TESIS - KS185411

NOWCASTING INDEKS HARGA KONSUMEN HARIAN MENGGUNAKAN *DYNAMIC FACTOR MODEL* DAN *SUPPORT VECTOR REGRESSION*

SANTI DEWI RAHAYU
06211950017006

Dosen Pembimbing
Dr.rer.pol. Dedy Dwi Prastyo,S.Si.,M.Si.
Dr. Ir. Setiawan,MS

Departemen Statistika
Fakultas Sains dan Analitika Data
Institut Teknologi Sepuluh Nopember
2021

TESIS - KS185411

NOWCASTING INDEKS HARGA KONSUMEN HARIAN MENGGUNAKAN *DYNAMIC FACTOR MODEL* DAN *SUPPORT VECTOR REGRESSION*

SANTI DEWI RAHAYU
06211950017006

Dosen Pembimbing
Dr.rer.pol. Dedy Dwi Prastyo,S.Si.,M.Si.
Dr. Ir. Setiawan,MS

Departemen Statistika
Fakultas Sains dan Analitika Data
Institut Teknologi Sepuluh Nopember
2021

THESIS - KS185411

NOWCASTING OF DAILY CONSUMER PRICE INDEX USING DYNAMIC FACTOR MODEL AND SUPPORT VECTOR REGRESSION

SANTI DEWI RAHAYU
06211950017006

Supervisors
Dr.rer.pol. Dedy Dwi Prastyo,S.Si.,M.Si.
Dr. Ir. Setiawan,MS

Department of Statistics
Faculty of Science and Data Analytics
Institut Teknologi Sepuluh Nopember
2021

LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Statistika (M.Stat)
Di
Institut Teknologi Sepuluh Nopember
Oleh:
SANTI DEWI RAHAYU
NRP: 06211950017006

Tanggal Ujian: 23 Agustus 2021
Periode Wisuda: Oktober 2021

Disetujui Oleh:
Pembimbing:

1. Dr. rer pol. Dedy Dwi Prastyo, S.Si, M.Si .....
   NIP. 19831204 200812 1 002

2. Dr. Ir. Setiawan, MS .....
   NIP. 19601030 198701 1 001

Penguji:

1. Santi Puteri Rahayu, S.Si, M.Si, Ph.D .....
   NIP. 19750115 199903 2 003

2. Dr. Drs. Agus Suharsono, MS .....
   NIP. 19580823 198403 1 003

Kepala Departemen Statistika
Fakultas Sains dan Analitika Data

Dr. Dra. Kartika Fithriasari, M.Si
NIP. 19691212 199303 2 002

(Halaman ini sengaja dikosongkan)

NOWCASTING* INDEKS HARGA KONSUMEN HARIAN MENGGUNAKAN *DYNAMIC FACTOR MODEL* DAN *SUPPORT VECTOR REGRESSION

Nama Mahasiswa	: Santi Dewi Rahayu
NRP	: 06211950017006
Pembimbing	: Dr.rer.pol. Dedy Dwi Prastyo,S.Si.,M.Si.
Co-Pembimbing	: Dr. Ir. Setiawan,MS

ABSTRAK

Indeks Harga Konsumen (IHK) merupakan salah satu indikator ekonomi yang digunakan untuk mengukur inflasi. Badan Pusat Statistik (BPS) mempublikasikan IHK dan inflasi dalam frekuensi bulanan dengan *time lag* satu hari kerja. Kebijakan yang diambil berdasarkan nilai inflasi bulanan bisa jadi kehilangan momentum karena peristiwa yang terkait dengan inflasi sudah terjadi jauh hari sebelum inflasi atau IHK dipublikasikan. Oleh karena itu, perhitungan IHK harian diperlukan untuk menggambarkan perubahan harga mendekati *real-time*. *Nowcasting* dapat mengatasi masalah ini dengan memprediksi inflasi harian melalui prediksi IHK harian. Penghitungan IHK harian dilakukan dengan memasukkan data harga bahan pokok harian di Sistem Informasi Ketersediaan dan Perkembangan Harga Bahan Pokok (SISKAPERBAPO) Provinsi Jawa Timur, data harian *Jakarta Interbank Spot Dollar Rate* (JISDOR) Bank Indonesia dan data harian harga minyak mentah Brent berjangka dari Id Investing ke dalam model *nowcasting* kemudian divalidasi dengan IHK bulanan BPS. Metode *nowcasting* yang digunakan dalam penelitian ini adalah *Time Series Regression* (TSR), *Support Vector Regression* (SVR) dan *Dynamic Factor Model* (DFM) untuk memperoleh *nowcasting* IHK harian Provinsi Jawa Timur. Akurasi model IHK ditingkatkan dengan membandingkan DFM dengan TSR dan SVR berdasarkan nilai *Root Mean Square Error* (RMSE), *symmetric Mean Absolute Percentage Error* (sMAPE) dan *Mean Absolute Deviation* (MAD). SVR *Polynomial* merupakan metode terbaik untuk *nowcasting* IHK harian. IHK harian hasil *nowcasting* dari model IHK bulanan digunakan sebagai variabel respon pada model IHK harian. SVR- *Polynomial* merupakan metode terbaik untuk *nowcasting* IHK harian pada model IHK harian.

Kata kunci: *Nowcasting*, *Dynamic Factor Model*, *Support Vector Regression*, *Time Series Regression*, Indeks Harga Konsumen, JISDOR, SISKAPERBAPO, RMSE, sMAPE, MAD.

(Halaman ini sengaja dikosongkan)

NOWCASTING OF DAILY CONSUMER PRICE INDEX USING DYNAMIC FACTOR MODEL AND SUPPORT VECTOR REGRESSION

Name of Student	: Santi Dewi Rahayu
ID Number	: 06211950017006
Supervisor	: Dr.rer.pol. Dedy Dwi Prastyo,S.Si.,M.Si.
Co-Supervisor	: Dr. Ir. Setiawan,MS

ABSTRACT

Consumer Price Index (CPI) is one of the economic indicators used to measure inflation. *Badan Pusat Statistik* (BPS) publishes a monthly CPI and inflation with a time lag of one working day. Policies based on the monthly inflation rate could be losing momentum as the events associated with inflation had occurred long before inflation or CPI was published. Therefore, it is necessary to calculate daily CPI to describe near real-time price changes. Nowcasting can overcome this issue by predicting daily inflation through predicting daily CPI. The calculation of daily CPI is done by entering daily data price of basic commodities in *Sistem Informasi Ketersediaan dan Perkembangan Harga Bahan Pokok* (SISKAPERBAPO), daily Jakarta Interbank Spot Dollar Rate (JISDOR) from *Bank Indonesia*, and daily Brent crude oil futures prices from Id Investing into a nowcasting model and validated by monthly CPI published by BPS. The nowcasting method used in this study is the Time Series Regression (TSR), Support Vector Regression (SVR), and Dynamic Factor Model (DFM) applied to predict daily CPI nowcasts in East Java Province. The performance comparison between DFM, TSR, and SVR is evaluated based on the Root Mean Square Error (RMSE), symmetric Mean Absolute Percentage Error (sMAPE), and Mean Absolute Deviation (MAD). SVR Polynomial is the best method for daily CPI prediction. The daily CPI nowcasting results from the monthly CPI model are used as response variables in the daily CPI model. SVR- Polynomial is the best method for nowcasting daily CPI on the daily CPI model.

Keywords: Nowcasting, Dynamic Factor Model, Support Vector Regression, Time Series Regression, Consumer Price Index, JISDOR, SISKAPERBAPO, RMSE, sMAPE, MAD.

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Alhamdulillahi Robbil ‘alamin, segala puji dan syukur Penulis panjatkan kehadirat Allah SWT atas limpahan rahmat, hidayah, serta pertolongan-Nya sehingga Penulis dapat menyelesaikan tesis yang berjudul “***Nowcasting* Indeks Harga Konsumen Harian Menggunakan *Dynamic Factor Model* dan *Support Vector Regression***”. Tesis ini disusun sebagai salah satu syarat dalam menyelesaikan pendidikan pada Program Pascasarjana Departemen Statistika, Fakultas Sains dan Analitika Data, Institut Teknologi Sepuluh Nopember (ITS).

Penyusunan tesis ini tidak terlepas dari bimbingan, bantuan, dan dukungan dari berbagai pihak baik secara teknis maupun non-teknis. Oleh karena itu, melalui kesempatan ini penulis mengucapkan terima kasih yang sebesar-besarnya kepada yang terhormat:

1. Kepala Badan Pusat Statistik (BPS) RI beserta jajarannya, Kepala Pusdiklat BPS beserta jajarannya, Kepala BPS Provinsi Jawa Timur beserta jajarannya, Kepala BPS Kabupaten Sampang beserta jajarannya, yang telah memberikan kesempatan dan kepercayaan kepada Penulis sehingga dapat melanjutkan program studi S2 di ITS,
2. Bapak Dr. rer pol. Dedy Dwi Prastyo, S.Si, M.Si selaku dosen pembimbing sekaligus Kepala Program Studi Pascasarjana Statistika Departemen Statistika ITS yang telah memberikan banyak arahan, saran, dan nasihat dalam menyelesaikan tesis ini dan memfasilitasi serta mengatur kelancaran kegiatan belajar mengajar dan penyelesaian tesis tahap demi tahap,
3. Bapak Dr. Ir. Setiawan, MS selaku dosen co-pembimbing yang telah memberikan banyak arahan, saran, dan nasihat dalam menyelesaikan tesis ini,
4. Ibu Santi Puteri Rahayu, S.Si, M.Si, Ph.D selaku dosen penguji sekaligus dosen wali dan Bapak Dr. Drs. Agus Suharsono, MS selaku dosen penguji yang telah memberikan saran bagi perbaikan tesis ini,
5. Ibu Dr. Kartika Fithriasari, M.Si selaku Kepala Departemen Statistika FSAD ITS, Ibu Santi Wulan Purnami, M.Si., Ph.D selaku Sekretaris Departemen I (Bidang Akademik, Kemahasiswaan, Penelitian dan Pengabdian Kepada Masyarakat) dan Ibu Dr. Vita Ratnasari, M.Si selaku Sekretaris Departemen

II (Bidang Sumber Daya Keuangan, Sumber Daya Manusia, dan Sarana Prasarana) yang telah memfasilitasi sarana dan prasarana untuk kegiatan belajar dan mengajar selama studi di ITS,

6. Bapak dan Ibu dosen pengajar Departemen Statistika ITS, atas ilmu yang telah diajarkan,
7. Bapak/Ibu Staf Tata Usaha (TU) dan karyawan Departemen Statistika ITS Surabaya yang telah membantu dalam masalah administrasi dan lain sebagainya selama masa studi di ITS,
8. Yang terhormat orang tuaku, Bapak Sugeng Raharjo dan Ibu Sunarti, Bapak Joko Irianto dan Ibu Rahayu Suyati yang senantiasa mendoakan kebaikan bagi Penulis, semoga Allah SWT selalu melimpahkan kebaikan serta keberkahan kepada mereka,
9. Teristimewa, suamiku tercinta Didik Purwandika dan putriku yang solehah Hafizhah Azkadina Fadhillah terima kasih atas segala doa, pengorbanan, pengertian, dukungan, dan keceriaan yang selalu menjadi penyemangat bagi Penulis untuk menyelesaikan studi dengan baik, doa dan harapan terbaik selalu untuk kalian,
10. Semua sahabat dan rekan-rekan mahasiswa TB BPS angkatan 2019 dan 2018 serta rekan-rekan mahasiswa Pascasarjana Statistika ITS atas semua bantuan, dukungan, doa, dan saran yang sangat berharga bagi terselesaikannya tesis ini.

Penulis menyadari bahwa tesis ini masih sangat jauh dari kesempurnaan. Oleh karena itu, penulis mengharapkan saran dan kritik yang bersifat membangun untuk perbaikan.

Surabaya, Agustus 2021

Penulis

DAFTAR ISI

LEMBAR PENGESAHAN TESIS i
ABSTRAK iii
ABSTRACT v
KATA PENGANTAR vii
DAFTAR ISI ix
DAFTAR TABEL xiii
DAFTAR GAMBAR xvii
DAFTAR LAMPIRAN xix
DAFTAR NOTASI xxi
BAB 1 PENDAHULUAN 1
1.1 Latar Belakang 1
1.2 Perumusan Masalah 4
1.3 Tujuan Penelitian 5
1.4 Manfaat Penelitian 5
1.5 Batasan Penelitian 5
BAB 2 TINJAUAN PUSTAKA 7
2.1 Analisis Time Series 7
2.1.1 *Autocorrelation Function* dan *Partial Autocorrelation Function* 8
2.1.2 Stasioneritas dalam Rata-rata dan Varians 9
2.2 *Nowcasting* 11
2.3 *Dynamic Factor Model* 12
2.4 *Support Vector Regression* 17
2.5 *Time Series Regression* 23
2.6 Pemilihan *Model* Terbaik 28
2.7 Indeks Harga Konsumen 29
2.8 Faktor-Faktor yang Mempengaruhi Indeks Harga Konsumen 31

2.9 Sumber Data Harga 33
BAB 3 METODE PENELITIAN 37
3.1 Metode Analisis 37
3.2 Pengunduhan Data Mentah dari Sumber Data *Online* 37
3.3 Analisa Data Mentah 38
3.4 Tahapan Pengolahan Awal Data atau *Preprocessing* 49
3.4.1 Mengubah IHK ke dalam Tahun Dasar yang Sama 49
3.4.2 Mengatasi Permasalahan Nilai yang Hilang 49
3.4.3 Deteksi *Outlier* 49
3.4.4 Standarisasi Data 50
3.5 Struktur Data 51
3.6 Alokasi Data 53
3.7 Pembangunan Model *Nowcasting* 53
3.7.1 Optimisasi *Hyperparameter* SVR 53
3.7.2 Pembangunan *Nowcasting* IHK Bulanan 53
3.7.3 Pembangunan *Nowcasting* IHK Harian 54
3.7.4 Metode *Nowcasting* dalam Pembangunan Model IHK Harian. 54
BAB 4 HASIL DAN PEMBAHASAN 57
4.1 Kajian terhadap Model DFM, SVR, dan TSR 57
4.1.1 Kajian Model DFM 57
4.1.2 Kajian Model SVR 57
4.1.3 Kajian Model TSR 58
4.2 Hasil *Preprocessing* 59
4.3 Pembangunan *Nowcasting* IHK Bulanan 61
4.4 Pembangunan *Nowcasting* IHK Harian 98
BAB 5 KESIMPULAN DAN SARAN 111
5.1 Kesimpulan 111
5.2 Saran 112
DAFTAR PUSTAKA 115

LAMPIRAN 119

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

Tabel 2.1 Transformasi Box-Cox 10

Tabel 2.2 Fungsi Kernel 22

Tabel 2.3 Jumlah Paket Komoditas SBH 8 Kabupaten/ Kota dan Provinsi Jawa Timur 31

Tabel 2.4 Contoh Data Rata-Rata Harga di Kota Surabaya pada Tingkat Konsumen Tanggal 1 Januari 2021 33

Tabel 3.1 Ringkasan Data Nilai yang Hilang di Delapan Kabupaten/Kota IHK Jawa Timur 38

Tabel 3.2 Variabel Penelitian dalam Dataset Bulanan 43

Tabel 3.3 Variabel Penelitian dalam Dataset Harian 45

Tabel 3.4 Kalendar Rilis Data dalam Satu Bulan dari Variabel Penelitian 45

Tabel 3.5 Struktur Data Bulanan dalam Penelitian 51

Tabel 3.6 Struktur Data Harian dalam Penelitian 52

Tabel 4.1 Perubahan IHK dengan Tahun Dasar yang Sama di Provinsi Jawa Timur 59

Tabel 4.2 Contoh *Missing Value* pada Dataset Harian Kabupaten Jember 60

Tabel 4.3 Uji Multikolinearitas Rata-rata Bulanan Harga Konsumen Standar 61

Tabel 4.4 Nilai *Rounded Value* Rata-rata Bulanan Harga Konsumen Standar Sebelum Transformasi 64

Tabel 4.5 Nilai *Rounded Value* Rata-rata Bulanan Harga Konsumen Stadar Setelah Transformasi Box Cox 65

Tabel 4.6 Uji ADF Rata-rata Bulanan Harga Konsumen Standar 71

Tabel 4.7 *Eigenvalue*, Proporsi dan Kumulatif Proporsi Variasi yang Terjelaskan dari Variabel Rata-rata Bulanan Harga Konsumen Stasioner 73

Tabel 4.8 Hasil Penentuan *Lag* Ordo (p) pada Model VAR Berdasarkan AIC74

Tabel 4.9 Hasil Pengujian dengan Metode DFM (r=11, p=3, q=5).. 75

Tabel 4.10 Nilai *Rounded Value* Harga Konsumen Harian Standar Sebelum Transformasi 75

Tabel 4.11 Nilai *Rounded Value* Harga Konsumen Harian Standar Setelah Transformasi Box Cox 77
Tabel 4.12 Uji ADF Harga Konsumen Harian 83
Tabel 4.13 Uji Multikolinearitas Rata-rata Bulanan Harga Konsumen Standar 85
Tabel 4.14 *Eigenvalue*, Proporsi dan Kumulatif Proporsi Variasi yang Terjelaskan dari Dua Puluh Lima Variabel Rata-rata Bulanan Harga Konsumen Stasioner Terpilih 86
Tabel 4.15 *Component Matrix* dari Rata-rata Bulanan Harga Konsumen Standar Stasioner Terpilih 87
Tabel 4.16 Hasil Penentuan *Lag* Ordo (*p*) pada Model VAR Berdasarkan AIC90
Tabel 4.17 Hasil Pengujian dengan Metode DFM (*r*=10, *p*=2, *q*=6) ... 90
Tabel 4.18 Hasil Evaluasi Prediksi IHK Bulanan dengan DFM (*r*=10, *p*=2, *q*=6) 91
Tabel 4.19 Performansi IHK Harian Hasil *Nowcasting* dengan DFM (*r*=10, *p*=2, *q*=6) terhadap IHK Aktual 91
Tabel 4.20 Optimisasi *Hyperparameter* Dataset Bulanan dengan *Grid Search*92
Tabel 4.21 Hasil Evaluasi Prediksi IHK Bulanan dengan SVR 92
Tabel 4.22 Performansi IHK Harian Hasil *Nowcasting* dengan SVR terhadap IHK Aktual 93
Tabel 4.23 Uji KMO dan Uji Bartlett Rata-rata Bulanan Harga Konsumen Standar Terpilih 93
Tabel 4.24 *Eigenvalue*, Proporsi dan Kumulatif Proporsi Variasi yang Terjelaskan..... 94
Tabel 4.25 Koefisien dari Tujuh *Principal Component* yang Terbentuk dari Dua Puluh Lima Rata-rata Bulanan Harga Konsumen Standar Terpilih 95
Tabel 4.26 Hasil Pengujian dengan *Time Series Regression*..... 96
Tabel 4.27 Hasil Evaluasi Prediksi IHK Bulanan dengan TSR Model 3 97
Tabel 4.28 Performansi IHK Harian Hasil *Nowcasting* terhadap IHK Aktual Model 3..... 97
Tabel 4.29 Hasil Evaluasi Prediksi IHK Bulanan 97
Tabel 4.30 Performansi IHK Harian Hasil *Nowcasting* terhadap IHK Aktual 98

Tabel 4.31 *Eigenvalue,* Proporsi dan Kumulatif Proporsi Variasi yang Terjelaskan dari Dua Puluh Lima Variabel Harga Konsumen Harian Stasioner Terpilih 99
Tabel 4.32 *Component Matrix* dari Harga Konsumen Harian Standar Stasioner Terpilih 101
Tabel 4.33 Hasil Penentuan *Lag* Ordo (*p*) pada Model VAR Berdasarkan AIC 103
Tabel 4.34 Hasil Pengujian dengan Metode DFM (*r*=8, *p*=8, *q*=5)..... 104
Tabel 4.35 Hasil Evaluasi Prediksi IHK Harian dengan DFM (*r*=8, *p*=8, *q*=5) 105
Tabel 4.36 Optimisasi *Hyperparameter* Dataset Harian dengan *Grid Search* 105
Tabel 4.37 Hasil Evaluasi Prediksi IHK Harian dengan SVR 106
Tabel 4.38 Uji Multikolinearitas Harga Konsumen Harian Standar.... 107
Tabel 4.39 Uji KMO dan Uji Bartlett Harga Konsumen Harian Standar Terpilih 107
Tabel 4.40 *Eigenvalue,* Proporsi dan Kumulatif Proporsi Variasi yang Terjelaskan 108
Tabel 4.41 Koefisien dari Tujuh *Principal Component* yang Terbentuk dari Dua Puluh Lima Harga Konsumen Harian Standar Terpilih 109
Tabel 4.42 Hasil Pengujian dengan *Time Series Regression* pada IHK Harian 110
Tabel 4.43 Hasil Evaluasi Prediksi IHK Harian dengan TSR Model 1 110
Tabel 4.44 Hasil Evaluasi Prediksi IHK Harian 110

(Halaman ini sengaja dikosongkan)

DAFTAR GAMBAR

Gambar 2.1 Pola Data *Time Series* 7
Gambar 2.2 SVR Linear Satu Dimensi 18
Gambar 2.3 Batas *Error* dalam SVR 20
Gambar 3.1 Diagram Tahapan Penelitian 37
Gambar 3.2 Diagram Pembangunan *Nowcasting* IHK Harian 55
Gambar 4.1 Boxplot IHK Bulanan Provinsi Jawa Timur Tahun Dasar 2018 61
Gambar 4.2 Plot Box-Cox Data IHK Bulanan Standar..... 62
Gambar 4.3 Plot (a) *Time Series* dan (b) ACF IHK Bulanan Standar 63
Gambar 4.4 Plot (a) *Time Series* dan (b) ACF IHK Bulanan Standar *Differencing Lag* 1 63
Gambar 4.5 Plot *Time Series* Rata-rata Bulanan Harga Konsumen Standar Sesudah Stasioner 67
Gambar 4.6 *Screeplot* dari Variabel Rata-rata Bulanan Harga Konsumen Stasioner..... 73
Gambar 4.7 Plot *Time Series* Harga Konsumen Harian Standar Sesudah Stasioner..... 79
Gambar 4. 8 *Screeplot* dari Dua Puluh Lima Variabel Rata-rata Bulanan Harga Konsumen Stasioner Terpilih..... 85
Gambar 4. 9 *Screeplot* dari Rata-rata Bulanan Harga Konsumen Terpilih 95
Gambar 4.10 Plot (a) ACF dan (b) PACF Residual dari Regresi dengan Enam Variabel Rata-rata Bulanan Harga Konsumen Terpilih 96
Gambar 4.11 *Screeplot* dari Dua Puluh Lima Variabel Harga Konsumen Harian Stasioner Terpilih 99
Gambar 4.12 *Screeplot* dari Harga Konsumen Harian Standar Terpilih 108

(Halaman ini sengaja dikosongkan)

DAFTAR LAMPIRAN

Lampiran 1	Struktur Data Bulanan dalam Penelitian	123
Lampiran 2	Struktur Data Harian dalam Penelitian	124
Lampiran 3	Plot Box-Cox Variabel Z_X^m yang Belum Stasioner dalam Varians	125
Lampiran 4	Plot Box-Cox Variabel Z_X^m yang Sudah Stasioner dalam Varians	130
Lampiran 5	Plot ACF Data Z_X^m Sebelum Differencing	135
Lampiran 6	Plot Box-Cox Variabel Z_X^d yang Belum Stasioner dalam Varians	140
Lampiran 7	Plot Box-Cox Variabel Z_X^d yang Sudah Stasioner dalam Varians	145
Lampiran 8	Plot ACF Data Z_X^d Sebelum Differencing	150
Lampiran 9	Hasil Estimasi Parameter pada *Time Series Regression* Model IHK Bulanan dan Hasil Uji Asumsi Residual	155
Lampiran 10	Hasil Estimasi Parameter pada *Time Series Regression* Model IHK Harian dan Hasil Uji Asumsi Residual	157

(Halaman ini sengaja dikosongkan)

DAFTAR NOTASI

$x_{i,t}$	Variabel prediktor ke-*i* pada waktu ke-*t*
μ	Rata-rata
σ^2	Varians
γ_k	Kovarians
$\hat{\rho}_k$	ACF
$\hat{\phi}_{kk}$	PACF
ε_t	*Error white noise*
λ	Parameter transformasi
λ_{ir}	*loading factor*
$f_{r,t}$	*common factor*
$\xi_{i,t}$	komponen *idiosyncratic*
x_t	Matriks variabel prediktor
Λ	Matriks dari *loading factor*
F_t	Matriks dari *common factor*
y_t	Estimasi IHK
ε	*Epsilon* (Parameter SVR)
γ	*Gamma* (Parameter SVR)
d	*Degree* (Parameter SVR)
IHK_t^m	Indeks Harga Konsumen bulan ke-*t*
$P_{c,t}^m$	Harga jenis barang/ jasa *c* pada bulan ke-(*t*)
$P_{c,0}^m$	Harga jenis barang/ jasa *c* pada tahun dasar (hasil SBH)
$Q_{c,0}^m$	Kuantitas jenis barang/ jasa *c* pada tahun dasar (hasil SBH)
Inf_t^m	Laju inflasi/ deflasi bulan ke-(*t*)

(Halaman ini sengaja dikosongkan)

BAB 1
PENDAHULUAN

1.1 Latar Belakang

Inflasi adalah kecenderungan naiknya harga barang dan jasa secara umum dan terus menerus (Suseno & Astiyah, 2009) (Eksiandayani, Suhartono, & Prastyo, 2015). Kenaikan harga barang dan jasa yang disebut inflasi yaitu kenaikan harga barang dan jasa yang mengakibatkan kenaikan harga pada barang dan jasa lainnya. Perkembangan/ perubahan harga barang dan jasa yang dibayarkan oleh masyarakat secara umum ditunjukkan oleh salah satu indikator ekonomi yaitu Indeks Harga Konsumen (IHK) (BPS, 2020). Tingkat kenaikan (inflasi) atau tingkat penurunan (deflasi) dari barang dan jasa digambarkan oleh perubahan IHK dari waktu ke waktu.

Dampak inflasi yang tinggi terhadap perekonomian antara lain pendapatan riil masyarakat turun sehingga standar hidup dari masyarakat turun dan jumlah penduduk miskin bertambah serta menciptakan ketidakpastian (*uncertainty*) bagi pelaku ekonomi dalam mengambil keputusan (baik konsumsi, investasi maupun produksi) akibatnya menurunkan pertumbuhan ekonomi. Selain itu, tingkat bunga domestik riil menjadi tidak kompetitif akibat tingginya tingkat inflasi domestik dibandingkan dengan tingkat inflasi di negara tetangga sehingga dapat memberikan tekanan pada nilai rupiah.

Berdasarkan *Advanced Release Calendar* (ARC), Badan Pusat Statistik (BPS) mempublikasikan data IHK dan inflasi bulanan pada hari kerja pertama setiap bulan berikutnya. Contoh data inflasi bulan Januari akan dipublikasikan pada hari kerja pertama bulan Februari. Demikian juga inflasi bulan Februari akan dipublikasikan pada hari kerja pertama bulan Maret, dan seterusnya. Kebijakan yang diambil berdasarkan inflasi bulanan bisa jadi kehilangan momentum karena peristiwa yang terkait dengan inflasi sudah terjadi jauh hari sebelum inflasi atau IHK dipublikasikan. Oleh karena itu, perhitungan IHK harian diperlukan untuk menggambarkan perubahan harga mendekati *real-time*.

Ketiadaan referensi harga pasar bahan pokok mendorong pedagang untuk melakukan aksi spekulasi harga dengan mengambil margin keuntungan yang setinggi-tingginya. Hal ini berpotensi meningkatkan laju inflasi. Kesadaran pemerintah mengenai dampak buruk inflasi terhadap perekonomian mendorong pemerintah untuk menyediakan acuan sumber informasi harga bahan pokok yang dapat diakses oleh masyarakat secara *real-time.* Beberapa portal yang menyediakan informasi harga bahan pokok di antaranya Sistem Informasi Ketersediaan dan Perkembangan Harga Bahan Pokok (SISKAPERBAPO) di Jawa Timur, Pusat Informasi Harga Pangan Strategis (PIHPS) Nasional Bank Indonesia dan Sistem Pemantauan Pasar dan Kebutuhan Pokok (SP2KP) Kementrian Perdagangan. PIHPS dan SP2KP menyediakan harga bahan pokok hanya pada hari kerja (Senin sampai dengan Jumat) tidak termasuk Sabtu Minggu dan hari libur. Sebaliknya, SISKAPERBABO di Jawa Timur menyediakan harga bahan pokok *real-time.* Oleh karena itu, harga bahan pokok yang digunakan dalam penelitian ini mengacu pada data harga bahan pokok harian pada SISKAPERBABO di Jawa Timur. Data ini dapat dimanfaatkan untuk prediksi IHK harian. Prediksi IHK harian memungkinkan pengambil kebijakan membuat kebijakan lebih tepat dan cepat.

Banyak penelitian terkait faktor-faktor yang mempengaruhi inflasi di Indonesia antara lain menurut Nizar (2012) fluktuasi harga minyak di pasar dunia mendorong laju inflasi satu tahun ke depan. Menurut Sutawijaya & Zulfahmi (2012) serta Saputra & Nugroho (2014) nilai tukar atau kurs berdampak positif dan signifikan terhadap inflasi di Indonesia. Saputra & Nugroho (2014), Darma, Pusriadi, & Hakim (2018) serta Sundoro (2021) menyimpulkan bahwa harga bahan pokok seperti harga beras, harga daging ayam, harga bawang merah dan harga cabai merah berpengaruh positif dan signifikan terhadap inflasi. Berdasarkan penelitian sebelumnya tersebut maka variabel prediktor yang digunakan dalam penelitian ini antara lain harga minyak dunia, nilai tukar rupiah terhadap dollar *United States* (US), dan harga bahan pokok (harga beras, harga daging ayam, harga daging sapi, harga telur ayam, harga bawang merah, harga bawang putih, harga cabai merah, harga cabai rawit, harga minyak goreng dan harga gula pasir).

Beberapa penelitian terkait prediksi IHK maupun inflasi bulanan di Indonesia yang melibatkan variabel prediktor menggunakan beberapa metode di antaranya Regresi Linear Berganda (RLB) atau *Time Series Regression* (TSR) oleh Amrin (2016) dan Sumantri & Latifah (2019), *Autoregressive Integrated Moving Average with Exogenous Variable* (ARIMAX) oleh Newton, Kurnia, & Sumertajaya (2020) dan *Support Vector Regression* (SVR) oleh Khatimi, Alkaff, & Najipah (2017) dan Dewi, Adikara, & Adinugroho (2018). Prediksi IHK harian oleh Budiastuti (2017) dengan membandingkan beberapa metode di antaranya RLB, *Ridge Regression*, SVR dan *Random Forest* diperoleh kesimpulan bahwa SVR dengan fungsi kernel *Radial Basis Function* (RBF) merupakan metode terbaik untuk prediksi IHK harian di Kota Surabaya. Penelitian tersebut melakukan prediksi menggunakan data *online* dan belum membahas melakukan prediksi mendekati *real time.*

Beberapa dekade terakhir berkembang metode peramalan *time series* untuk prediksi saat ini, ke depannya dalam waktu dekat dan yang telah terjadi baru-baru ini disebut *nowcasting* (Banbura, Giannone, & Reichlin, Nowcasting, 2010). Metode ini mampu menyediakan informasi *real-time* untuk variabel respon yang memiliki *time lag* publikasi yang panjang, tersedia dalam frekuensi rendah padahal tingkat kebutuhan data tersebut sangat tinggi, revisi data, memiliki frekuensi yang berbeda dengan variabel prediktor dan memiliki *time lag* publikasi yang berbeda dengan variabel prediktornya. Menurut Tarsidin, Idham, & Rakhman (2018) beberapa pendekatan *nowcasting* yang umumnya digunakan antara lain *Bridge Equation*, *Mixed Data Sampling* (MIDAS), *Mixed Frequency Vector Autoregression* (MF-VAR) dan *Dynamic Factor Model* (DFM). Di antara beberapa pendekatan tersebut DFM merupakan metode yang populer untuk peramalan jangka pendek karena model tersebut adalah parsimoni, sanggup mengatasi *missing data* dan *mixed frequency* indikator dan berpotensi dapat mengestimasi jumlah variabel yang besar (Luciani, Pundit, Ramayandi, & Veronese, 2015).

Literatur tentang *nowcasting* di Indonesia jumlahnya masih terbatas di antaranya *nowcasting* pertumbuhan PDB di Indonesia oleh Luciani dkk (2015) menggunakan 11 indikator makroekonomi dengan pendekatan DFM, *nowcasting*

konsumsi rumah tangga dan investasi di Indonesia oleh Tarsidin dkk (2018) masing-masing menggunakan 5 indikator makroekonomi dengan pendekatan DFM dan *nowcasting* PDB oleh Ma'Arif (2019) menggunakan 13 indikator makroekonomi dengan pendekatan DFM. *Nowcasting* pertumbuhan PDB di Indonesia oleh Luciani dkk (2015) menunjukkan bahwa kinerja DFM lebih baik dibandingkan dengan AR(2), *Random Walk* (RW), *Bridge Equation* dan MIDAS berdasarkan nilai RMSE terkecil. Demikian juga, *nowcasting* konsumsi rumah tangga dan investasi di Indonesia oleh Tarsidin dkk (2018) menunjukkan bahwa DFM merupakan metode terbaik dibandingkan *Bridge Equation* dan ARIMA karena memiliki nilai RMSE terkecil. *Nowcasting* PDB oleh Ma'Arif (2019) berdasarkan nilai RMSE dan *Mean Absolute Deviation* (MAD) terkecil maka DFM merupakan model terbaik dibandingkan ARIMA dan ARIMAX untuk meramalkan pertumbuhan PDB.

Penelitian ini difokuskan pada *nowcasting* IHK harian di Jawa Timur. Metode *nowcasting* yang digunakan adalah DFM sedangkan SVR dan TSR digunakan sebagai pembanding. Evaluasi model berdasarkan nilai RMSE, *symmetric Mean Absolute Percentage Error* (sMAPE) dan *Mean Absolute Deviation* (MAD).

1.2 Perumusan Masalah

Inflasi merupakan indikator penting yang dipublikasikan setiap bulan dengan *time lag* satu hari kerja. Inflasi bulanan dihitung dari IHK bulanan. Kebijakan yang diambil berdasarkan nilai inflasi bulanan bisa jadi kehilangan momentum karena peristiwa yang terkait dengan inflasi sudah terjadi jauh hari sebelum inflasi atau IHK dipublikasikan. Oleh sebab itu diperlukan perhitungan IHK harian untuk menggambarkan perubahan harga mendekati *real-time*. Penghitungan IHK harian dilakukan dengan memasukkan data harga harian di SISKAPERBAPO, data harian JISDOR Bank Indonesia dan data harian harga minyak mentah Brent berjangka dari Id Investing ke dalam model *nowcasting* kemudian divalidasi dengan IHK bulanan BPS. Teknik *nowcasting* tersebut menggunakan DFM, SVR dan TSR. Oleh karena itu rumusan masalah dalam

penelitian ini adalah bagaimana model DFM, SVR, dan TSR yang sesuai untuk *nowcasting* IHK harian di Jawa Timur.

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah di atas, maka tujuan yang ingin dicapai dalam penelitian ini sebagai berikut:

1. mengkaji perbandingan model DFM, SVR dan TSR untuk *nowcasting*,
2. menerapkan model DFM, SVR dan TSR untuk *nowcasting* IHK harian Jawa Timur,
3. mengevaluasi dan membandingkan hasil *nowcasting* IHK harian Jawa Timur dengan model DFM, SVR dan TSR berdasarkan RMSE, sMAPE, dan MAD.

1.4 Manfaat Penelitian

Manfaat penelitian ini:

1. hasil *nowcasting* diharapkan dapat memberikan kontribusi bagi Pemerintah Provinsi Jawa Timur dalam melakukan evaluasi, penyusunan, perencanaan, dan penerapan kebijakan untuk kemajuan perekonomian di Jawa Timur, khususnya terkait penanganan inflasi,
2. hasil *nowcasting* diharapkan dapat memberikan alternatif bagi BPS mengenai metode analisis dalam peramalan data IHK/ inflasi harian,
3. penelitian ini diharapkan dapat memberikan kontribusi dalam bidang keilmuan mengenai analisis data *time series* khusunya *modeling statistic* dan *machine learning* serta menambah wawasan keilmuan secara umum kepada masyarakat.

1.5 Batasan Penelitian

Batasan masalah yang digunakan dalam penelitian ini antara lain:

1. harga bahan pokok untuk provinsi Jawa Timur dihitung dari rata-rata harga bahan pokok di 8 kabupaten/ kota IHK di Jawa Timur yaitu Kabupaten Jember, Kabupaten Banyuwangi, Kabupaten Sumenep, Kota

Kediri, Kota Malang, Kota Probolinggo, Kota Madiun dan Kota Surabaya tanpa penimbang komoditas dan tanpa penimbang kota,

2. data yang digunakan dalam penelitian ini mulai 1 Januari 2017 sampai dengan 31 Mei 2021.

BAB 2
TINJAUAN PUSTAKA

Tinjauan pustaka meliputi tinjauan statistika dan tinjauan non-statistika. Tinjauan statistika membahas tentang analisis *time series*, *nowcasting*, DFM, SVR, TSR, pemilihan model terbaik menggunakan RMSE, sMAPE, dan MAD. Tinjauan non-statistika membahas tentang IHK, faktor-faktor yang mempengaruhi IHK dan sumber data harga harian.

2.1 Analisis Time Series

Time series nerupakan serangkaian observasi dari suatu variabel yang diambil secara beruntun berdasarkan interval waktu yang tetap, misalnya harian, bulanan maupun tahunan. Analisis *time series* merupakan analisis yang mempelajari pola data pada interval waktu tersebut. Pola data *time series* secara umum di antaranya stasioner, *trend*, ,musiman (*seasonal),* dan siklus *(cycle)*. Pola stasioner (Gambar 2.1a) ketika nilai data berfluktuasi di sekitar rata-rata konstan. Pola tren (Gambar 2.1b) ketika data mengalami kenaikan atau penurunan jangka panjang. Pola musiman (Gambar 2.1c) ketika nilai data dipengaruhi oleh musiman sehingga berulang dengan periode waktu tertentu misal setiap 12 bulan per tahun, tujuh hari per minggu. Pola *cycle* (Gambar 2.1d) merupakan pola pengulangan yang teratur namun dengan periode yang berubah-ubah, misal siklus bisnis.

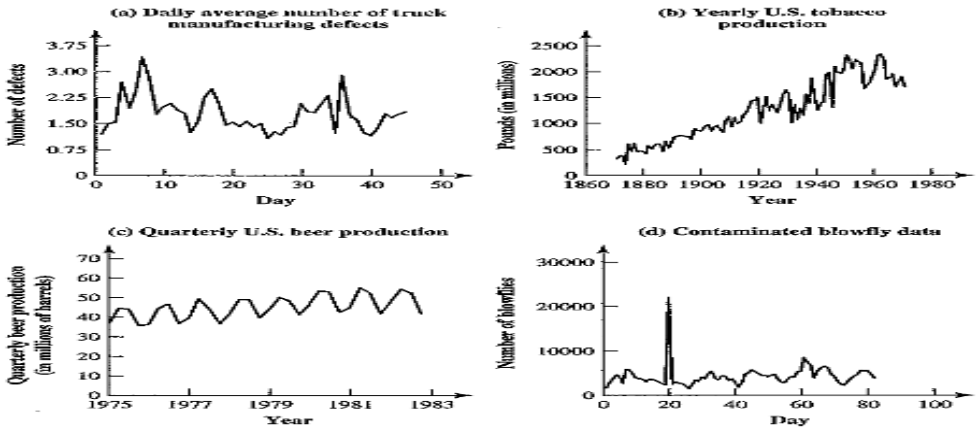

Sumber: Wei (2006)
Gambar 2.1 Pola Data *Time Series*

Data *time series* dikatakan stasioner apabila rata-rata dan variansnya berfluktuasi konstan setiap waktu. Secara teoritis, data *time series* $x_1, x_2, \ldots, x_T$ dikatakan stasioner jika:

1. $E(x_t) = E(x_{t-k}) = \mu$, untuk semua *t=1,2,...,T* (2.1)
2. $Var(x_t) = Var(x_{t-k}) = \sigma^2$, untuk semua *t*. (2.2)

2.1.1 *Autocorrelation Function* dan *Partial Autocorrelation Function*

Autocorrelation Function (ACF) digunakan untuk menjelaskan korelasi antara x_t dan x_{t-k} dari suatu proses yang sama dan hanya terpisah oleh *time lag* ke-*k* (Wei, 2006). *Autocorrelation* antara x_t dan x_{t-k} didefinisikan pada persamaan berikut:

$$\rho_k = \frac{Cov(x_t, x_{t-k})}{\sqrt{Var(x_t)}\sqrt{Var(x_{t-k})}} = \frac{\gamma_k}{\gamma_0} \tag{2.3}$$

dengan

ρ_k : nilai korelasi dari x_t dan x_{t-k}

γ_0 : varians(x_t)=varians(x_{t-k})

γ_k : nilai kovarians dari x_t dan x_{t-k}

$\gamma_k = E(X_t - \mu)(X_{t-k} - \mu)$

Partial Autocorrelation Function (PACF) mengukur keeratan hubungan antara x_t dan x_{t-k} setelah dependensi linear pada $x_{t-1}, x_{t-2}, \ldots, x_{t-k+1}$ dihilangkan (Wei, 2006). Fungsi PACF dinotasikan dengan ϕ_{kk} ditunjukkan oleh persamaan berikut dalam Cryer & Chan (2009) sebagai berikut:

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1}, \rho_{k-1}}{1 - \sum_{j=1}^{k-1} \phi_{k-1}, \rho_j} \tag{2.4}$$

dengan

$\phi_{k,j} = \phi_{k-1,j} - \phi_{kk}\phi_{k-1,j-1}$, untuk $j = 1, 2, \ldots, k-1$.

2.1.2 Stasioneritas dalam Rata-rata dan Varians

Stasioneritas pada model *time series* tejadi apabila keseimbangan level rata-rata dan varians yang konstan di sekitar level rata-rata (Wei, 2006). Salah satu teknik paling sederhana untuk menguji kestasioneran data *time series* dalam rata-rata menggunakan korelogram. Korelogram merupakan teknik identifikasi kestasioneran data *time series* melalui ACF dengan membuat plot antara $\rho_{i,k}$ dan *k*. Plot ini disebut korelogram populasi. Dalam praktiknya hanya *Sample Autocorrelation Function* (SACF) yang dapat dihitung. SACF antara x_t dan x_{t-k} didefinisikan pada persamaan berikut:

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum\left(x_t - \bar{x}\right)\left(x_{t+k} - \bar{x}\right)/T}{\sum\left(x_t - \bar{x}\right)^2/T}; t = 1, 2, \ldots, T; k = 1, 2, \ldots. \quad (2.5)$$

Plot antara $\hat{\rho}_k$ dan *k* disebut korelogram sampel. Pola korelogram sampel yang menurun dengan cepat seiring dengan meningkatnya *k* menunjukkan bahwa data sudah stasioner dalam rata-rata sedangkan pola korelogram turun lambat atau cenderung tidak menuju nol menunjukkan data tidak stasioner dalam rata-rata.

Uji formal untuk menguji kestasioneran data *time series* dalam rata-rata yaitu uji *Augmented Dickey-Fuller* (ADF). Persamaan yang digunakan dalam uji ADF sebagai berikut:

$$\Delta x_t = b_1 + b_2 t + \delta x_{t-1} + \sum_{j=1}^{k} a_j \Delta x_{t-j} + \varepsilon_t \quad (2.6)$$

dengan

ε_t : *error white noise*

b_1: konstanta

b_2: koefisien tren terhadap waktu

δ : koefisien estimasi pada x_{t-1}

k : order lag

a :koefisien

$\Delta x_{t-1} = x_{t-1} - x_{t-2}, \Delta x_{t-2} = x_{t-2} - x_{t-3}$ dan seterusnya

Hipotesis yang digunakan:

$H_0 : \delta = 0$ (Data tidak stasioner dalam rata-rata)

$H_1 : \delta < 0$ (Data stasioner dalam rata-rata)

Statistik uji yang digunakan sebagai berikut:

$$t_{hitung} = \frac{\hat{\delta}}{\sigma_{\hat{\delta}}} \tag{2.7}$$

dengan

$\hat{\delta}$: nilai dugaan δ

$\sigma_{\hat{\delta}}$: simpangan baku $\hat{\delta}$

Keputusan: H_0 ditolak jika $\left|t_{hitung}\right| > t_{\alpha,T}$ atau *p-value* =P(Z>z) lebih kecil dari signifikansi yang digunakan ($\alpha = 5\%$) maka dapat disimpulkan bahwa data telah stasioner dalam rata-rata.

Jika data tidak stasioner dalam rata-rata, data tersebut dapat distasionerkan dengan *differencing* namun jika data juga tidak stasioner dalam varians maka *differencing* tidak selalu baik digunakan untuk menstasionerkannya karena orde-nya bisa tinggi akibatnya banyak data yang hilang (Mulyana, 2004). Data *time series* dikatakan stasioner dalam varians jika *rounded value* (λ) sama dengan 1 atau interval batas atas dan batas bawahnya memuat angka 1. Data *time series* tidak stasioner dalam varians dapat diatasi dengan transformasi Box-Cox (Wei, 2006). Nilai λ yang digunakan dalam transformasi ditunjukkan oleh tabel berikut ini:

Tabel 2.1 Transformasi Box-Cox

Nilai λ	Transformasi
-2	$1/(x_t)^2$
-1	$1/x_t$
-0,5	$1/\sqrt{x_t}$
0	Lnx_t
0,5	$\sqrt{x_t}$
1	x_t
2	$(x_t)^2$

Sumber: Wei (2006)

2.2 *Nowcasting*

Istilah "*nowcasting"* pertama kali digunakan pada bidang meteorologi untuk prakiraan cuaca dan kini mulai berkembang di bidang ekonomi. *Nowcasting* berasal dari gabungan kata "*now"* dan "*forecasting"* yang merupakan metode untuk memprediksi masa kini. *Nowcasting* mampu memenuhi kebutuhan data bagi pemerintah dalam rangka memantau keadaan ekonomi *real-time* sebagai dasar pengambilan kebijakan yang cepat dan tepat.

Nowcasting sangat relevan untuk variabel ekonomi makro yang dikumpulkan pada frekuensi rendah, dipublikasikan dengan jeda dan diperoleh dengan menggunakan informasi dari data yang terkait dengan variabel target tetapi dikumpulkan pada frekuensi yang lebih tinggi dan dipublikasikan pada waktu yang lebih tepat (Banbura dkk, 2010). Inflasi adalah salah satu indikator makro penting yang dipublikasikan setiap bulan dengan jeda beberapa hari. *Nowcasting* dapat digunakan untuk memperoleh inflasi *real-time* dengan memanfaatkan informasi dari data yang terkait dengan inflasi tetapi dikumpulkan secara bulanan, mingguan maupun harian dengan waktu publikasi data yang lebih tepat.

Beberapa pendekatan *nowcasting* yang umum digunakan di antaranya *Bridge Equation,* MIDAS, MF-VAR dan DFM. *Bridge Equation* adalah regresi linear yang menghubungan variabel frekuensi tinggi (misalnya harga beras harian) dengan variabel frekuensi rendah (misalnya IHK bulanan) sehingga menghasilkan perkiraan kondisi ekonomi terbaru sebelum publikasi data variabel frekuensi rendah. Sebelum diregresikan dengan variabel frekuensi rendah bulanan, terlebih dahulu variabel frekuensi tinggi harian diproyeksikan misalnya menggunakan ARIMA kemudian digabungkan untuk mendapatkan nilai bulanan. Proses agregasi variabel harian menjadi variabel bulanan berpotensi menghilangkan beberapa informasi penting dari data. Hal ini merupakan kelemahan *Bridge Equation.* Untuk mengatasi masalah ini dikembangkan metode estimasi berdasarkan data frekuensi campuran yaitu MIDAS. Variabel frekuensi tinggi sebagai variabel prediktor (tanpa agregasi waktu namun variabel frekuensi tinggi diberikan penimbang empiris berupa polinomial *lag* fungsional) langsung diregresikan dengan variabel frekuensi rendah sebagai variabel respon dalam

regresi MIDAS (Schumacher, 2016). Berbeda dengan MIDAS dan sejalan dengan model VAR konvensional berdasarkan data frekuensi tunggal, MF-VAR merinci dinamika gabungan variabel frekuensi tinggi (misalnya IHK harian) yang diperoleh dari variabel frekuensi rendah (misalnya IHK bulanan) dan indikator variabel frekuensi tinggi (misalnya harga beras harian). Menurut Kuzin, Marcellino, & Schumacher (2009) sulit untuk menentukan mana yang lebih baik antara MIDAS dan MF-VAR karena MF-VAR cenderung bekerja lebih baik untuk horizon yang lebih panjang sedangkan MIDAS bekerja lebih baik untuk horizon yang lebih pendek untuk *nowcasting* pertumbuhan PDB triwulanan di Kawasan Euro.

2.3 *Dynamic Factor Model*

Sejarah panjang DFM dimulai pada tahun tujuh puluhan yang dikembangkan oleh Geweke (1977) dan Sargent dan Sims (1977) yang mengestimasi model menggunakan metode *frequency-domain* (Stock & Watson, 2016). Metodologinya kemudian dikembangkan oleh Mariano dan Murasawa (2003) untuk model skala kecil dan Giannone, Reichlin dan Small (2008) untuk model skala besar (Tarsidin dkk, 2018). Menurut Mariano & Murasawa (2003) model faktor dirancang untuk meringkas variasi dalam kumpulan data yang besar menjadi hanya beberapa variabel. Ide dasar dari model faktor ini adalah memanfaatkan kolinieritas pada series data di dalam panel dengan meringkas semua informasi yang tersedia menjadi beberapa *common factor*. *Common factor* mampu menangkap sebagian besar interaksi yang dinamis antara series data dan menyediakan model yang parsimoni yang bekerja baik dalam *forecasting*. Perkiraan yang parsimoni dari set informasi dengan jumlah *common factor* yang terbatas membuat proyeksi yang layak karena membutuhkan estimasi dari sejumlah parameter yang sedikit.

Model faktor ditentukan dengan x_{it} dinotasikan sebagai indikator harga konsumen yang stasioner dan tersedia. Diasumsikan struktur faktor berikut untuk mentransformasi indikator harga konsumen menjadi *common factor* (Giannone dkk, 2008):

$$x_{i,t} = \mu_i + \lambda_{i1} f_{1,t} + \lambda_{i2} f_{2,t} + \ldots + \xi_{i,t}; i = 1, 2, \ldots, n; t = 1, 2, ..., T \quad (2.8)$$

dengan

$\mu_i =$ rata-rata,

$\lambda_{ir} =$ *loading factor*,

$f_{r,t} =$ *common factor*,

$\xi_{i,t} =$ komponen *idiosyncratic*.

$\lambda_{i1} f_{1,t} + \lambda_{i2} f_{2,t} + \ldots + \lambda_{ir} f_{r,t}$ (*common component*) dan $\xi_{i,t}$ adalah dua proses stokastik stasioner orthogonal yang tidak teramati. Diasumsikan proses *common component* adalah fungsi linear dari beberapa *common factor* dengan $r < n$. *Common factor* dapat menangkap hampir semua pergerakan di dalam perekonomian.

Misalkan model pada Persamaan (2.8) ditulis ulang dalam notasi matriks sebagai berikut (Banbura & Runstler, 2011):

$$x_t = \mu + \Lambda f_t + \xi_t, \xi_t \sim N\left(0, \Sigma_\xi\right) \quad (2.9)$$

$$f_t = \sum_{k=1}^{p} A_k f_{t-k} + Bu_t, u_t \sim WN\left(0, I_q\right) \quad (2.10)$$

Matriks varians kovarians untuk ξ_t sebagai berikut:

$$\hat{\Sigma}_\xi = \frac{1}{T} \sum_{t=1}^{T} \left(x_t - \Lambda f_t\right)' \left(x_t - \Lambda f_t\right) \quad (2.11)$$

Keterangan:

$x_t = \left(x_{1t}, x_{2t}, \ldots, x_{nt}\right)'$ berisi indikator harga konsumen berukuran $(n \times 1)$ yang ditransformasi untuk mengikuti stasioner lemah, $t = 1, 2, \ldots, T$,

$\mu = \left(\mu_1, \mu_2, \ldots, \mu_n\right)'$ berisi konstanta,

Λ = Matriks *loading factor* berukuran ($n \times r$) yang mengikuti proses stasioner,

$f_t = \left(f_{1t}, f_{2t}, \ldots, f_{rt}\right)'$ berupa *common factor* berukutan $(r \times 1)$ yang mengikuti proses stasioner,

$\xi_t = \left(\xi_{1t}, \xi_{2t}, \ldots, \xi_{nt}\right)'$ berisi komponen *idiosyncratic* berukuran $(n \times 1)$yang mengikuti proses stasioner,

$A =$ Matriks berisi koefisien model VAR(p) berukuran ($r \times r$) dengan semua akar dari det $\left(I_r - Az\right)$,

$B =$ Matriks dari *full rank* q berukuran ($r \times q$),

$u_t =$ *white noise error* berukuran ($r \times 1$) berdimensi *q*.

