi*A+Qk;
    %Koreksi
    kg=pf*H(i,:)*inv((H(i,:)*pf*H(i,:)'+Rk));%Kalman gain
    ptopi=pf-(kg*H(i,:)*pf);
    p(:,2*i+1)=ptopi(:,1);
    p(:,2*i+2)=ptopi(:,2);
end
```

Lanjutan Lampiran 6

```
xtopi(:,i+1)=xf(:,i)+kg*(c(i,:)-(H(i,:)*xf(:,i)));  
end  
hasil=strcat('nilai a0,i = ',num2str(xtopi(1,n)), 'dan a1,i = ',  
num2str(xtopi(2,n)));  
hasil
```

```
%plot nilai a0 dan a1  
figure(1)  
set(plot(xtopi(1,:)), 'color', 'black')  
hold on  
set(plot(xtopi(2,:)), 'color', 'red')  
grid on  
title('Estimasi Koefisien Polinomial');  
xlabel('Waktu ke-');  
ylabel('Nilai Koefisien');  
legend('a0', 'a1');
```

```
%plot data, ARIMA, Filter Kalman ARIMA,  
figure(2)  
for i=1:n  
    bias(i)=xtopi(1,i+1)+xtopi(2,i+1)*a(i);  
    kf(i)=bias(i)+b(i);  
    ape(i)=(abs(a(i)-kf(i))/a(i))*100;  
    sape(1)=0;  
    sape(i+1)=ape(i)+sape(i);  
end  
mape=sape(i+1)/n  
hasil2=strcat('Nilai MAPE= ',num2str(mape));  
plot(a, '-*k')  
hold on  
set(plot(b), 'color', 'blue')  
hold on  
set(plot(kf), 'color', 'red')  
hold on  
grid on  
title('Estimasi inflasi malang polinomial 1');
```

Lanjutan Lampiran 6

```
xlabel('Waktu ke-');  
ylabel('nilai inflasi');  
legend('Data','ARIMA','Filter Kalman-ARIMA');
```

LAMPIRAN 7

Coding Filter Kalman (n=3)

```
clc
clear all

%Tahap inisialisasi
n=input('Masukkan banyak data (maksimal 7):');
Q=input('Q : ');%System noise strength
R=input('R : ');%Measurement noise strength
a00=input('a00 : ');
a10=input('a10 : ');
a20=input('a20 : ');
tic;
A=eye(3);%Nilai matrik dalam sistem
Qk=eye(3)*Q;%Nilai matrik error kovarian noise
Rk=R;%Nilai matrik error kovarian measurement
xtopi(:,1)=[a00 a10 a20]; %Nilai matrik xo awal
%Nilai matrik error kovarian sistem awal
p(:,1)=[1,0,0];
p(:,2)=[0,1,0];
p(:,3)=[0,0,1];

%Data yang diperlukan
a=xlsread('malang4.xlsx','malang_aktual');%Data inflasi malang
b=xlsread('malang4.xlsx','malang_forecast');%Data forecasting_malang
c=xlsread('malang4.xlsx','data_bias');%Data bias_malang
d=xlsread('malang4.xlsx','kuadrat');%Data kuadrat inflasi malang^2
H=[ones(7,1),a,d];

%Tahap Prediksi dan Koreksi
for i = 1:n
%Prediksi
    xf(:,i)=A*xtopi(:,i);
    ptopi=[p(1,3*i-2) p(1,3*i-1) p(1,3*i);
           p(2,3*i-2) p(2,3*i-1) p(2,3*i);
```

Lanjutan Lampiran 7