Variabel x_t pada Persamaan (2.9) merupakan fungsi dari intersep μ dan *r common factor* tidak teramati. Persamaan (2.10) merupakan proses struktur VAR(p) pada faktor f_t. Keduanya ξ_t dan u_t berdistribusi normal. Vektor dari komponen *idiosyncratic* ξ_t tidak berkorelasi dengan u_t pada semua *lag.*

Jumlah faktor ditentukan berdasarkan *eigenvalue*>1 pada *Principal Component Analysis* (PCA). Variabel prediktor jika ditulis dalam bentuk matriks X sebagai berikut:

$$X = \begin{bmatrix} x_{1,1} & x_{2,1} & \cdots & x_{n,1} \\ x_{1,2} & x_{2,2} & \cdots & x_{n,2} \\ \vdots & \vdots & \cdots & \vdots \\ x_{1,T} & x_{2,T} & \cdots & x_{n,T} \end{bmatrix} \tag{2.12}$$

Standarisasi data dilakukan sehingga diperoleh:

$$Z_X = \begin{bmatrix} z_1^{'} \\ z_2^{'} \\ \vdots \\ z_n^{'} \end{bmatrix} = \begin{bmatrix} z_{1,1} & z_{2,1} & \cdots & z_{n,1} \\ z_{1,2} & z_{2,2} & \cdots & z_{n,2} \\ \vdots & \vdots & \cdots & \vdots \\ z_{1,T} & z_{2,T} & \cdots & z_{n,T} \end{bmatrix} == \begin{bmatrix} \frac{x_{1,1} - \frac{1}{T}\sum_{t=1}^{T} x_{1,t}}{\sqrt{\sum_{t=1}^{T}\left(x_{1,t} - \bar{x}_1^2\right)}} & \frac{x_{2,1} - \frac{1}{T}\sum_{t=1}^{T} x_{2,t}}{\sqrt{\sum_{t=1}^{T}\left(x_{2,t} - \bar{x}_2^2\right)}} & \cdots & \frac{x_{n,1} - \frac{1}{T}\sum_{t=1}^{T} x_{n,t}}{\sqrt{\sum_{t=1}^{T}\left(x_{n,t} - \bar{x}_n^2\right)}} \\ \frac{x_{1,2} - \frac{1}{T}\sum_{t=1}^{T} x_{1,t}}{\sqrt{\sum_{t=1}^{T}\left(x_{1,t} - \bar{x}_1^2\right)}} & \frac{x_{2,2} - \frac{1}{T}\sum_{t=1}^{T} x_{2,t}}{\sqrt{\sum_{t=1}^{T}\left(x_{2,t} - \bar{x}_2^2\right)}} & \cdots & \frac{x_{n,2} - \frac{1}{T}\sum_{t=1}^{T} x_{n,t}}{\sqrt{\sum_{t=1}^{T}\left(x_{n,t} - \bar{x}_n^2\right)}} \\ \vdots & \vdots & \cdots & \vdots \\ \frac{x_{1,T} - \frac{1}{T}\sum_{t=1}^{T} x_{1,t}}{\sqrt{\sum_{t=1}^{T}\left(x_{1,t} - \bar{x}_1^2\right)}} & \frac{x_{2,T} - \frac{1}{T}\sum_{t=1}^{T} x_{2,t}}{\sqrt{\sum_{t=1}^{T}\left(x_{2,t} - \bar{x}_2^2\right)}} & \cdots & \frac{x_{n,T} - \frac{1}{T}\sum_{t=1}^{T} x_{n,t}}{\sqrt{\sum_{t=1}^{T}\left(x_{n,t} - \bar{x}_n^2\right)}} \end{bmatrix}$$

$$Z_X == \begin{bmatrix} \frac{x_{1,1}-\bar{x}_1}{\sqrt{s_{11}}} & \frac{x_{2,1}-\bar{x}_2}{\sqrt{s_{22}}} & \cdots & \frac{x_{n,1}-\bar{x}_n}{\sqrt{s_{nn}}} \\ \frac{x_{1,2}-\bar{x}_1}{\sqrt{s_{11}}} & \frac{x_{2,2}-\bar{x}_2}{\sqrt{s_{22}}} & \cdots & \frac{x_{n,2}-\bar{x}_n}{\sqrt{s_{nn}}} \\ \vdots & \vdots & \cdots & \vdots \\ \frac{x_{1,T}-\bar{x}_1}{\sqrt{s_{11}}} & \frac{x_{2,T}-\bar{x}_2}{\sqrt{s_{22}}} & \cdots & \frac{x_{n,T}-\bar{x}_n}{\sqrt{s_{nn}}} \end{bmatrix} \tag{2.13}$$

dengan vektor rata-rata sampel:

$$\bar{z} = \frac{1}{T}\left(1'Z_X\right)' = \frac{1}{T}Z_X'1 = \frac{1}{T}\begin{bmatrix} \sum_{t=1}^{T}\frac{x_{1,t}-\bar{x}_1}{\sqrt{s_{11}}} \\ \sum_{t=1}^{T}\frac{x_{2,t}-\bar{x}_2}{\sqrt{s_{22}}} \\ \vdots \\ \sum_{t=1}^{T}\frac{x_{n,t}-\bar{x}_n}{\sqrt{s_{nn}}} \end{bmatrix} \tag{2.14}$$

dan matriks kovarians sampel

$$S_{Z_X} = \frac{1}{T-1}\left(Z_X - \frac{1}{T}11'Z_X\right)'\left(Z_X - \frac{1}{T}11'Z_X\right) = \frac{1}{T-1}\left(Z_X - 1\bar{z}'\right)'\left(Z_X - 1\bar{z}'\right) = \frac{1}{T-1}Z_X'Z_X$$

$$= \frac{1}{T-1}\begin{bmatrix} \frac{(T-1)s_{11}}{s_{11}} & \frac{(T-1)s_{12}}{\sqrt{s_{11}}\sqrt{s_{22}}} & \cdots & \frac{(T-1)s_{1n}}{\sqrt{s_{11}}\sqrt{s_{nn}}} \\ \frac{(T-1)s_{12}}{\sqrt{s_{11}}\sqrt{s_{22}}} & \frac{(T-1)s_{22}}{s_{22}} & \cdots & \frac{(T-1)s_{2n}}{\sqrt{s_{22}}\sqrt{s_{nn}}} \\ \vdots & \vdots & \cdots & \vdots \\ \frac{(T-1)s_{1n}}{\sqrt{s_{11}}\sqrt{s_{nn}}} & \frac{(T-1)s_{2n}}{\sqrt{s_{22}}\sqrt{s_{nn}}} & \cdots & \frac{(T-1)s_{nn}}{s_{nn}} \end{bmatrix} = R \tag{2.15}$$

$Z_X'Z_X$ merupakan matriks korelasi dengan *eigenvalue* sebanyak $r = n$ solusi dari persamaan determinan berikut:

$$\left|Z_X'Z_X - \lambda I\right| = 0\,. \tag{2.16}$$

Setiap solusi *eigenvalue* memiliki *eigenvector* yang memenuhi sistem persamaan homogen berikut:

$$\left(Z_X'Z_X - \lambda_r I\right)e_r = 0 \tag{2.17}$$

$\left(\hat{\lambda}_r, \hat{e}_r\right)$ adalah pasangan *eigenvalue* dan *eigenvector* ke-*r* dari matriks *R* dengan $\hat{\lambda}_1 \geq \hat{\lambda}_2 \geq \ldots \geq \hat{\lambda}_r \geq 0$.

Panjang *lag* (*p*) ditentukan berdasarkan nilai *Akaike Information Criteria* (AIC) yang paling minimum. Nilai AIC diperoleh dari persamaan berikut:

$$AIC = T \log|\Sigma| + 2n \tag{2.18}$$

Matriks varians kovarians *error* dari model VAR didefinisikan sebagai $\hat{u}_t$ dengan *eigenvalue* ke-*i* dari matriks $\hat{u}_t$ diurutkan dari yang terbesar sampai yang terkecil sedemikian rupa sehingga $\hat{\lambda}_1 \geq \hat{\lambda}_2 \geq \ldots \geq \hat{\lambda}_r \geq 0$. Normalisasi ke-*l* dari *eigenvalue* ke-*l+1* sebagai berikut:

$$\hat{D}_l = \left(\frac{\hat{\lambda}_{l+1}^2}{\sum_{l=1}^{r} \hat{\lambda}_l^2} \right) \tag{2.19}$$

Banyaknya guncangan (*q*) yang optimal adalah minimum dari *l* pada vektor *L* dengan vektor *L* didefinisikan sebagai berikut:

$$L = \left\{ l : \hat{D}_l < m / \min\left[n^{\frac{1}{2}-\delta}, T^{\frac{1}{2}-\delta} \right] \right\} \tag{2.20}$$

$$\hat{q} = \min\left\{ l \in L \right\} \tag{2.21}$$

Keterangan:

$\hat{D}_l$: Normalisasi ke-*l*

m : Tingkat toleransi dengan $0 < m <\sim$

δ : Tingkat toleransi dengan $0 < \delta < 0,5$

Giannone dkk (2008) mengadopsi model faktor dua tahap. Tahap pertama yaitu parameter dari model, Λ dan f_t, diestimasi dengan *Principal Component Analysis* (PCA) menggunakan *standardized* dari panel data seimbang x_t yang tidak mengandung *missing value* dan *outlier*. Tahap kedua yaitu *Kalman Smoothing* yang digunakan untuk estimasi ulang terhadap faktor untuk panel tidak seimbang x_t dengan mempertimbangkan parameter yang telah diperoleh pada tahap sebelumnya.

Estimator *Principal Component* (PC) dari F_t adalah estimator rata-rata tertimbang dari persamaan $\Lambda'\Lambda/n = I_r$, di mana Λ adalah matriks *eigenvector* yang berasosiasi dengan *r eigenvalue* terbesar dari matriks varians sampel dari x_t, $\hat{\Sigma}_x = T^{-1}\sum_{t=1}^{T} x_t x_t'$. Estimator *PC* merupakan solusi dari masalah *least square*:

$$\min_{F_1,\ldots,F_T} V_r(\Lambda, F), \text{ dengan } V_r(\Lambda, F) = \frac{1}{nT}\sum_{t=1}^{T}(x_t - \Lambda F_t)'(x_t - \Lambda F_t) \tag{2.22}$$

tunduk pada normalisasi $n^{-1}\Lambda'\Lambda = I_r$. Untuk menyelesaikan Persamaan (2.18), pertama meminimalkan F_t *given* Λ untuk mendapatkan $F_t\left(\Lambda\left(\Lambda'\Lambda\right)^{-1}\right) = \left(\Lambda'\Lambda\right)^{-1}\Lambda' x_t$ kemudian konsentrasikan fungsi tujuan sehingga Persamaan (4.1) menjadi $\min_\Lambda T^{-1}\sum_{t=1}^{T} x_t'\left(I - \Lambda\left(\Lambda'\Lambda\right)^{-1}\right)x_t$. Masalah minimalisasi ini setara dengan $\max_\Lambda tr\left\{\left(\Lambda'\Lambda\right)^{1/2}\Lambda'\left(T^{-1}\sum_{t=1}^{T} x_t' x_t\right)\Lambda\left(\Lambda'\Lambda\right)^{1/2}\right\}$ setara dengan $\max_\Lambda tr\left(\Lambda'\hat{\Sigma}_{xx}\Lambda\right)$ tunduk pada $\Lambda'\Lambda/n = I_r$. Solusi untuk masalah ini adalah mengatur $\hat{\Lambda}$ sama dengan *eigenvector* berskala dari $\hat{\Sigma}_{xx}$ yang sesuai dengan *r eigenvalue* terbesar. Karena $\hat{\Lambda}'\hat{\Lambda} = nI_r$ maka estimator *least square* dari F_t adalah $\hat{F}_t = \hat{F}_t\left(n^{-1}\hat{\Lambda}\right) = n^{-1}\hat{\Lambda}' x_t$ yang merupakan PC *r* pertama yang terskalakan. Hasilnya akan digunakan untuk *nowcasting* variabel respon IHK pada persamaan berikut:

$$y_t = \beta_0 + \beta'\hat{f}_t + \varepsilon_t \tag{2.23}$$

Parameter pada Persamaan (2.23) diestimasi dengan OLS dan *forecast* untuk y_{t+h} ditunjukkan oleh persamaan berikut:

$$\hat{y}_{t+h} = \hat{\beta}_0 + \hat{\beta}'\hat{f}_{t+h} \tag{2.24}$$

2.4 *Support Vector Regression*

Support Vector Regression (SVR) merupakan bagian dari metode *Support Vector Machine* (SVM). Jika output dari model SVM berupa bilangan bulat atau diskrit, output data dalam kasus regresi berupa bilangan riil atau

kontinu. Dengan menggunakan konsep ε*-insensitive loss function*, yang diperkenalkan oleh Vapnik, SVM bisa digeneralisasi untuk melakukan pendekatan regresi. Menurut Ding (2012) keunggulan SVR adalah kemampuan mengatasi masalah data nonlinear dengan trik kernel. Jika regresi linear menghasilkan fungsi linear berupa garis lurus, algoritma SVR menghasilkan tren data bergelombang yang mengikuti jalur data yang terbentuk sehingga prediksi data yang dihasilkan lebih akurat. Selain itu, keunggulan SVR menurut Ding (2012) dan Riyani, Prastyo, & Suhartono (2019) yaitu kemampuan dalam mengatasi masalah *overfitting*, model yang dihasilkan hanya baik untuk data *training* dan tidak untuk data *testing*. Tujuan dasar SVM untuk klasifikasi adalah mencari sebuah *hyperplane* pemisah yang memaksimalkan margin antara dua kelas. Dalam kasus regresi, tujuan dasar SVR adalah menemukan fungsi *f(x)* yang memiliki deviasi atau *epsilon* (ε) paling besar dari target aktual (y_i) yang diperoleh dari *T* set data *training*, (x_t, y_t) di mana $t = 1, 2, \ldots, T$ dengan input $x_t = \{x_{1,t}, x_{2,t}, \ldots, x_{n,t}\} \subseteq R^n$ dan output $y_t = \{y_1, \ldots, y_T\} \subseteq R$. Jika ε bernilai 0 maka regresi bernilai sempurna atau digambarkan garis yang berada di tengah.

Berdasarkan Gambar 2.2 nampak ada tiga buah garis, yaitu:

a. garis paling atas disebut garis batas + merupakan garis yang melalui poin (satu *support vector*) yang menjadi titik terluar atau batas dari klaster +,
b. garis tengah disebut *hyperplane* merupakan garis yang memisahkan dua klaster yaitu klaster + dan klaster -,
c. Garis paling bawah disebut garis batas – merupakan garis yang melewati poin (satu *support vector*) yang menjadi titik terluar atau batas dari klaster-

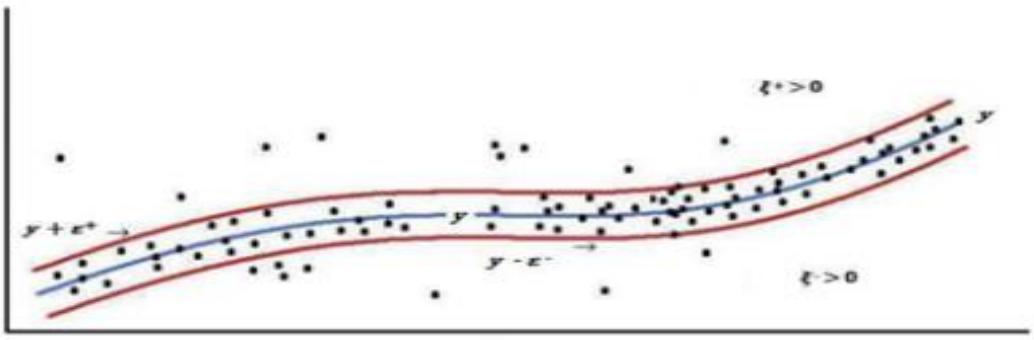

Sumber: Awad dan Khanna, 2015
Gambar 2.2 SVR Linear Satu Dimensi

Jarak antara garis batas + dengan garis tengah sama dengan jarak antara garis batas - dengan garis tengah disebut *epsilon* dengan simbol ε. Beberapa data poin ada yang bisa menjadi calon batas disebut sebagai *potential support vectors* sehingga semua data poin bisa masuk ke dalam satu klaster dengan tetap meminimasi nilai ε -nya. Semua titik atau data yang berada di luar area *tube* akan dikenai nilai penalti atau dikenal dengan parameter *C* pada SVR.

Misal terdapat fungsi berikut sebagai garis regresi:

$$f(x_t) = w'\phi(x_t) + b \tag{2.25}$$

dengan $\phi(x)$ menunjukkan titik di dalam *feature space* $\mathcal{F}$, hasil pemetaan x di dalam *input space*, koefisien w (vektor pembobot) dan b (bias) diestimasi dengan cara meminimalkan fungsi resiko (*risk function*) yang didefinisikan dalam persamaan:

$$R(C) = \frac{1}{2}\|w\|^2 + C\frac{1}{T}\sum_{t=1}^{T} L_\varepsilon\left(y_t, f(x_t)\right) \tag{2.26}$$

dengan $y_t - w\phi(x_t) - b \le \varepsilon$; $w\phi(x_t) - y_t + b \le \varepsilon$; $t = 1, 2, \ldots, T$, dan ε *-insensitive loss function* ditunjukkan oleh persamaan berikut:

$$L_\varepsilon\left(y_t, f(x_t)\right) = \begin{cases} 0; \left|y_t - f(x_t)\right| \le \varepsilon, \\ \left|y_t - f(x_t)\right| - \varepsilon; lainnya. \end{cases} . \tag{2.27}$$

Faktor $\|w\|^2$ adalah reguralisasi. Agar kapasitas fungsi dapat dikontrol maka fungsi harus dibuat setipis mungkin dengan cara meminimalkan $\|w\|^2$. Faktor kedua dalam fungsi tujuan adalah kesalahan empirik (*empirical error*) yang diukur dengan ε *-insensitive loss function*. Dengan menggunakan ide ε *-insensitive loss function* norm dari *w* harus diminimalkan agar mendapatkan generalisasi yang baik untuk fungsi regresi f. Karena itu diperlukannya menyelesaikan problem estimasi berikut:

$$\min \frac{1}{2}\|w\|^2 \tag{2.28}$$

dengan $y_t - w\phi(x_t) - b \le \varepsilon$; $w\phi(x_t) - y_t + b \le \varepsilon$; $t = 1, 2, \ldots, T$; dan $\sum e_t^2 = \sum (y_t - \hat{y}_t)^2 = \sum (y_t - (b_0 + b_1 x_t))^2$.

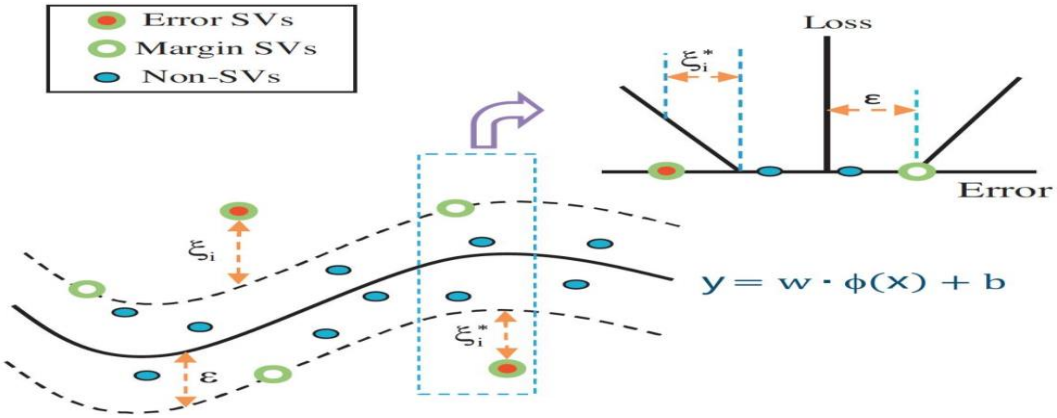

Gambar 2.3 Batas *Error* dalam SVR

Asumsikan bahwa ada suatu fungsi f yang dapat mengaproksimasi semua titik (x_t, y_t) dengan presisi ε. Semua titik ada dalam rentang $f \pm \varepsilon$ disebut *feasible,* nilai *error* dianggap 0. Kondisi dimana ada beberapa titik yang keluar dari rentang $f \pm \varepsilon$ disebut *infeasible,* nilai *error* akan dihitung sebagai variabel *slack* ξ atau ξ^*. Solusi pada masalah ini adalah sebuah tabung yang dibentuk dari sebuah garis dan memiliki toleransi terhadap *error* seperti yang ditunjukkan pada Gambar 2.3. Selanjutnya masalah optimasi pada Persamaan (2.26) dapat ditransformasi ke dalam bentuk berikut:

$$\min R(w, \xi_t, \xi_t^*) = \frac{1}{2}\|w\|^2 + C\sum_{t=1}^{T}(\xi_t + \xi_t^*) \tag{2.29}$$

dengan batasan $y_t - w'\phi(x_t) - b - \xi_t \le \varepsilon$; $w'\phi(x_t) - y_t + b - \xi_t^* \le \varepsilon$; dan $\xi_t, \xi_t^* \ge 0$, $t = 1, 2, \ldots, T$.

Kostanta C menentukan tawar menawar (*trade off*) antara ketipisan fungsi f dan batas atas deviasi lebih dari ε yang masih ditoleransi. Semua deviasi lebih besar daripada ε akan dikenakan penalti sebesar C. Dalam SVR, ε ekuivalen dengan akurasi dari aproksimasi terhadap data *training*, nilai ε yang kecil akan dikaitkan dengan nilai yang tinggi pada variabel *slack* ξ_t^* dan akurasi

aproksimasi yang tinggi. Sebaliknya, nilai yang tinggi untuk ε berkaitan dengan nilai ξ_t^* yang kecil dan aproksimasi yang rendah. Menurut Persamaan (2.29) nilai yang tinggi untuk variabel *slack* akan membuat kesalahan empirik mempunyai pengaruh yang besar terhadap faktor regulasi. Dalam SVR, *support vector* adalah data *training* yang terletak pada dan diluar batas f dari fungsi keputusan, karena itu jumlah *support vector* menurun dengan naiknya ε .

Optimalisasi pada Persamaan (2.29) dapat diselesaikan dengan *primal lagrangian* dalam bentuk sebagai berikut (Hong, 2009):

$$\begin{aligned} L\left(w,b,\xi_t,\xi_t^*,\alpha_t,\alpha_t^*,\beta_t,\beta_t^*\right) = \frac{1}{2}\|w\|^2 + C\left(\sum_{t=1}^{T}\left(\xi_t+\xi_t^*\right)\right) \\ -\sum_{t=1}^{T}\beta_t\left[w\phi\left(x_t\right)+b-y_t+\varepsilon+\xi_t\right] \\ -\sum_{t=1}^{T}\beta_t^*\left[y_t-w\phi\left(x_t\right)-b+\varepsilon+\xi_t^*\right] \\ -\sum_{t=1}^{T}\left(\alpha_t\xi_t+\alpha_t^*\xi_t^*\right). \end{aligned} \tag{2.30}$$

Persamaan (2.30) diminimalkan pada variabel primal w,b,ξ_t,ξ_t^* dan dimaksimalkan dalam bentuk *lagrangian multiplier* nonnegatif $\alpha_t,\alpha_t^*,\beta_t,\beta_t^*$ seperti ditampilkan pada persamaan berikut (Hong, 2009):

$$\frac{\partial L}{\partial w} = w - \sum_{t=1}^{T}\left(\beta_t-\beta_t^*\right)\phi\left(x_t\right) = 0, \tag{2.31}$$

$$\frac{\partial L}{\partial b} = \sum_{t=1}^{T}\left(\beta_t^*-\beta_t\right) = 0, \tag{2.32}$$

$$\frac{\partial L}{\partial \xi_t} = C-\beta_t-\alpha_t = 0, \tag{2.33}$$

$$\frac{\partial L}{\partial \xi_t^*} = C-\beta_t^*-\alpha_t^* = 0\,. \tag{2.34}$$

Akhirnya kondisi Karush-Kuhn-Tucker diterapkan pada regresi dan dengan menggunakan Persamaan (2.29) sehingga diperoleh *dual lagrangian* dengan mensubtitusikan Persamaan (2.31), (2.32), (2.33), dan (2.34) ke Persamaan (2.30). Persamaan *dual lagrangian*, Persamaan (2.35), diperoleh ketika fungsi kernel $K\left(x_t,x_j\right) = \varphi'\left(x_t\right)\varphi\left(x_j\right)$.

$$\partial\left(\beta_t,\beta_t^*\right)=\sum_{t=1}^{T}y_t\left(\beta_t-\beta_t^*\right)-\varepsilon\sum_{t=1}^{T}\left(\beta_t+\beta_t^*\right)$$
$$-\frac{1}{2}\sum_{t=1}^{T}\sum_{j=1}^{T}\left(\beta_t-\beta_t^*\right)\left(\beta_j-\beta_j^*\right)K\left(x_t,x_j\right) \tag{2.35}$$

dengan batasan $\sum_{t=1}^{T}\left(\beta_t-\beta_t^*\right)=0\,;0\le\beta_t\le C\,;0\le\beta_t^*\le C\,;t=1,2,\ldots,T$.

Lagrange Multipliers pada Persamaan (2.35) memenuhi persamaan $\beta_t*\beta_t^*=0$. *Lagrange Multipliers* β_t dan β_t^* dihitung dan vektor bobot optimal yang diharapkan dari *hyperplane* regresi sebagai berikut:

$$w^*=\sum_{t=1}^{T}\left(\beta_t-\beta_t^*\right)\phi\left(x_t\right), \tag{2.36}$$

sehingga didapatkan fungsi regresi:

$$f\left(x_t,\beta_t,\beta_t^*\right)=\sum_{t=1}^{T}\left(\beta_t-\beta_t^*\right)K\left(x_t,x_j\right)+b\,. \tag{2.37}$$

Di dalam kasus non linear, SVR akan menstranformasikan *original input space* ke dalam dimensi yang lebih tinggi, *feature space*. Setelah itu, SVR akan melakukan perhitungan sama seperti perhitungan linear, untuk mencari *hyperplane* regresi yang optimal. Fungsi kernel yang digunakan ditunjukkan oleh Tabel 2.2.

Tabel 2.2 Fungsi Kernel

Kernel	Formula
Linear	$\left(x_t,x_t'\right)$
RBF/ Gaussian	$\exp\left(-\gamma\left\|x_t-x_t'\right\|^2\right)$, $\gamma>0$
Polynomial	$\left(\gamma\left(x_t,x_t'\right)+r\right)^d$,d=degree,r=coef0

Performansi model *nowcasting* SVR tergantung pada penggunaan *hyperparameters* C, *epsilon* (ε), *degree*, parameter kernel (*gamma*) dan fungsi kernel yang digunakan.

C : parameter C untuk memberikan nilai penalti pada data jika terjadi eror pada *nowcasting*,

epsilon : parameter *epsilon* menandakan *epsilon tube* yang berarti tidak ada penalti di dalam *loss function* terhadap *point nowcasting* selama masih berada di dalam jarak *epsilon* dari nilai aktual,

degree : *degree* hanya digunakan oleh fungsi kernel *polynomial* (poly). Nilai parameter *degree* tidak digunakan pada kernel lainnya,

gamma : koefisien dari kernel RBF, Poly.

Perbedaan antara *hyperparameter* dan parameter adalah nilai *hyperparameter* ditentukan sebelum proses *training* dilakukan. *Grid search* merupakan salah satu metode konvensional dalam menentukan parameter yang optimal untuk sebuah model dengan menentukan *range* atau jangkauan parameter yang akan digunakan terlebih dahulu. *Grid search* memiliki akurasi yang baik karena semua kemungkinan pasangan parameter diuji untuk menentukan pasangan parameter mana yang memiliki akurasi paling baik. Hasil dari *Grid Search* digunakan di dalam model *nowcasting*. Kelemahan dari penggunaan *Grid Search* yaitu proses pencarian parameter yang optimal dengan metode *Grid Search* membutuhkan waktu yang lama sehingga metode ini sering disebut metode *cost expensive*.

2.5 *Time Series Regression*

Montgomery, Jennings, & Kulahci (2008) menunjukkan model regresi pada data *time series* melalui persamaan berikut:

$$y_t = \beta_0 + \beta_1 x_{1,t} + \beta_2 x_{2,t} + \ldots + \beta_n x_{n,t} + \varepsilon_t, t = 1, 2, \ldots, T \tag{2.38}$$

dengan

y_t = variabel respon pada waktu ke-*t*

$x_{i,t}$ = variabel prediktor ke-*i* pada waktu ke-*t*, $i = 1, 2, \ldots, n$

β_0 = nilai intersep model regresi

β_n = koefisien regresi variabel prediktor ke-*n*

ε_t = *error* pada waktu ke- *t* dengan asumsi IIDN (0, σ^2) yang artinya adalah independen, identik, dan berdistribusi normal dengan rata-rata nol dan varians konstan.

Persamaan (2.20) jika ditulis dalam bentuk matriks menjadi:

$$y = X\beta + \varepsilon \tag{2.39}$$

Nilai penduga parameter dengan OLS dengan meminimumkan jumlah kuadrat galat (*error*) dalam bentuk vektor dapat ditulis :

$$\hat{\beta} = \left(X'X\right)^{-1} X'y \tag{2.40}$$

dengan $\hat{\beta} = \left(\hat{\beta}_0, \hat{\beta}_1, \ldots, \hat{\beta}_n\right)$ adalah vektor *n+1* sebagai koefisien regresi, *X* adalah matriks variabel prediktor berukuran *t x (n+1)* dengan kolom pertama bernilai 1 untuk konstanta, dan *y* adalah vektor variabel respon.

Jika terjadi multikolinearitas antar variabel prediktor yang diketahui melalui $VIF_i = \frac{1}{1-R_i^2} > 10$, *Principal Component* (PC) dibentuk untuk mengatasinya. Menurut Ifadah (2011) keunggulan PCA yaitu mampu menghilangkan multikolinearitas tanpa harus mengurangi variabel asal. Sebelum *Principal Component Analysis* (PCA), perlu dilakukan uji Batlett dan pemeriksaan *Kaiser Meyer Olkin* (KMO).

Uji Bartlett digunakan untuk menguji kebebasan antar variabel prediktor $x_{1,t}, x_{2,t}, \ldots, x_{n,t}$ dengan rumusan hipotesis sebagai berikut:

$H_0 : \rho = I$

$H_1 : \rho \neq I; g = 0,1,2,\ldots$

Statistik uji:

$$Bartlett = \frac{(T-1)}{\left(1-\bar{r}^2\right)}\left[\sum_i^n \sum_g^{n-g}{}_{i<g}\left(\bar{r}_{ig} - \bar{r}\right)^2 - \hat{\gamma}\sum_{i=1}^n \left(\bar{r}_g - \bar{r}\right)^2\right] \tag{2.41}$$

Daerah kritis: $Bartlett_{hit} > \chi^2_{\alpha,(n+1)(n-1)/2}$ atau $p - value < \alpha$.

$$\bar{r}_g = \frac{1}{n-1}\sum_{i=1}^n \bar{r}_{ig}\ , \tag{2.42}$$

$$\bar{r} = \frac{2}{n(1-n)}\sum_i \sum \bar{r}_{ig}\ , \tag{2.43}$$

$$\hat{\gamma}_{ig} = \frac{(n-1)^2\left(1-\left(1-\bar{r}\right)\right)^2}{n-(n-2)\left(1-\bar{r}\right)^2}\ , \tag{2.44}$$

dengan

$\bar{r}_g$ adalah rata-rata elemen diagonal pada kolom atau baris ke-*g* dari matriks ***R*** (matriks korelasi) dan $\bar{r}$ adalah rata-rata keseluruhan dari elemen diagonal.

Pemeriksaan KMO bertujuan untuk mengetahui kecukupan data untuk dilakukan PCA dengan rumus sebagai berikut:

$$KMO = \frac{\sum_{i=1}^{n}\sum_{g=1}^{n} r_{ig}^2}{\sum_{i=1}^{n}\sum_{g=1}^{n} r_{ig}^2 + \sum_{i=1}^{n}\sum_{g=1}^{n} a_{ig}^2}, \tag{2.45}$$

dengan

r_{ig} : koefisien korelasi antara variabel ke-*i* dan *g*,

a_{ig} : koefisien korelasi parsial antara variabel ke-*i* dan *g*.

KMO>0,5 menunjukkan bahwa data sudah cukup untuk dilakukan PCA.

Eigenvalue diperoleh dengan menyelesaikan Persamaan (2.16) dan setiap solusi *eigenvalue* memiliki *eigenvector* yang memenuhi sistem persamaan homogen pada Persamaan (2.17). $\left(\hat{\lambda}_r, \hat{e}_r\right)$ adalah pasangan *eigenvalue* dan *eigenvector* ke-*r* dari matriks *R* dengan $\hat{\lambda}_1 \geq \hat{\lambda}_2 \geq \ldots \geq \hat{\lambda}_r \geq 0$. *Eigenvector* digunakan untuk membentuk matriks *Z* ke dalam suku-suku *principal component W*.

$$W = \begin{bmatrix} W_1 \\ W_2 \\ \vdots \\ W_r \end{bmatrix} = \begin{bmatrix} \hat{e}_{i,1}'z \\ \hat{e}_{i,2}'z \\ \vdots \\ \hat{e}_{i,r}'z \end{bmatrix} = \begin{bmatrix} \hat{e}_{1,1}'z_1 + \hat{e}_{2,1}'z_2 + \ldots + \hat{e}_{n,1}'z_n \\ \hat{e}_{1,2}'z_1 + \hat{e}_{2,2}'z_2 + \ldots + \hat{e}_{n,2}'z_n \\ \vdots \\ \hat{e}_{1,r}'z_1 + \hat{e}_{2,r}'z_2 + \ldots + \hat{e}_{n,r}'z_n \end{bmatrix} \tag{2.46}$$

Proporsi total varians sampel yang dapat dijelaskan oleh *principal component* ke-*r* $= \frac{\hat{\lambda}_r}{n}, r = 1, 2, \ldots, n$.

Variabel respon jika ditulis dalam bentuk matriks y yaitu $y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_T \end{bmatrix}$

dengan Z_{y_t} merupakan matriks hasil standarisasi dari variabel respon y :

$$Z_{y_t} = \begin{bmatrix} \dfrac{y_1 - \bar{y}}{\sqrt{\sum_{t=1}^{T}\left(y_t - \bar{y}\right)^2}} \\ \dfrac{y_2 - \bar{y}}{\sqrt{\sum_{t=1}^{T}\left(y_t - \bar{y}\right)^2}} \\ \vdots \\ \dfrac{y_T - \bar{y}}{\sqrt{\sum_{t=1}^{T}\left(y_t - \bar{y}\right)^2}} \end{bmatrix} = \begin{bmatrix} z_{y_1} \\ z_{y_2} \\ \vdots \\ z_{y_T} \end{bmatrix} \tag{2.47}$$

Variabel prediktor terdiri dari matriks *W*. Perumusan model TSR yaitu:

$$Z_{y_t} = \beta_0 + \sum_{r=1}^{r} \beta_r w_{r,t} + v_t \tag{2.48}$$

Model di atas jika dirumuskan ke dalam bentuk matriks sebagai berikut:

$$Z_y = W\beta + \varepsilon \tag{2.49}$$

dengan

$$Z_y = \begin{bmatrix} z_{y_1} \\ \vdots \\ z_{y_T} \end{bmatrix}; W = \begin{bmatrix} 1 & w_{1,1} & \dots & w_{r,1} \\ 1 & w_{1,2} & \dots & w_{r,2} \\ \vdots & \vdots & \dots & \vdots \\ 1 & w_{1,T} & \dots & w_{r,T} \end{bmatrix}; \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_r \end{bmatrix}; \varepsilon = \begin{bmatrix} \varepsilon_2 \\ \varepsilon_3 \\ \vdots \\ \varepsilon_T \end{bmatrix} \tag{2.50}$$

Estimasi nilai parameter dengan metode OLS:

$$Z_y = W\beta + \varepsilon; \hat{Z}_y = W\hat{\beta} \tag{2.51}$$

$$\varepsilon = Z_y - \hat{Z}_y = Z_y - W\hat{\beta} \tag{2.52}$$

$$\varepsilon^2 = \left(Z_y - W\hat{\beta}\right)'\left(Z_y - W\hat{\beta}\right) = (Z_y' - \hat{\beta}'W')\left(Z_y - W\hat{\beta}\right)$$

$$\varepsilon^2 = Z_y'Z_y - 2\hat{\beta}'W'Z_y + \hat{\beta}'W'W\hat{\beta} \tag{2.53}$$

$$\frac{\partial \varepsilon^2}{\partial \hat{\beta}'} = 0 \tag{2.54}$$

$$\frac{\partial \varepsilon^2}{\partial \hat{\beta}'} = \frac{\partial\left(Z_y'Z_y - 2\hat{\beta}'W'Z_y + \hat{\beta}'W'W\hat{\beta}\right)}{\partial \hat{\beta}'} = 0$$

$$-2W'Z_y + 2W'W\hat{\beta} = 0$$

$$W'W\hat{\beta} = W'Z_y \text{ maka } \hat{\beta} = \left(W'W\right)^{-1}W'Z_y \tag{2.55}$$

Setelah didapatkan model regresi *time series*, langkah selanjutnya yaitu uji hipotesis estimator model dan uji asumsi residual. Uji hipotesis estimator model regresi dilakukan dengan dua cara yaitu uji serentak dan uji parsial. Berikut uji serentak estimator model regresi:

Hipotesis :

$H_0 : \beta_1 = \beta_2 = \ldots = \beta_n$

$H_1 :$ minimal ada satu $\beta_i \neq 0; i = 1, 2, \ldots, n$

Statistik uji:

$$F_{hit} = \frac{\hat{\beta}' X' y - n\bar{y}^2 / n}{y' y - \hat{\beta}' X' y / (T - n - 1)} \tag{2.56}$$

Daerah kritis: Tolak H_0 jika $F_{hit} > F_{\alpha;n,(T-n-1)}$ atau *p-value*<*α*

Uji parsial model regresi sebagai berikut:

Hipotesis:

$H_0 : \beta_i = 0$

$H_1 : \beta_i \neq 0; i = 0, 1, 2, \ldots, n$

Statistik uji:

$$t_{hit} = \frac{\hat{\beta}_i}{SE\left(\hat{\beta}_i\right)} \tag{2.57}$$

Daerah kritis: Tolak H_0 jika $|t_{hit}| > t_{\frac{\alpha}{2};(T-n-1)}$ atau *p-value*<*α*

Residual adalah selisih antara data aktual pada variabel respon dengan hasil *nowcasting*-nya. Uji asumsi pada residual antara lain:

1. Asumsi Normalitas

Uji asumsi residual mengikuti distribusi normal dengan uji *Kolmogorov_Smirnov* sebagai berikut:

Hipotesis:

$H_0 : \varepsilon_t$ berdistribusi normal

$H_1 : \varepsilon_t$ tidak berdistribusi normal

Statistik uji:

$$D_{hit} = \max\left|F\left(Z_{e_t}\right) - F\left(\frac{t}{T}\right)\right| \tag{2.58}$$

dengan

$F\left(\frac{t}{T}\right)$: Probabilitas kumulatif dari $\frac{t}{T}$ atau $F\left(\frac{t}{T}\right) = f\left(t \le T\right), t = 1, 2, \ldots, T$

$F\left(Z_{e_t}\right)$: Probabilitas kumulatif dari $Z_{e_t} = \frac{e_t - \bar{e}}{s_{e_t}}$ atau $F\left(Z_{e_t}\right) = f\left(Z \le Z_{e_t}\right)$

Daerah kritis: Tolak H_0 jika $D_{hit} > D_{T;\alpha}$ atau *p-value*<*α*

2. Asumsi *White Noise*

Residual dikatakan *white noise* jika antar residual data saling independen. Pemeriksaan dapat dilakukan dengan melihat plot ACF/ korelogram. Asumsi *white noise* terpenuhi jika tidak terdapat *lag* yang melewati batas signifikan pada plot ACF. Jika asumsi *white noise* tidak terpenuhi, lag y_t digunakan sebagai tambahan variabel prediktor. Pemilihan *lag* dapat ditentukan berdasarkan plot ACF dan PACF (Lee, Suhartono, & Hamzah, 2010). Uji *Ljung-Box* dapat digunakan untuk menguji asumsi *white noise*. Hipotesis yang digunakan dalam pengujian *Ljung-Box* (Wei, 2006):

$H_0 : \rho_1 = \rho_2 = \ldots = \rho_k = 0$ (Residual memenuhi asumsi *white noise*)

H_1 : minimal ada satu $\rho_j \ne 0; j = 1, 2, \ldots, k$ (Residual tidak memenuhi asumsi *white noise*)

Statistik uji:

$$Q = T\left(T+2\right)\sum_{j=1}^{k}\frac{\hat{\rho}_j^2}{\left(T-j\right)} \tag{2.59}$$

dengan T adalah banyak waktu pengamatan dan $\hat{\rho}_j$ menunjukkan ACF residual pada lag ke-*j*.

Daerah kritis: Tolak H_0 jika $Q > \chi^2_{\alpha;k-(p+q)}$ atau *p-value*<*α*.

2.6 Pemilihan *Model* Terbaik

Hyndman & Koehler (2006) menyatakan bahwa RMSE dan MAD dapat digunakan untuk membandingkan metode yang berbeda pada data dengan skala

yang sama. RMSE lebih disukai daripada MSE karena RMSE dapat disamakan dengan skala data yang digunakan sedangkan MAD lebih tahan/ tidak sensitif terhadap *outlier* (Hyndman & Koehler, 2006). sMAPE ditambahkan karena permasalahan mengenai besarnya *error* ketika data aktual lebih besar dari data hasil ramalan atau sebaliknya dapat dihindari dengan menggunakan sMAPE (Makridakis & Hibon, 2000). Oleh karena itu, evaluasi kebaikan model menggunakan RMSE, sMAPE, dan MAD. Ketiganya ditunjukkan oleh tiga persamaan berikut:

$$RMSE = \sqrt{\frac{\sum_{t=1}^{T}\left(y_t - \hat{y}_t\right)^2}{T}} \tag{2.60}$$

$$sMAPE = \frac{2}{T}\sum_{t=1}^{T}\frac{\left|\hat{y}_t - y_t\right|}{\left(\left|y_t\right| + \left|\hat{y}_t\right|\right)} \times 100\% \tag{2.61}$$

$$MAD = \left(\frac{1}{T}\sum_{t=1}^{T}\left|y_t - \hat{y}_t\right|\right). \tag{2.62}$$

Keterangan:

t : waktu ke-t,

T : jumlah data/ waktu,

y_t : data aktual ke-t,

$\hat{y}_t$: data hasil *nowcasting* ke-t.

2.7 Indeks Harga Konsumen

Perhitungan inflasi tidak sesederhana menghitung kenaikan satu jenis barang atau jasa mengingat laju inflasi mencerminkan perubahan harga dari sejumlah barang dan jasa. Oleh karena itu, laju inflasi dihitung menggunakan angka indeks yaitu Indeks Harga Konsumen. IHK dihitung berdasarkan hasil pengolahan Survei Harga Konsumen (SHK) di setiap kota inflasi. Survei volume penjualan eceran khusus beras dan survei volume penjualan eceran komoditas tertentu seperti bensin, bahan bakar rumah tangga, barang lainnya dengan kualitas yang beragam juga dilaksanakan sebagai pelengkap SHK.

Secara umum perhitungan IHK menggunakan formula Indeks *Laspeyers* yang dimodifikasi (*Modifeid Laspeyers*) sebagai berikut (BPS, 2021):

$$IHK_t^m = \frac{\sum_{c=1}^{C} \frac{P_{c,t}^m}{P_{c,t-1}^m} P_{c,t-1}^m Q_{c,0}^m}{\sum_{c=1}^{C} P_{c,0}^m Q_{c,0}^m} \times 100 \qquad (2.63)$$

Keterangan:

IHK_t^m : Indeks Harga Konsumen bulan ke-*t*,

$P_{c,t}^m$: Harga jenis barang/ jasa *c* pada bulan ke-(*t*),

$P_{c,t-1}^m$: Harga jenis barang/ jasa *c* pada bulan ke-(*t-1*),

$\frac{P_{c,t}^m}{P_{c,t-1}^m}$: Relatif Harga (RH) jenis barang/ jasa *c* pada bulan ke-(*t*),

$P_{c,0}^m$: Harga jenis barang/ jasa *c* pada tahun dasar (hasil SBH),

$Q_{c,0}^m$: Kuantitas jenis barang/ jasa *c* pada tahun dasar (hasil SBH),

$P_{c,t-1}^m Q_{c,0}^m$: Nilai Konsumsi (NK) jenis barang/ jasa *c* pada bulan ke-(*t-1*),

$P_{c,0}^m Q_{c,0}^m$: Nilai Konsumsi (NK) jenis barang/ jasa *c* pada tahun dasar,

C : Jumlah jenis barang/ jasa yang tercakup dalam paket komoditas IHK.

Laju inflasi/ deflasi dapat dihitung dengan formula berikut:

$$Inf_t^m = \frac{IHK_t^m - IHK_{t-1}^m}{IHK_{t-1}^m} \times 100 \qquad (2.64)$$

Keterangan:

Inf_t^m : Laju inflasi/ deflasi bulan ke-(*t*),

IHK_t^m : Indeks harga konsumen bulan ke-(*t*),

IHK_{t-1}^m : Indeks harga konsumen bulan ke-(*t-1*).

Rumus di atas juga dapat digunakan untuk menghitung laju inflasi menurut tahun kalendar atau inflasi per tahun yaitu membagi indeks bulan berjalan tahun ke-(*y*) dengan indeks bulan Desember tahun ke-(*y-1*) atau indeks bulan yang sama tahun ke-*(y-1)*.

Sejak Januari 2014 sampai dengan Desember 2019 penghitungan IHK mencakup 82 kota (33 ibu kota provinsi dan 49 kota) di seluruh Indonesia dengan 859 komoditas barang dan jasa serta tahun 2012 digunakan sebagai tahun dasar. Mulai Januari 2020 penghitungan IHK mencakup 90 kota (34 ibu kota provinsi dan 56 kota) di seluruh Indonesia (82 kota cakupan SBH 2012 dan tambahan 8 kota baru) dengan 835 komoditas serta tahun 2018 digunakan sebagai tahun dasar. Selain itu terjadi perubahan dari sisi pengelompokan komoditas menjadi 11 kelompok dan 53 subkelompok yang didasarkan dari *Classification of Individual Consumption According to Purpose* (COICOP) 2018, yaitu kelompok makanan, minuman dan tembakau; kelompok pakaian dan alas kaki; kelompok perumahan, air, listrik, gas dan bahan bakar lainnya; kelompok perlengkapan, peralatan, dan pemeliharaan rutin rumah tangga; kelompok kesehatan; kelompok transportasi; kelompok informasi, komunikasi dan jasa keuangan; kelompok rekreasi, olahraga dan budaya; kelompok pendidikan; kelompok penyediaan makanan dan minuman/ restoran serta kelompok perawatan pribadi dan jasa lainnya.

Perhitungan IHK di Jawa Timur mencakup 8 kabupaten/ kota dengan perubahan jumlah paket komoditas seperti yang ditunjukkan oleh Tabel 2.3.

Tabel 2.3 Jumlah Paket Komoditas SBH 8 Kabupaten/ Kota dan Provinsi Jawa Timur

No.	Kabupaten/ Kota	Paket Komoditas	
		SBH 2012=100	SBH 2018=100
1	Kabupaten Jember	361	358
2	Kabupaten Banyuwangi	244	315
3	Kabupaten Sumenep	319	320
4	Kota Kediri	377	373
5	Kota Malang	372	382
6	Kota Probolinggo	323	340
7	Kota Madiun	325	335
8	Kota Surabaya	424	420
	Provinsi Jawa Timur	534	563

Sumber: (BPS Provinsi Jawa Timur, 2020)

2.8 Faktor-Faktor yang Mempengaruhi Indeks Harga Konsumen

Berdasarkan faktor-faktor utama yang menyebabkan inflasi maka inflasi dapat disebabkan dari sisi permintaan, sisi penawaran, ekspektasi maupun

gabungan dari ketiga faktor tersebut (Suseno & Astiyah, 2009). Pertambahan jumlah uang yang beredar dalam jangka pendek akan mengakibatkan penurunan suku bunga. Penurunan suku bunga akan meningkatkan jumlah permintaan agregat yaitu jumlah investasi dan konsumsi secara keseluruhan. Peningkatan permintaan tersebut mendorong peningkatan harga-harga. Kejadian ini disebut sebagai inflasi permintaan (*demand pull inflation atau Phillip Curve inflation*). Inflasi yang disebabkan oleh kenaikan biaya produksi atau biaya pengadaan barang dan jasa disebut inflasi penawaran (*cost push* atau *supply shock inflation*). Contoh inflasi penawaran yaitu depresiasi nilai tukar, kenaikan harga minyak dunia, kenaikan harga barang-barang yang dikendalikan oleh pemerintah seperti harga BBM dan Tarif Dasar Listrik (TDL). Selain itu inflasi penawaran juga disebabkan oleh faktor alam misalnya gagal panen atau panen yang berlebih, faktor sosial ekonomi misalnya hambatan dalam distribusi barang atau faktor yang timbul karena kebijakan tertentu seperti kebijakan tarif, pajak, pembatasan impor atau kebijakan lainnya. Persamaan inflasi permintaan dan penawaran yaitu kesamaan dalam hal kenaikan harga secara umum. Perbedaan kedua inflasi adalah kenaikan harga cenderung akan meningkatkan output pada inflasi permintaan namun menurunkan barang yang tersedia pada inflasi penawaran. Inflasi ekspektasi sangat berperan dalam pembentukan harga dan upah tenaga kerja serta disebabkan oleh ekspektasi pelaku ekonomi yang didasarkan pada perkiraan yang akan datang akibat adanya kebijakan yang dilakukan oleh pemerintah pada saat ini.

Nizar (2012) melakukan penelitian untuk mengetahui dampak fluktuasi harga minyak di pasar dunia terhadap perekonomian Indonesia periode tahun 2000 sampai dengan 2011 menggunakan data *time series* bulanan, hasilnya menunjukkan bahwa fluktuasi harga minyak dunia mendorong laju inflasi satu tahun ke depan. Sutawijaya dan Zulfahmi (2012) menggunakan data dari BPS dan BI periode tahun 1985 sampai dengan 2005 dengan metode *Ordinary Least Square* (OLS) diperoleh hasil bahwa tingkat suku bunga, jumlah uang yang beredar sempit (M1) dan nilai tukar atau kurs berdampak positif dan signifikan terhadap inflasi sedangkan investasi berdampak negatif dan signifikan terhadap inflasi. Saputra dan Nugroho (2014) menyimpulkan bahwa jumlah uang yang

beredar luas (M2), kurs dan harga beras berhubungan positif dan signifikan terhadap inflasi di Indonesia periode 2007 sampai dengan 2012. Menurut Darma dkk (2018) menyimpulkan bahwa harga beras, bawang merah dan cabai merah berpengaruh positif signifikan terhadap inflasi di Indonesia periode Juni 2017 sampai dengan Juni 2018. Menurut Sundoro (2021) menyimpulkan bahwa harga komoditas bahan pokok (beras, daging ayam dan cabai merah) dan komoditas bensin berpengaruh positif terhadap inflasi di Indonesia periode Oktober 2014 sampai dengan September 2019.

2.9 Sumber Data Harga

Data harga bahan pokok harian diperoleh dari SISKAPERBAPO Jawa Timur yang dikelola oleh Dinas Perindustrian dan Perdagangan (Disperindag) Jawa Timur. Data harga bahan pokok 8 kabupaten/ kota IHK di Jawa Timur diunduh untuk dicari rata-ratanya dan digunakan sebagai harga bahan pokok provinsi Jawa Timur. Data Jakarta *Interbank Spot Dollar Rate* (JISDOR) dapat diperoleh melalui webiste Bank Indonesia (BI). Data harga minyak mentah Brent berjangka diperoleh melalui situs Id Investing.

Tabel 2.4 Contoh Data Rata-Rata Harga di Kota Surabaya pada Tingkat Konsumen Tanggal 1 Januari 2021

Pasar : Tambahrejo. Keputran, Genteng, Pucang Anom, Wonokromo

NO	NAMA BAHAN POKOK	SATUAN	HARGA KEMARIN	HARGA SEKARANG
01	BERAS			
	-Bengawan	kg	12.620	12.620
	-Mentik	kg	12.000	12.000
	-IR 64	kg	9.450	9.450
02	GULA PASIR			
	-Gula Pasir Dalam Negri	kg	12.400	12.400
03	MINYAK GORENG			
	-Bimoli Botol/ Kemasan (Sps) 620 ml	620 ml	-	-
	-Bimoli Botol/ Kemasan (Sps) 2 liter	2 Liter	27.400	27.400
	-Tanpa merk/ Minyak Curah	kg	13.800	13.800

Tabel 2.4 Contoh Data Rata-Rata Kota Surabaya di Tingkat Konsumen Tanggal 1 Januari 2021 (Lanjutan)

Pasar : Tambahrejo. Keputran, Genteng, Pucang Anom, Wonokromo

NO	NAMA BAHAN POKOK	SATUAN	HARGA KEMARIN	HARGA SEKARANG
	-Bimoli Botol/ Kemasan (Sps) 2 liter	1 Liter	14.400	14.400
04	DAGING			
	-Daging Sapi Murni	kg	107.000	107.000
	-Daging Ayam Broiler	kg	33.200	33.200
	-Daging Ayam Kampung	kg	66.000	66.000
05	TELUR AYAM			
	-Telur Ayam Ras/ Petelur	kg	23.800	23.800
	-Telur Ayam Kampung	kg	32.480	32.480
06	SUSU			
	Kental Manis			
	-Susu Kental Manis Merk Bendera	397 gr/kl	10.000	10.000
	-Susu Kental Manis Merk Indomilk	390 gr/kl	10.000	10.000
	Susu Bubuk			
	-Susu Bubuk Merk Bendera (Instant)	400 gr/dos	40.200	40.200
	-Susu Bubuk Merk Indomilk (Instant)	400 gr/dos	39.000	39.000
07	JAGUNG PIPILAN KERING	kg	9.150	9.150
08	GARAM BERYODIUM			
	-Bata	Buah	1.375	1.375
	-Halus	kg	8.200	8.200
09	TEPUNG TERIGU			
	-Segitiga Biru (Kw Medium)	kg	9.400	9.400
10	KACANG KEDELAI			
	-Eks Impor	kg	10.100	10.100
	-Lokal	kg	8.250	8.250
11	MIE INSTANT			
	-Indomie Rasa Kari Ayam	Bungkus	2.420	2.420
12	CABE			
	-Keriting	kg	57.250	58.500
	-Biasa	kg	39.600	43.600
	-Cabe Rawit	kg	56.000	62.000
13	BAWANG MERAH	kg	27.600	27.600
	BAWANG PUTIH	kg	23.400	23.400
14	IKAN ASIN TERI	kg	80.000	80.000

Tabel 2.4 Contoh Data Rata-Rata Kota Surabaya di Tingkat Konsumen Tanggal 1 Januari 2021 (Lanjutan)

Pasar : Tambahrejo. Keputran, Genteng, Pucang Anom, Wonokromo

NO	NAMA BAHAN POKOK	SATUAN	HARGA KEMARIN	HARGA SEKARANG
15	KACANG HIJAU	kg	21.000	21.000
16	KACANG TANAH	kg	25.800	25.800
17	KETELA POHON	kg	5800	5800
18	SAYUR MAYUR			
	-KOL/KUBIS	kg	11.400	13.000
	-KENTANG	kg	13.800	13.600
	-TOMAT	kg	12.000	13.200
	-WORTEL	kg	11.700	12.700
	-BUNCIS	kg	11.800	12.200
19	SEMEN			
	-Semen Gresik	40 kg	52.000	52.000
	-Semen Tiga Roda	40 kg	47.000	47.000
	-Semen Padang	40 kg	-	-
	-Semen Tonasa	40 kg	-	-
	-Semen Bosowa	40 kg	-	-
	-Semen Dinamix	40 kg	-	-
20	IKAN SEGAR			
	-Ikan Bandeng	kg	34.200	34.200
	-Ikan Kembung	kg	37.250	37.250
	-Ikan Tuna	kg	39.500	39.500
	-Ikan Tongkol	kg	37.250	37.250
	-Ikan Cakalang	kg	32.000	32.000
22	KAYU BALOK MERANTI (4X10)	Batang	46.000	46.000
23	PAPAN MERANTI (4m X 3cm X 20 mm)	Lembar	77.000	77.000
24	TRIPLEK (6MM)	Lembar	82.000	82.000
25	BESI BETON (SNI MURNI)			
	-Besi Beton 6 mm (12/9m)	Batang	30.000	30.000
	-Besi Beton 8 mm (12/9m)	Batang	42.500	42.500
	-Besi Beton 10 mm (12/9m)	Batang	65.000	65.000
	-Besi Beton 12 mm (12/9m)	Batang	94.000	94.000
26	PAKU			
	-Paku Ukuran 10cm	kg	18.000	18.000
	-Paku Ukuran 2cm	kg	18.000	18.000
	-Paku Ukuran 3cm	kg	18.000	18.000
	-Paku Ukuran 4cm	kg	18.000	18.000
	-Paku Ukuran 5cm	kg	18.000	18.000
	-Paku Ukuran 7cm	kg	18.000	18.000

Tabel 2.4 Contoh Data Rata-Rata Kota Surabaya di Tingkat Konsumen Tanggal 1 Januari 2021 (Lanjutan)

Pasar : Tambahrejo. Keputran, Genteng, Pucang Anom, Wonokromo

NO	NAMA BAHAN POKOK	SATUAN	HARGA KEMARIN	HARGA SEKARANG
27	GAS ELPIJI 3KG	Tabung	18.000	18.000
28	PUPUK			
	-Pupuk KCL Non Subsidi	kg	-	-
	-Pupuk NPK Non Subsidi	kg	-	-
	-Pupuk SP 35 Non Subsidi	kg	-	-
	-Pupuk Urea Non Subsidi	kg	-	-
	-Pupuk ZA Non Subsidi	kg	-	-

BAB 3
METODE PENELITIAN

3.1 Metode Analisis

Kajian terhadap DFM, SVR, dan TSR dilakukan untuk menjawab tujuan pertama. Tahapan penelitian untuk menjawab tujuan kedua dan ketiga ditunjukkan oleh Gambar 3.1 yaitu unduh data mentah dari sumber data *online*, analisa data mentah, *preprocessing*, alokasi data, pembangunan model *nowcasting* IHK menggunakan dataset bulanan, pembangunan model *nowcasting* IHK menggunakan dataset harian, evaluasi model *nowcasting* harian dan kesimpulan.

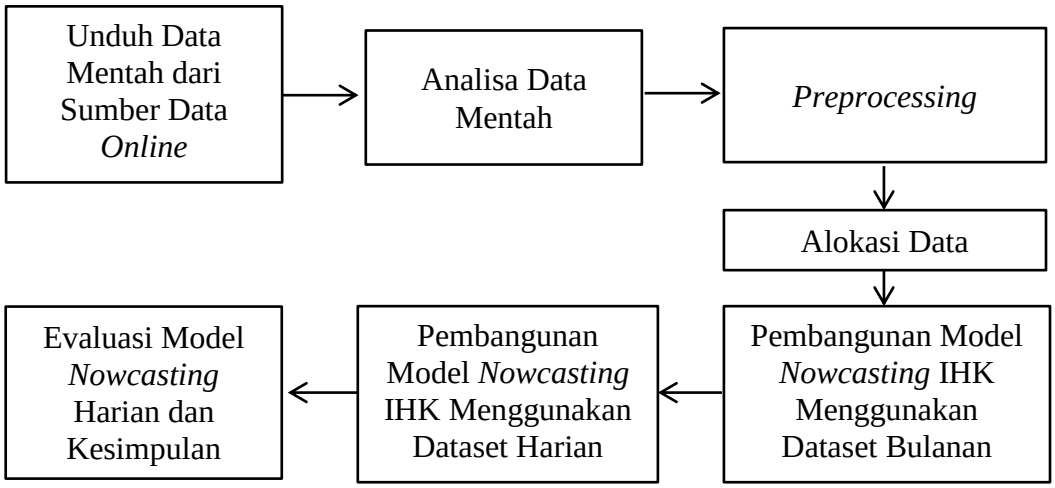

Gambar 3.1 Diagram Tahapan Penelitian

3.2 Pengunduhan Data Mentah dari Sumber Data *Online*

Data yang digunakan dalam penelitian ini adalah data sekunder terdiri dari dataset bulanan dan dataset harian. Periode untuk dataset bulanan yaitu Januari 2017 sampai dengan Mei 2021. Variabel respon dalam dataset bulanan adalah data IHK bulanan yang diperoleh dari BPS melalui https://jatim.bps.go.id. Variabel prediktor dalam dataset bulanan diperoleh dari rata-rata harga konsumen setiap bulan. Harga konsumen yang dimaksud yaitu data harga bahan pokok harian yang diperoleh dari SISKAPERBAPO, data JISDOR BI dan harga minyak mentah Brent berjangka dari Id Investing. Data tersebut merupakan variabel prediktor dalam dataset harian periode 1 Januari 2017 sampai dengan 31 Mei 2021. Data harga bahan pokok harian dapat diakses melalui

https://siskaperbapo.com/. Data JISDOR dapat diakses melalui https://www.bi.go.id/id/statistik/informasi-kurs/jisdor/default.aspx. Data harga minyak mentah Brent berjangka dapat diakses melalui https://id.investing.com/commodities/brent-oil-historical-data. Variabel respon IHK harian diestimasi nilainya menggunakan model bulanan.

3.3 Analisa Data Mentah

Variabel harga konsumen atau sumber data yang layak digunakan dalam penelitian dipilih melalui proses analisa data mentah. Data yang layak digunakan dalam penelitian yaitu data tanpa banyak *missing value* dalam setiap variabel dengan toleransi *missing value* 5% setiap kabupaten/ kota IHK di Jawa Timur dan *missing value* kurang dari 30 hari berturut-turut. Jika ada salah satu kabupaten/ kota IHK di Jawa Timur dengan *missing value* lebih dari 5% atau *missing value* lebih dari atau sama dengan 30 hari berturut-turut maka variabel tersebut tidak digunakan dalam penelitian ini. Variabel dengan *missing value* lebih dari 5% ditunjukkan oleh warna merah pada Tabel 3.1 sedangkan *missing value* lebih dari atau sama dengan 30 hari berturut-turut ditunjukkan oleh warna kuning. Berdasarkan Tabel 3.1 ada 31 harga bahan pokok yang digunakan dalam penelitian ini dari 68 harga bahan pokok yang ada di SISKAPERBAPO. Harga gas elpiji 3 kg ditambahkan sebagai variabel prediktor untuk mewakili kelompok perumahan, air dan bahan bakar rumah tangga.

Tabel 3.1 Ringkasan Data Nilai yang Hilang di Delapan Kabupaten/Kota IHK Jawa Timur

NO	NAMA BAHAN POKOK	JMR	BYW	SMP	KDR	MLG	PBL	MAD	SBY
01	BERAS								
	-Bengawan	6	1612	0	25	0	0	6	0
	-Mentik	6	1612	0	25	0	1034	6	0
	-IR 64	6	0	0	25	0	0	6	0
02	GULA PASIR								
	-Gula Pasir Dalam Negeri	6	0	0	25	0	0	6	0

Tabel 3.1 Ringkasan Data Nilai yang Hilang di Delapan Kabupaten/Kota IHK Jawa Timur (Lanjutan)

NO	NAMA BAHAN POKOK	JMR	BYW	SMP	KDR	MLG	PBL	MAD	SBY
03	MINYAK GORENG								
	-Bimoli Botol/ Kemasan (Sps)620 ml	6	1185	1582	602	1446	1611	479	582
	-Bimoli Botol/ Kemasan (Sps) 2 liter	6	0	0	25	0	0	6	0
	-Tanpa merk/ Minyak Curah	6	0	0	25	0	0	6	0
	-Bimoli Botol/ Kemasan (Sps) 2 liter	1612	1612	1612	1035	1106	1030	1097	1030
04	DAGING								
	-Daging Sapi Murni	6	0	0	25	0	0	6	0
	-Daging Ayam Broiler	6	0	0	25	0	0	6	0
	-Daging Ayam Kampung	6	0	0	25	0	0	10	0
05	TELUR AYAM								
	-Telur Ayam Ras/ Petelur	6	0	0	25	0	0	6	0
	-Telur Ayam Kampung	6	0	0	25	101	0	6	0
06	SUSU								
	Kental Manis								
	-Merk Bendera	6	0	0	25	0	0	6	0

Tabel 3.1 Ringkasan Data Nilai yang Hilang di Delapan Kabupaten/Kota IHK Jawa Timur (Lanjutan)

NO	NAMA BAHAN POKOK	JMR	BYW	SMP	KDR	MLG	PBL	MAD	SBY
	-Merk Indomilk	6	0	0	25	0	0	6	0
	Susu Bubuk								
	-Merk Bendera (Instant)	58	1612	1612	672	0	0	1249	0
	-Merk Indomilk (Instant)	619	1612	1612	672	0	0	1249	0
07	Jagung Pipilan Kering	6	0	0	25	0	0	6	0
08	GARAM BERYODIUM								
	-Bata	77	0	0	25	0	0	6	0
	-Halus	6	0	0	25	0	0	7	0
09	TEPUNG TERIGU								
	-Segitiga Biru (Kw Medium)	6	0	0	25	0	0	6	0
10	KACANG KEDELAI								
	-Eks Impor	6	0	0	25	0	0	6	0
	-Lokal	10	0	164	83	1583	162	8	0
11	MIE INSTANT								
	-Indomie Rasa Kari Ayam	6	0	0	25	0	0	6	0
12	CABE								
	-Keriting	1385	1612	1422	25	0	742	6	0
	-Biasa	6	0	0	25	0	0	6	0
	-Cabe Rawit	6	0	0	25	0	0	6	0
13	Bawang Merah	6	0	0	25	0	0	6	0
	Bawang Putih	6	0	0	25	0	0	6	0

Tabel 3.1 Ringkasan Data Nilai yang Hilang di Delapan Kabupaten/Kota IHK Jawa Timur (Lanjutan)

NO	NAMA BAHAN POKOK	JMR	BYW	SMP	KDR	MLG	PBL	MAD	SBY
14	Ikan Asin Teri	6	0	0	25	0	0	6	0
15	Kacang Hijau	6	0	0	25	0	0	6	0
16	Kacang Tanah	6	0	0	25	0	0	6	0
17	Ketela Pohon	6	0	0	25	0	0	6	0
18	SAYUR MAYUR								
	-Kol/Kubis	6	0	0	25	0	0	6	0
	-Kentang	6	0	0	25	0	0	6	0
	-Tomat	6	0	0	25	0	0	6	0
	-Wortel	6	0	0	25	0	0	6	0
	-Buncis	6	0	0	25	0	0	6	0
19	SEMEN								
	-Semen Gresik	6	0	0	26	0	2	6	67
	-Semen Tiga Roda	6	0	0	26	0	2	11	200
	-Semen Padang	1494	1612	1612	26	0	1612	1601	1612
	-Semen Tonasa	1495	1612	1612	26	781	1522	1612	942
	-Semen Bosowa	515	0	1612	26	781	1522	1612	942
	-Semen Dinamix	0	1612	1518	1515	1552	1522	1612	1612
20	IKAN SEGAR								
	-Ikan Bandeng	6	0	0	25	0	2	7	0
	-Ikan Kembung	6	0	1612	25	0	2	7	0
	-Ikan Tuna	6	0	1612	25	0	2	7	0
	-Ikan Tongkol	6	0	0	25	0	2	7	0
	-Ikan Cakalang	6	0	1612	25	0	2	7	0

Tabel 3.1 Ringkasan Data Nilai yang Hilang di Delapan Kabupaten/Kota IHK Jawa Timur (Lanjutan)

NO	NAMA BAHAN POKOK	JMR	BYW	SMP	KDR	MLG	PBL	MAD	SBY
22	Kayu Balok Meranti (4x10)	6	1612	0	1612	0	2	7	109
23	PAPAN MERANTI (4m X 3cm X 20 Mm)	6	1612	0	1612	0	2	7	67
24	Triplek (6mm)	6	0	0	28	0	2	7	67
25	BESI BETON (SNI MURNI)								
	-Besi Beton 6 mm (12/9m)	8	0	0	28	0	2	11	67
	-Besi Beton 8 mm (12/9m)	8	0	0	28	0	2	7	67
	-Besi Beton 10 mm (12/9m)	8	0	0	28	0	2	7	67
	-Besi Beton 12 mm (12/9m)	8	0	0	28	0	2	7	67
26	PAKU								
	-Paku Ukuran 10cm	8	0	0	28	774	2	7	67
	-Paku Ukuran 2cm	8	0	0	28	782	2	7	67
	-Paku Ukuran 3cm	8	0	0	28	0	2	7	364
	-Paku Ukuran 4cm	8	0	0	28	321	2	7	67
	-Paku Ukuran 5cm	8	0	0	28	0	2	7	364
	-Paku Ukuran 7cm	8	0	0	28	0	2	7	67

Tabel 3.1 Ringkasan Data Nilai yang Hilang di Delapan Kabupaten/Kota IHK Jawa Timur (Lanjutan)

NO	NAMA BAHAN POKOK	JMR	BYW	SMP	KDR	MLG	PBL	MAD	SBY
27	GAS ELPIJI 3KG	8	0	0	28	0	2	7	0
28	PUPUK								
	-Pupuk KCL Non Subsidi	8	1612	1612	1612	1607	2	7	946
	-Pupuk NPK Non Subsidi	8	0	1612	1612	845	2	7	944
	-Pupuk SP 35 Non Subsidi	8	1612	1612	1612	840	2	7	944
	-Pupuk Urea Non Subsidi	8	0	1612	1612	843	2	7	944
	-Pupuk ZA Non Subsidi	8	1612	1612	1612	845	2	12	944

Keterangan:

JMR=Jember; BYW=Banyuwangi; SMP=Sumenep; KDR=Kota Kediri; MLG=Kota Malang; PBL=Kota Probolinggo; MAD=Kota Madiun; SBY=Kota Surabaya.

Ringkasan variabel penelitian dalam dataset bulanan ditunjukkan oleh Tabel 3.2. Ringkasan variabel penelitian dalam dataset harian ditunjukkan oleh Tabel 3.3. Kalendar rilis data dalam satu bulan dari variabel penelitian yang digunakan dalam penelitian ini disajikan lebih jelas dalam Tabel 3.4.

Tabel 3.2 Variabel Penelitian dalam Dataset Bulanan

Nama	Variabel	Nama	Variabel
Y^m	IHK Bulanan BPS(%)	X_1^m	Rata-rata Bulanan Harga minyak dunia Brent (USD/Barel)

Tabel 3.2 Variabel Penelitian dalam Dataset Bulanan (Lanjutan)

Nama	Variabel	Nama	Variabel
X_2^m	Rata-rata Bulanan JISDOR (USD/IDR)	X_{18}^m	Rata-rata Bulanan Harga Cabai Biasa (kg)
X_3^m	Rata-rata Bulanan Harga Beras IR 64 (kg)	X_{19}^m	Rata-rata Bulanan Harga Cabai Rawit (kg)
X_4^m	Rata-rata Bulanan Harga Gula Pasir Dalam Negeri (kg)	X_{20}^m	Rata-rata Bulanan Harga Bawang Merah (kg)
X_5^m	Rata-rata Bulanan Harga Minyak Goreng Bimoli Botol/Kemasan (2L)	X_{21}^m	Rata-rata Bulanan Harga Bawang Putih (kg)
X_6^m	Rata-rata Bulanan Harga Minyak Goreng Curah (kg)	X_{22}^m	Rata-rata Bulanan Harga Ikan Asin Teri (kg)
X_7^m	Rata-rata Bulanan Harga Daging Sapi Murni (kg)	X_{23}^m	Rata-rata Bulanan Harga Kacang Hijau (kg)
X_8^m	Rata-rata Bulanan Harga Daging Ayam Broiler (kg)	X_{24}^m	Rata-rata Bulanan Harga Kacang Tanah (kg)
X_9^m	Rata-rata Bulanan Harga Daging Ayam Kampung (kg)	X_{25}^m	Rata-rata Bulanan Harga Ketela Pohon (kg)
X_{10}^m	Rata-rata Bulanan Harga Telur Ayam Ras (kg)	X_{26}^m	Rata-rata Bulanan Harga Kol/ Kubis (kg)
X_{11}^m	Rata-rata Bulanan Harga Susu Kental Manis Merk Bendera (397 gr/kl)	X_{27}^m	Rata-rata Bulanan Harga Kentang (kg)
X_{12}^m	Rata-rata Bulanan Harga Susu Kental Manis Merk Indomilk (390 gr/kl)	X_{28}^m	Rata-rata Bulanan Harga Tomat (kg)
X_{13}^m	Rata-rata Bulanan Harga Jagung Pipilan Kering (kg)	X_{29}^m	Rata-rata Bulanan Harga Wortel (kg)
X_{14}^m	Rata-rata Bulanan Harga Garam Beryodiun Halus (kg)	X_{30}^m	Rata-rata Bulanan Harga Buncis (kg)
X_{15}^m	Rata-rata Bulanan Harga Tepung Terigu Segitiga Biru Kw Medium (kg)	X_{31}^m	Rata-rata Bulanan Harga Ikan Bandeng (kg)
X_{16}^m	Rata-rata Bulanan Harga Kacang Kedelai Eks Impor (kg)	X_{32}^m	Rata-rata Bulanan Harga Ikan Tongkol (kg)
X_{17}^m	Rata-rata Bulanan Harga Indomie Rasa Kari Ayam (Bungkus)	X_{33}^m	Rata-rata Bulanan Harga Gas Elpiji 3 Kg

Tabel 3.3 Variabel Penelitian dalam Dataset Harian

Nama	Variabel	Nama	Variabel
Y^d	*Nowcast* IHK Harian (%)	X_{17}^d	Harga Indomie Rasa Kari Ayam (Bungkus)
X_1^d	Harga minyak dunia Brent (USD/Barel)	X_{18}^d	Harga Cabai Biasa (kg)
X_2^d	JISDOR (USD/IDR)	X_{19}^d	Harga Cabai Rawit (kg)
X_3^d	Harga Beras IR 64 (kg)	X_{20}^d	Harga Bawang Merah (kg)
X_4^d	Harga Gula Pasir Dalam Negeri (kg)	X_{21}^d	Harga Bawang Putih (kg)
X_5^d	Harga Minyak Goreng Bimoli Botol/Kemasan (2L)	X_{22}^d	Harga Ikan Asin Teri (kg)
X_6^d	Harga Minyak Goreng Curah (kg)	X_{23}^d	Harga Kacang Hijau (kg)
X_7^d	Harga Daging Sapi Murni (kg)	X_{24}^d	Harga Kacang Tanah (kg)
X_8^d	Harga Daging Ayam Broiler (kg)	X_{25}^d	Harga Ketela Pohon (kg)
X_9^d	Harga Daging Ayam Kampung (kg)	X_{26}^d	Harga Kol/ Kubis (kg)
X_{10}^d	Harga Telur Ayam Ras (kg)	X_{27}^d	Harga Kentang (kg)
X_{11}^d	Harga Susu Kental Manis Merk Bendera (397 gr/kl)	X_{28}^d	Harga Tomat (kg)
X_{12}^d	Harga Susu Kental Manis Merk Indomilk (390 gr/kl)	X_{29}^d	Harga Wortel (kg)
X_{13}^d	Harga Jagung Pipilan Kering (kg)	X_{30}^d	Harga Buncis (kg)
X_{14}^d	Harga Garam Beryodiun Halus (kg)	X_{31}^d	Harga Ikan Bandeng (kg)
X_{15}^d	Harga Tepung Terigu Segitiga Biru Kw Medium (kg)	X_{32}^d	Harga Ikan Tongkol (kg)
X_{16}^d	Harga Kacang Kedelai Eks Impor (kg)	X_{33}^d	Harga Gas Elpiji 3 Kg

Tabel 3.4 Kalendar Rilis Data dalam Satu Bulan dari Variabel Penelitian

Variabel	Satuan	Frekuensi	Sumber	Publikasi	*Time Lag*
Indeks Harga Konsumen	%	Bulanan	BPS	Hari kerja pertama setiap bulan	1 sampai dengan 4 hari

Tabel 3.4 Kalendar Rilis Data dalam Satu Bulan dari Variabel Penelitian (Lanjutan)

Variabel	Satuan	Frekuensi	Sumber	Publikasi	*Time Lag*
Harga minyak dunia Brent	USD/Barel	Harian	Id Investing	Setiap hari kerja penutupan 04.00	-
JISDOR	USD/IDR	Harian	BI	Setiap hari kerja pukul 16.15 WIB; setelah COVID19 15.15 WIB	-
Harga Beras IR 64	Kg	Harian	SISKAPERBAPO	Setiap hari kerja pukul 13.00 WIB	-
Harga Gula Pasir Dalam Negeri	Kg				
Harga Minyak Goreng Bimoli Botol/Kemasan	2L				
Harga Minyak Goreng Curah	Kg				
Harga Daging Sapi Murni	Kg				
Harga Daging Ayam Broiler	Kg				
Harga Daging Ayam Kampung	Kg				
Harga Telur Ayam Ras	Kg				
Harga Susu Kental Manis Merk Bendera	397 gr/kl				

Tabel 3.4 Kalendar Rilis Data dalam Satu Bulan dari Variabel Penelitian (Lanjutan)

Variabel	Satuan	Frekuensi	Sumber	Publikasi	*Time Lag*
Harga Susu Kental Manis Merk Indomilk	390 gr/kl				
Harga Jagung Pipilan Kering	Kg				
Harga Garam Beryodiun Halus	Kg	Harian	SISKAPERBAPO	Setiap hari kerja pukul 13.00 WIB	-
Harga Tepung Terigu Segitiga Biru Kw Medium	Kg				
Harga Kacang Kedelai Eks Impor	Kg				
Harga Indomie Rasa Kari Ayam	(Bungkus)				
Harga Cabai Biasa	Kg				
Harga Cabai Rawit	Kg				
Harga Bawang Merah	Kg				
Harga Bawang Putih	Kg				
Harga Ikan Asin Teri	Kg				
Harga Kacang Hijau	Kg				
Harga Kacang Tanah	Kg				

Tabel 3.4 Kalendar Rilis Data dalam Satu Bulan dari Variabel Penelitian (Lanjutan)

Variabel	Satuan	Frekuensi	Sumber	Publikasi	*Time Lag*
Harga Ketela Pohon	Kg				
Harga Kol/ Kubis	Kg				
Harga Kentang	Kg				
Harga Tomat	Kg				
Harga Wortel	Kg				
Harga Buncis	Kg				
Harga Ikan Bandeng	Kg	Harian	SISKAPERBAPO	Setiap hari kerja pukul 13.00 WIB	-
Harga Ikan Tongkol	Kg				
Harga Gas Elpiji	3 Kg				

Berdasarkan variabel-variabel penelitian di atas maka definisi operasional yang digunakan pada penelitian ini sebagai berikut:

1. Indeks harga konsumen adalah indeks yang menghitung rata-rata perubahan harga dalam suatu periode dari suatu kumpulan harga barang dan jasa yang dikonsumsi oleh penduduk/ rumah tangga dalam kurun waktu tertentu .
2. Harga minyak dunia Brent berjangka adalah harga minyak bumi per barel dalam satuan mata uang *United States Dollar* (USD).
3. JISDOR merupakan harga spot USD/IDR, yang disusun berdasarkan kurs transaksi USD/IDR terhadap rupiah antar bank di pasar valuta asing Indonesia, melalui Sistem Monitoring Transaksi Valuta Asing Terhadap Rupiah (SISMONTAVAR) di Bank Indonesia secara *real time*.
4. Harga bahan pokok di Jawa Timur merupakan rata-rata harga bahan pokok dari 8 kabupaten/ kota IHK di Jawa Timur.

3.4 Tahapan Pengolahan Awal Data atau *Preprocessing*

3.4.1 Mengubah IHK ke dalam Tahun Dasar yang Sama

Periode Januari 2014 sampai dengan Desember 2019 perhitungan IHK menggunakan tahun dasar 2012 sedangkan mulai Januari 2020 perhitungan IHK menggunakan tahun dasar yang baru yaitu 2018. IHK menggunakan skala 100 dan dilakukan pembaruan daftar timbang setiap lima tahun untuk menyesuaikan daftar timbang dengan kondisi dan kebutuhan yang terjadi. Model *nowcasting* yang baik sebaiknya menggunakan satu tahun dasar yang sama. Metode menyamakan tahun dasar merupakan turunan dari rumus perhitungan inflasi pada Persamaan (2.64) yaitu:

$$IHK_{t-1}^{m} = \frac{IHK_{t}^{m}}{\left(100 + Inf_{t}^{m}\right)} \times 100 \tag{3.1}$$

Keterangan :

IHK_{t}^{m} : Indeks Harga Konsumen bulan ke-*t*

IHK_{t-1}^{m} : Indeks Harga Konsumen bulan ke-(*t-1*)

Inf_{t}^{m} : Inflasi bulan ke-*t*

3.4.2 Mengatasi Permasalahan Nilai yang Hilang

Nilai yang hilang (missing value) perlu dilakukan imputasi data. Menurut Purwanto (2019) imputasi data dengan *median* mudah dilakukan dan lebih efektif dibandingkan dengan *mean* ketika persentase *missing value* rendah. Metode *median of nearby points* merupakan metode imputasi yang paling baik untuk mengestimasi *missing value* dibandingkan dengan *series mean, mean of nearby points, linear interpolation* dan *linear at trend at point* (Evriyanto, 2004). Oleh karena itu, metode *median of nearby points* digunakan untuk imputasi data *missing value.*

3.4.3 Deteksi *Outlier*

Box-Plot dapat digunakan untuk deteksi *outlier*. Nilai *outlier* adalah nilai data yang letaknya lebih dari 1,5 x panjang kotak atau *Inner Quartile Range* (IQR), diukur dari *Upper Quartile* (UQ) atau *Lower Quartile* (LQ). Jika persentase *outlier* kurang dari 15% (meskipun besarnya *outlier* dapat meningkat), efeknya pada model secara statistik tidak signifikan seperti tidak ada *outlier* dalam

data (Khamis, Ismail, Ilaron, & Mohammed, 2005). Oleh karena itu, jika persentase *outlier* kurang dari 15% maka *outlier* tersebut tetap digunakan dalam membangun model prediksi IHK.

3.4.4 Standarisasi Data

Standarisasi data perlu dilakukan karena data memiliki satuan ukur yang berbeda seperti yang ditunjukkan Tabel 3.4. Tujuan dari standarisasi data agar nilai data berada pada range yang sama dan mendapatkan hasil akurasi yang lebih akurat. Rumus standarisasi data menggunakan persamaan berikut:

$$Z_{i,t} = \frac{x_{i,t} - \overline{x}_i}{s_{x_i}} \tag{3.2}$$

3.5 Struktur Data

Tabel 3.5 Struktur Data Bulanan dalam Penelitian

Bulan	y_t^m	$x_{1,t}^m$	$x_{2,t}^m$	$x_{3,t}^m$	$x_{4,t}^m$	$x_{5,t}^m$	$x_{6,t}^m$	$x_{7,t}^m$	$x_{8,t}^m$	$x_{9,t}^m$	$x_{10,t}^m$	$x_{12,t}^m$	$\dots$	$x_{33,t}^m$
1/2017	y_1^m	$x_{1,1}^m$	$x_{2,1}^m$	$x_{3,1}^m$	$x_{4,1}^m$	$x_{5,1}^m$	$x_{6,1}^m$	$x_{7,1}^m$	$x_{8,1}^m$	$x_{9,1}^m$	$x_{10,1}^m$	$x_{12,1}^m$	$\dots$	$x_{33,1}^m$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\dots$	$\vdots$
12/2017	y_{12}^m	$x_{1,12}^m$	$x_{2,12}^m$	$x_{3,12}^m$	$x_{4,12}^m$	$x_{5,12}^m$	$x_{6,12}^m$	$x_{7,12}^m$	$x_{8,12}^m$	$x_{9,12}^m$	$x_{10,12}^m$	$x_{12,12}^m$	$\dots$	$x_{33,12}^m$
1/2018	y_{13}^m	$x_{1,13}^m$	$x_{2,13}^m$	$x_{3,13}^m$	$x_{4,13}^m$	$x_{5,13}^m$	$x_{6,13}^m$	$x_{7,13}^m$	$x_{8,13}^m$	$x_{9,13}^m$	$x_{10,13}^m$	$x_{12,13}^m$	$\dots$	$x_{33,13}^m$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\dots$	$\vdots$
12/2018	y_{24}^m	$x_{1,24}^m$	$x_{2,24}^m$	$x_{3,24}^m$	$x_{4,24}^m$	$x_{5,24}^m$	$x_{6,24}^m$	$x_{7,24}^m$	$x_{8,24}^m$	$x_{9,24}^m$	$x_{10,24}^m$	$x_{12,24}^m$	$\dots$	$x_{33,24}^m$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\dots$	$\vdots$
1/2021	y_{49}^m	$x_{1,49}^m$	$x_{2,49}^m$	$x_{3,49}^m$	$x_{4,49}^m$	$x_{5,49}^m$	$x_{6,49}^m$	$x_{7,49}^m$	$x_{8,49}^m$	$x_{9,49}^m$	$x_{10,49}^m$	$x_{12,49}^m$	$\dots$	$x_{33,49}^m$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\dots$	$\vdots$
5/2021	y_{53}^m	$x_{1,53}^m$	$x_{2,53}^m$	$x_{3,53}^m$	$x_{4,53}^m$	$x_{5,53}^m$	$x_{6,53}^m$	$x_{7,53}^m$	$x_{8,53}^m$	$x_{9,53}^m$	$x_{10,53}^m$	$x_{12,53}^m$	$\dots$	$x_{33,53}^m$

Tabel 3.6 Struktur Data Harian dalam Penelitian

Tanggal	y_t^d	$x_{1,t}^d$	$x_{2,t}^d$	$x_{3,t}^d$	$x_{4,t}^d$	$x_{5,t}^d$	$x_{6,t}^d$	$x_{7,t}^d$	$x_{8,t}^d$	$x_{9,t}^d$	$x_{10,t}^d$	$x_{12,t}^d$	$\dots$	$x_{33,t}^d$
1/1/2017	y_1^d	$x_{1,1}^d$	$x_{2,1}^d$	$x_{3,1}^d$	$x_{4,1}^d$	$x_{5,1}^d$	$x_{6,1}^d$	$x_{7,1}^d$	$x_{8,1}^d$	$x_{9,1}^d$	$x_{10,1}^d$	$x_{12,1}^d$	$\dots$	$x_{33,1}^d$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\dots$	$\vdots$
31/1/2017	y_2^d	$x_{1,31}^d$	$x_{2,31}^d$	$x_{3,31}^d$	$x_{4,31}^d$	$x_{5,31}^d$	$x_{6,31}^d$	$x_{7,31}^d$	$x_{8,31}^d$	$x_{9,31}^d$	$x_{10,31}^d$	$x_{12,31}^d$	$\dots$	$x_{33,31}^d$
1/2/2017	y_{32}^d	$x_{1,32}^d$	$x_{2,32}^d$	$x_{3,32}^d$	$x_{4,32}^d$	$x_{5,32}^d$	$x_{6,32}^d$	$x_{7,32}^d$	$x_{8,32}^d$	$x_{9,32}^d$	$x_{10,32}^d$	$x_{12,32}^d$	$\dots$	$x_{33,32}^d$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\dots$	$\vdots$
28/2/2017	y_{59}^d	$x_{1,59}^d$	$x_{2,59}^d$	$x_{3,59}^d$	$x_{4,59}^d$	$x_{5,59}^d$	$x_{6,59}^d$	$x_{7,59}^d$	$x_{8,59}^d$	$x_{9,59}^d$	$x_{10,59}^d$	$x_{12,59}^d$	$\dots$	$x_{33,59}^d$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\dots$	$\vdots$
1/5/2021	y_{1582}^d	$x_{1,1582}^d$	$x_{2,1582}^d$	$x_{3,1582}^d$	$x_{4,1582}^d$	$x_{5,1582}^d$	$x_{6,1582}^d$	$x_{7,1582}^d$	$x_{8,1582}^d$	$x_{9,1582}^d$	$x_{10,1582}^d$	$x_{12,1582}^d$	$\dots$	$x_{33,1582}^d$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\dots$	$\vdots$
31/5/2021	y_{1612}^d	$x_{1,1612}^d$	$x_{2,1612}^d$	$x_{3,1612}^d$	$x_{4,1612}^d$	$x_{5,1612}^d$	$x_{6,1612}^d$	$x_{7,1612}^d$	$x_{8,1612}^d$	$x_{9,1612}^d$	$x_{10,1612}^d$	$x_{12,1612}^d$	$\dots$	$x_{33,1612}^d$

3.6 Alokasi Data

Di dalam penelitian ini, data dibagi menjadi dua bagian, yaitu data *training* dan data *testing*. Hal ini dilakukan untuk menghindari *overfitting*. *Overfitting* yaitu keadaan di mana model prediksi biasanya mempunyai hasil prediksi sempurna namun gagal memprediksi data lainnya. Data *training* mulai 1 Januari 2017 sampai dengan 31 Desember 2020 sedangkan data *testing* mulai 1 Januari 2021 sampai dengan 31 Mei 2021.

3.7 Pembangunan Model *Nowcasting*

3.7.1 Optimisasi *Hyperparameter* SVR

Sebelum melakukan proses pemilihan parameter dan *fitting* (proses *training* data), dilakukan inisiasi parameter dan inisiasi r*ange* parameter. *Range* parameter untuk memberikan alternatif pilihan parameter yang akan diujikan. Setiap nilai di dalam *range* parameter ini akan diuji untuk mencari *range* dengan nilai evaluasi terbaik yaitu kombinasi parameter yang meghasilkan RMSE, sMAPE, dan MAD terkecil atau mendekati nol. *Hyperparameter* yang dioptimasi dan *range* parameter yang digunakan pada SVR sebagai berikut**:**

i. Kernel Linear dan RBF mempunyai inisiasi parameter yang sama yaitu $C = \{1, 2, \ldots, 99\}$ **;** $Gamma = \{0,1; 1,1; 2,1\}$ **;** $\varepsilon = \{0,1; 1,1\}$,

ii. Kernel Polynomial mempunyai inisiasi parameter yaitu $C = \{1, 2, \ldots, 99\}$; $Gamma = \{0,1; 1,1; 2,1\}$; $\varepsilon = \{0,1; 1,1\}$ dan $degree = \{1\}$.

3.7.2 Pembangunan *Nowcasting* IHK Bulanan

Pembangunan model pertama yaitu pembangunan model *nowcasting* IHK bulanan. Pembangunan ini bertujuan membuat model *nowcasting* IHK bulanan dan menggunakan model *nowcasting* IHK bulanan untuk estimasi IHK harian. *Nowcasting* IHK bulanan menggunakan metode DFM, SVR, dan TSR. Akurasi model ditingkatkan dengan membandingkan IHK bulanan BPS dengan rata-rata bulanan IHK hasil *nowcasting*. Evaluasi model menggunakan nilai RMSE, sMAPE, dan MAD.

3.7.3 Pembangunan *Nowcasting* IHK Harian

Pembangunan model kedua yaitu pembangunan model *nowcasting* IHK harian. Pembangunan ini bertujuan membuat model *nowcasting* IHK harian, mencari nilai estimasi IHK harian jika data harian yang baru tersedia. *Nowcasting* IHK harian menggunakan metode DFM, SVR, dan TSR. Evaluasi model menggunakan nilai RMSE, sMAPE, dan MAD.

3.7.4 Metode *Nowcasting* dalam Pembangunan Model IHK Harian

Gambar 3.2 menunjukkan diagram pembangunan *nowcasting* IHK harian secara keseluruhan. Langkah-langkah analisis dalam membangun model IHK bulanan dengan DFM merujuk pada Sub Bab (2.3), SVR merujuk pada Sub Bab (2.4), dan TSR merujuk pada Sub Bab (2.5). Setelah diperoleh model IHK bulanan dari ketiga metode, evaluasi model IHK bulanan pada data *training* dan *testing* dengan membandingkan RMSE, sMAPE, dan MAD terkecil. Performansi ditingkatkan dengan menghitung selisih antara IHK bulanan aktual dengan rata-rata bulanan IHK harian hasil *nowcasting.* IHK harian dengan performansi terbaik (RMSE, sMAPE, dan MAD terkecil) digunakan sebagai variabel respon dalam membangun model IHK harian.

Langkah-langkah analisis dalam membangun model IHK harian dengan DFM merujuk pada Sub Bab (2.3), SVR merujuk pada Sub Bab (2.4), dan TSR merujuk pada Sub Bab (2.5).Setelah diperoleh model IHK harian, evaluasi model IHK harian pada data *training* dan *testing* dengan membandingkan RMSE, sMAPE, dan MAD terkecil. Model IHK harian dengan RMSE, sMAPE, dan MAD terkecil pada data *testing* merupakan model terbaik untuk *nowcasting* IHK harian.

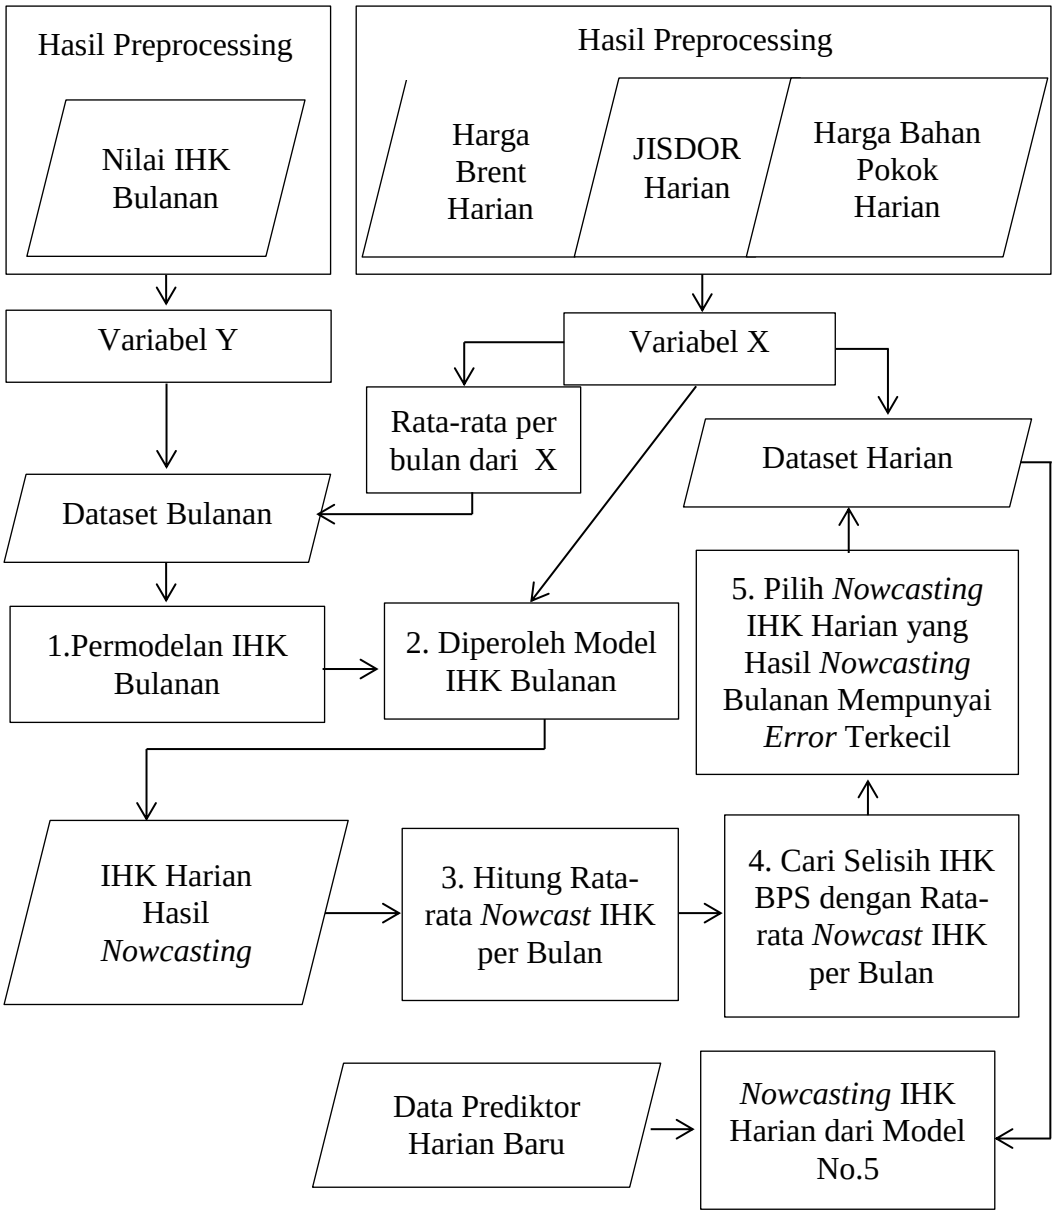

Gambar 3.2 Diagram Pembangunan *Nowcasting* IHK Harian

BAB 4
HASIL DAN PEMBAHASAN

4.1 Kajian terhadap Model DFM, SVR, dan TSR

4.1.1 Kajian Model DFM

Sebelum membangun model DFM, variabel respon dan variabel prediktor harus stasioner dalam rata-rata dan varians. Jika data tidak stasioner dalam varians maka perlu ditransformasi menggunakan transformasi Box Cox pada Tabel 2.1. Setelah stasioner dalam varians, data perlu diuji kestasionerannya dalam rata-rata menggunakan uji ADF. Tahap selanjutnya yaitu menentukan jumlah faktor (*r*), jumlah *lag* ordo (*p*) pada model VAR, dan banyak guncangan (*q*).

Jumlah faktor ditentukan berdasarkan *eigenvalue*>1 pada *Principal Component Analysis* (PCA). *Eigenvalue* diperoleh dengan menyelesaikan persamaan determinan pada Persamaan (2.16). Panjang *lag* (*p*) ditentukan berdasarkan nilai AIC yang paling minimum, ditunjukkan oleh Persamaan (2.18). Banyaknya guncangan (*q*) yang optimal ditunjukkan oleh Persamaan (2.20). Model DFM dibangun dengan jumlah faktor sebanyak *r*, jumlah *lag* ordo *p* pada model VAR dan banyak guncangan *q*.

Estimator F_t merupakan solusi dari masalah *least square* pada Persamaan (2.22) yaitu $\hat{F}_t = \hat{F}_t\left(n^{-1}\hat{\Lambda}\right) = n^{-1}\hat{\Lambda}' x_t$. Estimator OLS dari Persamaan (2.23) yaitu $\hat{\beta} = \left(\hat{F}_t'\hat{F}_t\right)^{-1}\hat{F}_t' y$. Uji asumsi residual yaitu uji asumsi residual berdistribusi normal menggunakan Persamaan (2.58) dan uji asumsi residual *white noise* menggunakan Persamaan (2.59).

4.1.2 Kajian Model SVR

Fungsi regresi, fungsi resiko (*risk function*), persamaan ε *-insensitive loss function* dan hasil transformasi dari optimasi fungsi resiko pada SVR dituliskan pada Persamaan (2.25), (2.26), (2.27), dan (2.29). Optimalisasi pada Persamaan (2.29) dapat diselesaikan dengan *primal lagrangian* pada Persamaan (2.30). Persamaan (2.30) diminimalkan pada variabel primal w, b, ξ_t, ξ_t^* dan

dimaksimalkan dalam bentuk *lagrangian multiplier* nonnegatif $\alpha_t, \alpha_t^*, \beta_t, \beta_t^*$ seperti ditampilkan pada Persamaan (2.31), (2.32), (2.33), dan (2.34).

Akhirnya kondisi Karush-Kuhn-Tucker diterapkan pada regresi dan dengan menggunakan Persamaan (2.29) sehingga diperoleh *dual lagrangian* dengan mensubtitusikan Persamaan (2.31), (2.32), (2.33), dan (2.34) ke Persamaan (2.30). Persamaan *dual lagrangian*, Persamaan (2.35), diperoleh ketika fungsi kernel $K\left(x_t, x_j\right) = \varphi'\left(x_t\right)\varphi\left(x_j\right)$.

Lagrange Multipliers pada Persamaan (2.35) memenuhi persamaan $\beta_t * \beta_t^* = 0$. *Lagrange Multipliers* β_t dan β_t^* dihitung dan vektor bobot optimal yang diharapkan dari *hyperplane* regresi pada Persamaan (2.36) sehingga didapatkan fungsi regresi pada Persamaan (2.37).

4.1.3 Kajian Model TSR

Variabel prediktor jika ditulis dalam bentuk matriks X ditunjukkan oleh Persamaan (2.12). Jika terjadi multikolinearitas antar variabel prediktor yang diketahui melalui $VIF_i = \dfrac{1}{1-R_i^2} > 10$, *Principal Component* (PC) dibentuk untuk mengatasinya. Sebelum *Principal Component Analysis* (PCA), perlu dilakukan uji Bartlett dan pemeriksaan KMO. Jika $p-value < \alpha$ pada Uji Bartlett dan KMO>0,5 maka PCA dapat dilanjutkan.

Jumlah PC yang terbentuk ditentukan berdasarkan *eigenvalue* > 1. *Eigenvalue* diperoleh dengan menyelesaikan Persamaan (2.16) dan setiap solusi *eigenvalue* memiliki *eigenvector* yang memenuhi sistem persamaan homogen pada Persamaan (2.17). $\left(\hat{\lambda}_r, \hat{e}_r\right)$ adalah pasangan *eigenvalue* dan *eigenvector* ke-*r* dari matriks *R* dengan $\hat{\lambda}_1 \geq \hat{\lambda}_2 \geq \ldots \geq \hat{\lambda}_r \geq 0$. *Eigenvector* digunakan untuk membentuk matriks *Z* ke dalam suku-suku *principal component W* pada Persamaan (2.46).

Z_{y_t} merupakan matriks hasil standarisasi dari variabel respon y ditunjukkan oleh Persamaan (2.47) dan variabel prediktor terdiri dari matriks *W*. Model TSR dalam bentuk matriks ditunjukkan oleh Persamaan (2.49) dan

estimatornya ditunjukkan oleh Persamaan (2.55). Uji hipotesis serentak ditunjukkan oleh Persamaan (2.56) dan uji parsial ditunjukkan oleh Persamaan (2.57). Uji asumsi residual yaitu uji asumsi residual berdistribusi normal menggunakan Persamaan (2.58) dan uji asumsi residual *white noise* menggunakan Persamaan (2.59).

4.2 Hasil *Preprocessing*

Data IHK yang digunakan dalam penelitian ini menggunakan dua tahun dasar yang berbeda yaitu IHK Januari 2017 sampai dengan Desember 2019 menggunakan tahun dasar 2012 sedangkan IHK Januari 2020 sampai dengan Mei 2021 menggunakan tahun dasar 2018 dalam perhitungannya. Oleh karena itu, IHK tersebut perlu disamakan tahun dasarnya terlebih dahulu menggunakan rumus pada Persamaan (3.1). Hasilnya ditunjukkan oleh Tabel 4.1.

Tabel 4.1 Perubahan IHK dengan Tahun Dasar yang Sama di Provinsi Jawa Timur

Bulan	IHK	Inflasi	IHK (2018=100)	Bulan	IHK	Inflasi	IHK (2018=100)
Jan-17	126,94	1,52	95,87	Sep-18	132,41	-0,01	100,00
Feb-17	127,26	0,25	96,11	Okt-18	132,65	0,19	100,18
Mar-17	127,14	-0,09	96,02	Nov-18	133,01	0,27	100,45
Apr-17	127,51	0,29	96,30	Des-18	133,81	0,6	101,06
Mei-17	128,12	0,48	96,76	Jan-19	134,27	0,34	101,41
Jun-17	128,75	0,49	97,24	Feb-19	134,02	-0,18	101,22
Jul-17	128,94	0,15	97,38	Mar-19	134,24	0,16	101,38
Agt-17	128,62	-0,25	97,14	Apr-19	134,8	0,41	101,81
Sep-17	128,86	0,19	97,32	Mei-19	135,19	0,29	102,10
Okt-17	128,88	0,02	97,34	Jun-19	135,36	0,13	102,23
Nov-17	129,18	0,23	97,56	Jul-19	135,57	0,16	102,39
Des-17	130,09	0,71	98,25	Agt-19	135,74	0,12	102,52
Jan-18	130,87	0,6	98,84	Sep-19	135,65	-0,07	102,45
Feb-18	131,09	0,16	99,00	Okt-19	135,61	-0,02	102,42
Mar-18	131,16	0,06	99,06	Nov-19	135,93	0,23	102,66
Apr-18	131,4	0,18	99,24	Des-19	136,65	0,53	103,20
Mei-18	131,63	0,17	99,41	Jan-20	103,72	0,5	103,72
Jun-18	132,19	0,42	99,84	Feb-20	104,04	0,31	104,04
Jul-18	132,27	0,07	99,90	Mar-20	104,03	-0,01	104,03
Agt-18	132,42	0,11	100,01	Apr-20	103,90	-0,12	103,90

Sumber: Diolah

Tabel 4.1 Perubahan IHK dengan Tahun Dasar yang Sama di Provinsi Jawa Timur (Lanjutan)

Bulan	IHK	Inflasi	IHK (2018=100)	Bulan	IHK	Inflasi	IHK (2018=100)
Mei-20	104,09	0,18	104,09	Des-20	104,69	0,46	104,69
Jun-20	104,38	0,28	104,38	Jan-21	105,02	0,32	105,02
Jul-20	104,08	-0,29	104,08	Feb-21	105,25	0,22	105,25
Agt-20	104,12	0,04	104,12	Mar-21	105,37	0,11	105,37
Sep-20	103,96	-0,15	103,96	Apr-21	105,48	0,10	105,48
Okt-20	103,94	-0,02	103,94	Mei-21	105,77	0,27	105,77
Nov-20	104,21	0,26	104,21				

Sumber: Diolah

Data harga bahan pokok pada SISKAPERBAPO mengandung *missing value*. Hasil imputasi pada data yang mengandung *missing value* menggunakan *median of nearby point* ditunjukkan oleh Tabel 4.3. Imputasi data dengan *median of nearby point* yaitu metode imputasi dengan mengisi *missing value* dari median data di sekitar *missing value*.