```
p(3,3*i-2) p(3,3*i-1) p(3,3*i)];
pf=A*ptopi*A'+Qk;
%Koreksi
kg=pf*H(i,:)*inv((H(i,:)*pf*H(i,:)'+Rk));%Kalman gain
ptopi=pf-(kg*H(i,:)*pf);
p(:,3*i+1)=ptopi(:,1);
p(:,3*i+2)=ptopi(:,2);
p(:,3*i+3)=ptopi(:,3);
xtopi(:,i+1)=xf(:,i)+kg*(c(i,:)-(H(i,:)*xf(:,i)));
end
hasil=strcat('nilai a0,i = ',num2str(xtopi(1,n)),'dan a1,i = ',
num2str(xtopi(2,n)),'dan a2=',num2str(xtopi(3,n)));
hasil
%plot nilai a0,a1, dan a2
figure(1)
set(plot(xtopi(1,:)),'color','black')
hold on
set(plot(xtopi(2,:)),'color','red')
hold on
set(plot(xtopi(3,:)),'color','blue')
grid on
title('Estimasi Koefisien Polinomial');
xlabel('Waktu ke-');
ylabel('Nilai Koefisien');
legend('a0','a1','a2');
%plot data, ARIMA, dan Filter Kalman ARIMA,
figure(2)
for i=1:n
    bias(i)=xtopi(1,i+1)+xtopi(2,i+1)*a(i)+xtopi(3,i+1)*d(i);
    kf(i)=bias(i)+ b(i);
    ape(i)=(abs(a(i)-kf(i))/a(i))*100;
    sape(1)=0;
    sape(i+1)=ape(i)+sape(i);
end
mape=sape(i+1)/n
hasil2=strcat('Nilai MAPE= ',num2str(mape));
plot(a,'-k')
```

Lanjutan Lampiran 7

```
hold on
set(plot(b),'color','blue')
hold on
set(plot(kf),'color','red')
hold on
grid on
title('Estimasi inflasi malang polinomial 2');
xlabel('Waktu ke-');
ylabel('nilai inflasi malang');
legend('Data','VAR','Filter Kalman-VAR');
```

LAMPIRAN 8

Coding Filter Kalman (n=4)

```
clc
clear all

%Tahap inisialisasi
n=input('Masukkan banyak data (maksimal 7):');
Q=input('Q : ');%System noise strength
R=input('R : ');%Measurement noise strength
a00=input('a00 : ');
a10=input('a10 : ');
a20=input('a20 : ');
a30=input('a30 : ');
tic;

A=eye(4);%Nilai matrik dalam sistem
Qk=eye(4)*Q;%Nilai matrik error kovarian noise
Rk=R;%Nilai matrik error kovarian measurement
xtopi(:,1)=[a00 a10 a20 a30]; %Nilai matrik xo awal
%Nilai matrik error kovarian sistem awal
p(:,1)=[1,0,0,0];
p(:,2)=[0,1,0,0];
p(:,3)=[0,0,1,0];
p(:,4)=[0,0,0,1];

%Data yang diperlukan
a=xlsread('malang4.xlsx','malang_aktual');%Data inflasi malang
b=xlsread('malang4.xlsx','malang_forecast');%Data forecasting_malang
c=xlsread('malang4.xlsx','data_bias');%Data bias_malang
d=xlsread('malang4.xlsx','kuadrat');%Data kuadrat inflasi malang^2
e=xlsread('malang4.xlsx','triple');%data triple inflasi malang^3
H=[ones(7,1),a,d,e];
% Tahap Prediksi dan Koreksi
for i = 1:n
    %Prediksi
    xf(:,i)=A*xtopi(:,i);
```

Lanjutan Lampiran 8