Tabel 4.2 Contoh *Missing Value* pada Dataset Harian Kabupaten Jember

Tanggal	Harga Beras IR64 (kg)		Harga Gula Pasir Dalam Negeri (kg)	
	Sebelum	Sesudah	Sebelum	Sesudah
18/05/2020	10.167	10.167	15.000	15.000
19/05/2020	9.833	9.833	15.167	15.167
20/05/2020	9.833	9.833	15.167	15.167
21/05/2020	9.833	9.833	15.167	15.167
22/05/2020	9.833	9.833	15.333	15.333
23/05/2020	10.167	10.167	15.833	15.833
24/05/2020	-	9.833	-	15.167
25/05/2020	-	9.833	-	15.167
26/05/2020	-	9.833	-	15.167
27/05/2020	-	9.833	-	15.167
28/05/2020	-	9.833	-	15.167
29/05/2020	-	9.833	-	15.167
30/05/2020	9.833	9.833	16.000	16.000
31/05/2020	9.833	9.833	15.833	15.833
1/06/2020	10.000	10.000	15.500	15.500
2/06/2020	9.667	9.667	14.833	14.833
3/06/2020	9.667	9.667	14.833	14.833
4/06/2020	9.667	9.667	14.833	14.833

Sumber: Diolah

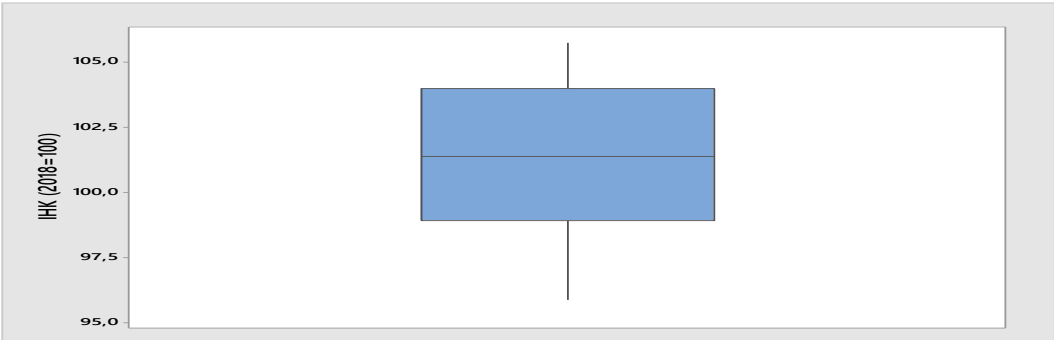

Sumber: Diolah
Gambar 4.1 Boxplot IHK Bulanan Provinsi Jawa Timur Tahun Dasar 2018

Berdasarkan Gambar 4.1 tidak ada *outlier* pada data IHK periode Januari 2017 sampai dengan Mei 2021 tahun dasar 2018. Oleh karena itu, seluruh data IHK digunakan dalam pembangunan model IHK harian Provinsi Jawa Timur.

4.3 Pembangunan *Nowcasting* IHK Bulanan

4.3.1 Pembangunan Model DFM untuk *Nowcasting* IHK Bulanan

Uji multikolinearitas pada variabel prediktor ditunjukkan oleh Tabel 4.4, dapat disimpulkan bahwa terdapat multikolinearitas antar variabel prediktor. Multikolinearitas ditunjukkan oleh VIF>10. Oleh karena itu *nowcasting* IHK bulanan dengan model DFM dapat dilanjutkan.

Tabel 4.3 Uji Multikolinearitas Rata-rata Bulanan Harga Konsumen Standar

Nama	VIF	Nama	VIF	Nama	VIF
Z_1^m	55,37	Z_{10}^m	9,14	Z_{19}^m	31,32
Z_2^m	40,74	Z_{11}^m	18,74	Z_{20}^m	15,55
Z_3^m	17,77	Z_{12}^m	19,92	Z_{21}^m	10,73
Z_4^m	38,24	Z_{13}^m	91,90	Z_{22}^m	44,62
Z_5^m	108,82	Z_{14}^m	8,28	Z_{23}^m	168,97
Z_6^m	37,42	Z_{15}^m	278,74	Z_{24}^m	65,47
Z_7^m	46,07	Z_{16}^m	128,72	Z_{25}^m	371,80
Z_8^m	7,56	Z_{17}^m	6,48	Z_{26}^m	11,42
Z_9^m	104,22	Z_{18}^m	13,71	Z_{27}^m	28,31

Tabel 4.3 Uji Multikolinearitas Rata-rata Bulanan Harga Konsumen Standar (Lanjutan)

Nama	VIF	Nama	VIF	Nama	VIF
Z_{28}^{m}	8,16	Z_{30}^{m}	7,38	Z_{32}^{m}	66,87
Z_{29}^{m}	28,38	Z_{31}^{m}	51,30	Z_{33}^{m}	126,82

Syarat dalam prosedur pemodelan DFM yaitu series data harus stasioner. Oleh karena itu, perlu dilakukan identifikasi stasioneritas pada seluruh variabel, baik stasioner dalam varians ataupun stasioner dalam rata-rata sebelum masuk ke tahap DFM. Identifikasi kestasioneran data dalam varians dapat dilakukan dengan melihat plot *Box-Cox*. Data yang digunakan dalam penelitian ini adalah nilai baku/ hasil standarisasi yang masih mengandung nilai negatif, maka ditambahkan suatu konstanta. Pada penelitian ini, peneliti menambahkan nilai konstanta sebesar 8, sehingga deret data tersebut dapat diuji *Box-Cox transformation*.

Plot Box-Cox pada Gambar 4.2 menunjukkan bahwa pada data IHK bulanan standar memiliki *rounded value* yang sudah memuat nilai 1 (satu) sehingga dapat disimpulkan bahwa data IHK bulanan tersebut sudah merupakan data yang stasioner dalam varians atau tidak perlu dilakukan transformasi lebih lanjut. Dengan demikian, data IHK bulanan yang digunakan selanjutnya adalah data IHK bulanan hasil standarisasi (data awal).

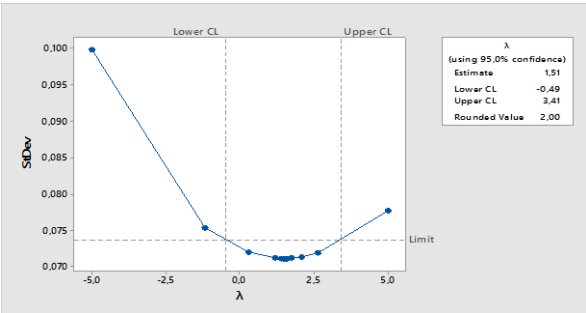

Gambar 4.2 Plot Box-Cox Data IHK Bulanan Standar

Identifikasi stasioneritas data IHK bulanan standar terhadap rata-rata dengan melihat plot *time series*, plot ACF, dan uji ADF. Data dikatakan stasioner jika plot *time series* menunjukkan pola rata-rata yang tetap dan tidak dipengaruhi

oleh waktu sedangkan pada plot ACF menunjukkan pola yang turun cepat dan segera *cut off* pada *lag* tertentu. Data dikatakan stasioner jika *p-value* <0,05 pada uji ADF.

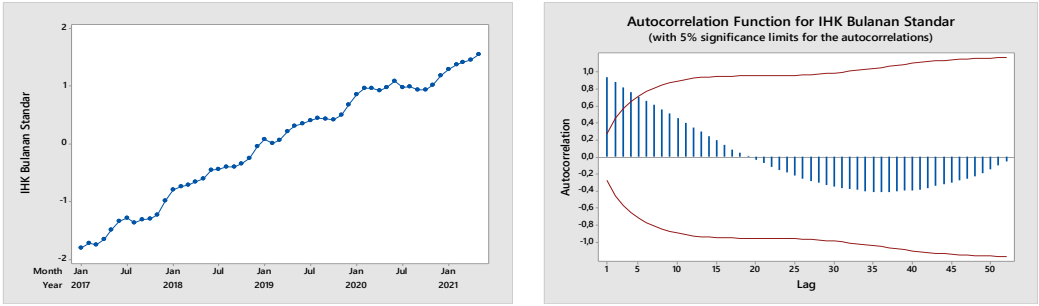

(a) (b)

Gambar 4.3 Plot (a) *Time Series* dan (b) ACF IHK Bulanan Standar

Gambar 4.3 menunjukkan bahwa data belum stasioner dalam rata-rata ditunjukkan oleh plot *time series* yang menunjukkan adanya tren dan plot ACF menunjukkan *lag* yang turun lambat. Demikian juga berdasarkan hasil uji ADF, data belum stasioner dalam rata-rata ditunjukkan oleh *p-value* (0,60) > 0,05. Oleh karena itu, data IHK bulanan standar perlu di-*differencing lag* 1.

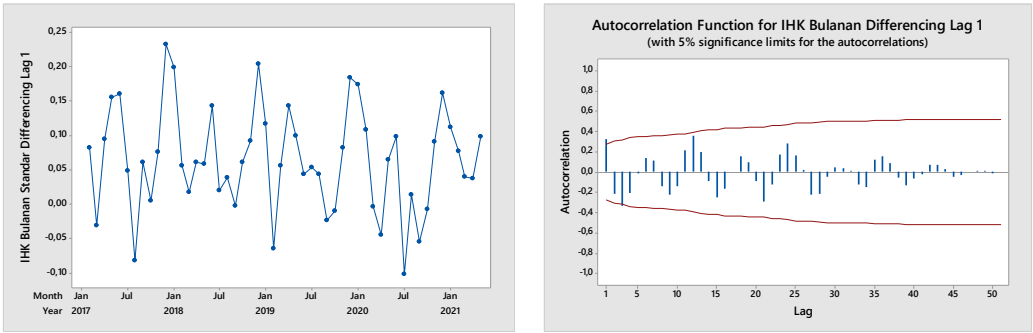

(a) (b)

Gambar 4.4. Plot (a) *Time Series* dan (b) ACF IHK Bulanan Standar *Differencing Lag* 1

Berdasarkan Gambar 4.4, data IHK bulanan standar setelah di-*differencing lag* 1 sudah stasioner dalam rata-rata ditunjukkan oleh plot *time series* yang berfluktuasi di sekitar rata-rata dan plot ACF menunjukkan *cut off after lag* 1. Demikian juga berdasarkan hasil uji ADF, data sudah stasioner dalam rata-rata ditunjukkan oleh *p-value* (<0,01) < 0,05.

Tabel 4.4 Nilai *Rounded Value* Rata-rata Bulanan Harga Konsumen Standar Sebelum Transformasi

Variabel	*Estimate*	*Lower CL*	*Upper CL*	*Rounded Value*
Z_1^m	2,02	0,49	3,99	2,00
Z_2^m	-5,00	*	*	-5,00
Z_3^m	-1,95	-3,90	-0,31	-2,00
Z_4^m	-4,66	*	-2,64	-5,00
Z_5^m	2,17	0,31	4,37	2,00
Z_6^m	-0,90	-3,12	1,26	-1,00
Z_7^m	-1,03	-2,96	0,47	-1,00
Z_8^m	0,22	-1,79	2,66	0,00
Z_9^m	-1,65	-3,46	0,44	-2,00
Z_{10}^m	-1,25	-3,15	0,97	-1,00
Z_{11}^m	2,64	0,55	*	3,00
Z_{12}^m	-3,50	1,25	*	3,00
Z_{13}^m	0,58	-1,34	2,71	0,50
Z_{14}^m	1,65	0,14	3,10	2,00
Z_{15}^m	0,85	-1,30	2,94	1,00
Z_{16}^m	-3,17	*	-0,87	-3,00
Z_{17}^m	-5,00	*	*	-5,00
Z_{18}^m	-2,64	*	-0,48	-3,00
Z_{19}^m	-4,76	*	-2,17	-5,00
Z_{20}^m	-0,64	-2,82	1,38	-0,50
Z_{21}^m	-3,42	*	1,23	-3,00
Z_{22}^m	1,69	-0,39	3,73	2,00
Z_{23}^m	-2,42	*	-0,34	-2,00
Z_{24}^m	-1,00	-3,22	1,30	-1,00
Z_{25}^m	0,92	-1,19	2,94	1,00
Z_{26}^m	-1,61	-3,68	0,50	-2,00
Z_{27}^m	0,66	-1,04	2,35	0,50
Z_{28}^m	-2,00	-4,28	-0,02	-2,00

Tabel 4.4 Nilai *Rounded Value* Rata-rata Bulanan Harga Konsumen Standar Sebelum Transformasi (Lanjutan)

Variabel	*Estimate*	*Lower CL*	*Upper CL*	*Rounded Value*
Z_{29}^{m}	-1,86	-3,94	0,42	-2,00
Z_{30}^{m}	-2,21	-4,71	-0,19	-2,00
Z_{31}^{m}	0,68	-1,22	2,70	0,50
Z_{32}^{m}	1,60	-0,41	3,60	2,00
Z_{33}^{m}	1,97	0,17	4,19	2,00

Tabel 4.4 merupakan *rounded value* (lambda) yang belum mengalami tahap transformasi. Plot Box-Cox bisa dilihat pada Lampiran 3. Data dikatakan stasioner dalam varians jika diantara nilai batas bawah dan batas atas dari *rounded value* terdapat nilai satu. Ada 18 dari 33 rata-rata bulanan harga konsumen standar yang belum stasioner dalam varians. Oleh karena itu, kedelapan belas rata-rata bulanan harga konsumen standar yang belum stasioner dalam varians perlu dilakukan transformasi.

Tabel 4.5 Nilai *Rounded Value* Rata-rata Bulanan Harga Konsumen Stadar Setelah Transformasi Box Cox

Variabel	Transformasi	*Estimate*	*Lower CL*	*Upper CL*	*Rounded Value*
Z_{1}^{m}	Z_{1}^{m}	2,02	0,49	3,99	2,00
Z_{2}^{m}	$1/\left(Z_{2}^{m}+8\right)^{5}$	1,02	0,64	1,47	1,00
Z_{3}^{m}	$1/\left(Z_{3}^{m}+8\right)^{2}$	0,90	0,10	1,93	1,00
Z_{4}^{m}	$1/\left(Z_{4}^{m}+8\right)^{5}$	0,93	0,56	1,31	1,00
Z_{5}^{m}	Z_{5}^{m}	2,17	0,31	4,37	2,00
Z_{6}^{m}	Z_{6}^{m}	-0,90	-3,12	1,26	-1,00
Z_{7}^{m}	$1/\left(Z_{7}^{m}+8\right)$	1,33	-0,47	2,86	1,00
Z_{8}^{m}	Z_{8}^{m}	0,22	-1,79	2,66	0,00
Z_{9}^{m}	$1/\left(Z_{9}^{m}+8\right)^{2}$	0,82	-0,08	1,85	1,00
Z_{10}^{m}	$1/\left(Z_{10}^{m}+8\right)$	1,25	-0,97	3,15	1,00

Tabel 4.5 Nilai *Rounded Value* Rata-rata Bulanan Harga Konsumen Stadar Setelah Transformasi Box Cox (Lanjutan)

Variabel	Transformasi	*Estimate*	*Lower CL*	*Upper CL*	*Rounded Value*
Z_{11}^{m}	$\left(Z_{11}^{m}+8\right)^{3}$	0,80	0,19	1,64	1,00
Z_{12}^{m}	$\left(Z_{12}^{m}+8\right)^{3}$	1,17	0,46	1,85	1,00
Z_{13}^{m}	Z_{13}^{m}	0,58	-1,34	2,71	0,50
Z_{14}^{m}	Z_{14}^{m}	1,65	0,14	3,10	2,00
Z_{15}^{m}	Z_{15}^{m}	0,85	-1,30	2,94	1,00
Z_{16}^{m}	$1/\left(Z_{16}^{m}+8\right)^{3}$	1,06	0,26	1,92	1,00
Z_{17}^{m}	$1/\left(Z_{17}^{m}+8\right)^{5}$	1,04	0,76	1,41	1,00
Z_{18}^{m}	$1/\left(Z_{18}^{m}+8\right)^{3}$	0,80	0,18	1,73	1,00
Z_{19}^{m}	$1/\left(Z_{19}^{m}+8\right)^{5}$	0,95	0,45	1,49	1,00
Z_{20}^{m}	Z_{20}^{m}	-0,64	-2,82	1,38	-0,50
Z_{21}^{m}	$1/\left(Z_{21}^{m}+8\right)^{3}$	1,14	0,46	1,86	1,00
Z_{22}^{m}	Z_{22}^{m}	1,69	-0,39	3,73	2,00
Z_{23}^{m}	$1/\left(Z_{23}^{m}+8\right)^{2}$	1,21	0,12	2,48	1,00
Z_{24}^{m}	Z_{24}^{m}	-1,00	-3,22	1,30	-1,00
Z_{25}^{m}	Z_{25}^{m}	0,92	-1,19	2,94	1,00
Z_{26}^{m}	$1/\left(Z_{26}^{m}+8\right)^{2}$	0,80	-0,08	1,93	1,00
Z_{27}^{m}	Z_{27}^{m}	0,66	-1,04	2,35	0,50
Z_{28}^{m}	$1/\left(Z_{28}^{m}+8\right)^{2}$	1,00	0,01	2,11	1,00
Z_{29}^{m}	$1/\left(Z_{29}^{m}+8\right)^{2}$	-1,86	-3,94	0,42	-2,00
Z_{30}^{m}	$1/\left(Z_{30}^{m}+8\right)^{2}$	1,11	0,07	2,32	1,00
Z_{31}^{m}	Z_{31}^{m}	0,68	-1,22	2,70	0,50
Z_{32}^{m}	Z_{32}^{m}	1,60	-0,41	3,60	2,00
Z_{33}^{m}	Z_{33}^{m}	1,97	0,17	4,19	2,00

Tabel 4.5 merupakan *rounded value* yang sudah mengalami tahap transformasi dengan menggunakan transformasi *Box-Cox*. Plot *Box-Cox* bisa dilihat pada Lampiran 4. Semua variabel sudah stasioner dalam varians ditunjukkan oleh nilai satu diantara batas bawah dan batas atas *rounded value*.

Langkah selanjutnya yaitu identifikasi stasioneritas dalam rata-rata pada data rata-rata bulanan harga konsumen standar dengan melihat plot *time series*, plot ACF, dan uji ADF. Data dikatakan sudah stasioner dalam rata-rata jika pada plot ACF menunjukkan pola turun cepat dan *cut off* pada *lag* tertentu. Lampiran 5 merupakan plot ACF untuk variabel yang belum stasioner dalam rata-rata sehingga variabel tersebut perlu dilakukan *differencing*.

Gambar 4.5 menunjukkan plot *time series* dari data rata-rata bulanan harga konsumen yang sudah stasioner dalam rata-rata. Identifikasi stasioner dalam rata-rata dengan plot *time series* ditunjukkan oleh data yang berfluktuasi di sekitar rata-rata seiring berjalannya waktu. Selain berdasarkan visualisasi dari plot *time series*, identifikasi data stasioner dalam rata-rata juga menggunakan uji *Augmented Dickey-Fuller* (ADF).

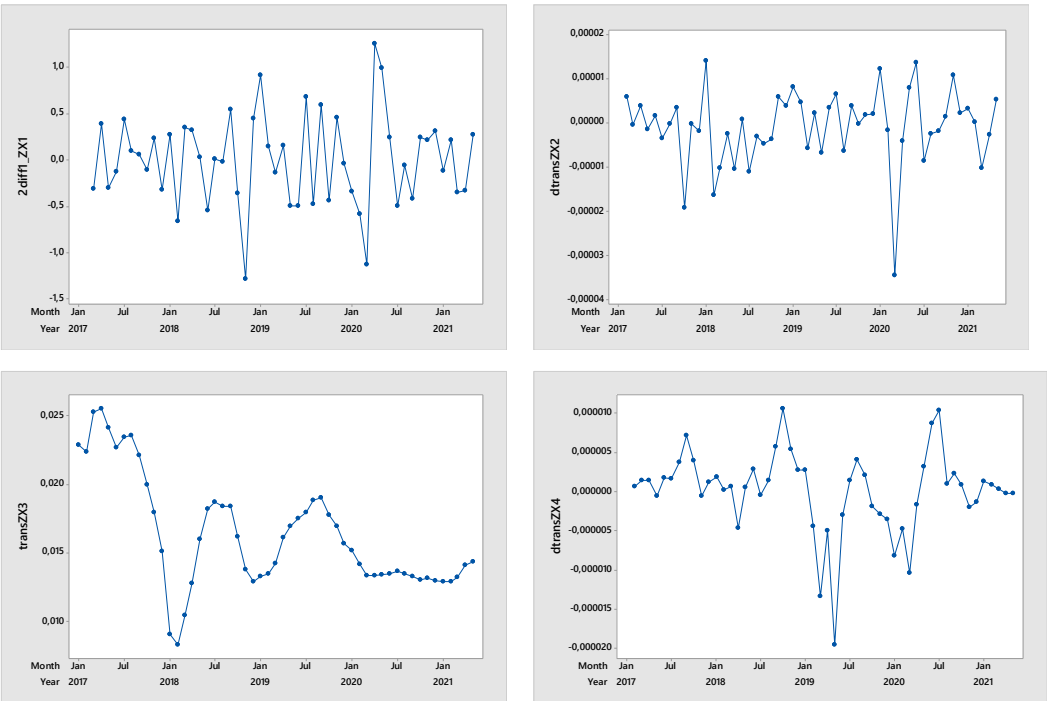

Gambar 4.5 Plot *Time Series* Rata-rata Bulanan Harga Konsumen Standar Sesudah Stasioner

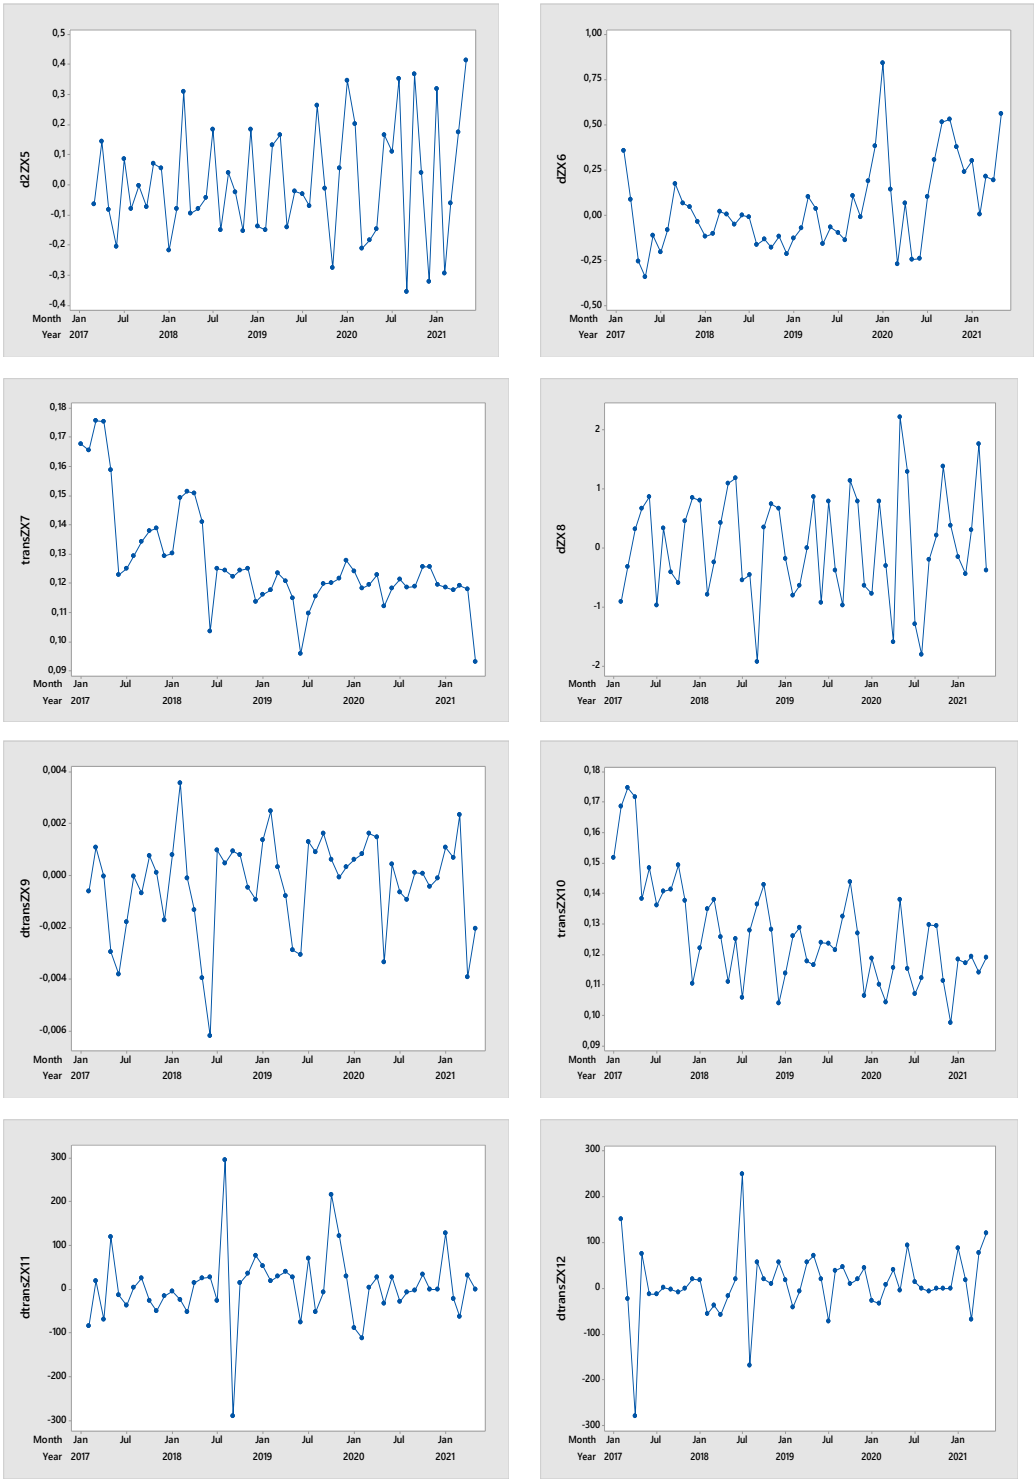

Gambar 4.5 Plot *Time Series* Rata-rata Bulanan Harga Konsumen Standar Sesudah Stasioner (Lanjutan)

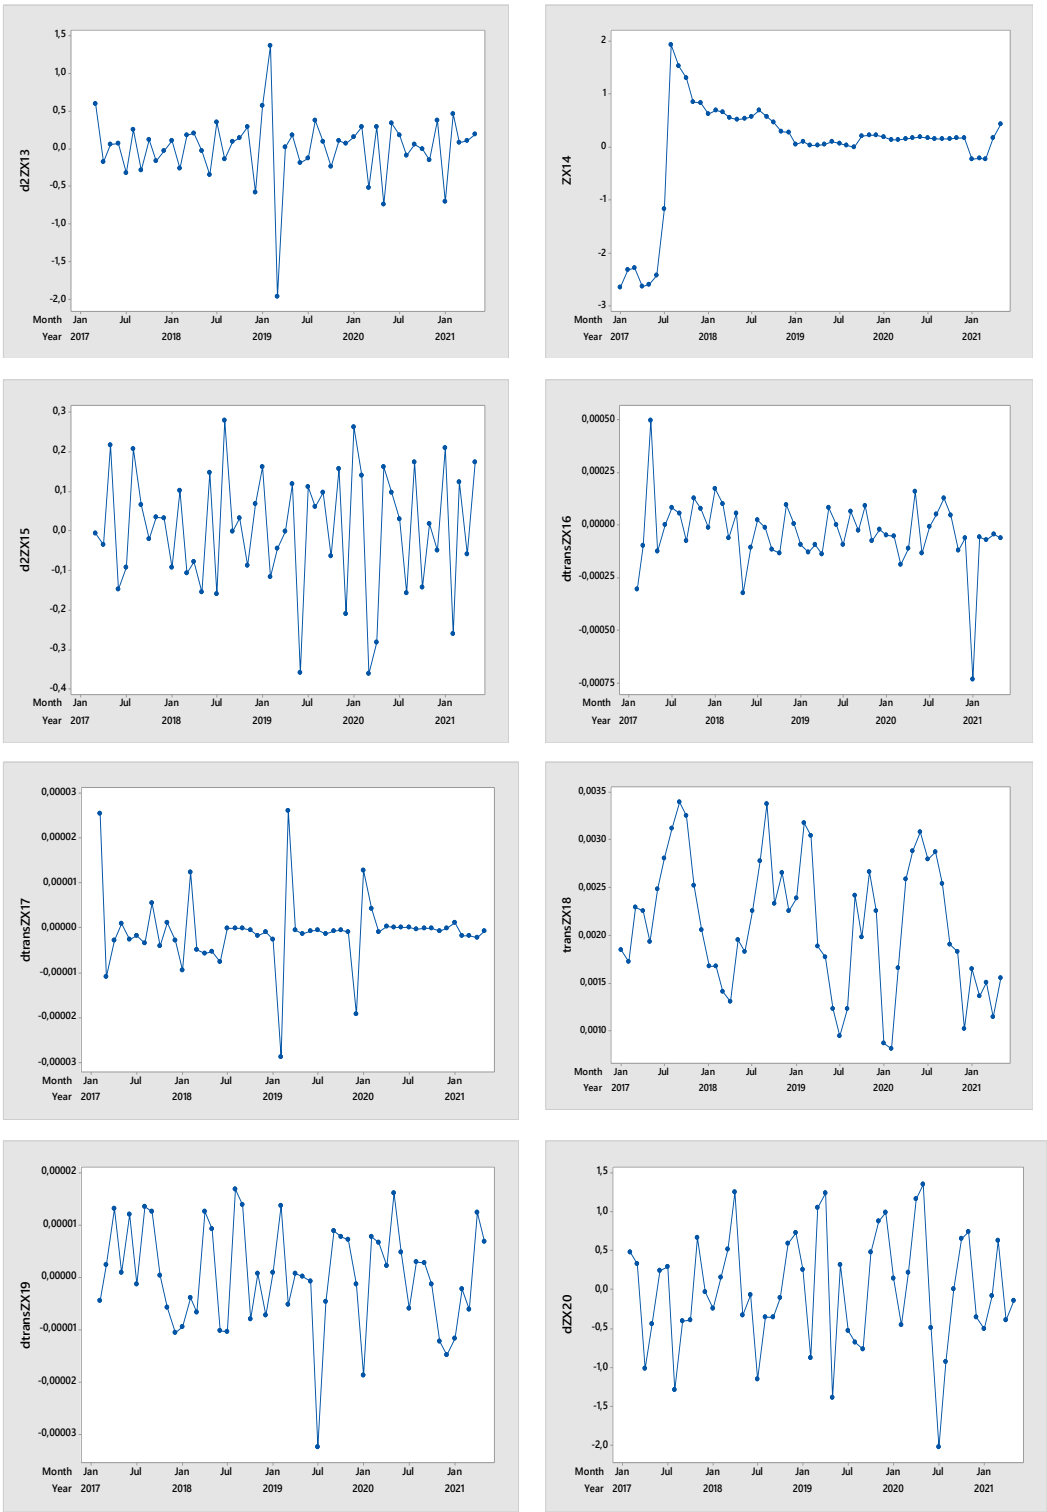

Gambar 4.5 Plot *Time Series* Rata-rata Bulanan Harga Konsumen Standar Sesudah Stasioner (Lanjutan)

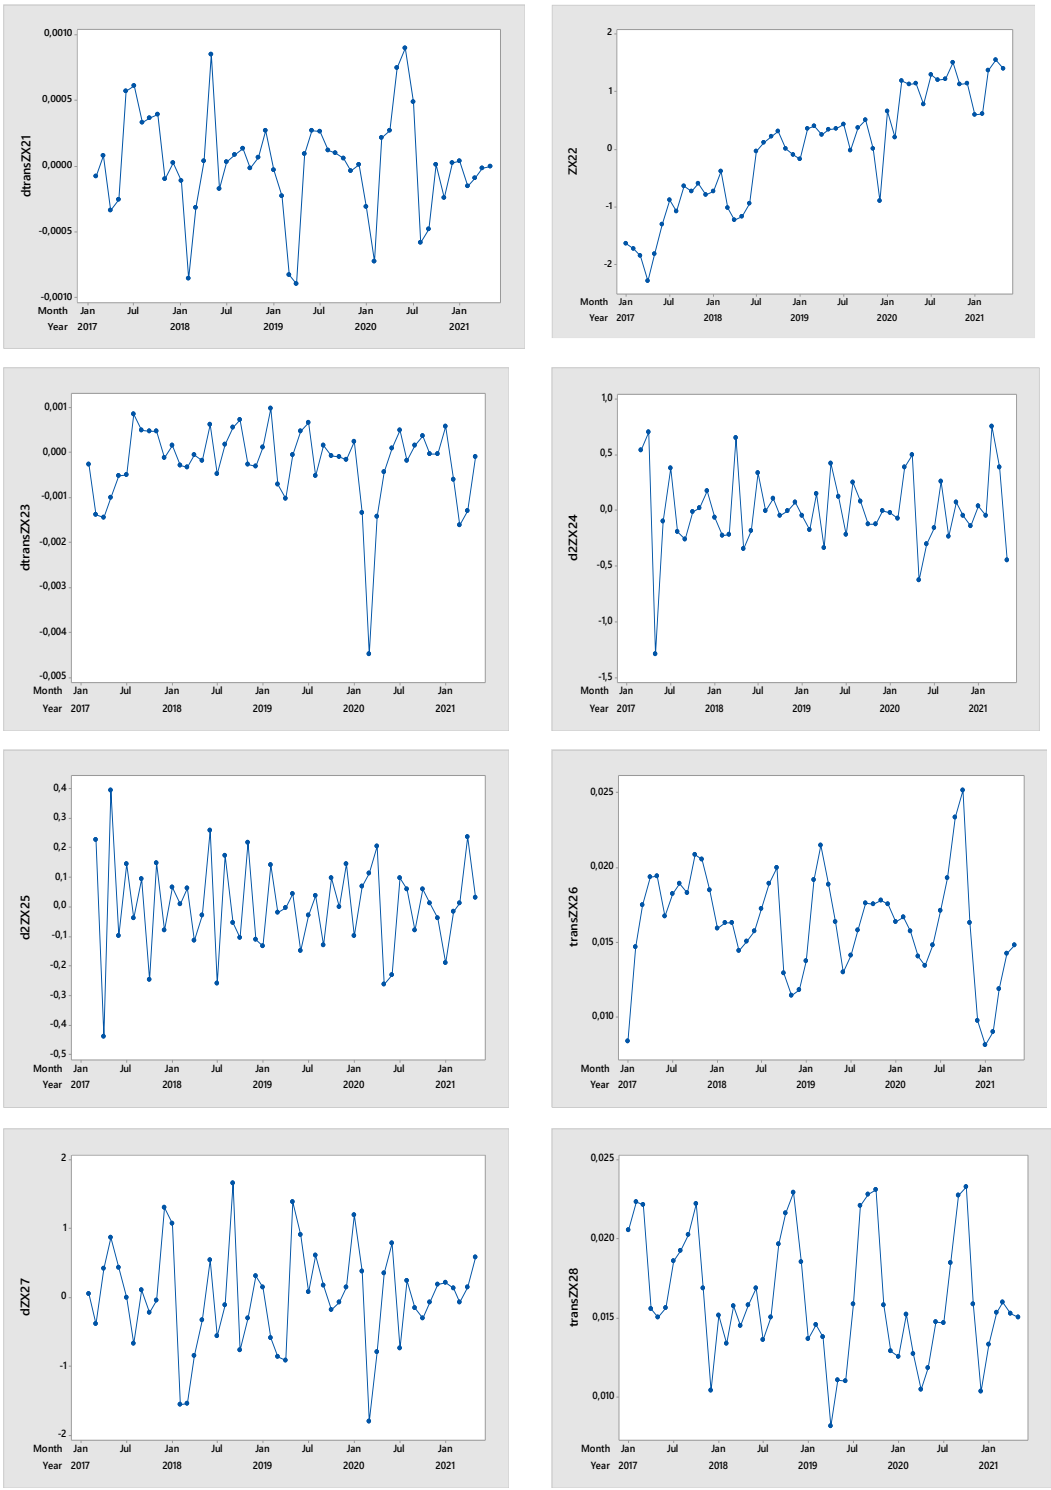

Gambar 4.5 Plot *Time Series* Rata-rata Bulanan Harga Konsumen Standar Sesudah Stasioner (Lanjutan)

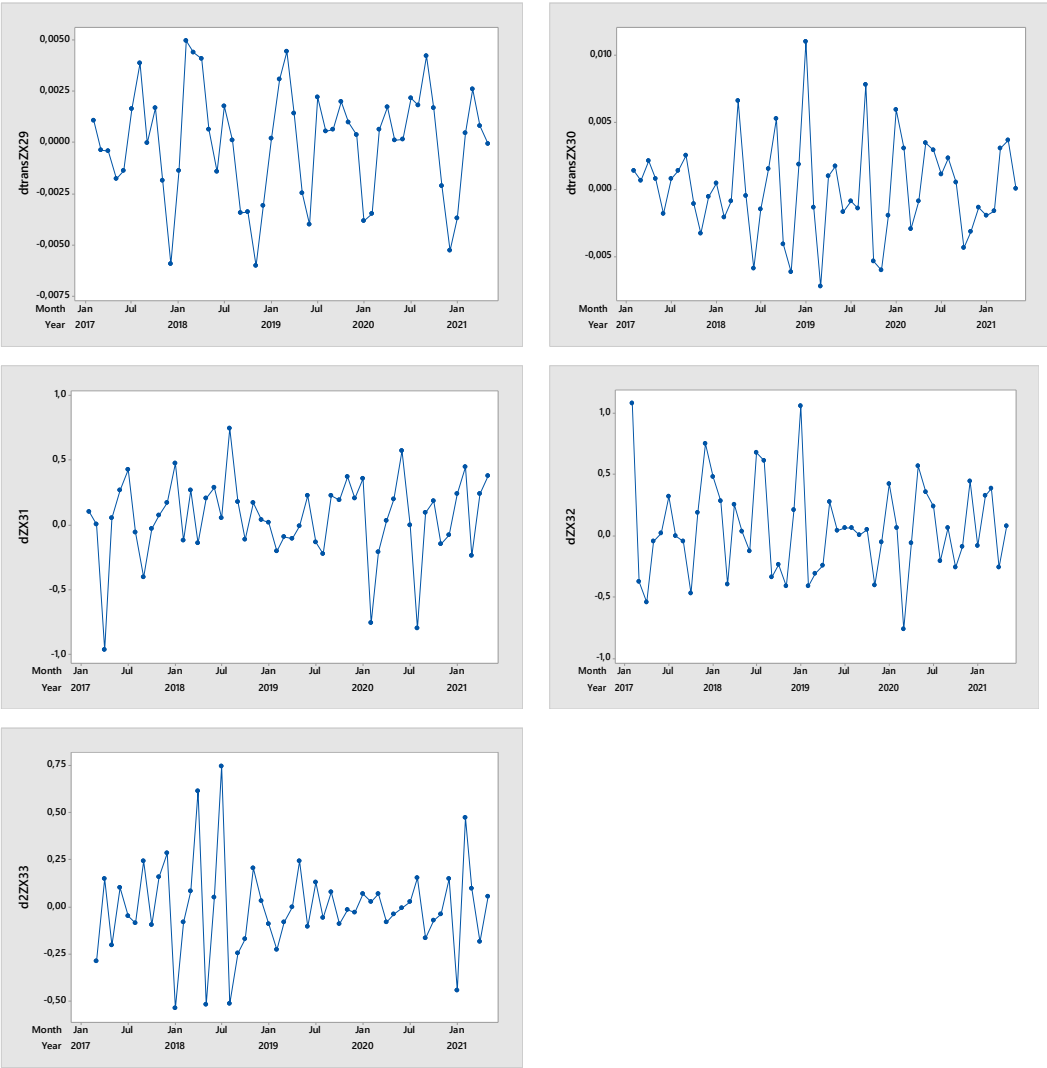

Gambar 4.5 Plot *Time Series* Rata-rata Bulanan Harga Konsumen Standar Sesudah Stasioner (Lanjutan)

Tabel 4.6 merupakan hasil uji ADF dan dihasilkan *p-value* yang nilainya dibawah 0,05. Oleh karena itu dapat disimpulkan bahwa semua variabel rata-rata bulanan harga konsumen sudah stasioner dalam rata-rata.

Tabel 4.6 Uji ADF Rata-rata Bulanan Harga Konsumen Standar

Variabel	*p-value*		Ket.	Variabel	*p-value*		Ket.
	Sebelum	Sesudah			Sebelum	Sesudah	
Z_1^m	0,73	<0,01	2*Diff*	Z_3^m	0,03	0,03	*trans*
Z_2^m	0,81	<0,01	*trans-Diff*	Z_4^m	0,43	<0,01	*trans -Diff*

Tabel 4.6 Uji ADF Rata-rata Bulanan Harga Konsumen Standar (Lanjutan)

Variabel	*p-value*		Ket.	Variabel	*p-value*		Ket.
	Sebelum	Sesudah			Sebelum	Sesudah	
Z_5^m	>0,99	<0,01	2*Diff*	Z_{20}^m	0,17	<0,01	*Diff*
Z_6^m	>0,99	<0,01	*Diff*	Z_{21}^m	0,054	<0,01	*trans -Diff*
Z_7^m	<0,01	<0,01	*trans*	Z_{22}^m	0,02	0,02	-
Z_8^m	0,24	<0,01	*Diff*	Z_{23}^m	0,71	0,04	*trans -Diff*
Z_9^m	0,13	<0,01	*trans-Diff*	Z_{24}^m	0,59	<0,01	2*Diff*
Z_{10}^m	0,02	0,02	*trans*	Z_{25}^m	0,48	<0,01	2*Diff*
Z_{11}^m	0,50	<0,01	*trans-Diff*	Z_{26}^m	<0,01	<0,01	*trans*
Z_{12}^m	0,40	<0,01	*trans-Diff*	Z_{27}^m	0,39	<0,01	*Diff*
Z_{13}^m	0,20	<0,01	2*Diff*	Z_{28}^m	<0,01	<0,01	*trans*
Z_{14}^m	0,02	0,02	-	Z_{29}^m	0,10	<0,01	*trans -Diff*
Z_{15}^m	0,55	0,02	2*Diff*	Z_{30}^m	0,24	0,02	*trans -Diff*
Z_{16}^m	0,67	0,02	*trans-Diff*	Z_{31}^m	0,59	<0,01	*Diff*
Z_{17}^m	0,80	<0,01	*trans-Diff*	Z_{32}^m	0,63	<0,01	*Diff*
Z_{18}^m	0,02	0,02	*trans*	Z_{33}^m	0,85	<0,01	2*Diff*
Z_{19}^m	0,08	0,01	*trans-Diff*				

Data yang digunakan periode Januari 2017 sampai dengan Desember 2020 sebagai data *training* dan periode Januari 2021 sampai dengan Mei 2021 sebagai data *testing*. Berdasarkan Gambar 4.6, tiga puluh tiga variabel rata-rata bulanan harga konsumen stasioner diekstrak menjadi sebelas *common factor*. Terlihat bahwa dari *component number* satu sampai dengan sebelas arah garis menurun dengan cukup tajam. Setelah *component number* sebelas dan seterusnya arah garis masih menurun, namun dengan *slope* yang lebih kecil. Hal ini menunjukkan bahwa sebelas faktor paling baik untuk meringkas tiga puluh tiga variabel tersebut.

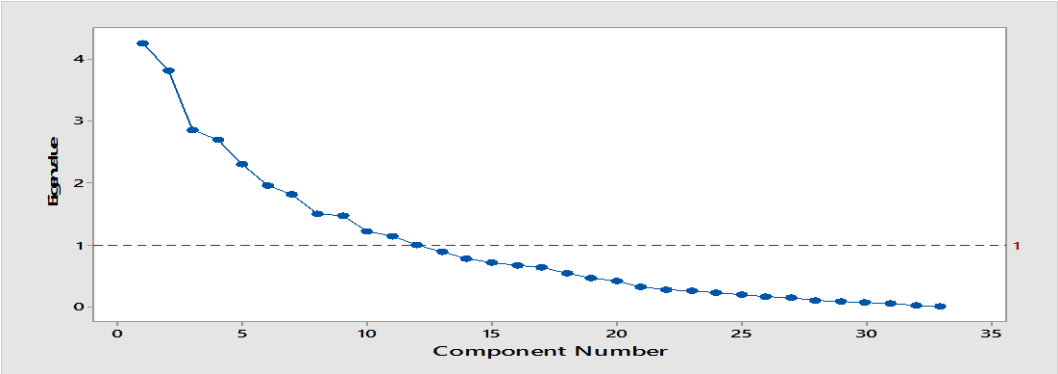

Gambar 4.6 *Screeplot* dari Variabel Rata-rata Bulanan Harga Konsumen Stasioner

Selain berdasarkan *screeplot*, penentuan jumlah *common factor* juga berdasarkan *eigenvalue* hasil PCA. Tabel 4.7 menunjukkan bahwa terdapat sebelas *common factor* dengan *eigenvalue* yang nilainya lebih dari satu.

Tabel 4.7 *Eigenvalue*, Proporsi dan Kumulatif Proporsi Variasi yang Terjelaskan dari Variabel Rata-rata Bulanan Harga Konsumen Stasioner

Faktor	*Eigenvalue*	Proporsi	Kumulatif
1	4,246	12,868	12,868
2	3,807	11,538	24,406
3	2,856	8,655	33,061
4	2,698	8,176	41,237
5	2,304	6,982	48,219
6	1,955	5,924	54,142
7	1,809	5,481	59,623
8	1,493	4,525	64,149
9	1,464	4,438	68,586
10	1,224	3,708	72,294
11	1,139	3,450	75,744
12	0,991	3,003	78,747
13	0,879	2,663	81,410
14	0,781	2,366	83,776
15	0,715	2,167	85,943
16	0,662	2,006	87,949
17	0,636	1,926	89,875
18	0,536	1,623	91,498
19	0,463	1,404	92,902
20	0,422	1,278	94,179
21	0,316	0,958	95,137
22	0,278	0,844	95,981

Tabel 4.7 *Eigenvalue*, Proporsi dan Kumulatif Proporsi Variasi yang Terjelaskan dari Variabel Rata-rata Bulanan Harga Konsumen Stasioner (Lanjutan)

Faktor	*Eigenvalue*	Proporsi	Kumulatif
23	0,261	0,792	96,772
24	0,218	0,662	97,434
25	0,202	0,611	98,045
26	0,159	0,482	98,528
27	0,149	0,452	98,979
28	0,103	0,313	99,292
29	0,088	0,266	99,558
30	0,063	0,192	99,750
31	0,052	0,158	99,908
32	0,021	0,065	99,973
33	0,009	0,027	100,000

Langkah selanjutnya adalah menentukan jumlah *lag* ordo *p* pada VAR dan penentuan banyaknya guncangan (*q*). Tabel 4.8 merupakan nilai AIC untuk setiap *lag*. Hasil tersebut menunjukan nilai AIC terkecil ada pada *lag* ke-3 sehingga dalam penelitian ini digunakan *lag* ordo (*p*) pada model VAR adalah 3 dengan nilai AIC sebesar $-\infty$.

Tabel 4.8 Hasil Penentuan *Lag* Ordo (*p*) pada Model VAR Berdasarkan AIC

Lag	AIC
1	3,473
2	-9,064
3	$-\infty$

Banyaknya guncangan (q) yang optimal ditentukan melalui kriteria informasi dengan *eigenvalue* dari matriks galat model VAR(p) dan akan selalu lebih kecil atau sama dengan banyaknya faktor dinamis (r). Banyaknya guncangan (q) menggambarkan banyaknya guncangan idiosinkratik pada model VAR jika diketahui banyaknya faktor dinamis yang digunakan adalah sebanyak (r) dengan panjang lag pada model VAR adalah (p). Pada tahap sebelumya, telah ditentukan banyaknya faktor dinamis r adalah sebanyak 11 dengan lag ordo (p) pada model VAR adalah 3. *Eigenvalue* dari matriks ragam peragam galat model VAR (p) diurutkan dari nilai yang tertinggi. Kemudian, diambil akar ciri tertinggi

sebanyak faktor dinamis (r) yaitu 11 yang akan dihitung normalisasinya. Banyaknya guncangan (q) yang optimal yaitu 5.

Langkah selanjutnya adalah melakukan pemodelan dengan metode DFM. Model DFM (r=11, p=3, q=5) mempunyai residual yang *white noise* dan berdistribusi normal. Secara matematis model DFM (r=11, p=3, q=5) dapat dituliskan sebagai berikut:

$$\hat{Z}_{y_t}^m = 0,023 f_1^m + 0,004 f_2^m + 0,008 f_3^m + 0,020 f_4^m + 0,008 f_5^m + 0,008 f_6^m + 0,019 f_7^m$$
$$+0,010 f_8^m + 0,007 f_9^m - 0,011 f_{10}^m + 0,012 f_{11}^m + \hat{Z}_{y_{t-1}}^m$$

Tabel 4.9 Hasil Pengujian dengan Metode DFM (r=11, p=3, q=5)

Koefisien					
	f_1^m	f_2^m	f_3^m	f_4^m	f_5^m
	0,023	0,004	0,008	0,020	0,008
f_6^m	f_7^m	f_8^m	f_9^m	f_{10}^m	f_{11}^m
0,017	0,019	0,010	0,007	-0,011	0,012
Uji Asumsi Residual					
White Noise	*p-value*	Keterangan	Normal	*p-value*	Keterangan
Lag 6	0,613	Terpenuhi	KS	0,974	Terpenuhi
Lag 12	0,734	Terpenuhi			

Setelah diperoleh model DFM dari IHK bulanan, IHK harian diprediksi menggunkan model IHK bulanan tersebut. Sebelum prediksi IHK harian, terlebih dahulu variabel prediktor harian yaitu harga konsumen diuji stasioneritasnya baik stasioner dalam varians maupun rata-rata. Tabel 4.10 merupakan *rounded value* (lambda) yang belum mengalami tahap transformasi. Plot *Box-Cox* bisa dilihat pada Lampiran 6. Dua puluh delapan dari tiga puluh tiga variabel tersebut perlu ditransformasi agar stasioner terhadap varians.

Tabel 4.10 Nilai *Rounded Value* Harga Konsumen Harian Standar Sebelum Transformasi

Variabel	*Estimate*	*Lower CL*	*Upper CL*	*Rounded Value*
Z_1^d	1,03	0,81	1,25	1,00
Z_2^d	-2,51	-2,89	-2,11	-2,51

Tabel 4.10 Nilai *Rounded Value* Harga Konsumen Harian Standar Sebelum Transformasi (Lanjutan)

Variabel	*Estimate*	*Lower CL*	*Upper CL*	*Rounded Value*
Z_3^d	0,82	0,53	1,14	1,00
Z_4^d	-3,10	-3,50	-2,72	-3,00
Z_5^d	0,65	0,27	0,99	0,50
Z_6^d	-1,24	-1,67	-0,81	-1,00
Z_7^d	-0,75	-0,98	-0,56	-0,75
Z_8^d	0,13	-0,19	0,42	0,00
Z_9^d	0,37	0,05	0,66	0,50
Z_{10}^d	-0,11	-0,46	0,28	0,00
Z_{11}^d	-0,90	-1,05	-0,81	-1,00
Z_{12}^d	-0,59	-0,74	-0,45	-0,50
Z_{13}^d	1,40	1,13	1,67	1,40
Z_{14}^d	1,68	1,49	1,89	1,68
Z_{15}^d	4,77	4,22	*	5,00
Z_{16}^d	1,01	0,70	1,39	1,00
Z_{17}^d	-3,93	-4,20	-3,65	-4,00
Z_{18}^d	-3,17	-3,59	-2,76	-3,00
Z_{19}^d	-4,18	-4,62	-3,71	-4,00
Z_{20}^d	-0,74	-1,14	-0,37	-0,50
Z_{21}^d	-3,70	-4,11	-3,41	-4,00
Z_{22}^d	4,87	4,51	*	5,00
Z_{23}^d	1,23	0,83	1,60	1,00
Z_{24}^d	0,98	0,58	1,31	1,00
Z_{25}^d	3,69	3,38	4,03	4,00
Z_{26}^d	-1,29	-1,67	-0,90	-1,00
Z_{27}^d	0,08	-0,28	0,40	0,00
Z_{28}^d	-1,83	-2,18	-1,45	-2,00
Z_{29}^d	-0,95	-1,29	-0,56	-1,00
Z_{30}^d	-0,30	-0,69	0,08	-0,50

Tabel 4.10 Nilai *Rounded Value* Harga Konsumen Harian Standar Sebelum Transformasi (Lanjutan)

Variabel	*Estimate*	*Lower CL*	*Upper CL*	*Rounded Value*
Z_{31}^{d}	1,90	1,52	2,20	2,00
Z_{32}^{d}	-0,47	-0,73	-0,23	-0,50
Z_{33}^{d}	4,17	3,82	4,50	4,00

Tabel 4.11 merupakan *rounded value* yang sudah mengalami tahap transformasi dengan menggunakan transformasi *Box-Cox*. Plot *Box-Cox* bisa dilihat pada Lampiran 7. Semua variabel sudah stasioner dalam varians ditunjukkan oleh nilai satu diantara batas bawah dan batas atas *rounded value*-nya.