```
ptopi=[p(1,4*i-3) p(1,4*i-2) p(1,4*i-1) p(1,4*i);
        p(2,4*i-3) p(2,4*i-2) p(2,4*i-1) p(2,4*i);
        p(3,4*i-3) p(3,4*i-2) p(3,4*i-1) p(3,4*i);
        p(4,4*i-3) p(4,4*i-2) p(4,4*i-1) p(4,4*i)];
pf=A*ptopi*A'+Qk;
%Koreksi
kg=pf*H(i,:)*inv((H(i,:)*pf*H(i,:)'+Rk));%Kalman gain
ptopi=pf-(kg*H(i,:)*pf);
p(:,4*i+1)=ptopi(:,1);
p(:,4*i+2)=ptopi(:,2);
p(:,4*i+3)=ptopi(:,3);
p(:,4*i+4)=ptopi(:,4);
xtopi(:,1+i)=xf(:,i)+kg*(c(i,:)- (H(i,:)*xf(:,i)));
end
hasil=strcat('nilai a0,i = ',num2str(xtopi(1,n)),'dan a1,i = ',
num2str(xtopi(2,n)),'a2=',num2str(xtopi(3,n)),'dan
a3=',num2str(xtopi(4,n)));
hasil
%plot nilai a0,a1,a2 dan a3
figure(1)
set(plot(xtopi(1,:)),'color','black')
hold on
set(plot(xtopi(2,:)),'color','red')
hold on
set(plot(xtopi(3,:)),'color','blue')
hold on
set(plot(xtopi(4,:)),'color','green')
grid on
title('Estimasi Koefisien Polinomial');
xlabel('Waktu ke-');
ylabel('Nilai Koefisien');
legend('a0','a1','a2','a3');

%plot data, ARIMA, Filter Kalman, dan VAR
figure(2)
for i=1:n
```

Lanjutan Lampiran 8

```
bias(i)=xtopi(1,i+1)+xtopi(2,i+1)*a(i)+
xtopi(3,i+1)*d(i)+xtopi(4,i+1)*e(i);
kf(i)=bias(i)+b(i);
ape(i)=(abs(a(i)-kf(i))/a(i))*100;
sape(1)=0;
sape(i+1)=ape(i)+sape(i);
end
mape=sape(i+1)/n;
hasil2=strcat('Nilai MAPE= ',num2str(mape))
plot(a,'-k')
hold on
set(plot(b),'color','blue')
hold on
set(plot(kf),'color','red')
grid on
title('Estimasi inflasi malang polinomial 3');
xlabel('Waktu ke-');
ylabel('nilai inflasi malang');
legend('Data','VAR','Filter Kalman-VAR');
```

LAMPIRAN 9

Hasil Estimasi Parameter Model ARIMA di $Z_1(t)$

| Model | Estimasi Parameter | P-value | Signifikansi |
|----------------------|--------------------|---------|--------------|
| ARIMA ([1],0,[2]) | ϕ_1 | 0.0000 | Signifikan |
| | θ_2 | 0.0000 | |
| ARIMA (0,0,[2]) | θ_2 | 0.0000 | Signifikan |
| ARIMA ([1],0,0) | ϕ_1 | 0.0000 | Signifikan |

LAMPIRAN 10

Hasil Estimasi Parameter Model ARIMA di Z2(t)

| Model | Estimasi Parameter | P-value | Signifikansi |
|------------------------|--------------------|---------|------------------|
| ARIMA ([2,3],0,[3]) | ϕ_2 | 0.1522 | Tidak Signifikan |
| | ϕ_3 | 0.0000 | |
| | θ_3 | 0.0000 | |
| ARIMA ([2,3],0,[6]) | ϕ_2 | 0.0013 | Signifikan |
| | ϕ_3 | 0.05000 | |
| | θ_6 | 0.0016 | |
| ARIMA ([2],0,[3,6]) | ϕ_2 | 0.0000 | Signifikan |
| | θ_3 | 0.0005 | |
| | θ_6 | 0.0060 | |
| ARIMA ([3],0,[3,6]) | ϕ_3 | 0.0000 | Signifikan |
| | θ_3 | 0.0000 | |
| | θ_6 | 0.0000 | |
| ARIMA ([2],0,[3]) | ϕ_2 | 0.0000 | Signifikan |
| | θ_3 | 0.0049 | |
| ARIMA ([2],0,[6]) | ϕ_2 | 0.0000 | Signifikan |
| | θ_6 | 0.0064 | |
| ARIMA ([3],0,[3]) | ϕ_3 | 0.0000 | Signifikan |
| | θ_3 | 0.0000 | |
| ARIMA ([3],0,[6]) | ϕ_3 | 0.0000 | Signifikan |
| | θ_6 | 0.0022 | |

DAFTAR PUSTAKA

- [1] Prastowo, N J. 2008. “Dampak BI Rate terhadap Pasar Keuangan”. Bank Indonesia: Working Paper No.21.
- [2] Subandi. 2005. “Analisis Peramalan Inflasi Di Indonesia dengan Menggunakan Metode ARIMA dan *Vector Autoregressive*”. Pustaka FE UNPAD
- [3] Nasution, D., Hendranata, A. 2014. *Laporan Perkembangan Output GAP di Indonesia*. Laporan tengah singkat juni 2014 FGD kedua
- [4] Kurniawan, T. 2014. “Penerapan Metode Kalman Filter dalam Perbaikan Hasil Prediksi Cuaca dengan Metode ARIMA”. Tugas Akhir Jurusan Matematika, Institut Teknologi Sepuluh Nopember, Surabaya.
- [5] Fauzi, I H. 2015. “Perbandingan GSTAR dan ARIMA-Kalman Filter dalam Perbaikan Hasil Prediksi Debit Air Sungai Brantas”. Tugas Akhir Jurusan Matematika, Institut Teknologi Sepuluh Nopember, Surabaya.
- [6] Makridakis, McGee, dan Wheelright, W. (1999). *Metode dan Aplikasi Peramalan*. Edisi kedua. Terj. Andriyanto, U.S. Bina Rupa Aksara: Jakarta.
- [7] Wei, W.W.S. (1994). *Time series Analysis: Univariate and Multivariate Methods*. United State of America: Addison-Wesley Publishing Company, Inc.
- [8] Tsay, R.S. (2002). *Analysis of Financial Time series: Financial Econometrics*. University of Chicago: John Wiley & Sons, Inc.
- [9] Wutsqa, D. U. (2008). Model *Feedforward Neural Network* untuk Data *Time Series* Multivariat. *Seminar Disertasi Universitas Gajah Mada Yogyakarta*.
- [10] Welch, G. Dan Bishop, G. (2011). *An introduction to the Kalman Filter*. University of North Carolina: Chapel Hil, Amerika.

- [11] Kurniawan, T.(2014). *Penerapan Metode Filter Kalman dalam Perbaikan Hasil Prediksi Cuaca dengan Metode ARIMA*, Tugas Akhir Jurusan Matematika, Institut Teknologi Sepuluh Nopember, Surabaya.

BIODATA PENULIS



Nama lengkap penulis adalah Popy Febritasari. Penulis lahir di Malang pada tanggal 1 Februari 1994. Penulis berasal dari Kota Malang, Jawa Timur. Pendidikan formal yang ditempuh yaitu TK Kemala Bhayangkari (1998-2000), SDN Blimbing III Malang (2000-2006), SMP Negeri 3 Malang (2006-2009) dan SMA Negeri 1 Malang (2009-2012). Pada tahun 2012, penulis melanjutkan pendidikan S1 di Institut Teknologi Sepuluh Nopember (ITS) Surabaya di Jurusan Matematika dengan bidang minat matematika

terapan. Penulis mengikuti beberapa organisasi mahasiswa yaitu HIMATIKA ITS dan berbagai macam kepanitiaan yang diadakan di ITS, seperti ITS EXPO (2013 dan 2014), Olimpiade Matematika ITS (2013 dan 2014), Rektor Cup dan Pekan Olahraga Mahasiswa ITS Cabang Olahraga Bola Basket. Info lebih lanjut mengenai Tugas Akhir ini dapat ditujukan melalui email: popyfebrita@yahoo.com.