Tabel 4.11 Nilai *Rounded Value* Harga Konsumen Harian Standar Setelah Transformasi Box Cox

Variabel	Transformasi	*Estimate*	*Lower CL*	*Upper CL*	*Rounded Value*
Z_{1}^{d}	Z_{1}^{d}	1,03	0,81	1,25	1,00
Z_{2}^{d}	$1/\left(Z_{2}^{d}+8\right)^{2,5}$	1,00	0,84	1,16	1,00
Z_{3}^{d}	Z_{3}^{d}	0,82	0,53	1,14	1,00
Z_{4}^{d}	$1/\left(Z_{4}^{d}+8\right)^{3}$	1,03	0,91	1,17	1,00
Z_{5}^{d}	$\sqrt{\left(Z_{5}^{d}+8\right)}$	1,30	0,59	1,96	1,00
Z_{6}^{d}	$1/\left(Z_{6}^{d}+8\right)$	1,24	0,81	1,67	1,00
Z_{7}^{d}	$1/\left(Z_{7}^{d}+8\right)^{0,75}$	1,00	0,71	1,26	1,00
Z_{8}^{d}	$Log(Z_{8}^{d}+8)$	1,40	0,73	1,98	1,00
Z_{9}^{d}	$\sqrt{\left(Z_{9}^{d}+8\right)}$	0,70	0,19	1,33	0,50
Z_{10}^{d}	$Log\left(Z_{10}^{d}+8\right)$	0,70	0,11	1,51	1,00
Z_{11}^{d}	$1/\left(Z_{11}^{d}+8\right)$	0,90	0,81	1,05	1,00
Z_{12}^{d}	$1/\sqrt{\left(Z_{12}^{d}+8\right)}$	1,17	0,85	1,48	1,00
Z_{13}^{d}	$\left(Z_{13}^{d}+8\right)^{1,4}$	1,00	0,80	1,19	1,00

Tabel 4.11 Nilai *Rounded Value* Harga Konsumen Harian Standar Setelah Transformasi Box Cox (Lanjutan)

Variabel	Transformasi	*Estimate*	*Lower CL*	*Upper CL*	*Rounded Value*
Z_{14}^{d}	$\left(Z_{14}^{d}+8\right)^{1,68}$	1,00	0,88	1,12	1,00
Z_{15}^{d}	$\left(Z_{15}^{d}+8\right)^{5}$	0,95	0,89	1,02	1,00
Z_{16}^{d}	Z_{16}^{d}	1,01	0,70	1,39	1,00
Z_{17}^{d}	$1/\left(Z_{17}^{d}+8\right)^{4}$	0,90	0,91	1,06	1,00
Z_{18}^{d}	$1/\left(Z_{18}^{d}+8\right)^{3}$	1,06	0,92	1,19	1,00
Z_{19}^{d}	$1/\left(Z_{19}^{d}+8\right)^{4}$	1,04	0,93	1,17	1,00
Z_{20}^{d}	$1/\sqrt{\left(Z_{20}^{d}+8\right)}$	1,48	0,81	2,26	1,00
Z_{21}^{d}	$1/\left(Z_{21}^{d}+8\right)^{4}$	0,94	0,84	1,03	1,00
Z_{22}^{d}	$\left(Z_{22}^{d}+8\right)^{5}$	0,97	0,90	1,05	1,00
Z_{23}^{d}	Z_{23}^{d}	1,23	0,83	1,60	1,00
Z_{24}^{d}	Z_{24}^{d}	0,98	0,58	1,31	1,00
Z_{25}^{d}	$\left(Z_{25}^{d}+8\right)^{4}$	0,92	0,84	1,00	1,00
Z_{26}^{d}	$1/\left(Z_{26}^{d}+8\right)$	1,29	0,90	1,67	1,00
Z_{27}^{d}	$Log\left(Z_{27}^{d}+8\right)$	1,23	0,56	1,89	1,00
Z_{28}^{d}	$1/\left(Z_{28}^{d}+8\right)^{2}$	0,91	0,74	1,11	1,00
Z_{29}^{d}	$1/\left(Z_{29}^{d}+8\right)$	0,95	0,56	1,29	1,00
Z_{30}^{d}	$1/\sqrt{\left(Z_{30}^{d}+8\right)}$	0,60	-0,21	1,33	0,50
Z_{31}^{d}	$\left(Z_{31}^{d}+8\right)^{2}$	0,90	0,78	1,13	1,00
Z_{32}^{d}	$1/\sqrt{\left(Z_{32}^{d}+8\right)}$	0,93	0,39	1,43	1,00
Z_{33}^{d}	$(Z_{33}^{d}+8)^{4}$	1,04	0,96	1,13	1,00

Langkah selanjutnya yaitu identifikasi stasioneritas dalam rata-rata pada variabel harga konsumen harian standar dengan melihat plot *time series*, plot ACF, dan uji ADF. Data dikatakan sudah stasioner dalam rata-rata jika pada plot

ACF menunjukkan pola turun cepat dan *cut off* pada *lag* tertentu. Pada Lampiran 8 merupakan plot ACF untuk variabel harga konsumen harian standar yang belum stasioner dalam rata-rata, oleh karena itu perlu dilakukan *differencing*.

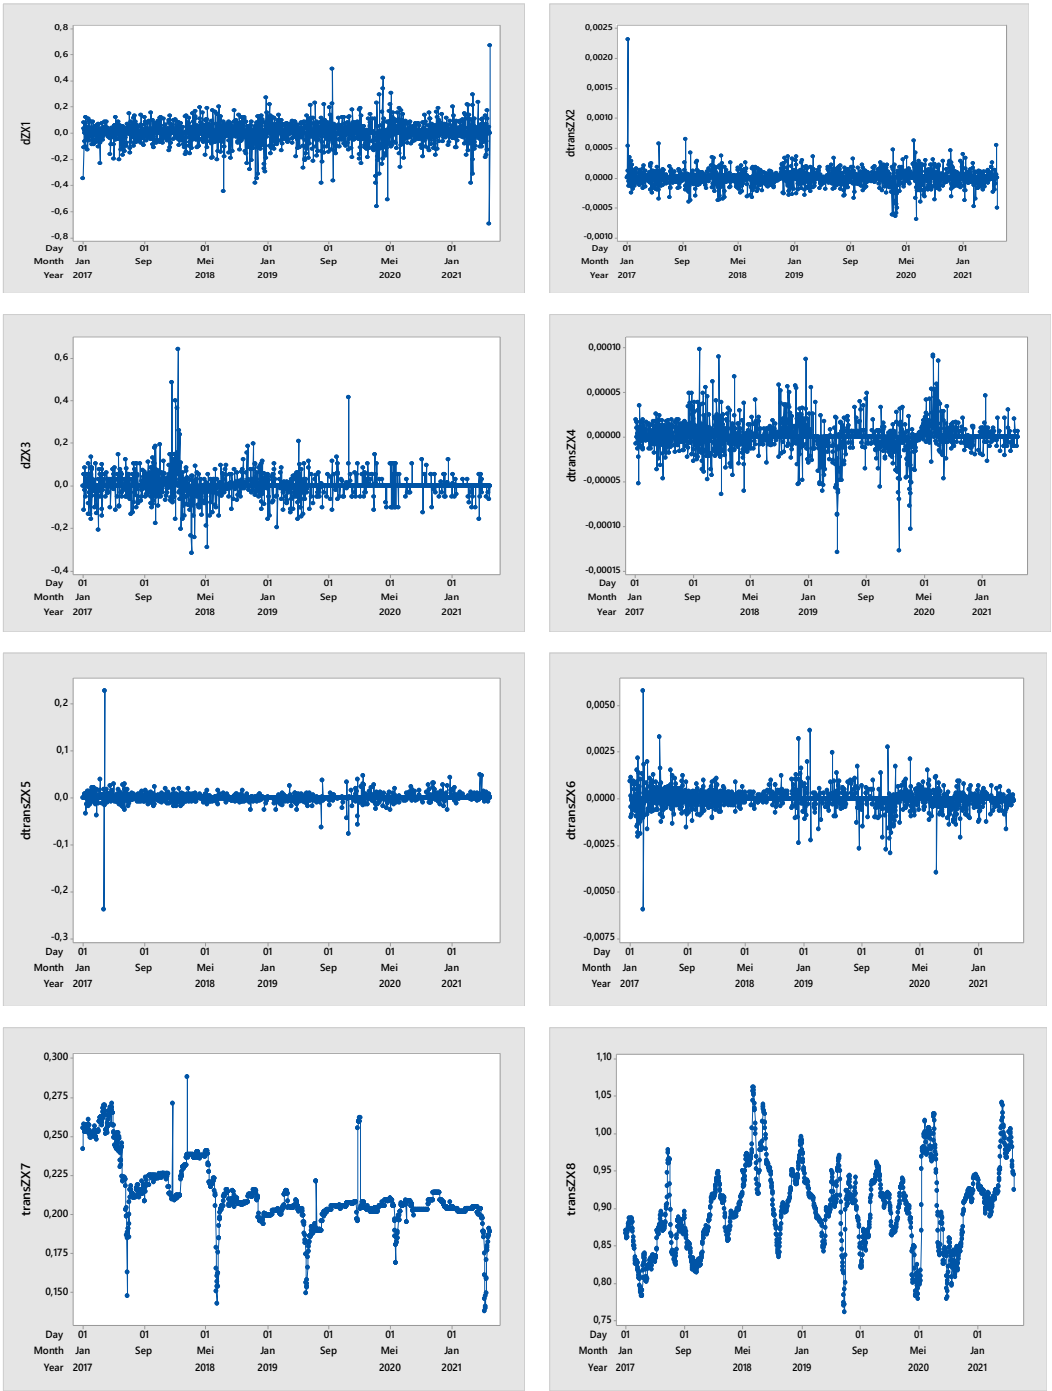

Gambar 4.7 Plot *Time Series* Harga Konsumen Harian Standar Sesudah Stasioner

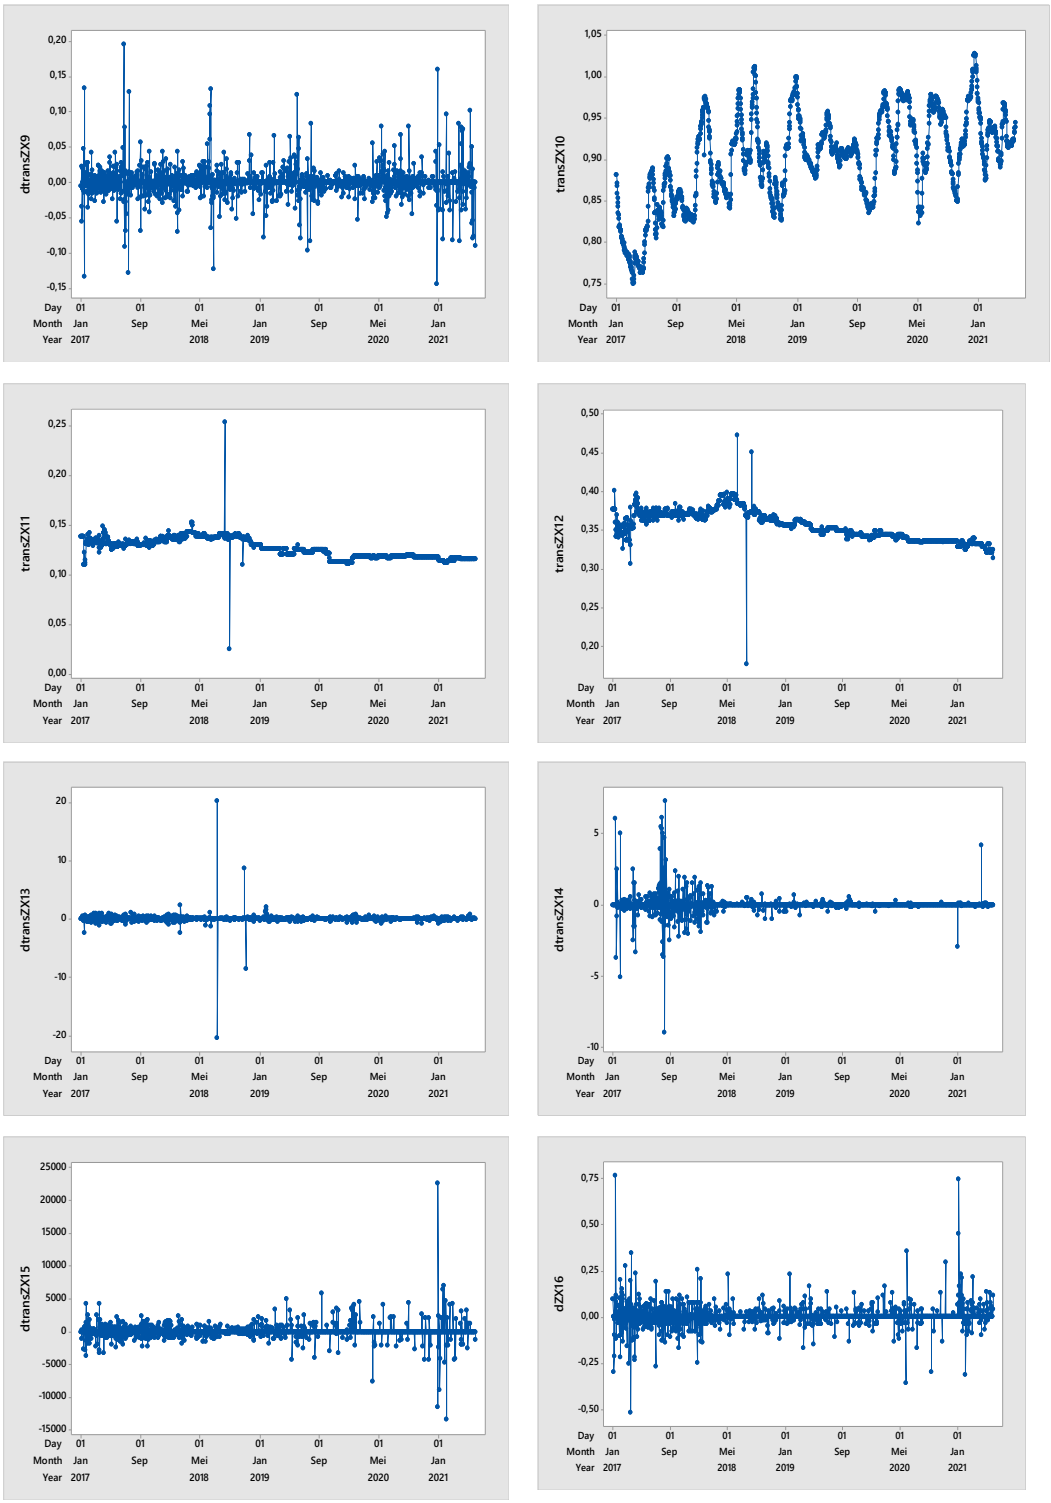

Gambar 4.7 Plot *Time Series* Harga Konsumen Harian Standar Sesudah Stasioner (Lanjutan)

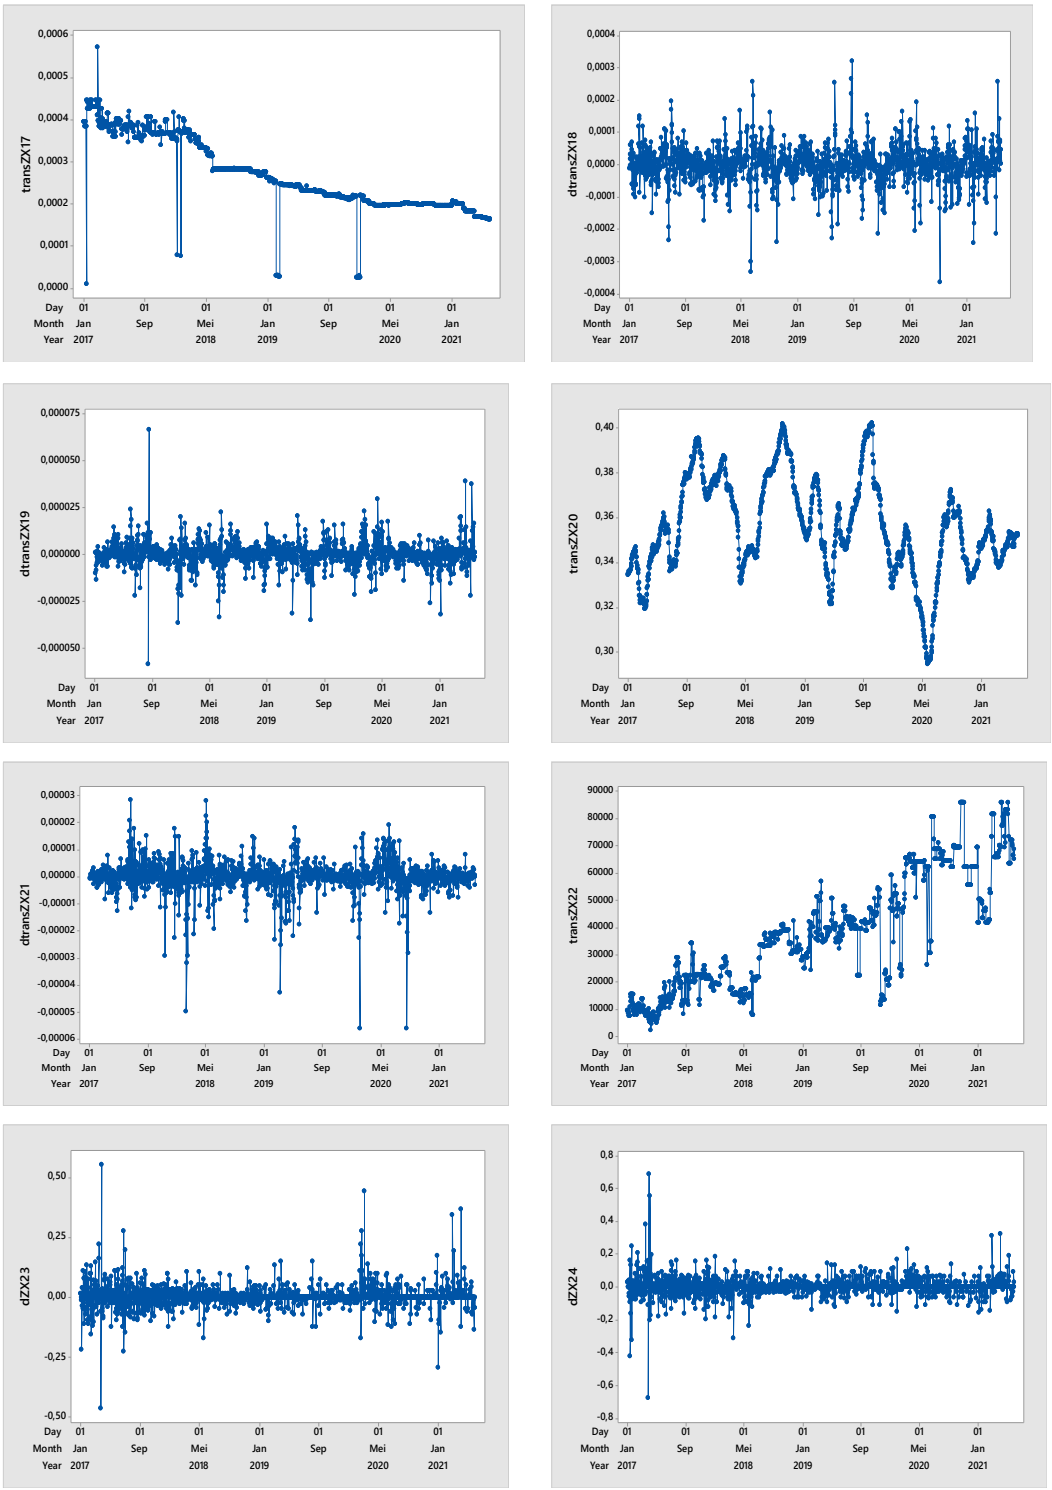

Gambar 4.7 Plot *Time Series* Harga Konsumen Harian Standar Sesudah Stasioner (Lanjutan)

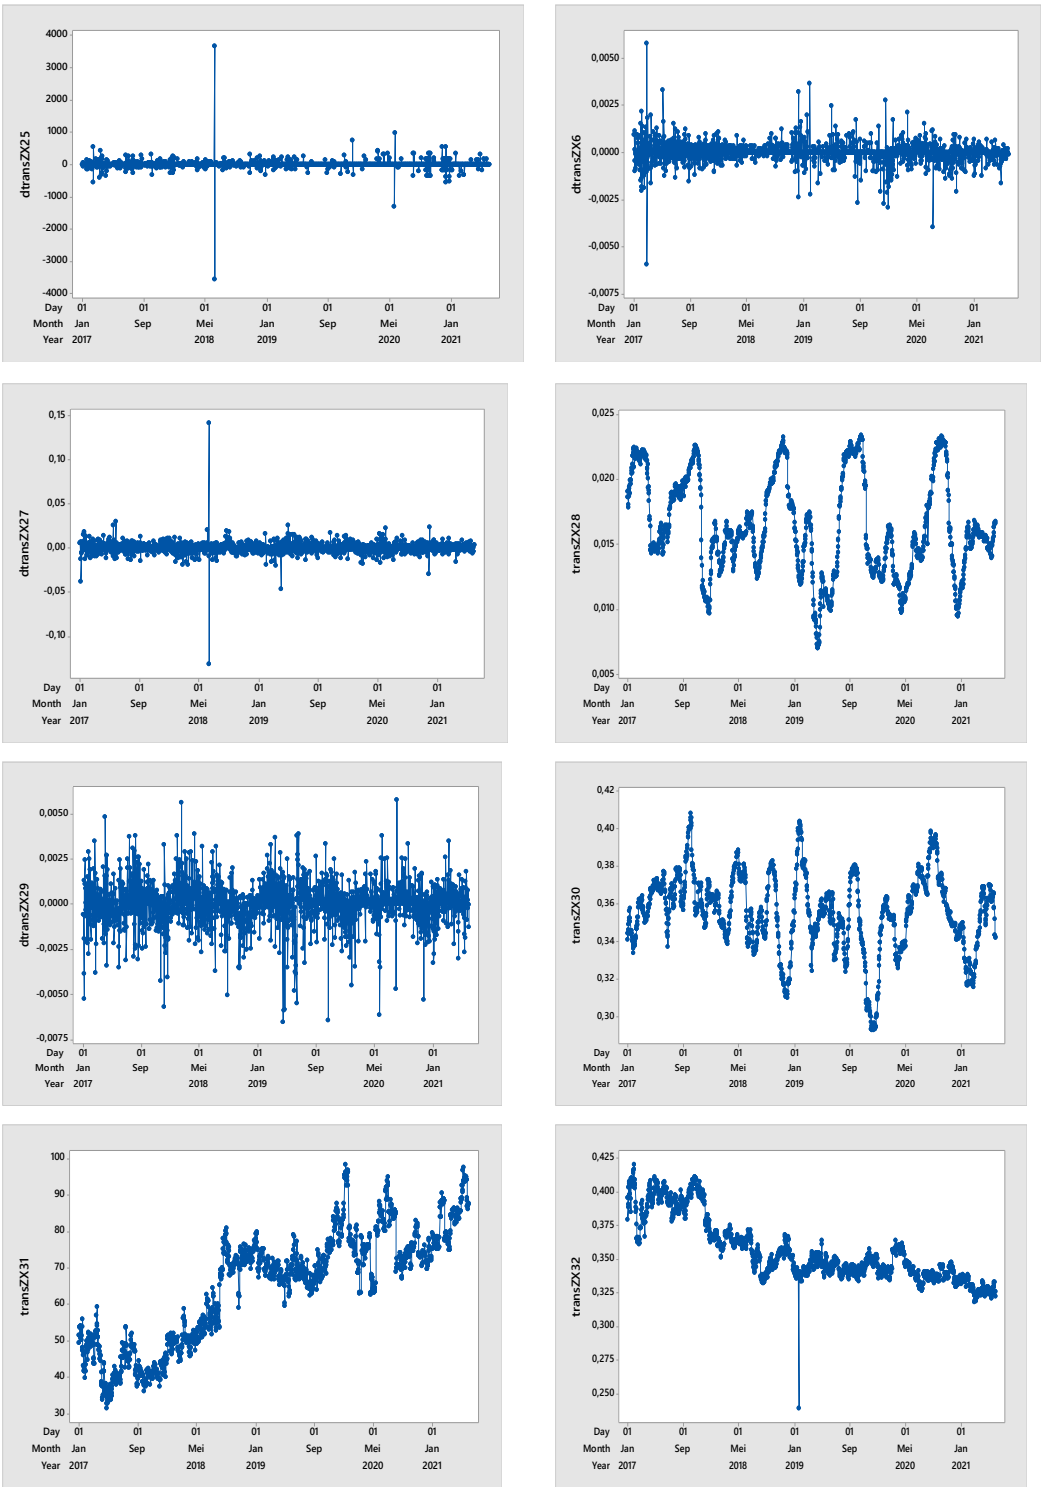

Gambar 4.7 Plot *Time Series* Harga Konsumen Harian Standar Sesudah Stasioner (Lanjutan)

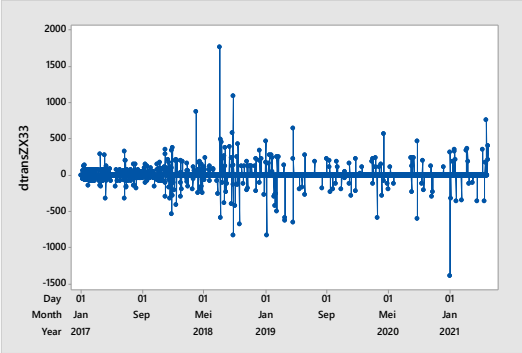

Gambar 4.7 Plot *Time Series* Harga Konsumen Harian Standar Sesudah Stasioner (Lanjutan)

Gambar 4.7 menunjukkan plot *time series* dari variabel harga konsumen harian yang sudah stasioner dalam rata-rata. Identifikasi stasioner dalam rata-rata dengan plot *time series* ditunjukkan oleh data yang berfluktuasi di sekitar rata-rata seiring berjalannya waktu. Selain berdasarkan visualisasi dari plot *time series*, identifikasi data stasioner dalam rata-rata juga menggunakan uji *Augmented Dickey-Fuller* (ADF). Tabel 4.12 merupakan hasil uji ADF dan dihasilkan *p-value* yang nilainya dibawah 0,05. Oleh karena itu dapat disimpulkan bahwa semua variabel tersebut sudah stasioner dalam rata-rata.

Tabel 4.12 Uji ADF Harga Konsumen Harian

Variabel	*p-value*		Ket.	Variabel	*p-value*		Ket.
	Sebelum	Sesudah			Sebelum	Sesudah	
Z_1^d	0,57	<0,01	*Diff*	Z_{10}^d	<0,01	<0,01	*trans*
Z_2^d	0,38	<0,01	*trans-Diff*	Z_{11}^d	<0,01	<0,01	*trans*
Z_3^d	0.45	<0,01	*Diff*	Z_{12}^d	0,02	0,02	*trans*
Z_4^d	0,59	<0,01	*trans-Diff*	Z_{13}^d	0,20	<0,01	*trans -Diff*
Z_5^d	>0,99	<0,01	*trans-Diff*	Z_{14}^d	0,34	<0,01	*trans -Diff*
Z_6^d	>0,99	<0,01	*trans-Diff*	Z_{15}^d	0,49	<0,01	*trans -Diff*
Z_7^d	<0,01	<0,01	*trans*	Z_{16}^d	0,99	<0,01	*Diff*
Z_8^d	<0,01	<0,01	*trans*	Z_{17}^d	<0,01	<0,01	*trans*
Z_9^d	0,08	<0,01	*trans-Diff*	Z_{18}^d	0,0503	<0,01	*trans -Diff*

Tabel 4.12 Uji ADF Harga Konsumen Harian (Lanjutan)

Variabel	*p-value*		Ket.	Variabel	*p-value*		Ket.
	Sebelum	Sesudah			Sebelum	Sesudah	
Z_{19}^{d}	0,09	0,01	*trans-Diff*	Z_{27}^{d}	0,16	<0,01	*trans -Diff*
Z_{20}^{d}	0,04	0,04	*trans*	Z_{28}^{d}	0,02	0,02	*trans*
Z_{21}^{d}	0,36	<0,01	*trans-Diff*	Z_{29}^{d}	0,28	<0,01	*trans -Diff*
Z_{22}^{d}	<0,01	<0,01	*trans*	Z_{30}^{d}	<0,01	<0,01	*trans*
Z_{23}^{d}	0,94	<0,01	*Diff*	Z_{31}^{d}	0,02	0,02	*trans*
Z_{24}^{d}	0,91	<0,01	*Diff*	Z_{32}^{d}	0,01	0,01	*trans*
Z_{25}^{d}	0,37	<0,01	trans-2*Diff*	Z_{33}^{d}	0,71	<0,01	*trans -Diff*
Z_{26}^{d}	0,01	0,01	*trans*				

IHK harian diprediksi menggunakan model DFM (r=11, p=3, q=5) tidak dapat dilakukan karena variabel harga konsumen harian yang sudah stasioner tidak memiliki *invers* akibatnya terjadi kesalahan dalam menghitung *eigenvalue* sehingga tidak bisa digunakan untuk membentuk *common factor*. Oleh karena itu, 33 variabel harga konsumen harian yang sudah stasioner tersebut dilakukan eliminasi secara bertahap sehingga tersisa 25 variabel. Variabel tersebut yaitu harga minyak dunia Brent berjangka (Z_1^d), JISDOR (Z_2^d), harga gula pasir dalam negeri (Z_4^d), harga minyak goreng curah (Z_6^d), harga daging sapi murni (Z_7^d), harga daging ayam broiler (Z_8^d), harga daging ayam kampung (Z_9^d), harga telur ayam ras (Z_{10}^d), harga susu kental manis merk Bendera 397 gram/kaleng (Z_{11}^d), harga susu kental manis merk Indomilk 390 gram/kaleng (Z_{12}^d), harga Indomie rasa kari ayam (Z_{17}^d), harga cabai biasa (Z_{18}^d), harga cabai rawit (Z_{19}^d), harga bawang merah (Z_{20}^d), harga bawang putih (Z_{21}^d), harga ikan asin teri (Z_{22}^d), harga kacang hijau (Z_{23}^d), harga kacang tanah (Z_{24}^d), harga kol/ kubis (Z_{26}^d), harga

kentang (Z_{27}^{d}), harga tomat (Z_{28}^{d}), harga wortel (Z_{29}^{d}), harga buncis (Z_{30}^{d}), harga ikan bandeng (Z_{31}^{d}), dan harga ikan tongkol (Z_{32}^{d}).

Tabel 4.13 Uji Multikolinearitas Rata-rata Bulanan Harga Konsumen Standar

Nama	VIF	Nama	VIF	Nama	VIF
Z_{1}^{m}	12,36	Z_{12}^{m}	14,65	Z_{26}^{m}	3,48
Z_{2}^{m}	18,38	Z_{17}^{m}	3,38	Z_{27}^{m}	9,06
Z_{4}^{m}	14,24	Z_{18}^{m}	5,98	Z_{28}^{m}	5,73
Z_{6}^{m}	6,86	Z_{19}^{m}	9,44	Z_{29}^{m}	5,35
Z_{7}^{m}	15,62	Z_{20}^{m}	7,97	Z_{30}^{m}	3,25
Z_{8}^{m}	4,31	Z_{21}^{m}	5,64	Z_{31}^{m}	34,61
Z_{9}^{m}	20,61	Z_{22}^{m}	20,75	Z_{32}^{m}	22,24
Z_{10}^{m}	4,42	Z_{23}^{m}	60,34		
Z_{11}^{m}	12,02	Z_{24}^{m}	38,86		

Uji multikolinearitas pada 25 variabel rata-rata bulanan harga konsumen terpilih ditunjukkan oleh Tabel 4.13, dapat disimpulkan bahwa terdapat multikolinearitas antar variabel prediktor. Multikolinearitas ditunjukkan oleh VIF>10. Oleh karena itu *nowcasting* IHK bulanan dengan model DFM dapat dilanjutkan. Model IHK bulanan dibangun kembali menggunakan dua puluh lima variabel terpilih agar dapat dilakukan *nowcasting* terhadap IHK harian. Ada dua skenario yang digunakan yaitu model DFM IHK bulanan dengan 25 variabel harga konsumen terpilih dan skenario kedua menambahkan variabel *lag* 1 dari IHK bulanan stasioner untuk memasukkan variabel tren ke dalam model.

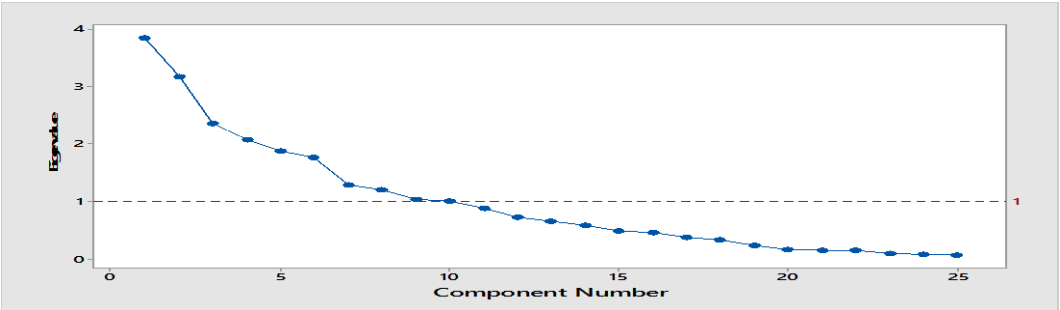

Gambar 4.8 *Screeplot* dari Dua Puluh Lima Variabel Rata-rata Bulanan Harga Konsumen Stasioner Terpilih

Berdasarkan Gambar 4.8, dari dua puluh lima variabel rata-rata bulanan harga konsumen stasioner terpilih diekstrak menjadi sepuluh *common factor*. Terlihat bahwa dari *component number* satu sampai dengan sepuluh arah garis menurun dengan cukup tajam. Setelah *component number* sebelas dan seterusnya arah garis masih menurun, namun dengan *slope* yang lebih kecil. Selain berdasarkan *screeplot*, penentuan jumlah *common factor* berdasarkan *eigenvalue* hasil PCA juga menunjukkan bahwa terdapat sepuluh *common factor* dengan *eigenvalue* yang nilainya lebih dari satu.

Tabel 4.14 *Eigenvalue*, Proporsi dan Kumulatif Proporsi Variasi yang Terjelaskan dari Dua Puluh Lima Variabel Rata-rata Bulanan Harga Konsumen Stasioner Terpilih

Faktor	*Eigenvalue*	Proporsi	Kumulatif
1	3,843	15,372	15,372
2	3,166	12,663	28,035
3	2,348	9,393	37,428
4	2,073	8,292	45,720
5	1,867	7,469	53,189
6	1,765	7,058	60,247
7	1,287	5,148	65,395
8	1,201	4,805	70,200
9	1,029	4,117	74,317
10	1,010	4,041	78,358
11	0,876	3,506	81,863
12	0,719	2,876	84,739
13	0,652	2,609	87,348
14	0,584	2,335	89,682
15	0,482	1,930	91,612
16	0,460	1,841	93,453
17	0,370	1,478	94,931
18	0,329	1,314	96,245
19	0,229	0,917	97,162
20	0,167	0,668	97,830
21	0,151	0,605	98,436
22	0,148	0,594	99,029
23	0,096	0,385	99,415
24	0,080	0,320	99,734
25	0,066	0,266	100,000

Tabel 4.15 *Component Matrix* dari Rata-rata Bulanan Harga Konsumen Standar Stasioner Terpilih

Variabel	f_1^m	f_2^m	f_3^m	f_4^m	f_5^m	f_6^m	f_7^m	f_8^m	f_9^m	f_{10}^m
Z_1^m	-0,090	-0,179	0,188	0,104	-0,148	0,490	-0,003	0,208	0,047	0,015
Z_2^m	-0,276	-0,195	0,077	0,119	0,329	0,252	-0,019	0,174	-0,188	0,112
Z_4^m	-0,034	-0,361	0,165	-0,082	-0,006	-0,168	-0,403	0,064	0,160	0,199
Z_6^m	-0,006	0,202	0,310	0,005	0,401	0,100	0,105	0,141	-0,041	-0,172
Z_7^m	0,312	-0,153	-0,210	0,204	0,103	0,145	-0,146	-0,114	0,254	-0,167
Z_8^m	-0,202	-0,107	-0,407	-0,136	0,169	0,079	-0,041	-0,035	-0,133	0,201
Z_9^m	0,197	0,133	0,302	0,050	-0,073	0,130	-0,391	0,076	-0,002	0,053
Z_{10}^m	0,288	-0,328	-0,112	0,050	0,218	0,036	0,020	0,078	0,186	0,086
Z_{11}^m	-0,028	-0,035	-0,169	-0,395	0,015	0,266	-0,125	-0,207	-0,297	-0,008
Z_{12}^m	-0,212	0,098	0,148	-0,201	-0,173	-0,221	0,129	-0,041	0,294	-0,221
Z_{17}^m	0,006	0,211	0,067	0,000	0,128	0,042	0,098	-0,212	0,551	0,557
Z_{18}^m	0,133	-0,306	0,249	-0,210	-0,166	-0,029	0,279	0,024	0,026	0,140
Z_{19}^m	0,193	-0,256	-0,027	-0,010	-0,254	0,074	0,414	-0,004	-0,249	0,238
Z_{20}^m	-0,015	0,108	-0,176	-0,193	0,102	0,401	0,165	0,473	0,275	0,068
Z_{21}^m	-0,170	-0,300	-0,037	-0,129	-0,348	-0,133	-0,014	0,203	0,087	-0,048
Z_{22}^m	-0,146	0,276	0,339	-0,202	-0,072	-0,028	0,035	0,150	-0,201	0,361
Z_{23}^m	-0,183	-0,243	0,304	-0,069	0,285	0,000	-0,123	-0,097	-0,098	-0,173

Tabel 4.15 *Component Matrix* dari Rata-rata Bulanan Harga Konsumen Standar Stasioner Terpilih (Lanjutan)

Variabel	f_1^m	f_2^m	f_3^m	f_4^m	f_5^m	f_6^m	f_7^m	f_8^m	f_9^m	f_{10}^m
Z_{24}^m	0,155	0,118	0,044	0,267	-0,171	-0,038	0,017	0,449	-0,003	-0,228
Z_{26}^m	0,272	-0,056	0,235	-0,077	0,243	0,028	0,399	-0,247	0,011	-0,168
Z_{27}^m	-0,295	-0,170	0,028	0,304	0,189	-0,174	0,311	-0,016	-0,015	-0,016
Z_{28}^m	0,179	-0,245	0,168	-0,168	0,227	-0,265	-0,168	0,184	0,038	0,099
Z_{29}^m	0,277	0,012	0,181	-0,228	-0,140	0,313	-0,078	-0,235	-0,043	-0,133
Z_{30}^m	-0,086	-0,147	0,197	0,436	-0,225	0,209	0,031	-0,169	0,006	0,098
Z_{31}^m	-0,231	-0,133	0,005	-0,329	-0,027	0,118	0,104	0,041	0,329	-0,340
Z_{32}^m	-0,340	-0,036	0,083	0,124	-0,119	0,218	-0,113	-0,328	0,178	-0,059

Setelah diketahui bahwa sepuluh faktor adalah jumlah yang paling optimal, Tabel 4.15 menunjukkan distribusi dari dua puluh lima variabel tersebut pada sepuluh faktor yang terbentuk. Angka-angka pada Tabel 4.15 adalah *factor loading*, yang menunjukkan besar korelasi antara suatu variabel dengan ke sepuluh faktor. Perbandingan korelasi pada masing-masing variabel dilakukan untuk menentukan suatu variabel akan masuk ke suatu faktor yang mana. Variabel dengan korelasi terbesar pada suatu faktor menunjukkan bahwa variabel tersebut merupakan bagian dari faktor yang terbentuk.

Faktor 1 terdiri dari variabel rata-rata bulanan harga daging sapi murni dan harga ikan tongkol. Faktor 2 terdiri dari variabel rata-rata bulanan harga telur ayam ras dan harga cabai biasa. Faktor 3 terdiri dari variabel rata-rata bulanan harga daging ayam broiler dan harga kacang hijau. Faktor 4 terdiri dari variabel rata-rata bulanan harga susu kental manis merk Bendera 397 gram/kaleng dan harga buncis. Faktor 5 terdiri dari variabel rata-rata bulanan JISDOR, harga minyak goreng curah, dan harga bawang putih. Faktor 6 terdiri dari variabel rata-rata bulanan harga minyak dunia brent USD/Barel, harga tomat, dan harga wortel. Faktor 7 terdiri dari variabel rata-rata bulanan harga gula pasir dalam negeri, harga daging ayam kampung, harga cabai rawit, harga kol/ kubis, dan harga kentang. Faktor 8 terdiri dari variabel rata-rata bulanan harga bawang merah dan harga kacang tanah. Faktor 9 terdiri dari variabel rata-rata bulanan harga susu kental manis merk Indomilk 390 gram/kaleng. Faktor 10 terdiri dari variabel rata-rata bulanan harga Indomie rasa kari ayam, harga ikan asin teri, dan harga ikan bandeng. Dengan demikian, dua puluh lima variabel di atas telah direduksi menjadi sepuluh faktor.

Langkah selanjutnya adalah menentukan jumlah *lag* ordo *p* pada VAR dan penentuan banyaknya guncangan (*q*). Tabel 4.16 merupakan nilai AIC untuk setiap *lag*. Hasil tersebut menunjukan nilai AIC terkecil ada pada *lag* ke-2. Oleh karena itu, penelitian ini menggunakan *lag* ordo (*p*) pada model VAR adalah 2 dengan nilai AIC sebesar -4,120

Tabel 4.16 Hasil Penentuan *Lag* Ordo (*p*) pada Model VAR Berdasarkan AIC

Lag	AIC
1	1,702
2	-4,120

Pada tahap sebelumya, telah ditentukan banyaknya faktor dinamis *r* sebanyak 10 dengan lag ordo (*p*) pada model VAR adalah 2. Banyaknya guncangan (*q*) yang optimal yaitu 6. Langkah selanjutnya adalah melakukan pemodelan dengan metode DFM. Kedua model DFM (*r*=10, *p*=2, *q*=6) mempunyai residual yang *white noise* dan berdistribusi normal.

Tabel 4.17 Hasil Pengujian dengan Metode DFM (*r*=10, *p*=2, *q*=6)

Variabel Prediktor Stasioner			
$25Z_X^m$		$25Z_X^m$ dan $Z_{y_{t-1}}^m$	
Komponen	Koefisien	Komponen	Koefisien
f_1^m	-0,025	f_1^m	-0,018
f_2^m	0,009	f_2^m	0,003
f_3^m	0,029	f_3^m	0,022
f_4^m	-0,001	f_4^m	0,013
f_5^m	0,006	f_5^m	-0,001
f_6^m	-0,012	f_6^m	-0,022
f_7^m	-0,023	f_7^m	-0,026
f_8^m	0,012	f_8^m	0,002
f_9^m	0,003	f_9^m	-0,003
f_{10}^m	0,005	f_{10}^m	0,003
		$Z_{y_{t-1}}^m$	0.584
Uji Asumsi Residual			
White Noise	*p-value*	White Noise	*p-value*
Lag 6: Ya	0,344	*Lag* 6: Ya	0,351
Lag 12: Ya	0,354	*Lag* 12: Ya	0,359
Normal	*p-value*	Normal	*p-value*
Ya	0,567	Ya	0,887

Tabel 4.18 Hasil Evaluasi Prediksi IHK Bulanan dengan DFM (r=10, p=2, q=6)

Prediktor	RMSE *Train**	sMAPE *Train**	MAD *Train**	RMSE *Test*	sMAPE *Test*	MAD *Test*
$25\,Z_X^m$	4,950	4,321	4,301	0,907	0,774	0,823
$25Z_X^m$ dan $Z_{y_{t-1}}^m$	1,986	1,733	1,753	0,293	0,245	0,086

*) Evaluasi mulai Maret 2017

Tabel 4.18 menunjukkan evaluasi prediksi IHK bulanan dengan metode DFM tanpa atau dengan menambahkan variabel *lag* 1 dari IHK bulanan stasioner. Hasilnya menunjukkan bahwa penambahan variabel tren ke dalam model dapat meningkatkan akurasi peramalan. Hal ini ditunjukkan oleh RMSE, sMAPE, dan MAD terkecil pada model DFM (r=10, p=2, q=6) dengan tambahan variabel *lag* 1 dari IHK bulanan stasioner. Namun performansi IHK harian hasil *nowcasting* DFM (r=10, p=2, q=6) tanpa tambahan variabel *lag* 1 dari IHK bulanan stasioner mempunyai performansi yang lebih baik meskipun nilai RMSE, sMAPE, dan MAD masih sangat besar untuk digunakan *nowcasting* IHK harian. Model DFM (r=10, p=2, q=6) tanpa tambahan variabel *lag* 1 dari IHK bulanan stasioner ditunjukkan sebagai berikut:

$$\begin{aligned}\hat{Z}_{y_t}^m = &-0,025\,f_{1,t}^m + 0,009\,f_{2,t}^m + 0,029\,f_{3,t}^m - 0,001\,f_{4,t}^m + 0,006\,f_{5,t}^m - 0,012\,f_{6,t}^m - 0,023\,f_{7,t}^m \\ &+0,012\,f_{8,t}^m + 0,003\,f_{9,t}^m + 0,005\,f_{10,t}^m + \hat{Z}_{y_{t-1}}^m\end{aligned}$$

Tabel 4.19 Performansi IHK Harian Hasil *Nowcasting* dengan DFM (r=10, p=2, q=6) terhadap IHK Aktual

Prediktor	RMSE	sMAPE	MAD
$25\,Z_X^d$	64,354	41,612	56,561
$25Z_X^d$ dan $Z_{y_{t-1}}^d$	114,729	59,901	97,328

Keterangan: Performansi Mulai Bulan Februari 2017

4.3.2 Pembangunan Model SVR untuk *Nowcasting* IHK Bulanan

Dua skenario juga diterapkan pada metode SVR. Skenario pertama model SVR IHK bulanan dengan 25 variabel harga konsumen terpilih dan skenario kedua menambahkan variabel *lag* 1 dari IHK bulanan. Optimisasi *hyperparameter* yang digunakan untuk kedua skenario sama. Optimisasi tersebut menggunakan

metode *Grid Search* dan ditentukan berdasarkan nilai RMSE, sMAPE, dan MAD terkecil pada data *testing* ditunjukkan oleh Tabel 4.20 berikut:

Tabel 4.20 Optimisasi *Hyperparameter* Dataset Bulanan dengan *Grid Search*

Metode	Gamma	Epsilon	C	Degree
SVR-Linear	0,1	0,1	1	
SVR-RBF	0,1	0,1	1	
SVR-*Polynomial*	0,1	0,1	5	1

Setelah diperoleh *hyperparameter* yang optimal selanjutnya model SVR dibangun dan digunakan untuk *nowcasting* IHK harian.

Tabel 4.21 Hasil Evaluasi Prediksi IHK Bulanan dengan SVR

Prediktor: 25 Z_X^m						
Metode	RMSE *Train*	sMAPE *Train*	MAD *Train*	RMSE *Test*	sMAPE *Test*	MAD *Test*
SVR-Linear	0,36406	0,28566	0,28732	1,27059	0,97862	1,02191
SVR-RBF	0,34448	0,27770	0,27881	3,70751	3,54388	3,66936
SVR-*Polynomial*	0,36364	0,28498	0,28672	1,12938	0,86256	0,90145
Prediktor: 25 Z_X^m dan $Z_{y_{t-1}}^m$						
Metode	RMSE *Train**	sMAPE *Train**	MAD *Train**	RMSE *Test*	sMAPE *Test*	MAD *Test*
SVR-Linear	0,22518	0,20770	0,20898	0,63248	0,51846	0,54532
SVR-RBF	0,26530	0,24980	0,25188	3,66744	3,50894	3,63389
SVR-*Polynomial*	0,22511	0,20753	0,20881	0,63146	0,51729	0,54410

*) Evaluasi mulai Pebruari 2017

Hasil evaluasi prediksi IHK bulanan dengan metode SVR berdasarkan tipe kernel dan variabel prediktor ditunjukkan oleh Tabel 4.21. SVR *Polynomial* merupakan metode terbaik untuk prediksi IHK bulanan dengan atau tanpa ditambahkan variabel *lag* berdasarkan RMSE, sMAPE maupun MAD terkecil pada data *testing*. Demikian juga berdasarkan performansi IHK harian terhadap IHK aktual, SVR *Polynomial* merupakan metode terbaik dalam *nowcasting* IHK harian dibandingkan dengan metode SVR dengan tipe kernel linear dan RBF. Performansi IHK harian terhadap IHK aktual ditunjukkan oleh Tabel 4.22 berikut:

Tabel 4.22 Performansi IHK Harian Hasil *Nowcasting* dengan SVR terhadap IHK Aktual

Prediktor: 25 Z_X^d			
Metode	RMSE	sMAPE	MAD
SVR-Linear	0,65713	0,46305	0,47035
SVR-RBF	1,31304	0,84339	0,85745
SVR-*Polynomial*	0,61201	0,43682	0,44331
Prediktor: 25 Z_X^d dan $Z_{y_{t-1}}^d$			
Metode	RMSE	sMAPE	MAD
SVR-Linear	0,68411	0,52782	0,53429
SVR-RBF	1,411764	0,90540	0,91853
SVR-*Polynomial*	0,68408	0,52814	0,53460

Model SVR-*Polynomial* ($\gamma = 0{,}1; \varepsilon = 0{,}1; C$=5;$d$=1) dengan 25 Z_X^m berikut:

$$\begin{aligned}\hat{Z}_{y_t}^m = 0{,}1(&0{,}192\left(Z_{1,t}^m Z_{1,t}^{m'}\right)+0{,}532\left(Z_{2,t}^m Z_{2,t}^{m'}\right)+0{,}202\left(Z_{4,t}^m Z_{4,t}^{m'}\right) -0{,}753\left(Z_{6,t}^m Z_{6,t}^{m'}\right)+0{,}849\left(Z_{7,t}^m Z_{7,t}^{m'}\right)\\ &+0{,}116\left(Z_{8,t}^m Z_{8,t}^{m'}\right)-0{,}810\left(Z_{9,t}^m Z_{9,t}^{m'}\right)+0{,}956\left(Z_{10,t}^m Z_{10,t}^{m'}\right)+0{,}881\left(Z_{11,t}^m Z_{11,t}^{m'}\right)+0{,}465\left(Z_{12,t}^m Z_{12,t}^{m'}\right)\\ &+0{,}786\left(Z_{17,t}^m Z_{17,t}^{m'}\right)+2{,}223\left(Z_{18,t}^m Z_{18,t}^{m'}\right)-1{,}442\left(Z_{19,t}^m Z_{19,t}^{m'}\right)+0{,}419\left(Z_{20,t}^m Z_{20,t}^{m'}\right)+0{,}225\left(Z_{21,t}^m Z_{21,t}^{m'}\right)\\ &+1{,}187\left(Z_{22,t}^m Z_{22,t}^{m'}\right)+0{,}946\left(Z_{23,t}^m Z_{23,t}^{m'}\right)+1{,}594\left(Z_{24,t}^m Z_{24,t}^{m'}\right)-0{,}084\left(Z_{26,t}^m Z_{26,t}^{m'}\right)-0{,}723\left(Z_{27,t}^m Z_{27,t}^{m'}\right)\\ &-0{,}967\left(Z_{28,t}^m Z_{28,t}^{m'}\right)-0{,}159\left(Z_{29,t}^m Z_{29,t}^{m'}\right)+1{,}049\left(Z_{30,t}^m Z_{30,t}^{m'}\right)+0{,}603\left(Z_{31,t}^m Z_{31,t}^{m'}\right)+3{,}235\left(Z_{32,t}^m Z_{32,t}^{m'}\right))+0{,}008\end{aligned}$$

4.3.3 Pembangunan Model TSR untuk *Nowcasting* IHK Bulanan

Sebelum permodelan dengan TSR, data terlebih dahulu dibagi menjadi data *training* dan *testing*. Tabel 4.13 menunjukkan ada multikolinearitas di antara dua puluh lima variabel rata-rata bulanan harga konsumen terpilih, ditunjukkan oleh VIF lebih dari 10. Multikolinearitas diatasi dengan membentuk *principal component* (PC). Uji kecukupan data dengan uji KMO dan uji Bartlett dilakukan sebelum melakukan TSR dengan PC untuk mengatasi multikolinearitas.

Tabel 4.23 Uji KMO dan Uji Bartlett Rata-rata Bulanan Harga Konsumen Standar Terpilih

Uji KMO		0,605
Uji Bartlett	*Chi-squared*	1.288
	df	300
	p-value	$<2{,}2*10^{-16}$

Nilai KMO sebesar 0,605 > 0,5 (batas toleransi kecukupan data). *p-value* dari uji Bartlett sebesar 0 < 0,05 sehingga dapat disimpulkan bahwa data rata-rata bulanan harga konsumen standar terpilih memiliki hubungan satu sama lain dan sudah cukup memadai untuk dilakukan analisis lanjutan yaitu *Principal Component Analysis* (PCA) dan TSR.

Tabel 4.24 *Eigenvalue*, Proporsi dan Kumulatif Proporsi Variasi yang Terjelaskan

PC	*Eigen*	Proporsi	Kumulatif
1	7,212	30,181	30,181
2	4,308	18,029	48,211
3	2,768	11,585	59,795
4	1,731	7,245	67,040
5	1,535	6,424	73,464
6	1,087	4,548	78,012
7	1,053	4,406	82,418
8	0,937	3,921	86,339
9	0,703	2,944	89,283
10	0,590	2,467	91,751
11	0,369	1,542	93,293
12	0,312	1,307	94,600
13	0,302	1,264	95,863
14	0,233	0,977	96,841
15	0,208	0,871	97,712
16	0,149	0,624	98,336
17	0,124	0,518	98,854
18	0,097	0,407	99,261
19	0,063	0,263	99,524
20	0,038	0,158	99,682
21	0,023	0,097	99,779
22	0,020	0,082	99,861
23	0,015	0,063	99,924
24	0,012	0,051	99,975
25	0,006	0,025	100,000

Penentuan jumlah PC yang dibentuk, ditentukan berdasarkan *eigenvalue*>1. Ada 7 PC dengan *eigenvalue* > 1 berdasarkan Tabel 4.24 dan Gambar 4.9. Ketujuh PC yang terbentuk mampu menjelaskan keragaman variabel rata-rata harga konsumen standar terpilih sebesar 82,418%.

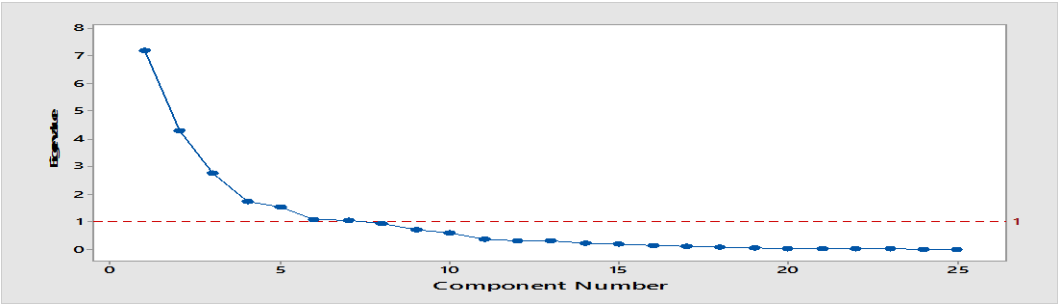

Gambar 4.9 *Screeplot* dari Rata-rata Bulanan Harga Konsumen Terpilih

Berikut ini disajikan nilai koefisien dari tujuh PC yang terbentuk yaitu:

Tabel 4.25 Koefisien dari Tujuh *Principal Component* yang Terbentuk dari Dua Puluh Lima Rata-rata Bulanan Harga Konsumen Standar Terpilih

i	W_1^m	W_2^m	W_3^m	W_4^m	W_5^m	W_6^m	W_7^m
1	-0,116	0,431	-0,144	-0,079	0,013	-0,184	0,020
2	0,296	0,032	0,106	-0,231	-0,007	0,230	-0,097
3	0,125	-0,411	-0,091	-0,062	0,052	0,112	-0,088
4	-0,069	-0,194	0,065	-0,061	0,101	-0,128	0,372
5	0,270	0,150	0,000	0,196	0,022	-0,005	-0,177
6	0,135	0,221	-0,140	0,122	0,310	0,181	0,303
7	0,266	0,292	-0,020	0,050	-0,076	-0,043	0,037
8	0,277	0,078	-0,115	0,188	0,285	-0,144	0,202
9	0,269	-0,172	-0,031	-0,002	-0,222	-0,109	-0,064
10	0,240	-0,185	-0,007	-0,004	-0,286	-0,022	0,066
11	0,277	0,020	-0,036	-0,008	-0,170	-0,077	-0,141
12	0,036	-0,027	-0,416	0,122	-0,111	-0,456	0,305
13	-0,148	-0,136	-0,305	-0,111	-0,321	0,073	0,259
14	0,104	-0,319	-0,203	-0,228	0,285	0,134	0,093
15	-0,088	-0,223	-0,389	-0,174	-0,087	-0,251	-0,359
16	0,325	-0,011	0,144	0,005	-0,077	-0,094	-0,001
17	0,179	-0,216	0,200	-0,030	0,161	-0,016	0,159
18	0,101	-0,331	0,283	0,165	0,108	-0,098	0,128
19	0,031	-0,002	-0,278	0,055	0,070	0,427	0,290
20	-0,124	-0,163	0,041	0,624	-0,160	-0,132	0,115
21	0,142	-0,047	-0,283	0,008	0,533	-0,267	-0,287
22	0,031	-0,082	-0,225	0,549	-0,013	0,349	-0,341
23	0,093	0,039	-0,330	-0,073	-0,156	0,290	0,063
24	0,327	0,050	-0,047	-0,055	-0,193	0,052	0,050
25	0,300	0,112	-0,014	-0,040	-0,140	-0,134	0,093

Tabel 4.26 di bawah menunjukkan bahwa regresi yang terbentuk dengan 7 PC menghasilkan residual yang normal namun belum memenuhi asumsi *white*

noise, ditunjukkan oleh plot ACF residual pada Gambar 4.10(a). Plot ACF menunjukkan pola turun lambat atau *dies down*. Berdasarkan plot PACF residual yang ditunjukkan oleh Gambar 4.10(b) menunjukkan bahwa masih terdapat *lag* 1 yang signifikan. Oleh karena itu variabel *lag* 1 dari IHK bulanan ditambahkan sebagai variabel prediktor. Regresi antara IHK bulanan dengan 7 PC dan variabel *lag* dari IHK bulanan menghasilkan residual yang sudah memenuhi asumsi *white noise* dan normal namun masih terdapat multikolinearitas antar variabel prediktor W_1^m dan $Z_{y_{t-1}}^m$.

Tabel 4.26 Hasil Pengujian dengan *Time Series Regression*

Model	Variabel Prediktor	Signifikansi Parameter	Non-Multikol	Residual		
				White Noise		Normal
				Lag 6	*Lag* 12	
1	$W_1^m, W_2^m, \ldots, W_7^m$	W_1^m, W_5^m, W_6^m	Ya	Tidak	Tidak	Ya
2	$W_1^m, W_2^m, \ldots, W_7^m$ & $Z_{y_{t-1}}^d$	$W_1^m, W_3^m, W_4^m, Z_{y_{t-1}}^m$	Tidak	Ya	Ya	Ya
3	W_3^d, W_4^d & $Z_{y_{t-1}}^d$	$W_3^m, W_4^m, Z_{y_{t-1}}^m$	Ya	Ya	Ya	Ya

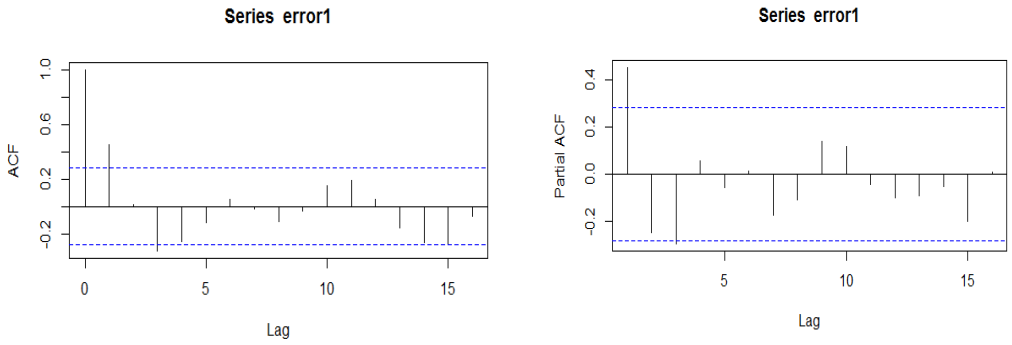

(a) (b)

Gambar 4.10 Plot (a) ACF dan (b) PACF Residual dari Regresi dengan Enam Variabel Rata-rata Bulanan Harga Konsumen Terpilih

Regresi antara IHK bulanan dengan variabel prediktor yang signifikan (PC ke-3, PC ke-4 dan variabel *lag* 1 IHK bulanan) menghasilkan residual yang *white noise*

dan normal serta tidak ada multikolinearitas antar variabel prediktornya. Model 3 dapat dituliskan sebagai berikut:

$$\hat{Z}_{y_t}^{m} = -0,021W_{3,t}^{m} + 0,020W_{4,t}^{m} + 0,972\hat{Z}_{y_{t-1}}^{m}$$

Model 3 digunakan untuk memprediksi IHK harian. Model lain tidak digunakan untuk prediksi IHK harian karena tidak memenuhi asumsi dalam regresi yaitu tidak ada multikolinearitas antar variabel prediktor dan asumsi residual identik, independen dan berdistribusi normal.

Hasil evaluasi prediksi IHK bulanan dengan metode TSR model ketiga ditunjukkan oleh Tabel 4.27 berikut:

Tabel 4.27 Hasil Evaluasi Prediksi IHK Bulanan dengan TSR Model 3

Kriteria	*Training**	*Testing*
RMSE	0,255	0,273
sMAPE	0,210	0,249
MAD	0,212	0,262

*) Evaluasi mulai Pebruari 2017

Performansi IHK harian terhadap IHK aktual pada model ketiga ditunjukkan oleh Tabel 4.28. berikut:

Tabel 4.28 Performansi IHK Harian Hasil *Nowcasting* terhadap IHK Aktual Model 3

Kriteria	Nilai
RMSE	4,159
sMAPE	3,275
MAD	3,300

4.3.4 Evaluasi Model *Nowcasting* IHK Bulanan

Tabel 4.29 Hasil Evaluasi Prediksi IHK Bulanan

Metode	RMSE *Train**	sMAPE *Train**	MAD *Train**
DFM (r=10, p=2, q=6) dengan 25 Z_X^m	4,950	4,321	4,301
SVR-*Polynomial* ($\gamma = 0,1; \varepsilon = 0,1; C$=5;$d$=1) dengan 25 Z_X^m	0,367	0,285	0,287
TSR dengan W_3^m, W_4^m & $Z_{y_{t-1}}^m$	0,257	0,213	0,215

*) Evaluasi mulai Maret 2017

Tabel 4.29 Hasil Evaluasi Prediksi IHK Bulanan (Lanjutan)

Metode	RMSE *Test*	sMAPE *Test*	MAD *Test*
DFM (r=10, p=2, q=6) dengan 25 Z_X^m	0,907	0,774	0,823
SVR-*Polynomial* ($\gamma = 0{,}1$; $\varepsilon = 0{,}1$; C=5; d=1) dengan 25 Z_X^m	1,129	0,862	0,901
TSR dengan W_3^m, W_4^m & $Z_{y_{t-1}}^m$	0,273	0,249	0,273

Hasil evaluasi prediksi IHK bulanan dari model IHK bulanan terbaik dari masing-masing metode dibandingkan, hasilnya ditunjukkan oleh Tabel 4.29. TSR dengan variabel prediktor PC ke-3, PC ke-4, dan variabel *lag* 1 dari IHK bulanan merupakan metode terbaik untuk prediksi IHK bulanan baik berdasarkan RMSE, sMAPE, maupun MAD terkecil. Namun performansi SVR-*Polynomial* ($\gamma = 0{,}1$; $\varepsilon = 0{,}1$; C=5; d=1) dengan variabel prediktor dua puluh lima variabel harga konsumen terpilih dalam *nowcasting* IHK harian merupakan yang terbaik dibandingkan metode yang lain. Hal ini ditunjukkan oleh Tabel 4.30 berikut:

Tabel 4.30 Performansi IHK Harian Hasil *Nowcasting* terhadap IHK Aktual

Metode	RMSE	sMAPE	MAD
DFM (r=10, p=2, q=6) dengan 25 Z_X^d	64,354	41,612	56,561
SVR-*Polynomial* ($\gamma = 0{,}1$; $\varepsilon = 0{,}1$; C=5; d=1) dengan 25 Z_X^d	0,614	0,442	0,435
TSR dengan W_3^d, W_4^d & $Z_{y_{t-1}}^d$	4,178	3,280	3,306

Keterangan: Performansi Mulai Bulan Februari 2017

IHK harian hasil *nowcasting* SVR-*Polynomial* digunakan sebagai variabel respon dalam membangun model *nowcasting* IHK harian.

4.4 Pembangunan *Nowcasting* IHK Harian

4.4.1 Pembangunan *Nowcasting* IHK Harian dengan Metode DFM

Seperti yang sudah dijelaskan sebelumnya bahwa 33 variabel harga konsumen harian yang sudah stasioner tersebut dilakukan eliminasi secara

bertahap sehingga tersisa 25 variabel. Ada dua skenario yang digunakan yaitu model DFM IHK harian dengan 25 variabel harga konsumen terpilih dan skenario kedua menambahkan variabel *lag* 1 dari IHK bulanan stasioner untuk memasukkan variabel tren ke dalam model.

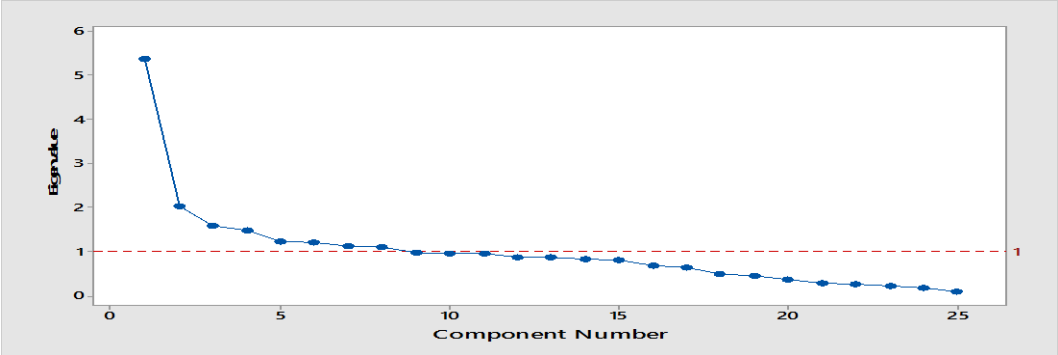

Gambar 4.11 *Screeplot* dari Dua Puluh Lima Variabel Harga Konsumen Harian Stasioner Terpilih

Berdasarkan Gambar 4.11, dari dua puluh lima variabel harga konsumen harian stasioner terpilih diekstrak menjadi delapan *common factor*. Terlihat bahwa dari *component number* satu sampai dengan delapan arah garis menurun dengan cukup tajam. Setelah *component number* sembilan dan seterusnya arah garis masih menurun, namun dengan *slope* yang lebih kecil. Selain berdasarkan *screeplot*, penentuan jumlah *common factor* berdasarkan *eigenvalue* hasil PCA juga menunjukkan bahwa terdapat delapan *common factor* dengan *eigenvalue* yang nilainya lebih dari satu.

Tabel 4.31 *Eigenvalue*, Proporsi dan Kumulatif Proporsi Variasi yang Terjelaskan dari Dua Puluh Lima Variabel Harga Konsumen Harian Stasioner Terpilih

Faktor	*Eigenvalue*	Proporsi	Kumulatif
1	5,377	21,507	21,507
2	2,030	8,121	29,628
3	1,575	6,298	35,926
4	1,485	5,939	41,865
5	1,222	4,887	46,752
6	1,197	4,787	51,538
7	1,115	4,459	55,997
8	1,103	4,414	60,411

Tabel 4.31 *Eigenvalue*, Proporsi dan Kumulatif Proporsi Variasi yang Terjelaskan dari Dua Puluh Lima Variabel Harga Konsumen Harian Stasioner Terpilih (Lanjutan)

Faktor	*Eigenvalue*	Proporsi	Kumulatif
9	0,977	3,907	64,317
10	0,959	3,838	68,155
11	0,952	3,809	71,964
12	0,878	3,511	75,474
13	0,861	3,443	78,918
14	0,827	3,310	82,227
15	0,807	3,227	85,455
16	0,690	2,761	88,216
17	0,631	2,523	90,739
18	0,487	1,950	92,689
19	0,452	1,809	94,498
20	0,363	1,451	95,949
21	0,276	1,105	97,054
22	0,266	1,062	98,116
23	0,211	0,844	98,960
24	0,167	0,667	99,627
25	0,093	0,373	100,000

Tabel 4.32 *Component Matrix* dari Harga Konsumen Harian Standar Stasioner Terpilih

Variabel	f_1^d	f_2^d	f_3^d	f_4^d	f_5^d	f_6^d	f_7^d	f_8^d
Z_1^d	-0,007	-0,002	0,004	-0,095	0,205	-0,007	0,047	0,552
Z_2^d	0,001	-0,049	-0,148	-0,060	0,414	-0,098	-0,126	-0,066
Z_4^d	-0,037	0,010	0,104	-0,125	0,501	-0,097	0,432	-0,150
Z_6^d	-0,031	-0,093	0,094	-0,046	-0,197	-0,240	0,507	-0,205
Z_7^d	-0,300	0,048	-0,318	-0,121	-0,025	0,144	-0,042	-0,027
Z_8^d	0,159	-0,461	0,305	0,039	0,024	-0,053	-0,047	0,016
Z_9^d	0,001	-0,085	-0,104	0,248	-0,029	-0,248	0,189	0,279
Z_{10}^d	0,301	-0,251	0,168	0,073	-0,098	0,093	0,014	0,112
Z_{11}^d	-0,301	-0,205	0,292	0,111	0,008	-0,036	-0,009	-0,014
Z_{12}^d	-0,297	-0,271	0,281	0,147	-0,044	0,053	0,003	0,046
Z_{17}^d	-0,386	-0,092	-0,060	-0,013	0,014	0,007	0,012	0,009
Z_{18}^d	-0,004	-0,024	0,213	-0,554	-0,094	-0,033	-0,232	0,007
Z_{19}^d	-0,030	0,058	0,209	-0,512	-0,174	-0,053	-0,216	0,142
Z_{20}^d	-0,122	0,182	0,495	0,251	0,019	-0,241	-0,230	-0,135
Z_{21}^d	-0,011	-0,094	0,053	-0,390	0,208	-0,212	0,273	0,118
Z_{22}^d	0,345	0,251	0,020	0,010	0,019	-0,010	0,124	0,013
Z_{23}^d	0,013	-0,030	-0,123	-0,062	-0,478	-0,196	0,128	-0,100

Tabel 4.32 *Component Matrix* dari Harga Konsumen Harian Standar Stasioner Terpilih (Lanjutan)

Variabel	f_1^d	f_2^d	f_3^d	f_4^d	f_5^d	f_6^d	f_7^d	f_8^d
Z_{24}^d	0,004	0,016	-0,109	-0,107	-0,281	-0,407	0,121	-0,179
Z_{26}^d	-0,063	0,454	0,130	0,156	-0,177	0,035	0,063	0,281
Z_{27}^d	0,014	-0,038	-0,147	0,034	-0,010	-0,453	-0,185	0,422
Z_{28}^d	-0,147	0,386	0,104	-0,002	0,206	-0,307	-0,187	-0,287
Z_{29}^d	-0,017	0,139	0,166	-0,158	-0,107	0,457	0,226	-0,041
Z_{30}^d	-0,118	0,296	0,269	0,004	-0,028	0,028	0,309	0,294
Z_{31}^d	0,394	0,056	0,023	-0,005	0,081	-0,051	-0,056	-0,097
Z_{32}^d	-0,366	-0,057	-0,206	-0,042	-0,025	0,031	0,028	0,030

Setelah diketahui bahwa delapan faktor adalah jumlah yang paling optimal, Tabel 4.32 menunjukkan distribusi dari dua puluh lima variabel tersebut pada delapan faktor yang terbentuk. Angka-angka pada Tabel 4.32 adalah *factor loading*, yang menunjukkan besar korelasi antara suatu variabel dengan ke delapan faktor. Perbandingan korelasi pada masing-masing variabel dilakukan untuk menentukan suatu variabel akan masuk ke suatu faktor yang mana. Variabel dengan korelasi terbesar pada suatu faktor menunjukkan bahwa variabel tersebut merupakan bagian dari faktor yang terbentuk.

Faktor 1 terdiri dari variabel harga telur ayam ras, harga susu kental manis merk Bendera 397 gram/ kaleng, harga susu kental manis merk Indomilk 390 gram/ kaleng, harga Indomie rasa kari ayam, harga ikan asin teri, harga ikan bandeng, dan harga ikan tongkol. Faktor 2 terdiri dari variabel harga daging ayam broiler, harga kol/ kubis, dan harga tomat. Faktor 3 terdiri dari variabel harga daging sapi murni dan harga bawang merah. Faktor 4 terdiri dari variabel harga cabai biasa, harga cabai rawit, dan harga bawang putih. Faktor 5 terdiri dari variabel JISDOR, harga gula pasir dalam negeri, harga kacang hijau, dan harga kacang tanah. Faktor 6 terdiri dari variabel harga kentang dan harga wortel. Faktor 7 terdiri dari variabel harga minyak goreng curah dan harga buncis. Faktor 8 terdiri dari variabel harga minyak dunia Brent dan harga daging ayam kampung. Dengan demikian, dua puluh lima variabel di atas telah direduksi menjadi delapan faktor.

Langkah selanjutnya adalah menentukan jumlah *lag* ordo *p* pada VAR dan penentuan banyaknya guncangan (*q*). Tabel 4.33 merupakan nilai AIC untuk setiap *lag*. Hasil tersebut menunjukan nilai AIC terkecil ada pada *lag* ke-8. Oleh karena itu, penelitian ini menggunakan *lag* ordo (*p*) pada model VAR adalah 8 dengan nilai AIC sebesar -8,465.

Tabel 4.33 Hasil Penentuan *Lag* Ordo (*p*) pada Model VAR Berdasarkan AIC

Lag	AIC	*Lag*	AIC	*Lag*	AIC	*Lag*	AIC
1	-7,180	4	-8,414	7	-8,459	10	-8,424
2	-8,075	5	-8,445	8	-8,465	11	-8,394
3	-8,317	6	-8,440	9	-8,438	12	-8,353

Pada tahap sebelumya, telah ditentukan banyaknya faktor dinamis *r* sebanyak 8 dengan lag ordo (*p*) pada model VAR adalah 8. Banyaknya guncangan (*q*) yang optimal yaitu 5. Langkah selanjutnya adalah melakukan pemodelan dengan metode DFM. Model DFM (*r*=8, *p*=8, *q*=5) dengan 25 variabel harga konsumen harian terpilih mempunyai residual yang berdistribusi normal namun tidak *white noise*. Model DFM (*r*=8, *p*=8, *q*=5) dengan 25 variabel harga konsumen harian terpilih dan tambahan variabel *lag* 1 dari IHK harian tidak memenuhi asumsi residual *white noise* dan berdistribusi normal. Oleh karena itu, *Nowcasting* IHK harian dengan metode DFM hanya dilakukan pada model DFM (*r*=8, *p*=8, *q*=5) tanpa tambahan variabel *lag* 1.

Tabel 4.34 Hasil Pengujian dengan Metode DFM (*r*=8, *p*=8, *q*=5)

Variabel Prediktor Stasioner			
$25Z_X^d$		$25Z_X^d$ dan $Z_{y_{t-1}}^d$	
Komponen	Koefisien	Komponen	Koefisien
Intersep	2,805	Intersep	0,719
f_1^d	-0,073	f_1^d	-0,019
f_2^d	0,012	f_2^d	0,003
f_3^d	0,012	f_3^d	0,003
f_4^d	-0,006	f_4^d	-0,003
f_5^d	-0,002	f_5^d	-0,001
f_6^d	0,004	f_6^d	0,001
f_7^d	-0,007	f_7^d	-0,002
f_8^d	-0,008	f_8^d	-0,001
		$Z_{y_{t-1}}^d$	0.744
Uji Asumsi Residual			
White Noise	*p-value*	White Noise	*p-value*
Lag 6: Tidak	$<2,2*10^{-16}$	*Lag* 6: Tidak	$<2,2*10^{-16}$
Lag 12: Tidak	$<2,2*10^{-16}$	*Lag* 12: Tidak	$<2,2*10^{-16}$
Normal	*p-value*	Normal	*p-value*
Ya	0,066	Tidak	$<2,2*10^{-16}$

Model DFM (*r*=8, *p*=8, *q*=5) tanpa tambahan variabel *lag* 1 ditunjukkan sebagai berikut:

$$\sqrt{\left(\hat{Z}_{y_t}^{d}+8\right)} = 2,805 - 0,073\, f_{1,t}^{d} + 0,012\, f_{2,t}^{d} + 0,012\, f_{3,t}^{d} - 0,006\, f_{4,t}^{d} - 0,002\, f_{5,t}^{d} + 0,004\, f_{6,t}^{d} - 0,007\, f_{7,t}^{d} - 0,008\, f_{8,t}^{d}$$

$$\hat{Z}_{y_t}^{d} = (2,805 - 0,073\, f_{1,t}^{d} + 0,012\, f_{2,t}^{d} + 0,012\, f_{3,t}^{d} - 0,006\, f_{4,t}^{d} - 0,002\, f_{5,t}^{d} + 0,004\, f_{6,t}^{d} - 0,007\, f_{7,t}^{d} - 0,008\, f_{8,t}^{d})^2 - 8$$

Tabel 4.35 menunjukkan evaluasi prediksi IHK harian dengan metode DFM tanpa variabel *lag* 1 dari IHK harian stasioner.

Tabel 4.35 Hasil Evaluasi Prediksi IHK Harian dengan DFM (r=8, p=8, q=5)

Prediktor	RMSE *Train**	sMAPE *Train**	MAD *Train**	RMSE *Test*	sMAPE *Test*	MAD *Test*
$25\, Z_X^d$	0,680	0,491	0,495	1,454	167,362	1,154

*) Evaluasi mulai 2 Januari 2017

4.4.2 Pembangunan *Nowcasting* IHK Harian dengan Metode SVR

Tabel 4.36 Optimisasi *Hyperparameter* Dataset Harian dengan *Grid Search*

Metode	Gamma	Epsilon	C	Degree
SVR-Linear	0,1	0,1	1	
SVR-RBF	0,1	0,1	4	
SVR-*Polynomial*	2,1	0,1	1	1

Dua skenario diterapkan pada metode SVR untuk *nowcasting* IHK harian. Skenario pertama dibangun model SVR IHK harian dengan 25 variabel harga konsumen terpilih dan skenario kedua menambahkan variabel *lag* 1 dari IHK harian. Optimisasi *hyperparameter* yang digunakan untuk kedua skenario sama. Optimisasi tersebut menggunakan metode *Grid Search* dan ditentukan berdasarkan nilai RMSE, sMAPE, dan MAD terkecil pada data *testing* ditunjukkan oleh Tabel 4.36 di atas.

Hasil evaluasi prediksi IHK harian dengan metode SVR berdasarkan tipe kernel dan variabel prediktor ditunjukkan oleh Tabel 4.37. SVR *Polynomial* dengan atau tanpa variabel lag dari IHK harian merupakan metode terbaik untuk prediksi IHK harian dibandingkan SVR dengan variabel prediktor yang sama namun tipe kernel berbeda. Secara keseluruhan SVR *Polynomial* dengan variabel

prediktor dua puluh lima harga konsumen terpilih ditambahkan variabel *lag* merupakan metode terbaik untuk prediksi IHK harian berdasarkan RMSE, sMAPE maupun MAD terkecil pada data *testing*.

Tabel 4.37 Hasil Evaluasi Prediksi IHK Harian dengan SVR

Prediktor: 25 Z_X^d						
Metode	RMSE *Train*	sMAPE *Train*	MAD *Train*	RMSE *Test*	sMAPE *Test*	MAD *Test*
SVR-Linear	0,12864	0,10864	0,10946	0,31647	0,27696	0,28924
SVR-RBF	0,14683	0,12414	0,12497	2,65381	2,23832	2,31251
SVR-*Polynomial*	0,12848	0,10847	0,10928	0,31545	0,27605	0,28829
Prediktor: 25 Z_X^d dan $Z_{y_{t-1}}^d$						
Metode	RMSE *Train**	sMAPE *Train**	MAD *Train**	RMSE *Test*	sMAPE *Test*	MAD *Test*
SVR-Linear	0,13314	0,11386	0,11474	0,30481	0,26699	0,27881
SVR-RBF	0,14609	0,12283	0,12367	2,67099	2,25944	2,33404
SVR-*Polynomial*	0,13298	0,11368	0,11456	0,30483	0,26697	0,27879

*) Evaluasi mulai 1 Januari 2017

Model SVR-*Polynomial* ($\gamma = 2{,}1; \varepsilon = 0{,}1; C=1; d=1$) dengan 25 Z_X^d dan $Z_{y_{t-1}}^d$ berikut:

$$\hat{Z}_{y_t}^d = 2{,}1(-0{,}018\left(Z_{1,t}^d Z_{1,t}^{d\,'}\right) + 0{,}021\left(Z_{2,t}^d Z_{2,t}^{d\,'}\right) + 0{,}010\left(Z_{4,t}^d Z_{4,t}^{d\,'}\right) - 0{,}030\left(Z_{6,t}^d Z_{6,t}^{d\,'}\right) + 0{,}038\left(Z_{7,t}^d Z_{7,t}^{d\,'}\right)$$
$$+0{,}010\left(Z_{8,t}^d Z_{8,t}^{d\,'}\right) - 0{,}020\left(Z_{9,t}^d Z_{9,t}^{d\,'}\right) + 0{,}047\left(Z_{10,t}^d Z_{10,t}^{d\,'}\right) + 0{,}048\left(Z_{11,t}^d Z_{11,t}^{d\,'}\right) + 0{,}025\left(Z_{12,t}^d Z_{12,t}^{d\,'}\right)$$
$$+0{,}043\left(Z_{17,t}^d Z_{17,t}^{d\,'}\right) + 0{,}096\left(Z_{18,t}^d Z_{18,t}^{d\,'}\right) - 0{,}068\left(Z_{19,t}^d Z_{19,t}^{d\,'}\right) + 0{,}015\left(Z_{20,t}^d Z_{20,t}^{d\,'}\right) + 0{,}015\left(Z_{21,t}^d Z_{21,t}^{d\,'}\right)$$
$$+0{,}058\left(Z_{22,t}^d Z_{22,t}^{d\,'}\right) + 0{,}042\left(Z_{23,t}^d Z_{23,t}^{d\,'}\right) + 0{,}055\left(Z_{24,t}^d Z_{24,t}^{d\,'}\right) - 0{,}004\left(Z_{26,t}^d Z_{26,t}^{d\,'}\right) - 0{,}020\left(Z_{27,t}^d Z_{27,t}^{d\,'}\right)$$
$$-0{,}033\left(Z_{28,t}^d Z_{28,t}^{d\,'}\right) - 0{,}017\left(Z_{29,t}^d Z_{29,t}^{d\,'}\right) + 0{,}042\left(Z_{30,t}^d Z_{30,t}^{d\,'}\right) + 0{,}040\left(Z_{31,t}^d Z_{31,t}^{d\,'}\right) + 0{,}164\left(Z_{32,t}^d Z_{32,t}^{d\,'}\right)$$
$$+0{,}006\hat{Z}_{y_{t-1}}) + 0{,}007$$

4.4.3 Pembangunan *Nowcasting* IHK Harian dengan TSR

Dua skenario diterapkan pada metode TSR untuk *nowcasting* IHK harian. Skenario pertama dibangun model TSR IHK harian dengan 25 variabel harga konsumen terpilih dan skenario kedua menambahkan variabel *lag* 1 dari IHK harian.

Tabel 4.38 Uji Multikolinearitas Harga Konsumen Harian Standar

Nama	VIF	Nama	VIF	Nama	VIF
Z_1^d	10,16	Z_{12}^d	1,83	Z_{26}^d	2,18
Z_2^d	6,56	Z_{17}^d	1,50	Z_{27}^d	6,41
Z_4^d	7,16	Z_{18}^d	2,91	Z_{28}^d	2,88
Z_6^d	3,34	Z_{19}^d	3,98	Z_{29}^d	4,13
Z_7^d	5,08	Z_{20}^d	4,45	Z_{30}^d	1,91
Z_8^d	2,27	Z_{21}^d	2,86	Z_{31}^d	9,13
Z_9^d	7,50	Z_{22}^d	6,32	Z_{32}^d	6,64
Z_{10}^d	2,75	Z_{23}^d	20,09		
Z_{11}^d	1,32	Z_{24}^d	18,14		

Tabel 4.38 menunjukkan ada multikolinearitas antar dua puluh lima variabel harga konsumen harian terpilih, ditunjukkan oleh VIF lebih dari 10. Salah satu cara untuk mengatasi multikolinearitas antar variabel tersebut yaitu membentuk *principal component* (PC). Uji kecukupan data dengan uji KMO dan uji Bartlett dilakukan sebelum melakukan TSR dengan PC untuk mengatasi multikolinearitas.

Tabel 4.39 Uji KMO dan Uji Bartlett Harga Konsumen Harian Standar Terpilih

Uji KMO		0,702
Uji Bartlett	*Chi-squared*	31.670
	df	300
	p-value	$<2{,}2*10^{-16}$

Nilai KMO sebesar 0,702 > 0,5 (batas toleransi kecukupan data). *p-value* dari uji Bartlett sebesar 0 < 0,05 sehingga dapat disimpulkan bahwa data harga konsumen harian standar terpilih memiliki hubungan satu sama lain dan sudah cukup memadai untuk dilakukan analisis lanjutan yaitu *Principal Component Analysis* (PCA) dan TSR.

Tabel 4.40 *Eigenvalue*, Proporsi dan Kumulatif Proporsi Variasi yang Terjelaskan

PC	*Eigen*	Proporsi	Kumulatif
1	6,104	25,252	25,252
2	4,017	16,618	41,870
3	2,674	11,060	52,930
4	1,750	7,239	60,170
5	1,460	6,040	66,210
6	1,098	4,542	70,752
7	1,026	4,246	74,998
8	0,993	4,106	79,104
9	0,782	3,233	82,337
10	0,757	3,130	85,467
11	0,647	2,678	88,145
12	0,572	2,365	90,509
13	0,398	1,647	92,157
14	0,367	1,516	93,673
15	0,323	1,335	95,008
16	0,268	1,108	96,116
17	0,203	0,840	96,957
18	0,171	0,706	97,663
19	0,157	0,648	98,311
20	0,129	0,535	98,845
21	0,086	0,357	99,203
22	0,075	0,309	99,512
23	0,066	0,272	99,784
24	0,031	0,129	99,914
25	0,021	0,086	100,000

Penentuan jumlah PC yang dibentuk, ditentukan berdasarkan *eigenvalue*>1. Ada 7 PC dengan *eigenvalue* > 1 berdasarkan Tabel 4.40 dan Gambar 4.12. Ketujuh PC yang terbentuk mampu menjelaskan keragaman variabel rata-rata harga konsumen standar terpilih sebesar 74,998%.

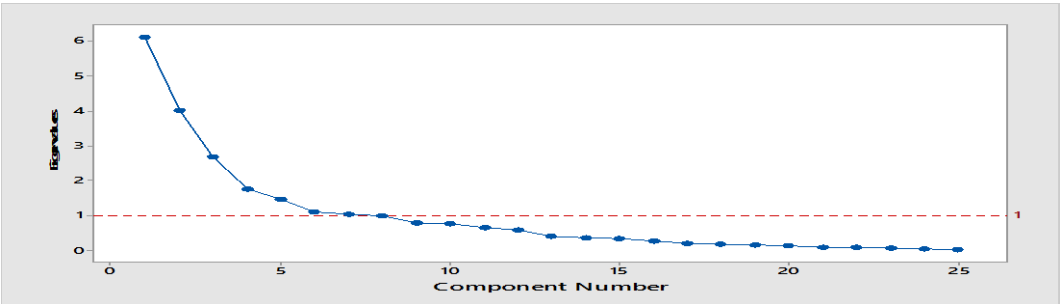

Gambar 4.12 *Screeplot* dari Harga Konsumen Harian Standar Terpilih

Tabel 4.41 Koefisien dari Tujuh *Principal Component* yang Terbentuk dari Dua Puluh Lima Harga Konsumen Harian Standar Terpilih

i	W_1^d	W_2^d	W_3^d	W_4^d	W_5^d	W_6^d	W_7^d
1	-0,108	0,448	-0,124	-0,090	0,020	0,185	0,017
2	0,319	0,000	0,109	-0,241	-0,041	-0,248	0,023
3	0,120	-0,432	-0,100	-0,068	0,016	-0,122	0,037
4	-0,077	-0,198	0,058	-0,043	0,094	0,132	-0,332
5	0,271	0,132	-0,022	0,207	0,026	-0,008	0,024
6	0,155	0,198	-0,156	0,155	0,305	-0,155	-0,251
7	0,294	0,281	-0,026	0,069	-0,073	0,020	-0,100
8	0,288	0,055	-0,126	0,164	0,261	0,167	-0,073
9	0,169	-0,122	-0,016	0,009	-0,276	0,160	0,282
10	0,199	-0,164	-0,004	0,001	-0,317	0,038	-0,070
11	0,231	0,002	-0,035	-0,006	-0,159	0,094	0,312
12	0,036	-0,015	-0,415	0,106	-0,140	0,446	-0,366
13	-0,161	-0,112	-0,305	-0,097	-0,327	-0,070	-0,300
14	0,105	-0,327	-0,224	-0,209	0,257	-0,107	-0,103
15	-0,108	-0,208	-0,383	-0,210	-0,109	0,231	0,252
16	0,336	-0,032	0,144	-0,001	-0,108	0,110	-0,069
17	0,189	-0,243	0,190	-0,012	0,144	0,025	-0,167
18	0,097	-0,352	0,269	0,178	0,106	0,096	-0,073
19	0,041	-0,004	-0,290	0,057	0,062	-0,407	-0,269
20	-0,137	-0,150	0,017	0,626	-0,158	0,128	-0,038
21	0,148	-0,063	-0,287	-0,033	0,512	0,291	0,314
22	0,031	-0,080	-0,248	0,529	-0,023	-0,319	0,290
23	0,093	0,043	-0,308	-0,095	-0,138	-0,319	0,127
24	0,346	0,040	-0,043	-0,051	-0,196	-0,051	-0,043
25	0,314	0,100	-0,003	-0,039	-0,149	0,146	-0,129

Tabel 4.41 di atas menunjukkan nilai koefisien dari tujuh PC yang terbentuk. Tabel 4.42 di bawah menunjukkan bahwa regresi yang terbentuk dengan 7 PC menghasilkan residual yang normal namun belum memenuhi asumsi *white noise*. Residual dari model IHK harian setelah ditambahkan variabel *lag* 1 dari IHK harian sebagai variabel prediktor belum memenuhi asumsi normal dan *white noise*. Oleh karena itu, metode TSR yang digunakan untuk *nowcasting* IHK harian yaitu model 1. Model1 ditunjukkan oleh persamaan sebagai berikut:

$$\hat{Z}_{y_t}^d = 0,369W_{1,t}^d - 0,040W_{2,t}^d - 0,004W_{3,t}^d - 0,003W_{4,t}^d - 0,101W_{5,t}^d + 0,148W_{6,t}^d - 0,055W_{7,t}^d$$

Tabel 4.42 Hasil Pengujian dengan *Time Series Regression* pada IHK Harian

Model	Variabel Prediktor	Signifikansi Parameter	Non-Multikol	Residual		
				White Noise		Normal
				Lag 6	*Lag* 12	
1	$W_1^d, W_2^d, \ldots, W_7^d$	$W_1^d, W_2^d, W_5^d, W_6^d, W_7^d$	Ya	Tidak	Tidak	Ya
2	$W_1^d, W_2^d, \ldots, W_7^d$ & $Z_{y_{t-1}}^d$	$W_1^d, W_2^d, W_5^d, W_6^d, W_7^d$ & $Z_{y_{t-1}}^d$	Tidak	Tidak	Tidak	Tidak
3	$W_2^d, W_5^d, W_6^d, W_7^d$ & $Z_{y_{t-1}}^d$	W_5^d, W_6^d, W_7^d & $Z_{y_{t-1}}^d$	Tidak	Tidak	Tidak	Tidak

Tabel 4.43 Hasil Evaluasi Prediksi IHK Harian dengan TSR Model 1

Prediktor	RMSE *Train*	sMAPE *Train*	MAD *Train*	RMSE *Test*	sMAPE *Test*	MAD *Test*
$W_1^d, W_2^d, \ldots, W_7^d$	0,502	0,373	0,376	0,437	0,351	0,366

4.4.4 Evaluasi Model *Nowcasting* IHK Harian

SVR *Polynomial* dengan variabel prediktor 25 harga konsumen harian terpilih ditambahkan variabel *lag* merupakan metode terbaik untuk prediksi IHK harian berdasarkan RMSE, sMAPE maupun MAD terkecil pada data *testing*.

Tabel 4.44 Hasil Evaluasi Prediksi IHK Harian

Metode	RMSE *Train**	sMAPE *Train**	MAD *Train**
DFM (r=8, p=8, q=5) dengan 25 Z_X^d	0,680	0,491	0,495
SVR-*Polynomial* ($\gamma = 2{,}1; \varepsilon = 0{,}1; C$=1;$d$=1) dengan 25 Z_X^d dan $Z_{y_{t-1}}^d$	0,133	0,114	0,114
TSR dengan $W_1^d, W_2^d, \ldots, W_7^d$	0,503	0,374	0,376
Metode	**RMSE *Test***	**sMAPE *Test***	**MAD *Test***
DFM (r=10, p=2, q=6) dengan 25 Z_X^m	1,454	167,362	1,154
SVR-*Polynomial* ($\gamma = 2{,}1; \varepsilon = 0{,}1; C$=1;$d$=1) dengan 25 Z_X^d dan $Z_{y_{t-1}}^d$	0,305	0,267	0,279
TSR dengan $W_1^d, W_2^d, \ldots, W_7^d$	0,437	0,351	0,366

*) Evaluasi mulai 2 Januari 2017

BAB 5
KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan, maka kesimpulan yang diperoleh dari penelitian ini adalah sebagai berikut:

1. IHK diestimasi dengan *Ordinary Least Square* (OLS) pada metode DFM dan TSR. Perbedaan di antara kedua metode ini yaitu data harus stasioner dalam rata-rata dan varians sebelum dilakukan permodelan DFM. Persamaan keduanya yaitu asumsi residual pada DFM dan TSR yaitu *white noise* dan normal. SVR didasarkan pada *structural risk minimization*, yaitu untuk mengestimasi suatu fungsi dengan cara meminimalkan batas atas dari *generalization error*,
2. Variabel harga konsumen harian stasioner tidak memiliki invers sehingga prediksi IHK harian tidak bisa dilakukan pada model DFM (r=11,p=3,q=5) dengan variabel harga konsumen bulanan stasioner sebanyak 33. Oleh karena itu, variabel harga konsumen harian yang stasioner dieliminasi secara bertahap sehingga diperoleh dua puluh lima variabel harga konsumen harian stasioner yang mempunya solusi. Model IHK Bulanan dengan metode DFM dibangun dengan jumlah faktor (r) yaitu 10, panjang *lag* ordo pada model VAR (p) yaitu 2 dan banyak guncagan (q) yaitu 6. Model IHK bulanan dengan metode SVR-Linear dibangun dengan parameter optimal *gamma*=0,1, *epsilon*=0,1, dan *cost*=1. Model IHK bulanan dengan metode SVR-RBF dibangun dengan parameter optimal *gamma*=0,1, *epsilon*=0,1, dan *cost*=1. Model IHK bulanan dengan metode SVR-*Polynomial* dibangun dengan parameter optimal *gamma*=0,1, *epsilon*=0,1, *cost*=5, *degree*=1. Model IHK bulanan dengan metode TSR yang dibangun dengan menambahkan variabel *lag* dari IHK bulanan sebagai variabel prediktor dihasilkan residual yang memenuhi asumsi *white noise* dan normal. Model IHK harian dengan metode DFM dibangun dengan jumlah faktor (r) yaitu 8, panjang *lag* ordo pada model VAR (p) yaitu 8 dan banyak guncagan (q) yaitu 5. Model

tersebut menghasilkan residual yang normal namun tidak *white noise*. Model IHK harian dengan metode SVR-Linear dibangun dengan parameter optimal *gamma*=0,1, *epsilon*=0,1, dan *cost*=1. Model IHK harian dengan metode SVR-RBF dibangun dengan parameter optimal *gamma*=0,1, *epsilon*=0,1, dan *cost*=4. Model IHK harian dengan metode SVR-*Polynomial* dibangun dengan parameter optimal *gamma*=2,1, *epsilon*=0,1, *cost*=1, *degree*=1. Model IHK harian dengan metode TSR yang dibangun dengan tujuh *principal component* sebagai variabel prediktor dihasilkan residual yang memenuhi asumsi normal namun tidak *white noise*.

3. Hasil evaluasi prediksi IHK bulanan menunjukkan bahwa TSR dengan variabel prediktor PC ke-3, PC ke-4, dan variabel *lag* 1 dari IHK bulanan merupakan metode terbaik untuk prediksi IHK bulanan baik berdasarkan RMSE, sMAPE, maupun MAD terkecil. Namun performansi SVR-*Polynomial* ($\gamma = 0{,}1; \varepsilon = 0{,}1; C$=5;$d$=1) dengan variabel prediktor dua puluh lima variabel harga konsumen terpilih dalam *nowcasting* IHK harian merupakan yang terbaik dibandingkan metode yang lain. SVR *Polynomial* ($\gamma = 2{,}1; \varepsilon = 0{,}1; C$=1;$d$=1) dengan variabel prediktor dua puluh lima harga konsumen terpilih ditambahkan variabel *lag* merupakan metode terbaik untuk prediksi IHK harian pada model IHK harian berdasarkan RMSE, sMAPE maupun MAD terkecil pada data *testing*.

5.2 Saran

Berdasarkan hasil dari penelitian ini maka saran untuk penelitian selanjutnya yaitu:

1. Terkait permodelan dengan metode DFM, perlu dibandingkan dengan metode *nowcasting* yang lain seperti *Bridge Equation* atau *Mixed Frequency*-VAR,
2. Terkait permodelan dengan metode SVR, optimasi *hyperparameter* bisa menggunakan metode yang lain seperti *random search* kemudian hasilnya dibandingkan dengan *grid search*,

3. Terkait permodelan dengan TSR, penanganan *residual* tidak *white noise* dapat dicoba melalui deteksi *outlier* dengan memasukkan *outlier* ke dalam model.

DAFTAR PUSTAKA

Amrin. (2016). Data Mining dengan Regresi Linear Berganda untuk Peramalan Tingkat Inflasi. *Jurnal Techno Nusa Mandiri Vol. XIII, No. 1 Maret 2016* , 74-79.

Banbura, M., & Runstler, G. (2011). A Look Into The Factor Model Black Box:Publication Lags and The Role of Hard and Soft Data in Forecasting GDP. *International Journal of Forecasting 27*, 333–346.

Banbura, M., Giannone, D., & Reichlin, L. (2010). Nowcasting. *ECB Working Paper Series No. 1275*, 1-38.

BPS. (2020). *Indeks Harga Konsumen di 82 Kota di Indonesia (2012=100) 2019.* Jakarta: BPS RI.

BPS. (2021). *Indeks Harga Konsumen 90 Kota di Indonesia (2018=100) 2020.* Jakarta: BPS RI.

BPS Jawa Timur. (2019). *BRS Perkembangan Indeks Harga Konsumen Jawa Timur April 2019.* Surabaya: BPS Provinsi Jawa Timur.

Budiastuti, R. (2017). *Prediksi Indeks Harga Konsumen Harian menggunakan Support Vector Regression Berbasis Cloud Computing Thesis.* Surabaya: Institut Teknologi Sepuluh November.

Cryer, J., & Chan, K.-S. (2009). *Time Series Analysis with Application in R Second Edition.* Iowa: Springer Science+Business Media, LLC.

Darma, D. C., Pusriadi, T., & Hakim, Y. P. (2018). Dampak Kenaikan Harga Komoditas Sembako terhadap Tingkat Inflasi di Indonesia. *Seminar Nasional dan Call For Paper: Manajemen, Akuntansi dan Perbankan*, 1048-1074.

Dewi, K., Adikara, P. P., & Adinugroho, S. (2018). Prediksi Indeks Harga Konsumen (IHK) Kelompok Perumahan, Air, Listrik, Gas Dan Bahan Bakar Menggunakan Metode Support Vector Regression. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer Vol. 2, No. 10, Oktober 2018*, 3856-3862 .

Ding, Z. (2012). Application of Support Vector Machine Regression in Stock Price Forecasting. *Zhu M. (eds) Business, Economics, Financial Sciences, and Management. Advances in Intelligent and Soft Computing, vol 143 Springer, Berlin, Heidelberg*, 359-365.

Eksiandayani, S., Suhartono, & Prastyo, D. D. (2015). Hybrid ARIMAX-NN Model for Forecasting Inflation. *International Conference on Science, Technology and Humanity*, 181-187.

Evriyanto, Y. (2004). *Perbandingan Metode Imputasi untuk Mengestimasi Data Hilang pada Data Kesehatan Ibu dan Anak di Jawa Timur Tesis.* Surabaya: Universitas Airlangga.

Giannone, D., Reichlin, L., & Small, D. (2008). Nowcasting: The Real-Time Informational Content of Macroeconomic Data. *Journal of Monetary Economics 55*, 665-676.

Hong, W.-C. (2009). Electric Load Forecasting by Support Vector Model. *Applied Mathematical Modelling 33*, 2444–2454.

Hyndman, R., & Koehler, A. (2006). Another Look at Measures of Forecast Accuracy. *International Journal of Forecasting 22*, 679-688.

Ifadah, A. (2011). *Analisis Metode Principle Component Analysis (Komponen Utama) dan Regresi Ridge dalam Mengatasi Dampak Multikolinearitas dalam Analisis Regresi Linear Berganda.* Semarang: Universitas Negeri Semarang.

Khamis, A., Ismail, Z., Ilaron, K., & Mohammed, A. T. (2005). The Effects of Outliers Data on Neural Network Performance. *Journal of Aplied Sciences 5(8)*, 1394-1398.

Khatimi, H., Alkaff, M., & Najipah, D. R. (2017). Penerapan Support Vector Regression (SVR) untuk Peramalan Inflasi Bulanan Nasional. *JTIULM - Volume 02, Nomor 2, Desember 2017*, 29 – 34 .

Kuzin, V., Marcellino, M., & Schumacher, C. (2009). MIDAS versus Mixed Frequency VAR: Nowcasting GDP in The Euro Area. *Discussion Paper Series 1:Economic Studies No.07 Deutsche Bundesbank Eurosystem*, 1-27.

Lee, M. H., Suhartono, & Hamzah, N. A. (2010). Calendar Variation Model Based On ARIMAX for Forecasting Sales Data with ramadhan Effect. *Proceedings of the Regional Conference on Statistical Sciences 2010 (RCSS'10)* , 349-361.

Luciani, M., Pundit, M., Ramayandi, A., & Veronese, G. (2015). Nowcasting Indonesia. *Finance and Economics Discussion Series*, 1-21.

Ma'Arif, S. (2019). *Nowcasting Pertumbuhan Produk Domestik Bruto menggunakan Dynamic Factor Model Thesis.* Surabaya: ITS.

Makridakis, S., & Hibon, M. (2000). The M3-Competition: results, conclusions and implications. *International Journal of Forecasting Vol. 16*, 451–476.

Mariano, R., & Murasawa, Y. (2003). A New Coincident Index of Business Cycles Based On Monthly and Quarterly Series. *Journal of Applied Econometrics 18 (4)*, 427-443.

Montgomery, D., Jennings, C., & Kulahci, M. (2008). *Introduction to Time Series Analysis and Forecasting.* New Jersey: John Wiley& Sons.

Mulyana. (2004). *Buku Ajar Analisis Data Deret Waktu.* Bandung: Universitas Padjadjaran.

Newton, Kurnia, A., & Sumertajaya, I. (2020). Analisis Inflasi Menggunakan Data Google Trends dengan Model ARIMAX di DKI Jakarta. *Indonesian Journal of Statistics and Its Applications. Vol 4 No 3*, 545 - 556 .

Nizar, M. A. (2012). Dampak Fluktuasi Harga Minyak Dunia terhadap Perekonomian Indonesia. *Buletin Ilmiah Litbang Perdagangan Vol.6 No.2*, 189-210.

Purwanto, A. D. (2019). *Perbandingan Metode Imputasi Mean Substitution dan Median Substitution pada Person Trait Estimation Skripsi.* Malang: Universitas Brawijaya.

Riyani, D., Prastyo, D. D., & Suhartono. (2019). Input Selection in Support Vector Regression for Univariate Time Series Forecasting. *The AIP Conference Proceedings 2194, 020105*, 1-7.

Saputra, K., & Nugroho. (2014). Analisis Faktor-Faktor yang Mempengaruhi Inflasi di Indonesia 2007-2012. *Diponegoro Journal of Economics Volume 3 No.1*, 1-15.

Schumacher, C. (2016). A Comparison of MIDAS and Bridge Equations. *International Journal of Forecasting 32*, 252-270.

Stock, J. H., & Watson, M. W. (2016). *Handbook of Macroeconomics* . United States: Elsevier.

Sumantri, F., & Latifah, U. (2019). Faktor-faktor yang Mempengaruhi Indeks Harga Konsumen . *Jurnal Sekretari dan Manajemen Widya Cipta Volume 3 No. 1 Maret 2019* , 25-34.

Sundoro, H. S. (2021). Pengaruh Harga Komoditas Pangan dan Bensin terhadap Tingkat Inflasi Selama Pemerintahan Jokowi. *E-Jurnal Ekonomi dan Bisnis Universitas Udayana*, 73-82.

Suseno, & Astiyah, S. (2009). *Inflasi.* Jakarta: Pusat Pendidikan dan Studi Kebanksentralan (PPSK) Bank Indonesia.

Sutawijaya, A., & Zulfahmi. (2012). Pengaruh Faktor-Faktor Ekonomi terhadap Inflasi di Indonesia. *Jurnal Organisasi dan Manajemen Volume 8 Nomor 2*, 85-101.

Tarsidin, Idham, & Rakhman, R. N. (2018). Nowcasting Household Consumption and Investment in Indonesia. *Bulletin of Monetary Economics and Banking, Volume 20, Number 3*, 375-404.

Wei, W. (2006). *Time Series Analysis Univariate and Multivariate Methods Second Edition.* USA: Pearson Education Inc.

Witten, I., Frank, E., Hall, M., & Pal, C. (2017). *Data Mining Practical Machine Learning Tools and Techiques Fourth Edition.* United States: Elsevier.

LAMPIRAN

Lampiran 1 Struktur Data Bulanan dalam Penelitian

Bulan	y_t^m	$x_{1,t}^m$	$x_{2,t}^m$	$x_{3,t}^m$	$x_{4,t}^m$	$x_{5,t}^m$	$x_{6,t}^m$	$x_{7,t}^m$	$x_{8,t}^m$	$x_{9,t}^m$	$x_{10,t}^m$	$x_{12,t}^m$	…	$x_{33,t}^m$
1/2017	95,87	55,68	13404	9018	12805	26065	11854	107512	29911	58985	18639	10052	…	17209
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	…	⋮
12/2017	98,25	64,26	13554	9627	11211	27102	11573	110070	30875	62914	23286	10004	…	17484
1/2018	98,84	69,01	13381	10569	11121	26986	11461	109992	33032	62492	21671	10001	…	17471
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	…	⋮
12/2018	101,06	57,59	14496	9891	10222	26388	10568	111589	34563	67044	24385	10042	…	18061
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	…	⋮
1/2021	105,02	55,13	14063	9894	12170	26260	13284	111055	32668	64717	22172	10162	…	17814
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	…	⋮
5/2021	105,77	67,86	14310	9707	12104	27300	14214	114371	36087	67285	22073	10150	…	17887

Lampiran 2 Struktur Data Harian dalam Penelitian

Tanggal	y_t^d	$x_{1,t}^d$	$x_{2,t}^d$	$x_{3,t}^d$	$x_{4,t}^d$	$x_{5,t}^d$	$x_{6,t}^d$	$x_{7,t}^d$	$x_{8,t}^d$	$x_{9,t}^d$	$x_{10,t}^d$	$x_{12,t}^d$	…	$x_{33,t}^d$
1/1/2017	97,21	61,08	14107	8992	12792	26017	11825	108200	29467	59454	20521	9992	…	17154
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	…	⋮
31/1/2017	96,50	55,70	13343	9046	12765	26131	11827	107700	29196	59613	17852	10042	…	17242
1/2/2017	95,95	56,80	13349	9029	12801	26093	11965	107650	28854	59371	17702	10008	…	17263
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	…	⋮
28/2/2017	96,24	55,59	13347	8960	12650	26242	12465	107546	26083	58637	17004	10029	…	17271
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	…	⋮
1/5/2021	105,04	67,83	14460	9723	12050	27192	14104	111583	35396	65958	21788	10150	…	17850
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	…	⋮
31/5/2021	105,47	69,32	14292	9665	12102	27392	14296	112479	32658	64208	22975	10150	…	18017

Lampiran 3 Plot *Box-Cox* Variabel Z_X^m yang Belum Stasioner dalam Varians

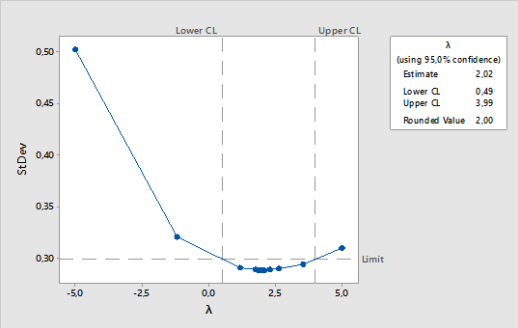

Rata-rata Bulanan Harga minyak dunia Brent (USD/Barel)

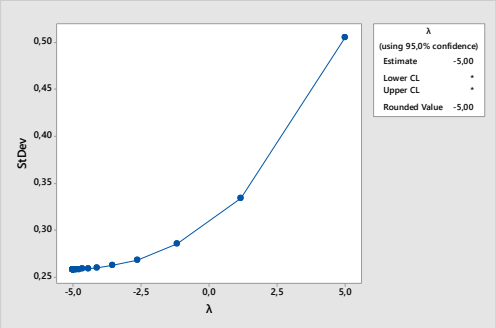

Rata-rata Bulanan JISDOR (USD/IDR)

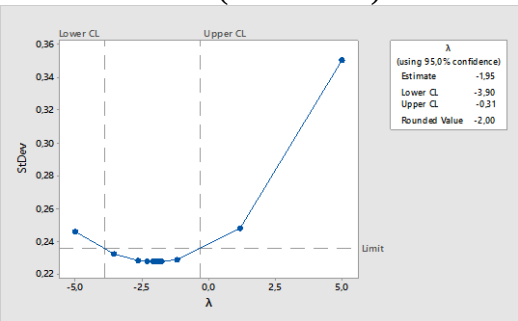

Rata-rata Bulanan Harga Beras IR 64

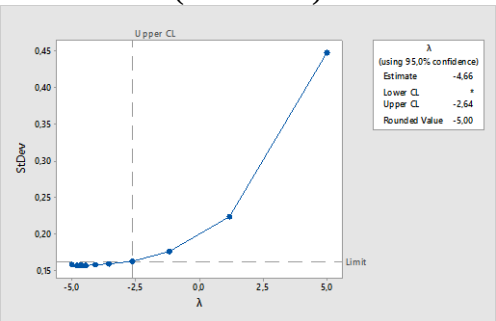

Rata-rata Bulanan Harga Gula Pasir Dalam Negeri

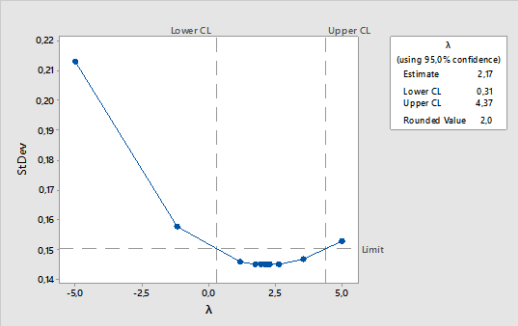

Rata-rata Bulanan Harga Minyak Goreng Bimoli Botol/Kemasan 2L

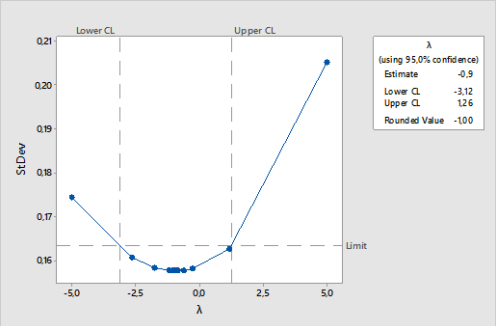

Rata-rata Bulanan Harga Minyak Goreng Curah

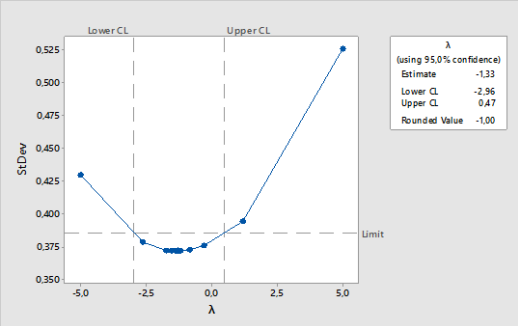

Rata-rata Bulanan Harga Daging Sapi Murni

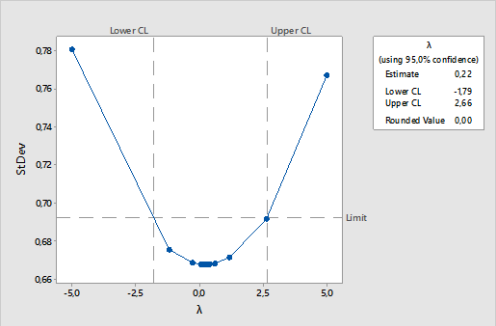

Rata-rata Bulanan Harga Daging Ayam Broiler

Lampiran 3 Plot *Box-Cox* Variabel Z_X^m yang Belum Stasioner dalam Varians (Lanjutan)

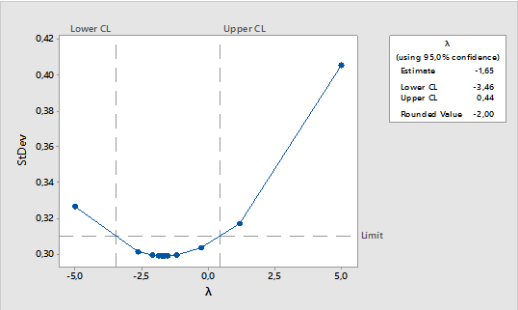

Rata-rata Bulanan Harga Daging Ayam Kampung

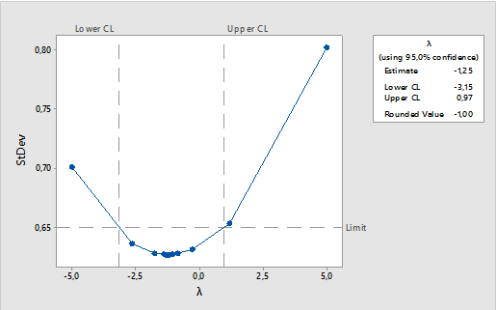

Rata-rata Bulanan Harga Telur Ayam Ras

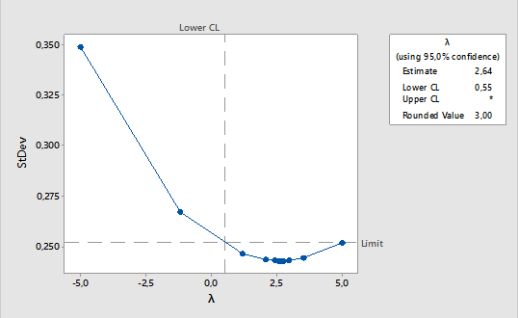

Rata-rata Bulanan Harga Susu Kental Manis Merk Bendera (397 gr/kl)

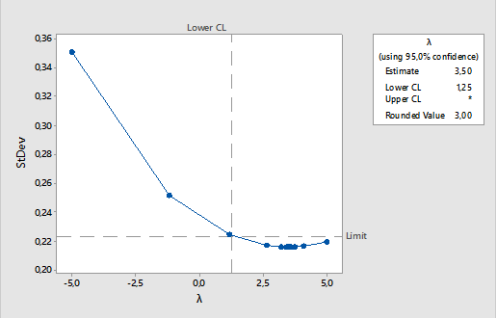

Rata-rata Bulanan Harga Susu Kental Manis Merk Indomilk (390 gr/kl)

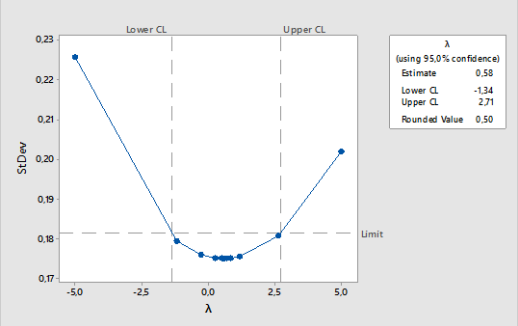

Rata-rata Bulanan Harga Jagung Pipilan Kering

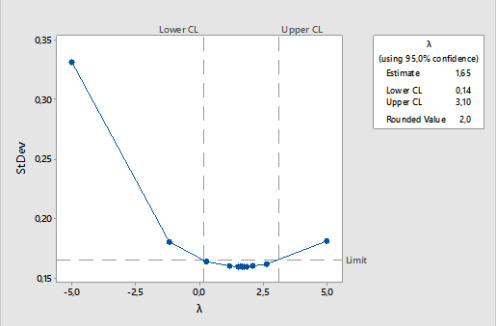

Rata-rata Bulanan Harga Garam Beryodiun Halus

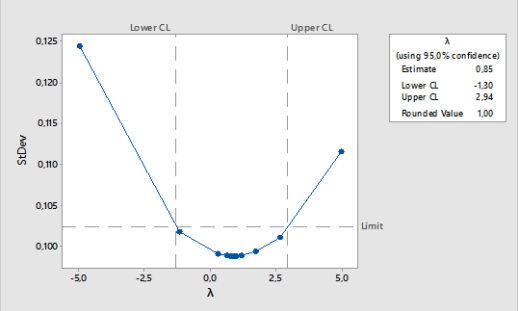

Rata-rata Bulanan Harga Tepung Terigu Segitiga Biru Kw Medium

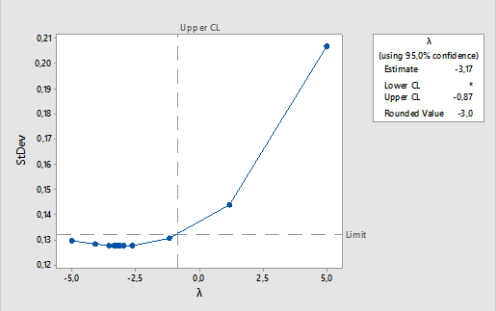

Rata-rata Bulanan Harga Kacang Kedelai Eks Impor

Lampiran 3 Plot *Box-Cox* Variabel Z_X^m yang Belum Stasioner dalam Varians (Lanjutan)

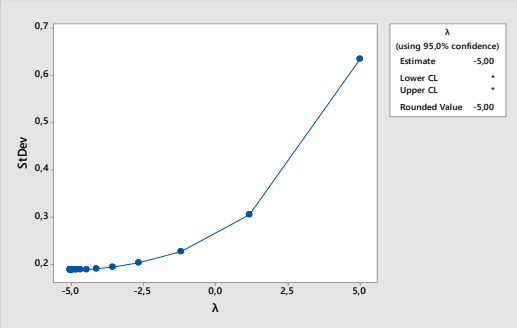

Rata-rata Bulanan Harga Indomie Rasa Kari Ayam

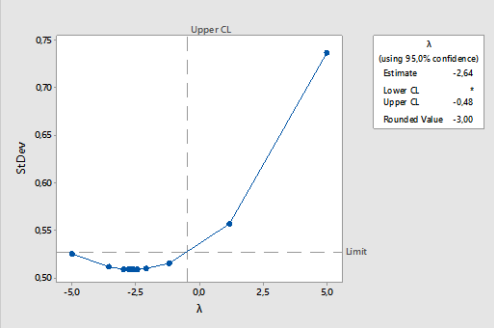

Rata-rata Bulanan Harga Cabai Biasa

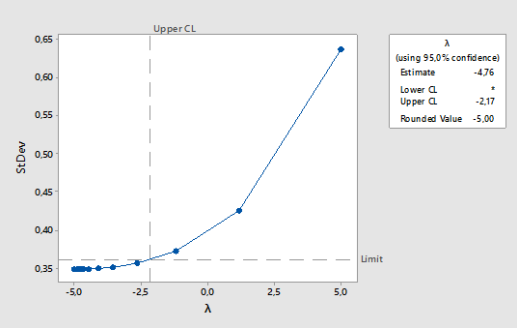

Rata-rata Bulanan Harga Cabai Rawit

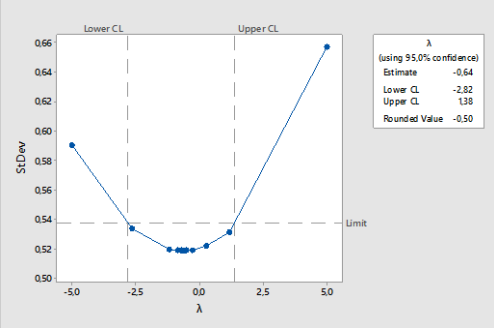

Rata-rata Bulanan Harga Bawang Merah

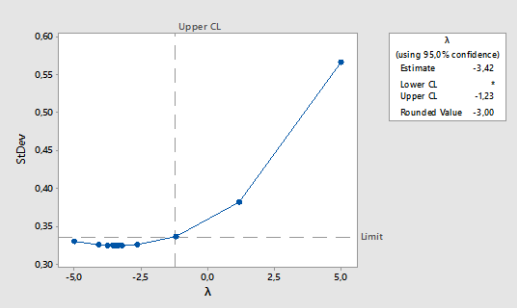

Rata-rata Bulanan Harga Bawang Putih

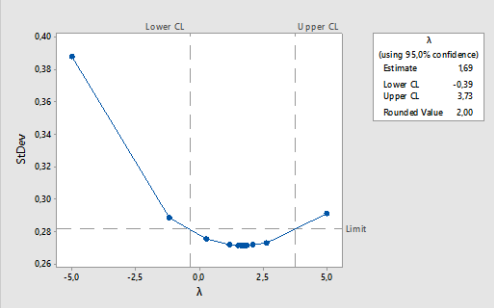

Rata-rata Bulanan Harga Ikan Asin Teri

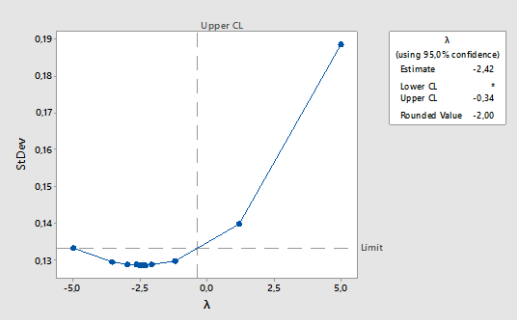

Rata-rata Bulanan Harga Kacang Hijau

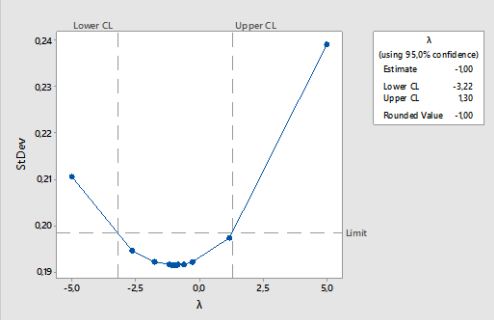

Rata-rata Bulanan Harga Kacang Tanah

Lampiran 3 Plot *Box-Cox* Variabel Z_X^m yang Belum Stasioner dalam Varians (Lanjutan)

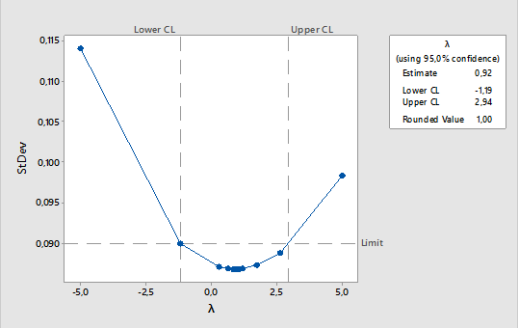

Rata-rata Bulanan Harga Ketela Pohon

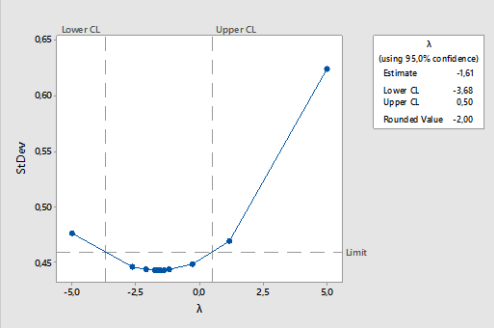

Rata-rata Bulanan Harga Kol/ Kubis

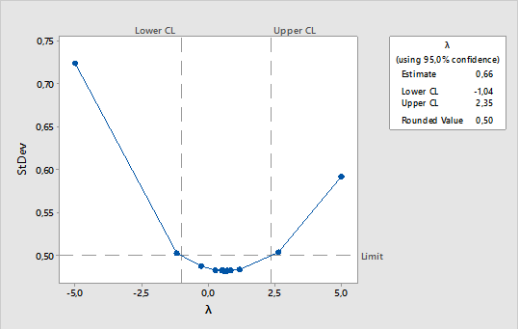

Rata-rata Bulanan Harga Kentang

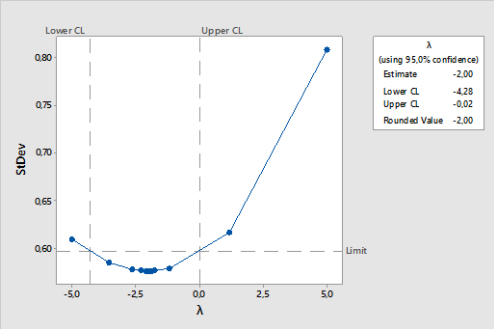

Rata-rata Bulanan Harga Tomat

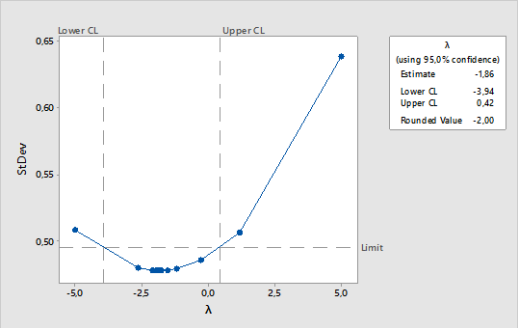

Rata-rata Bulanan Harga Wortel

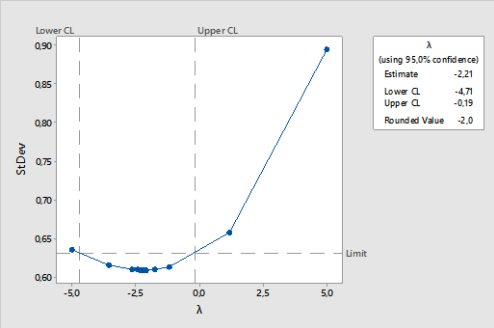

Rata-rata Bulanan Harga Buncis

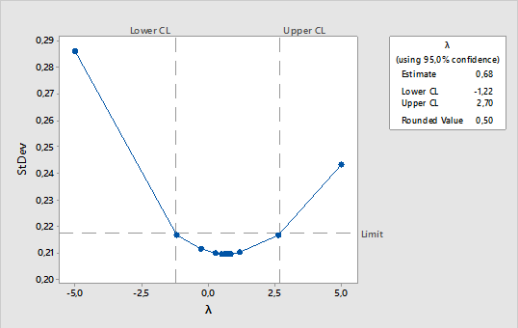

Rata-rata Bulanan Harga Ikan Bandeng

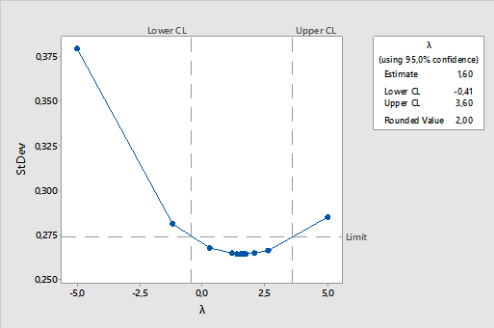

Rata-rata Bulanan Harga Ikan Tongkol

Lampiran 3 Plot *Box-Cox* Variabel Z_X^m yang Belum Stasioner dalam Varians (Lanjutan)

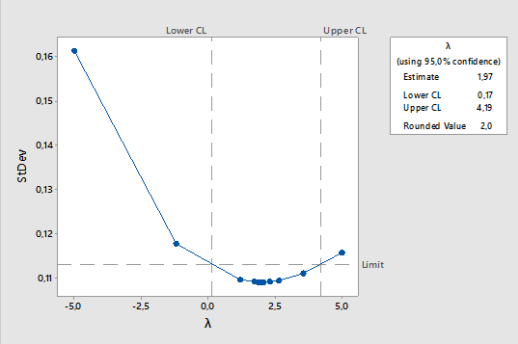

Rata-rata Bulanan Harga Gas Elpiji 3 Kg

Lampiran 4 Plot *Box-Cox* Variabel Z_X^m yang Sudah Stasioner dalam Varians

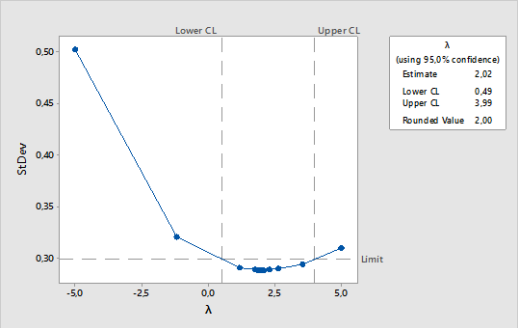

Rata-rata Bulanan Harga minyak dunia Brent (USD/Barel)

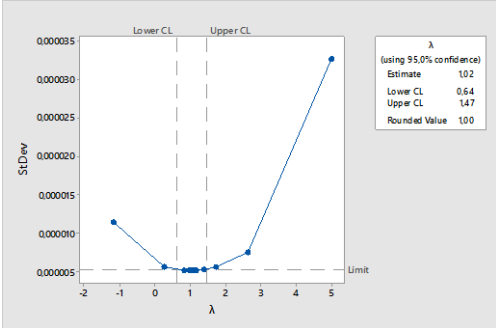

Rata-rata Bulanan JISDOR (USD/IDR)

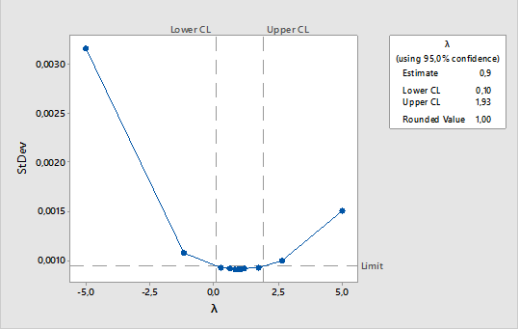

Rata-rata Bulanan Harga Beras IR 64

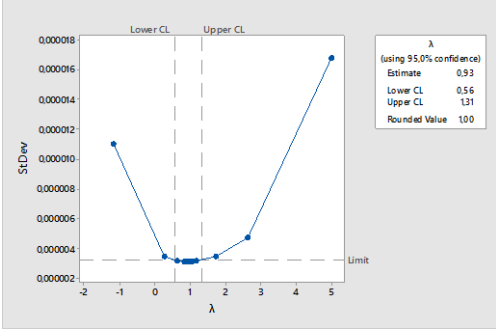

Rata-rata Bulanan Harga Gula Pasir Dalam Negeri

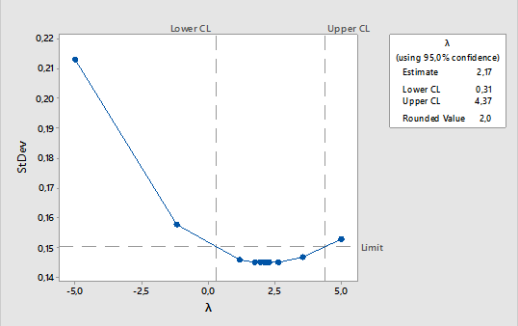

Rata-rata Bulanan Harga Minyak Goreng Bimoli Botol/Kemasan 2L

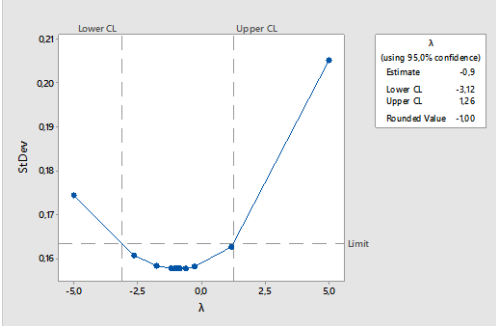

Rata-rata Bulanan Harga Minyak Goreng Curah

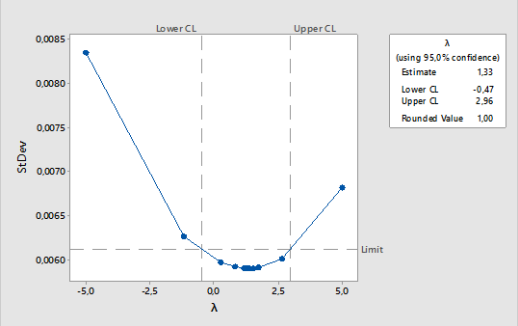

Rata-rata Bulanan Harga Daging Sapi Murni

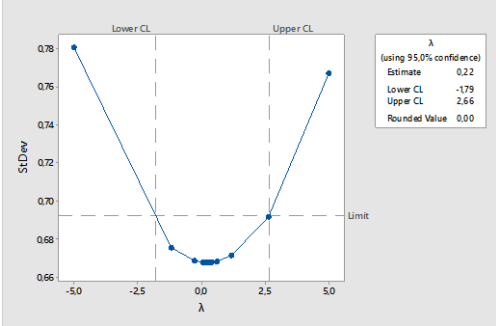

Rata-rata Bulanan Harga Daging Ayam Broiler

Lampiran 4 Plot *Box-Cox* Variabel Z_X^m yang Sudah Stasioner dalam Varians (Lanjutan)

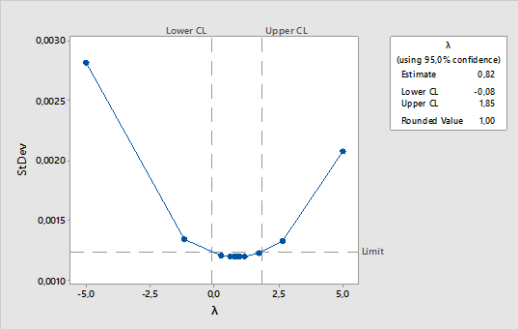

Rata-rata Bulanan Harga Daging Ayam Kampung

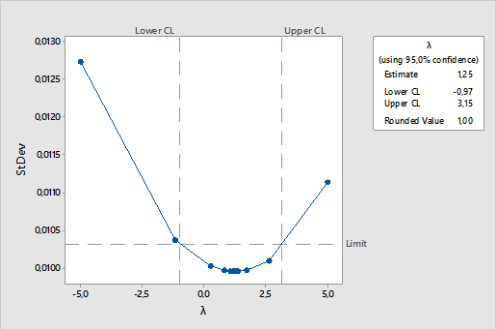

Rata-rata Bulanan Harga Telur Ayam Ras

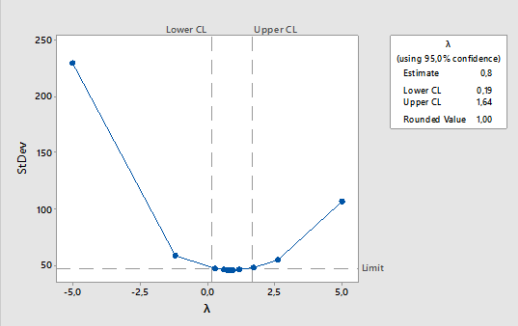

Rata-rata Bulanan Harga Susu Kental Manis Merk Bendera (397 gr/kl)

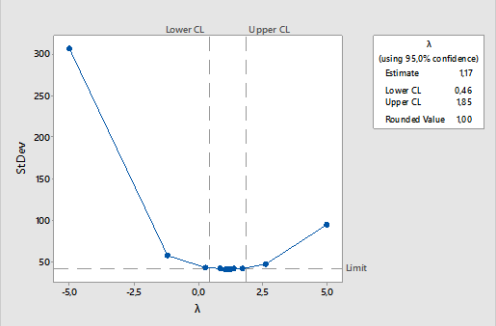

Rata-rata Bulanan Harga Susu Kental Manis Merk Indomilk (390 gr/kl)

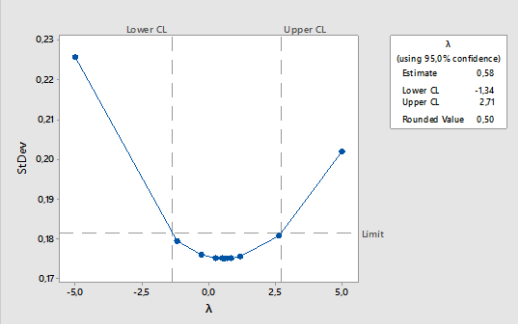

Rata-rata Bulanan Harga Jagung Pipilan Kering

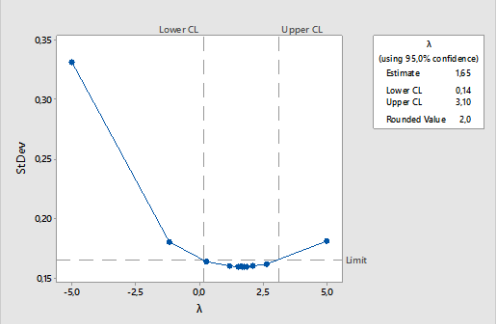

Rata-rata Bulanan Harga Garam Beryodiun Halus

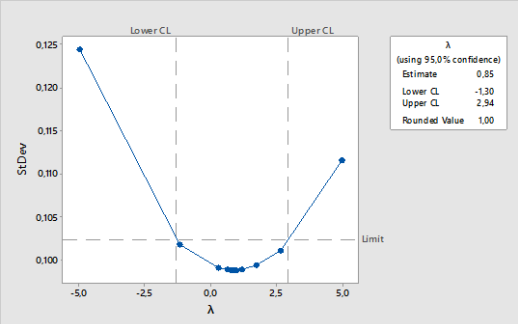

Rata-rata Bulanan Harga Tepung Terigu Segitiga Biru Kw Medium

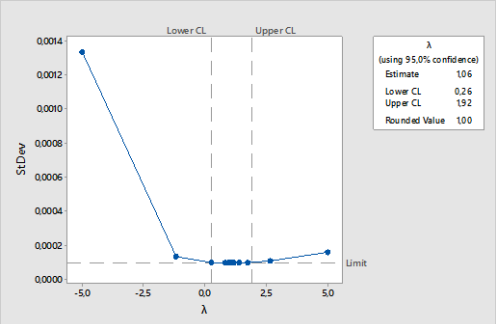

Rata-rata Bulanan Harga Kacang Kedelai Eks Impor

Lampiran 4 Plot *Box-Cox* Variabel Z_X^m yang Sudah Stasioner dalam Varians (Lanjutan)

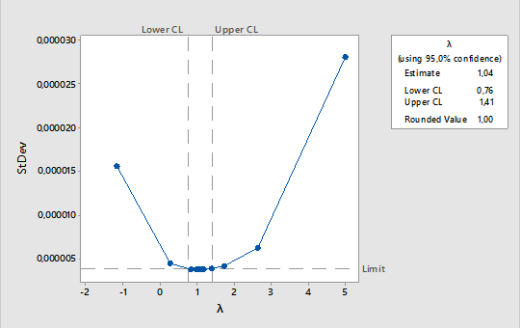

Rata-rata Bulanan Harga Indomie Rasa Kari Ayam

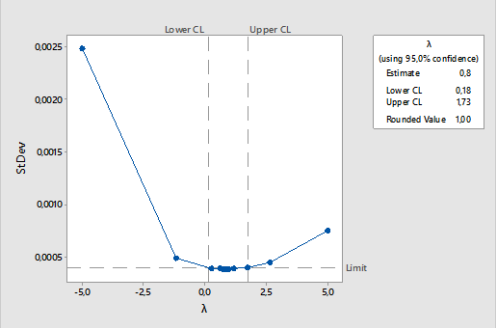

Rata-rata Bulanan Harga Cabai Biasa

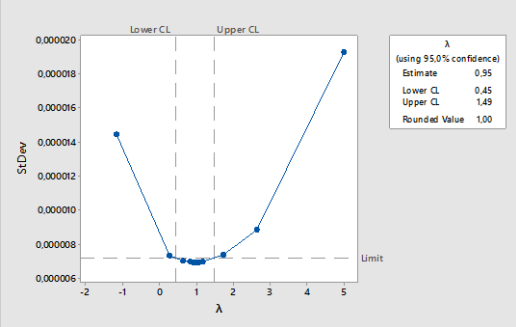

Rata-rata Bulanan Harga Cabai Rawit

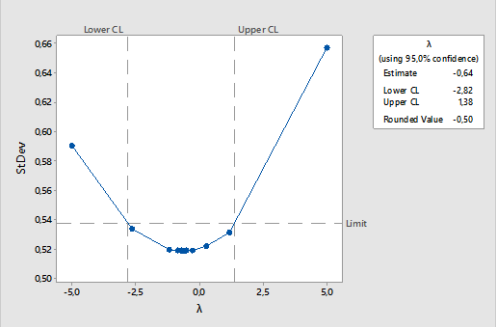

Rata-rata Bulanan Harga Bawang Merah

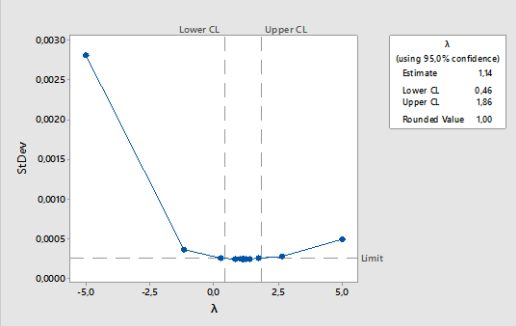

Rata-rata Bulanan Harga Bawang Putih

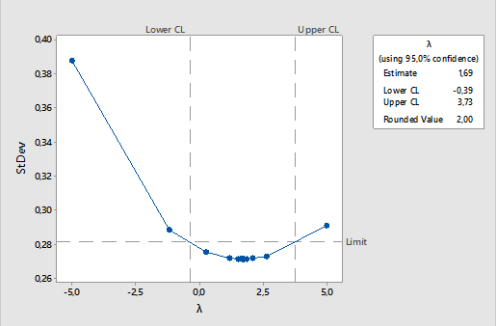

Rata-rata Bulanan Harga Ikan Asin Teri

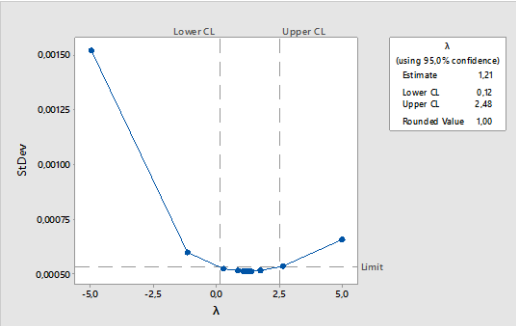

Rata-rata Bulanan Harga Kacang Hijau

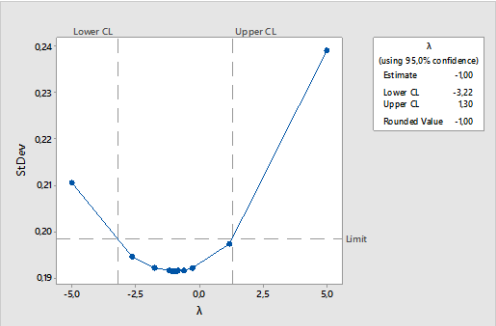

Rata-rata Bulanan Harga Kacang Tanah

Lampiran 4 Plot *Box-Cox* Variabel Z_X^m yang Sudah Stasioner dalam Varians (Lanjutan)

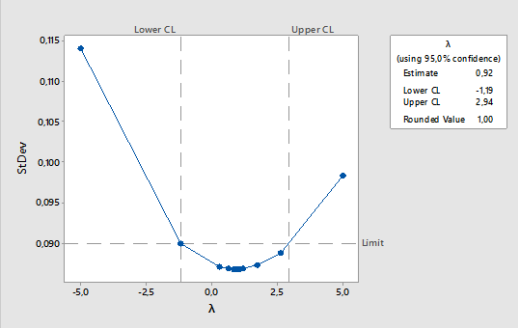

Rata-rata Bulanan Harga Ketela Pohon

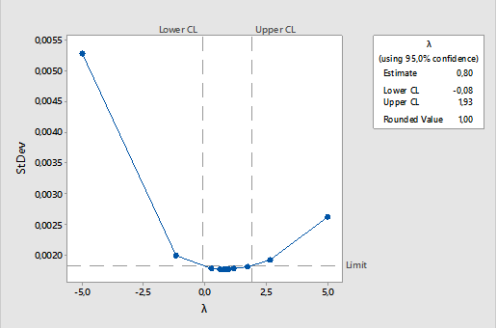

Rata-rata Bulanan Harga Kol/ Kubis

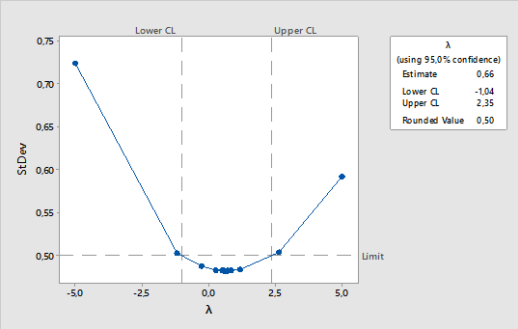

Rata-rata Bulanan Harga Kentang

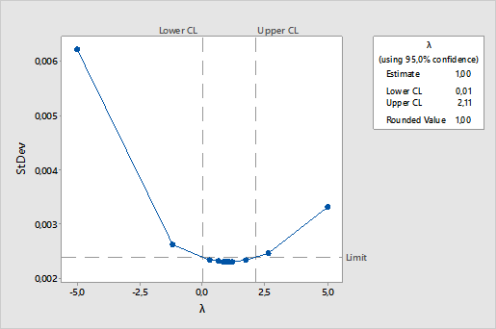

Rata-rata Bulanan Harga Tomat

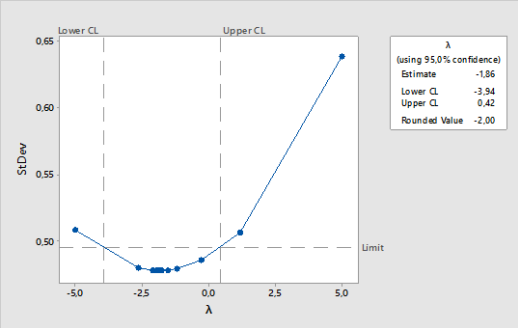

Rata-rata Bulanan Harga Wortel

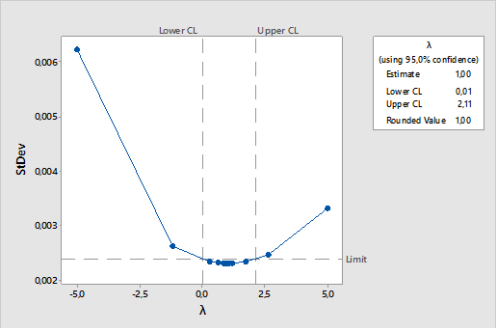

Rata-rata Bulanan Harga Buncis

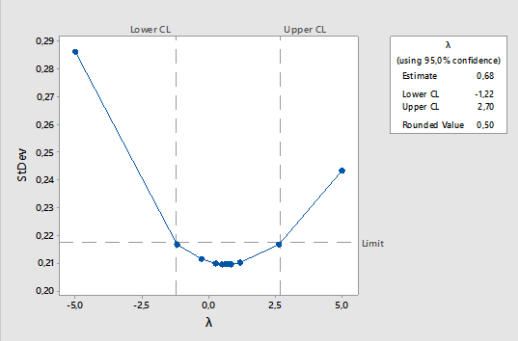

Rata-rata Bulanan Harga Ikan Bandeng

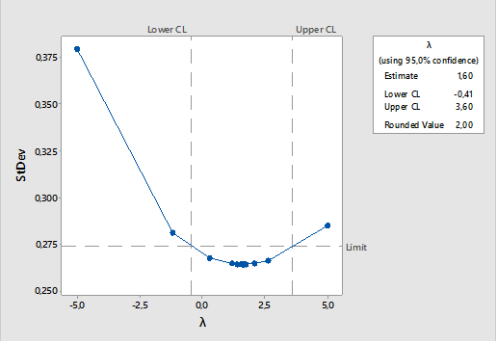

Rata-rata Bulanan Harga Ikan Tongkol

Lampiran 4 Plot *Box-Cox* Variabel Z_X^m yang Sudah Stasioner dalam Varians (Lanjutan)

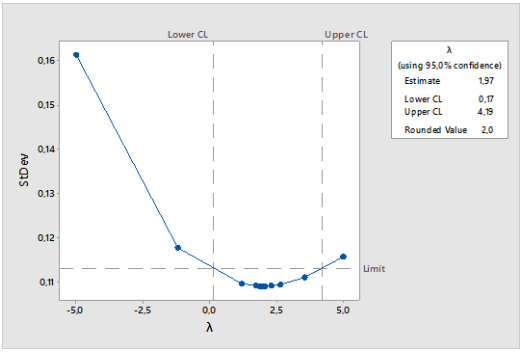

Rata-rata Bulanan Harga Gas Elpiji 3 Kg

Lampiran 5 Plot ACF Data Z_X^m Sebelum *Differencing*

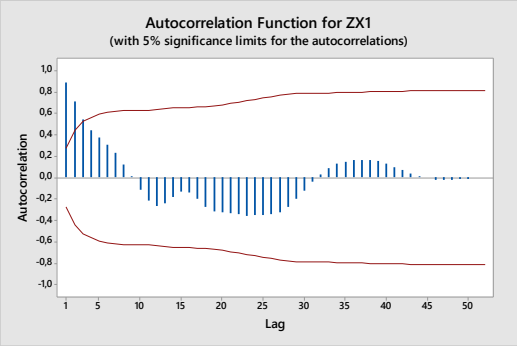

Rata-rata Bulanan Harga minyak dunia Brent (USD/Barel)

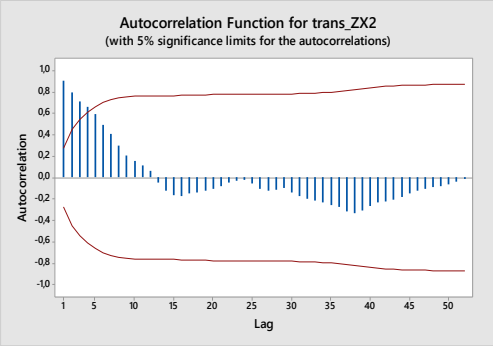

Rata-rata Bulanan JISDOR (USD/IDR)

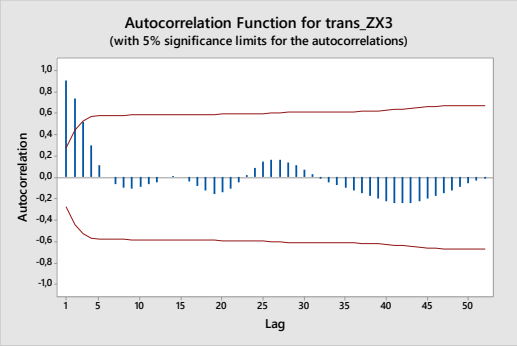

Rata-rata Bulanan Harga Beras IR 64

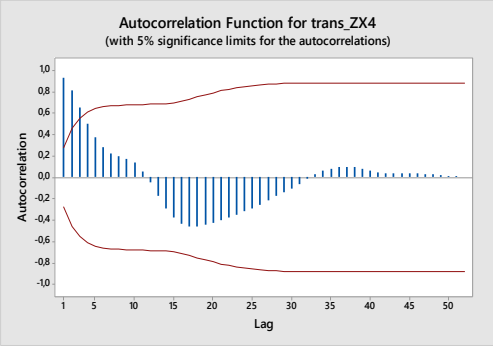

Rata-rata Bulanan Harga Gula Pasir Dalam Negeri

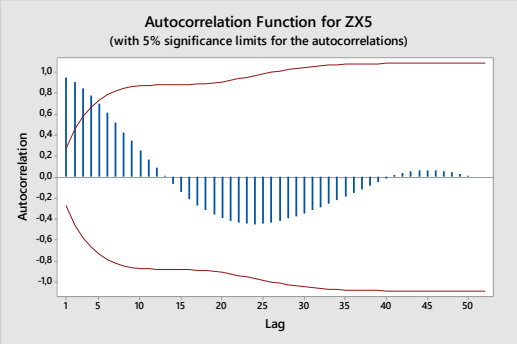

Rata-rata Bulanan Harga Minyak Goreng Bimoli Botol/Kemasan 2L

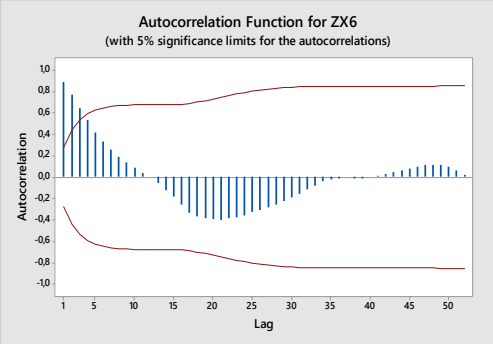

Rata-rata Bulanan Harga Minyak Goreng Curah

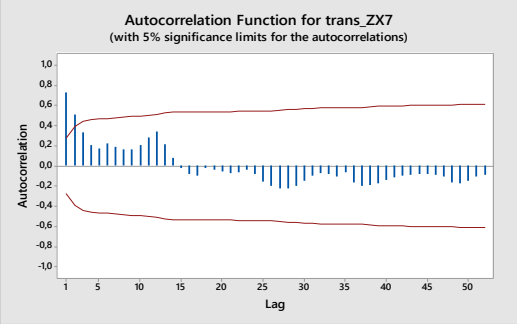

Rata-rata Bulanan Harga Daging Sapi Murni

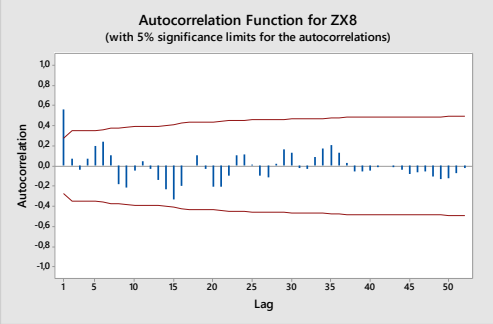

Rata-rata Bulanan Harga Daging Ayam Broiler

Lampiran 5 Plot ACF Data Z_X^m Sebelum *Differencing* (Lanjutan)

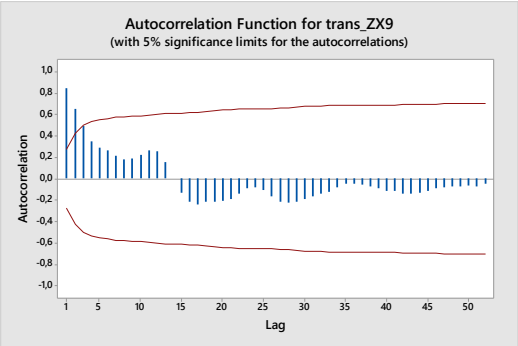

Rata-rata Bulanan Harga Daging Ayam Kampung

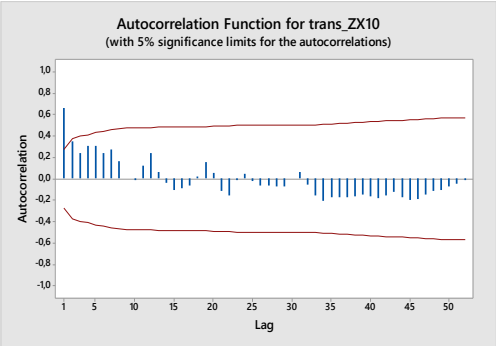

Rata-rata Bulanan Harga Telur Ayam Ras

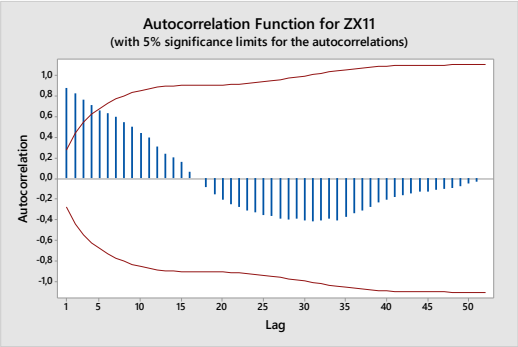

Rata-rata Bulanan Harga Susu Kental Manis Merk Bendera (397 gr/kl)

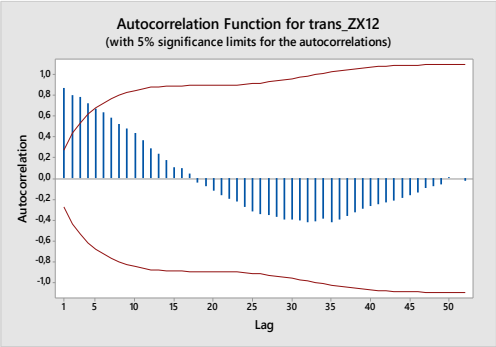

Rata-rata Bulanan Harga Susu Kental Manis Merk Indomilk (390 gr/kl)

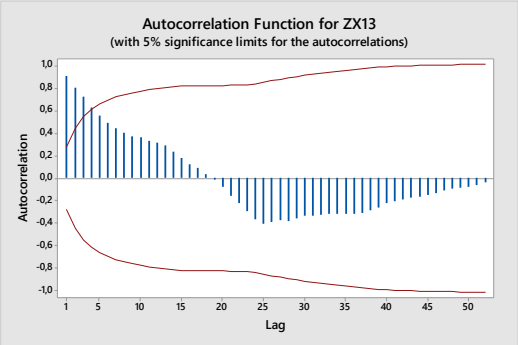

Rata-rata Bulanan Harga Jagung Pipilan Kering

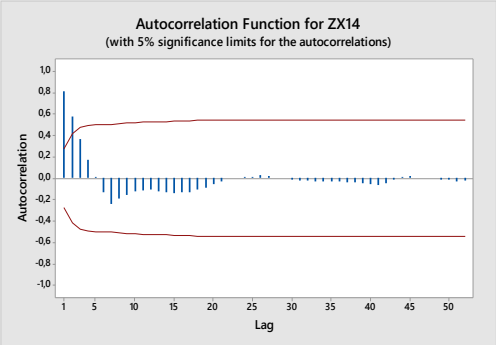

Rata-rata Bulanan Harga Garam Beryodiun Halus

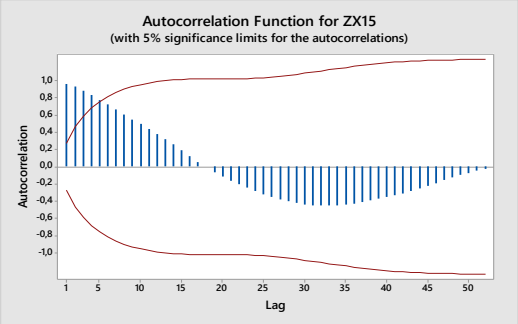

Rata-rata Bulanan Harga Tepung Terigu Segitiga Biru Kw Medium

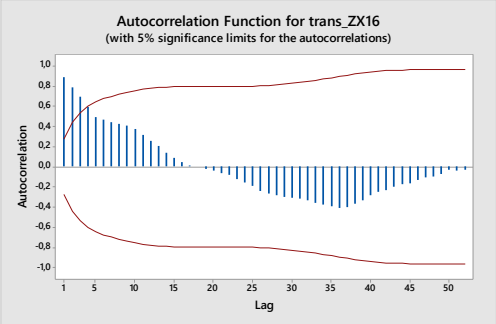

Rata-rata Bulanan Harga Kacang Kedelai Eks Impor

Lampiran 5 Plot ACF Data Z_X^m Sebelum *Differencing* (Lanjutan)

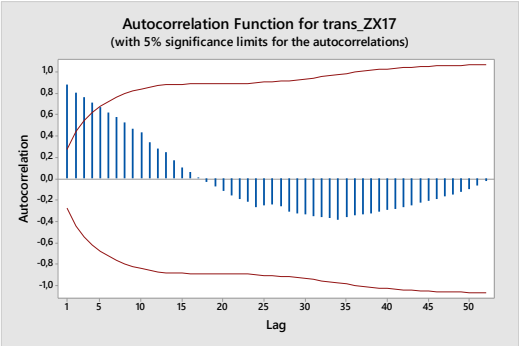

Rata-rata Bulanan Harga Indomie Rasa Kari Ayam

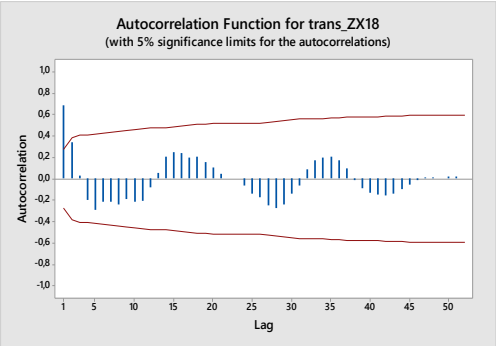

Rata-rata Bulanan Harga Cabai Biasa

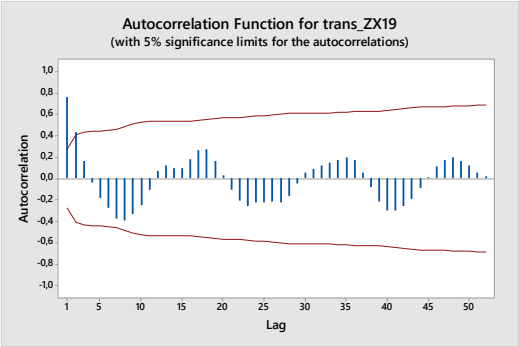

Rata-rata Bulanan Harga Cabai Rawit

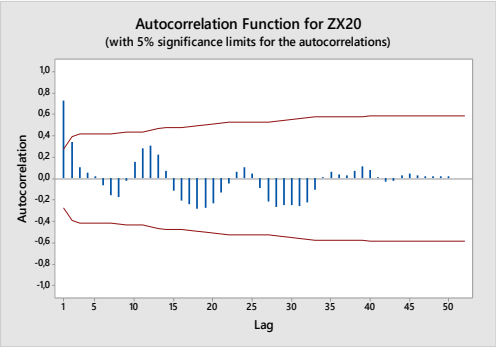

Rata-rata Bulanan Harga Bawang Merah

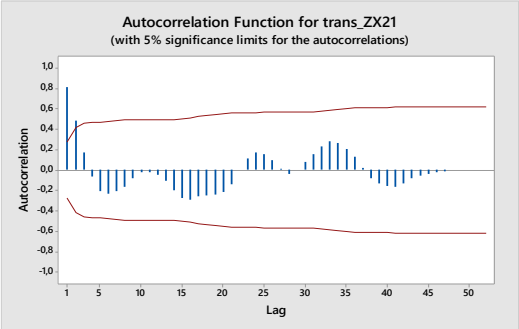

Rata-rata Bulanan Harga Bawang Putih

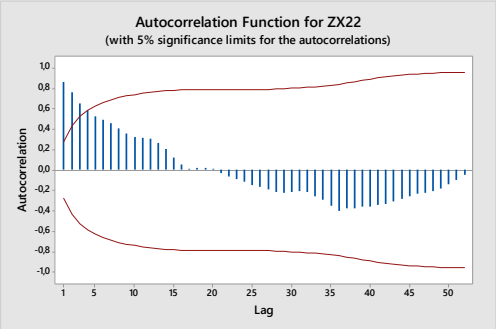

Rata-rata Bulanan Harga Ikan Asin Teri

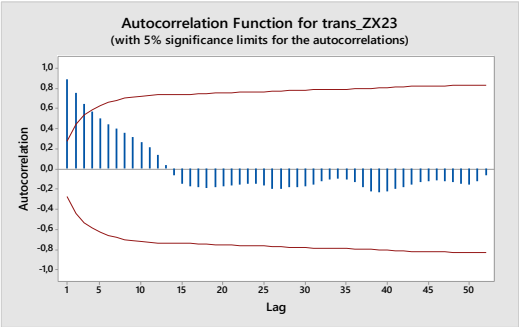

Rata-rata Bulanan Harga Kacang Hijau

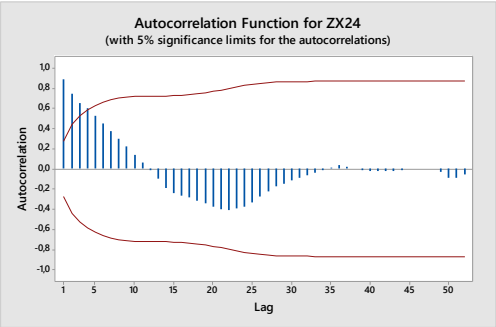

Rata-rata Bulanan Harga Kacang Tanah

Lampiran 5 Plot ACF Data Z_X^m Sebelum *Differencing* (Lanjutan)

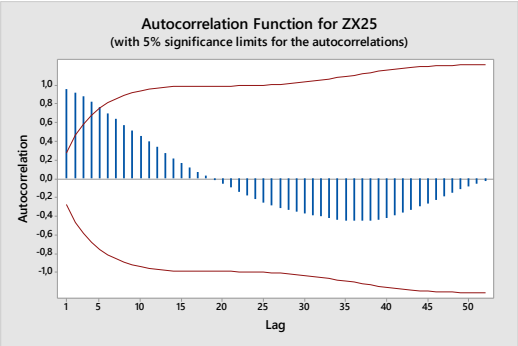

Rata-rata Bulanan Harga Ketela Pohon

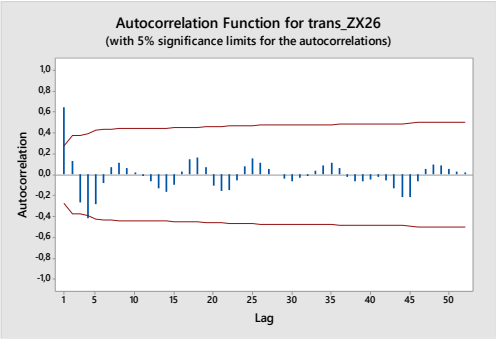

Rata-rata Bulanan Harga Kol/ Kubis

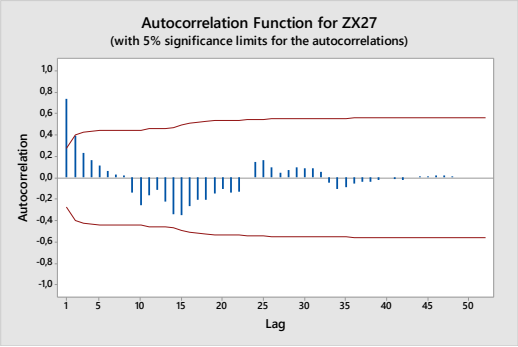

Rata-rata Bulanan Harga Kentang

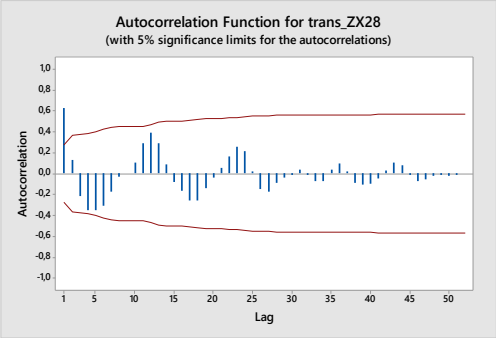

Rata-rata Bulanan Harga Tomat

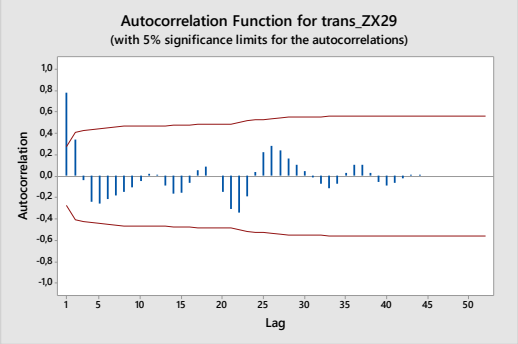

Rata-rata Bulanan Harga Wortel

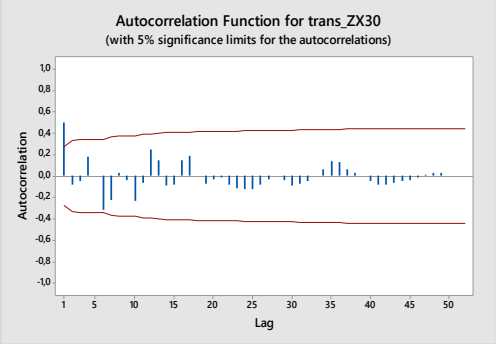

Rata-rata Bulanan Harga Buncis

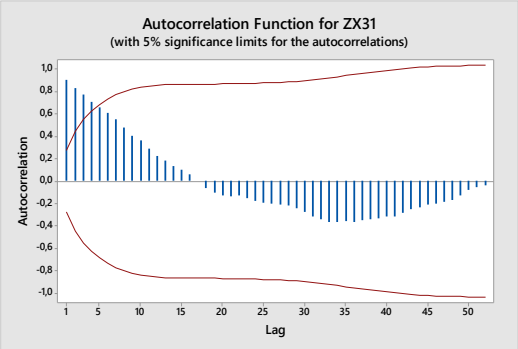

Rata-rata Bulanan Harga Ikan Bandeng

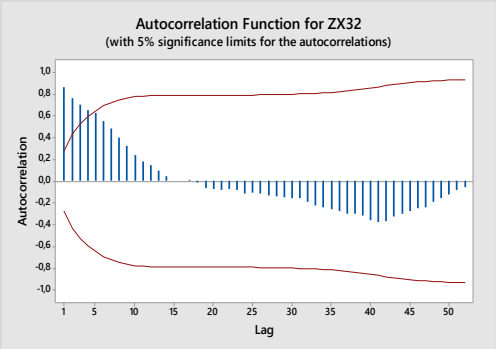

Rata-rata Bulanan Harga Ikan Tongkol

Lampiran 5 Plot ACF Data Z_X^m Sebelum *Differencing* (Lanjutan)

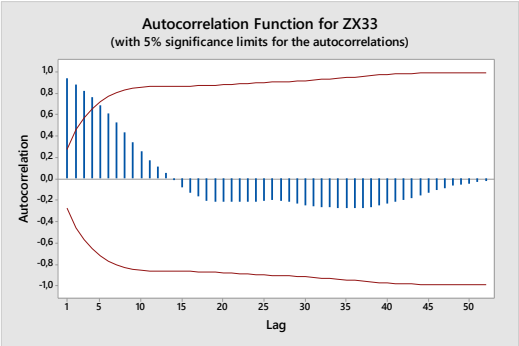

Rata-rata Bulanan Harga Gas Elpiji 3 Kg

Lampiran 6 Plot *Box-Cox* Variabel Z_X^d yang Belum Stasioner dalam Varians

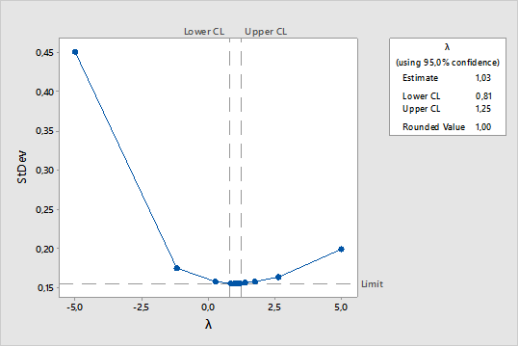

Harga minyak dunia Brent (USD/Barel)

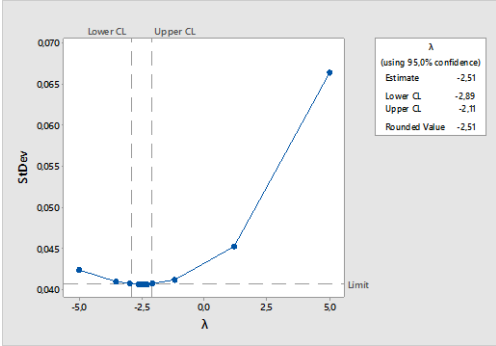

JISDOR (USD/IDR)

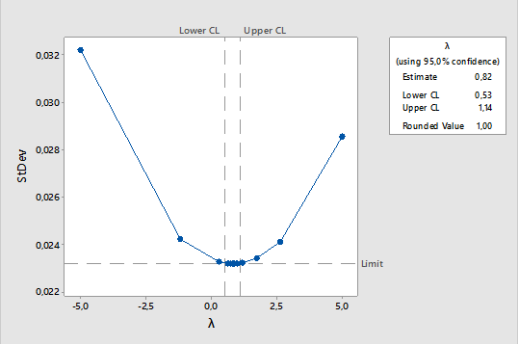

Harga Beras IR 64

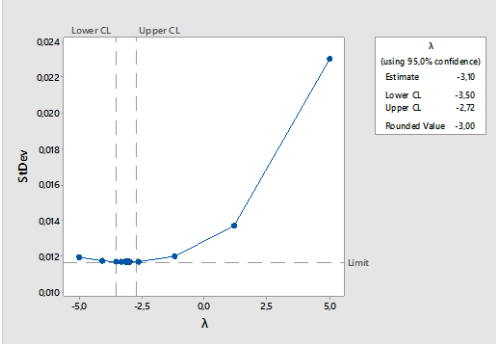

Harga Gula Pasir Dalam Negeri

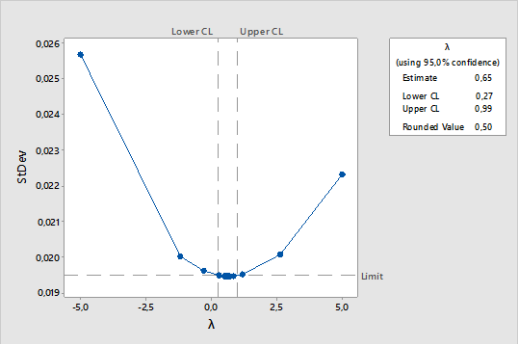

Harga Minyak Goreng Bimoli Botol/Kemasan 2L

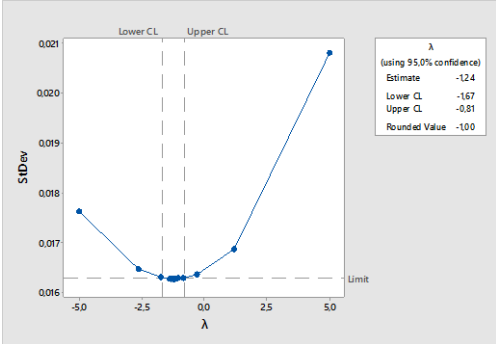

Harga Minyak Goreng Curah

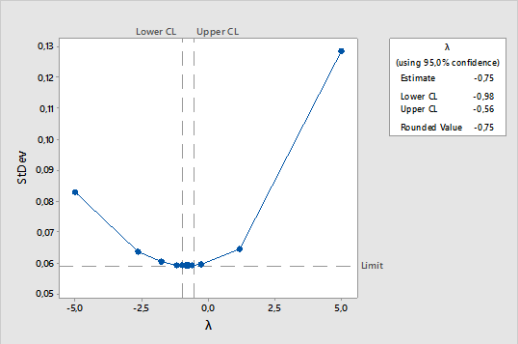

Harga Daging Sapi Murni

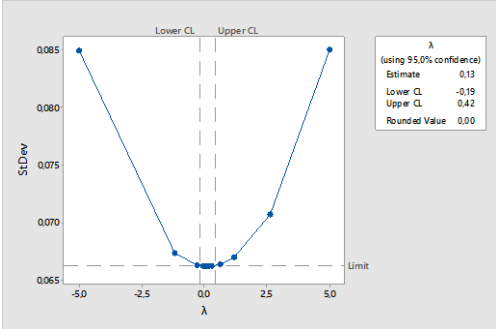

Harga Daging Ayam Broiler

Lampiran 6 Plot *Box-Cox* Variabel Z_X^d yang Belum Stasioner dalam Varians (Lanjutan)

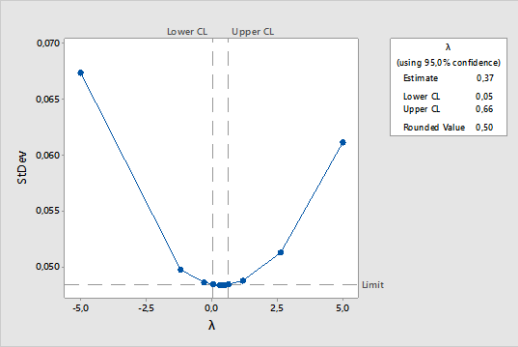

Harga Daging Ayam Kampung

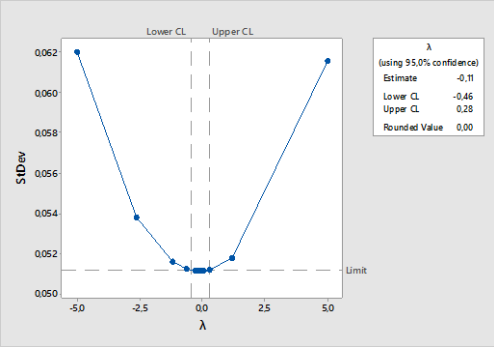

Harga Telur Ayam Ras

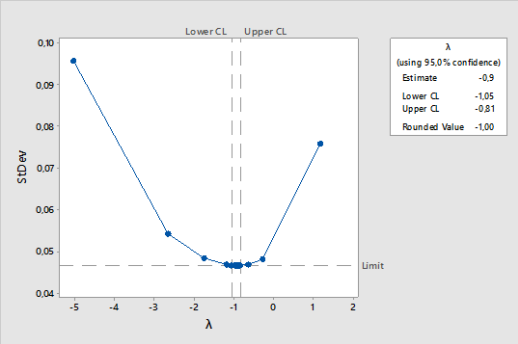

Harga Susu Kental Manis Merk Bendera (397 gr/kl)

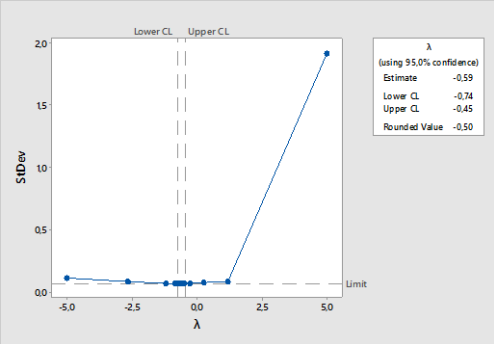

Harga Susu Kental Manis Merk Indomilk (390 gr/kl)

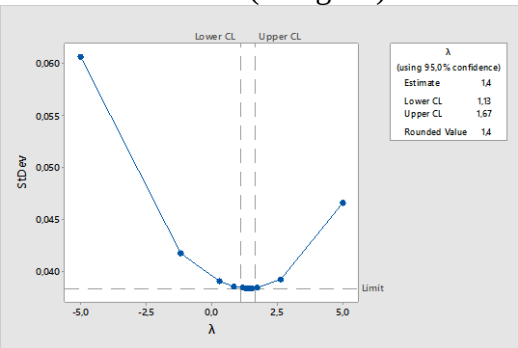

Harga Jagung Pipilan Kering

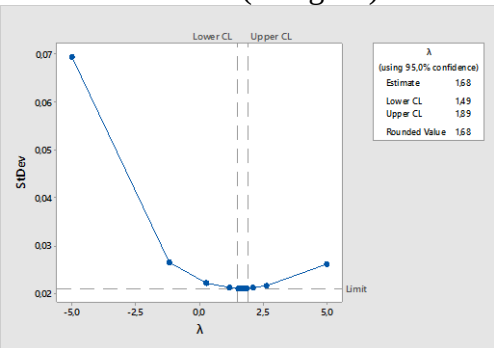

Harga Garam Beryodiun Halus

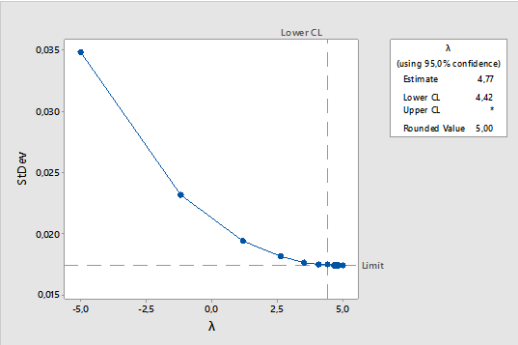

Harga Tepung Terigu Segitiga Biru Kw Medium

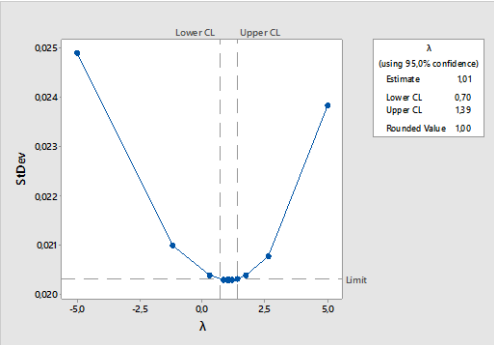

Harga Kacang Kedelai Eks Impor

Lampiran 6 Plot *Box-Cox* Variabel Z_X^d yang Belum Stasioner dalam Varians (Lanjutan)

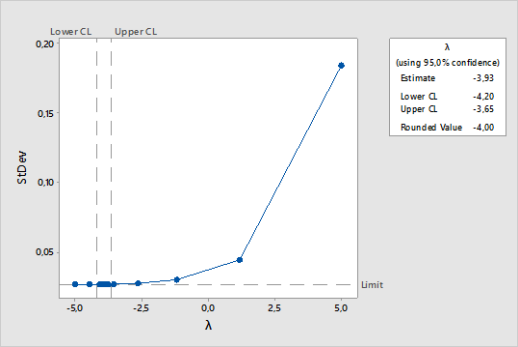

Harga Indomie Rasa Kari Ayam

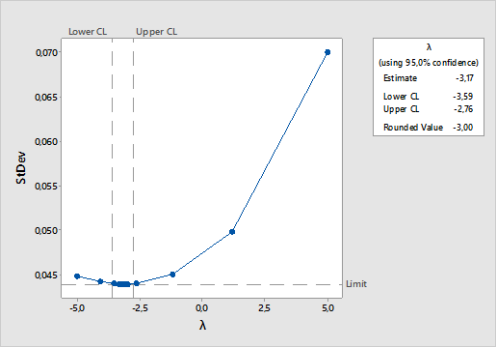

Harga Cabai Biasa

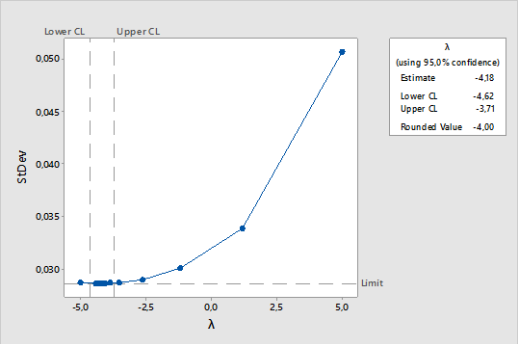

Harga Cabai Rawit

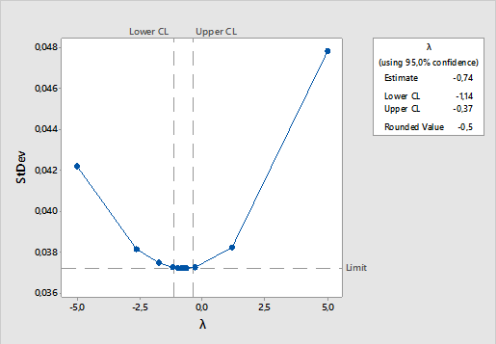

Harga Bawang Merah

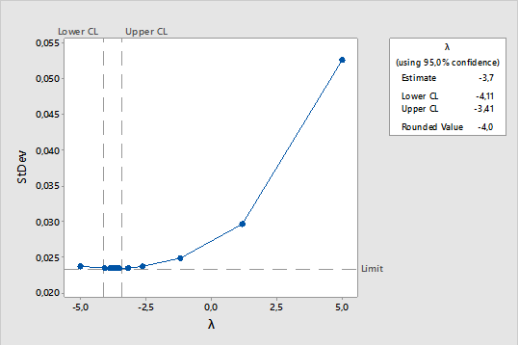

Harga Bawang Putih

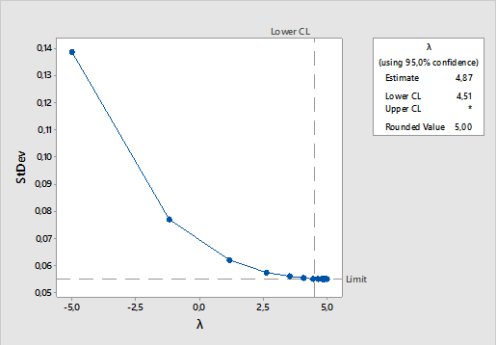

Harga Ikan Asin Teri

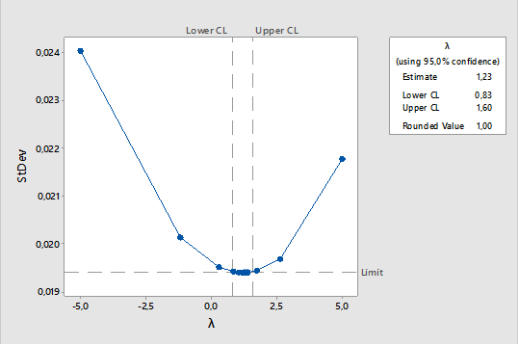

Harga Kacang Hijau

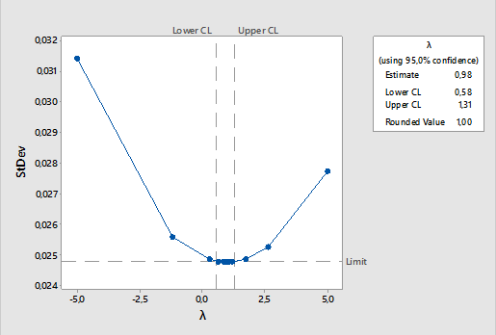

Harga Kacang Tanah

Lampiran 6 Plot *Box-Cox* Variabel Z_X^d yang Belum Stasioner dalam Varians (Lanjutan)

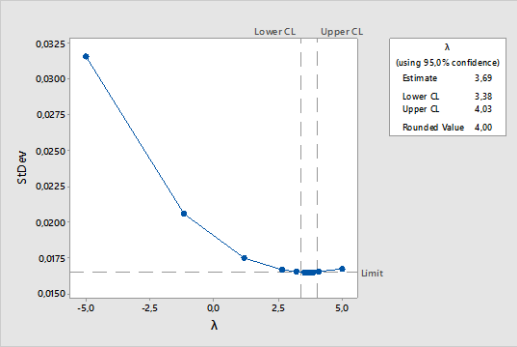

Harga Ketela Pohon

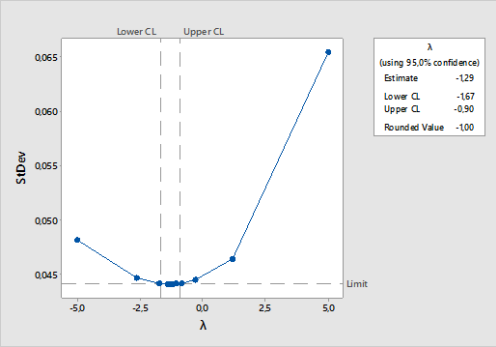

Harga Kol/ Kubis

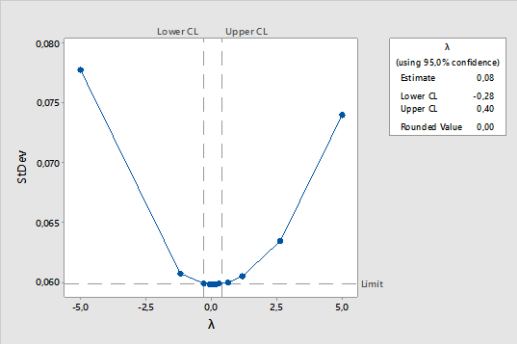

Harga Kentang

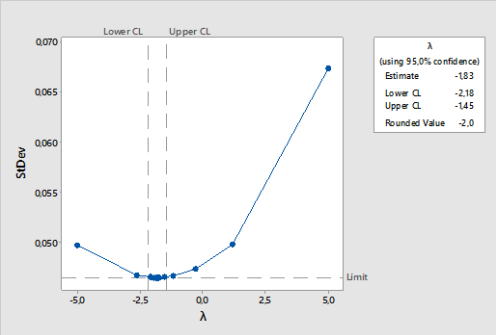

Harga Tomat

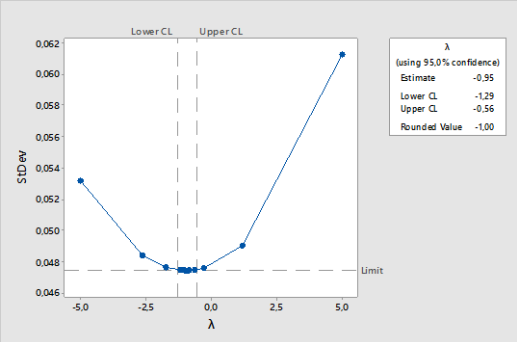

Harga Wortel

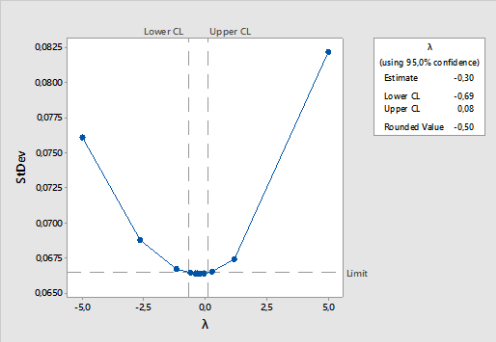

Harga Buncis

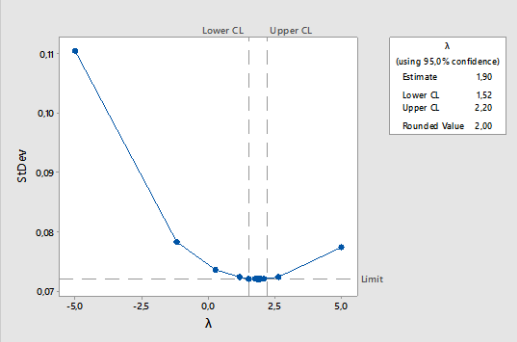

Harga Ikan Bandeng

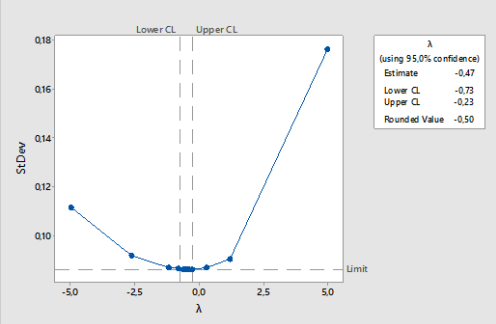

Harga Ikan Tongkol

Lampiran 6 Plot *Box-Cox* Variabel Z_X^d yang Belum Stasioner dalam Varians (Lanjutan)

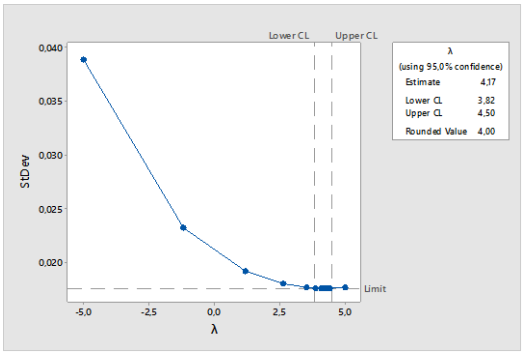

Harga Gas Elpiji 3 Kg

Lampiran 7 Plot *Box-Cox* Variabel Z_X^d yang Sudah Stasioner dalam Varians

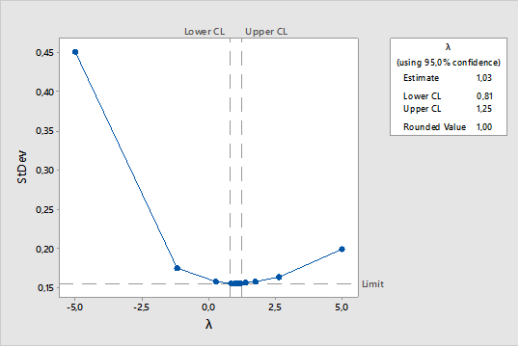

Harga minyak dunia Brent (USD/Barel)

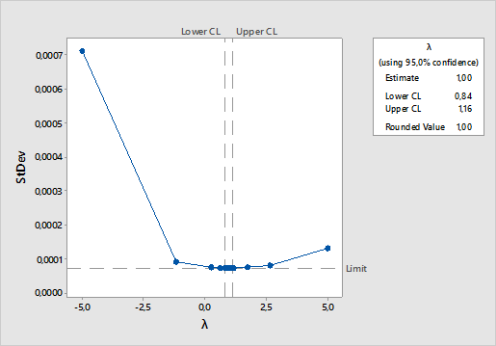

JISDOR (USD/IDR)

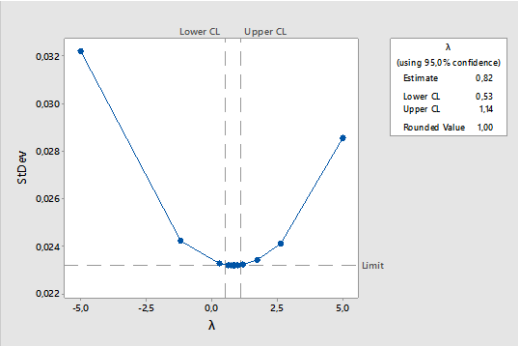

Harga Beras IR 64

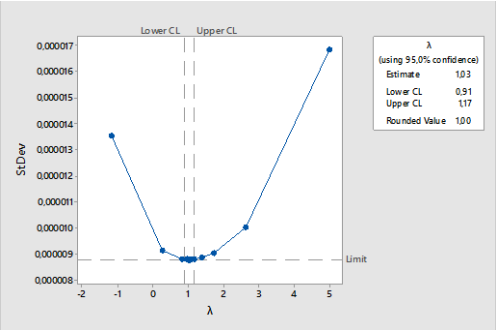

Harga Gula Pasir Dalam Negeri

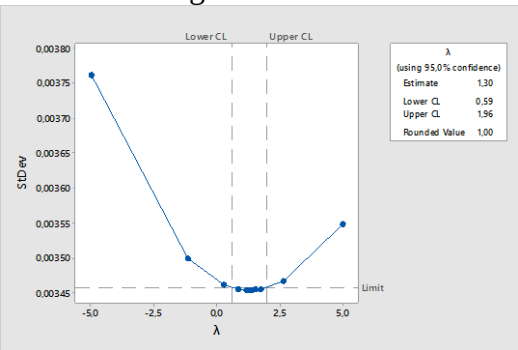

Harga Minyak Goreng Bimoli Botol/Kemasan 2L

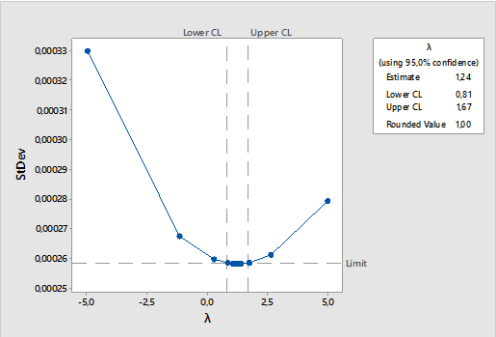

Harga Minyak Goreng Curah

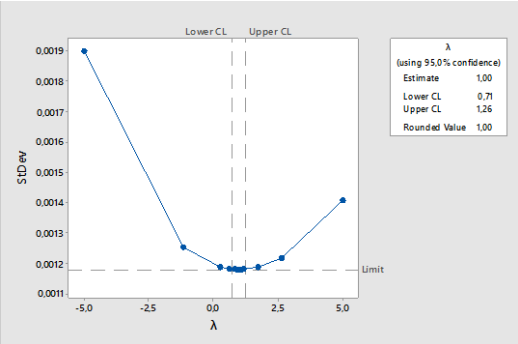

Harga Daging Sapi Murni

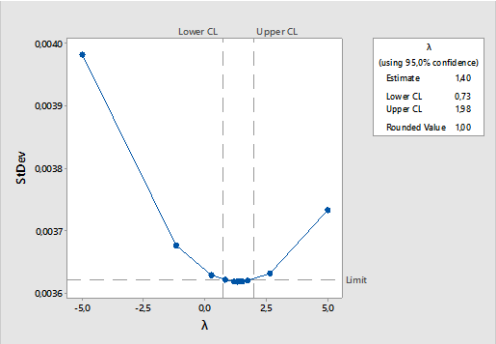

Harga Daging Ayam Broiler

Lampiran 7 Plot *Box-Cox* Variabel Z_X^d yang Sudah Stasioner dalam Varians (Lanjutan)

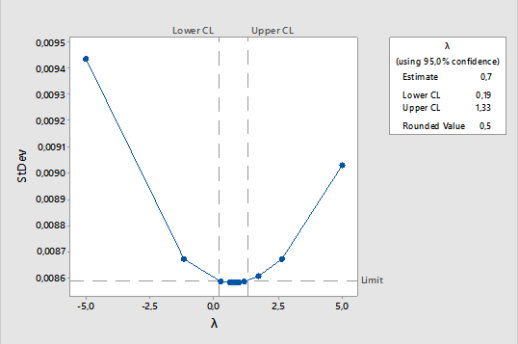

Harga Daging Ayam Kampung

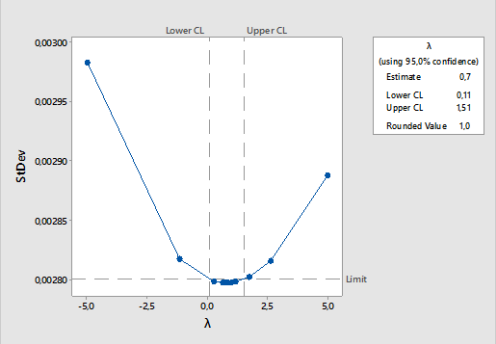

Harga Telur Ayam Ras

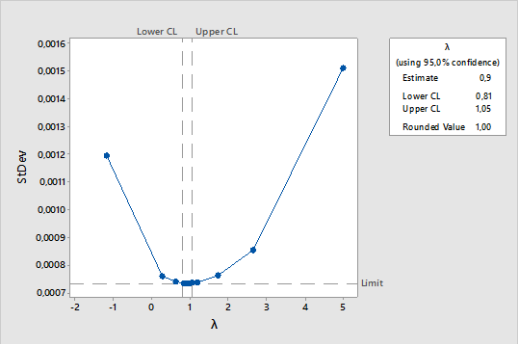

Harga Susu Kental Manis Merk Bendera (397 gr/kl)

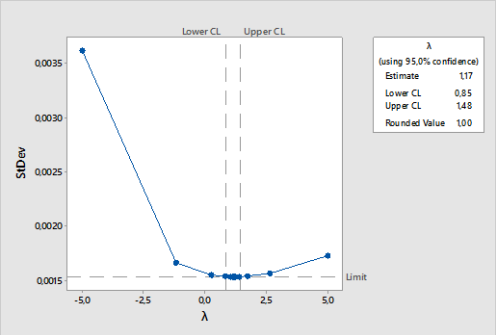

Harga Susu Kental Manis Merk Indomilk (390 gr/kl)

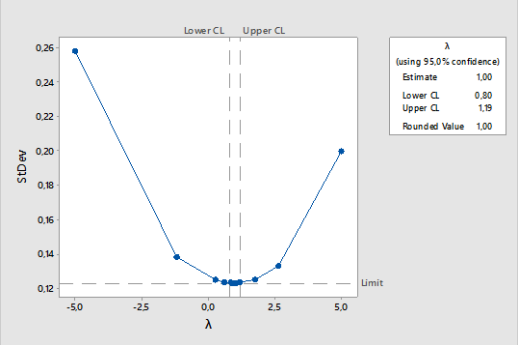

Harga Jagung Pipilan Kering

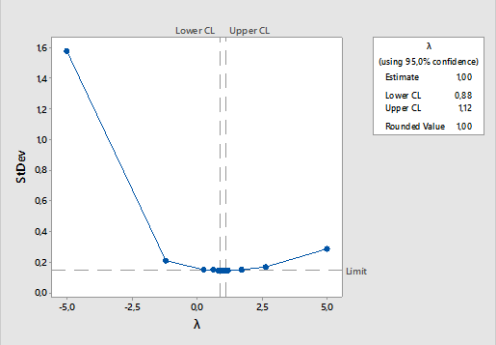

Harga Garam Beryodiun Halus

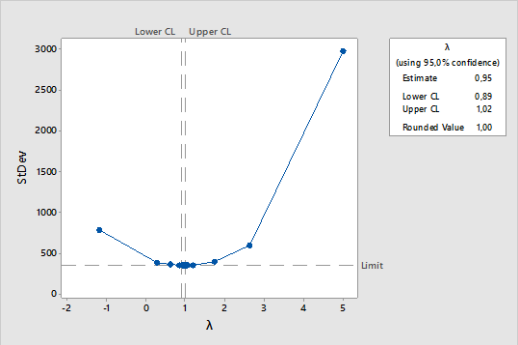

Harga Tepung Terigu Segitiga Biru Kw Medium

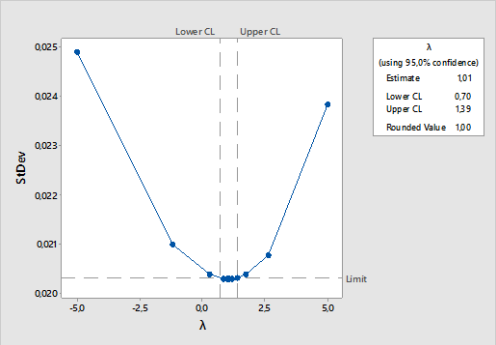

Harga Kacang Kedelai Eks Impor

Lampiran 7 Plot *Box-Cox* Variabel Z_X^d yang Sudah Stasioner dalam Varians (Lanjutan)

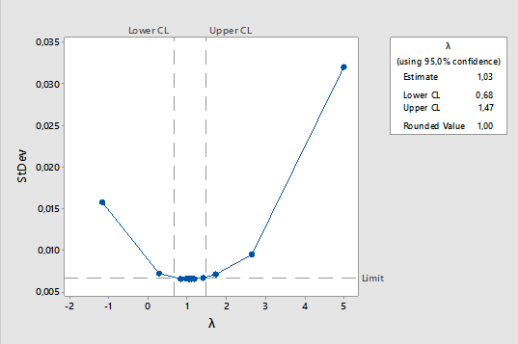

Harga Indomie Rasa Kari Ayam

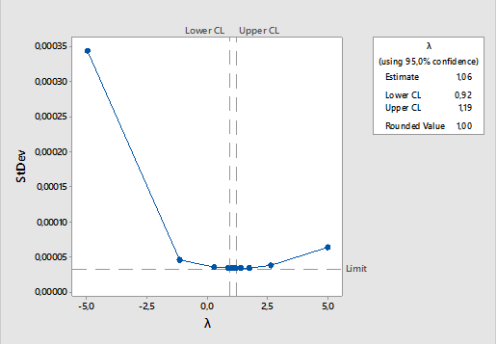

Harga Cabai Biasa

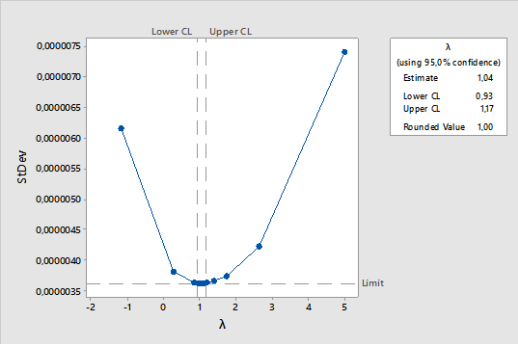

Harga Cabai Rawit

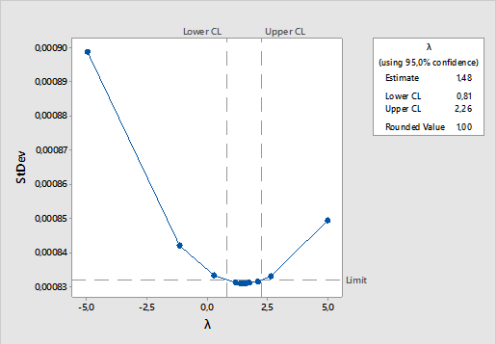

Harga Bawang Merah

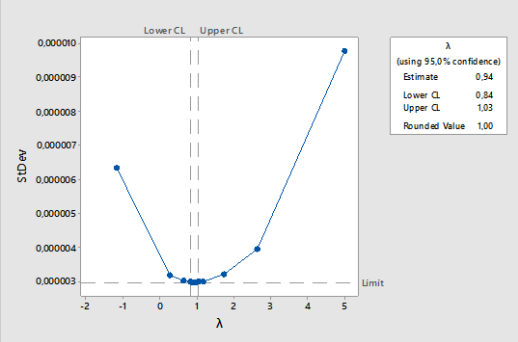

Harga Bawang Putih

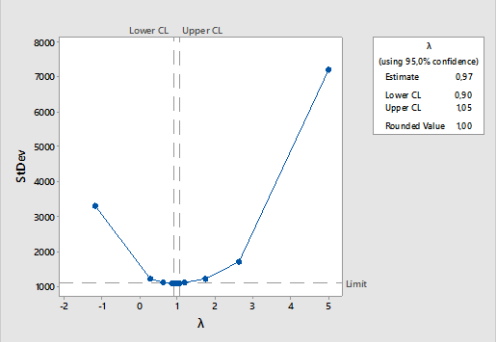

Harga Ikan Asin Teri

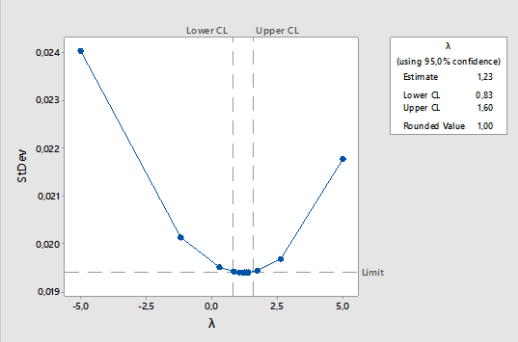

Harga Kacang Hijau

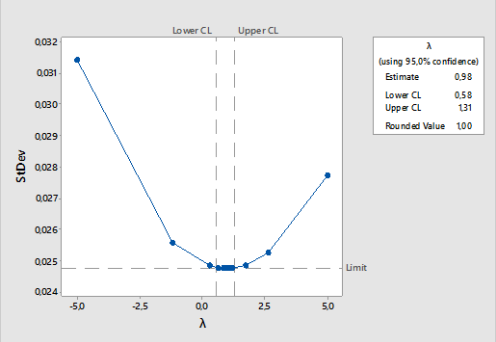

Harga Kacang Tanah

Lampiran 7 Plot *Box-Cox* Variabel Z_X^d yang Sudah Stasioner dalam Varians (Lanjutan)

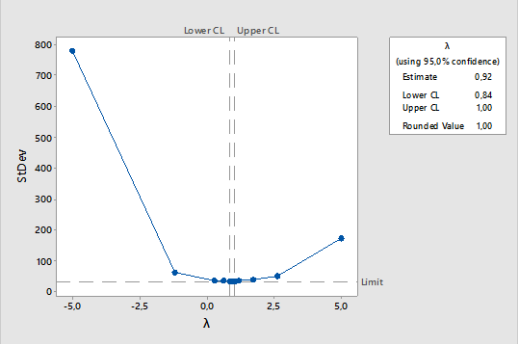

Harga Ketela Pohon

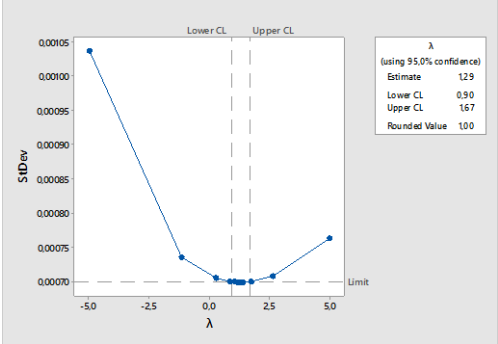

Harga Kol/ Kubis

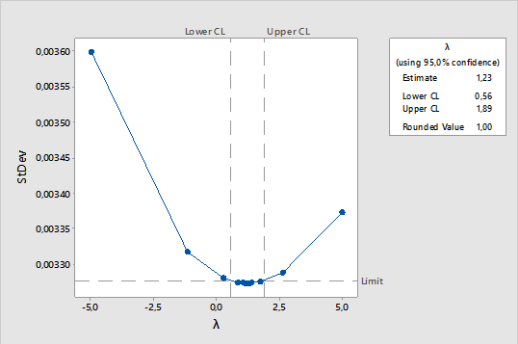

Harga Kentang

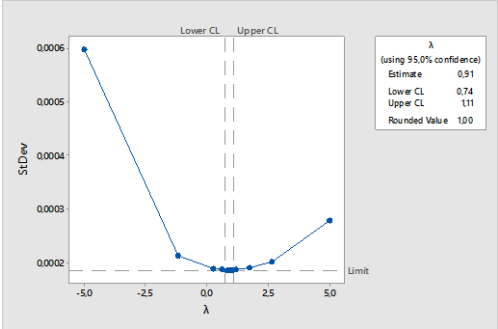

Harga Tomat

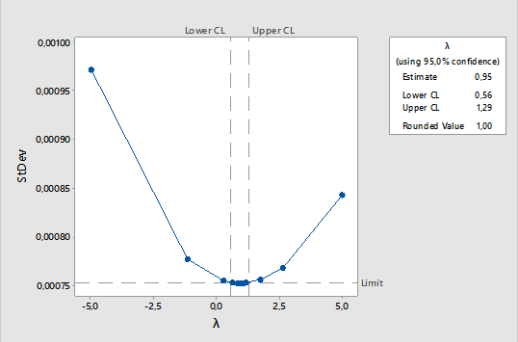

Harga Wortel

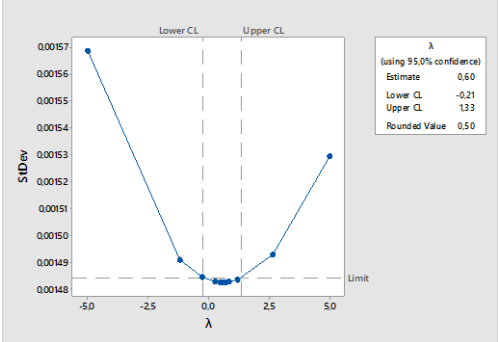

Harga Buncis

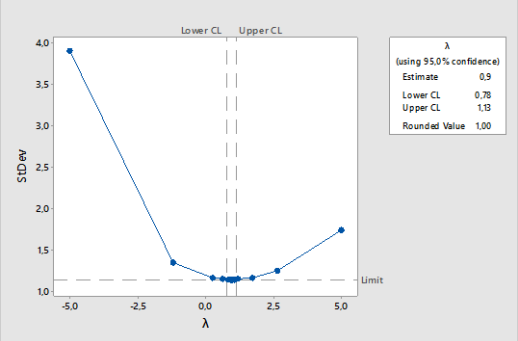

Harga Ikan Bandeng

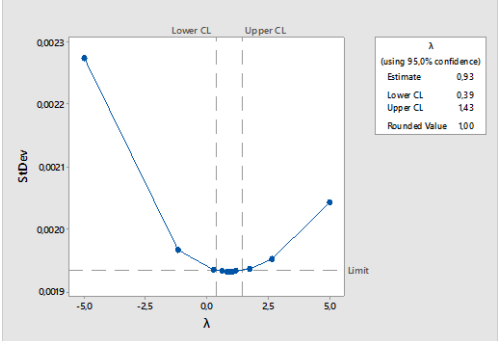

Harga Ikan Tongkol

Lampiran 7 Plot *Box-Cox* Variabel Z_X^d yang Sudah Stasioner dalam Varians (Lanjutan)

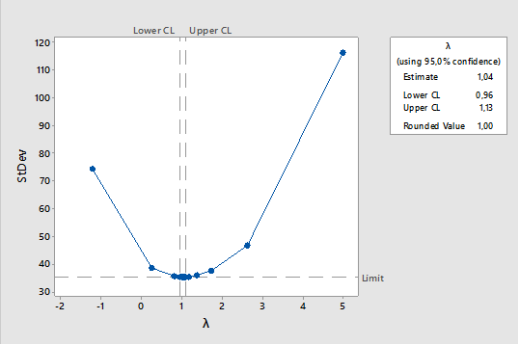

Harga Gas Elpiji 3 Kg

Lampiran 8 Plot ACF Data Z_X^d Sebelum *Differencing*

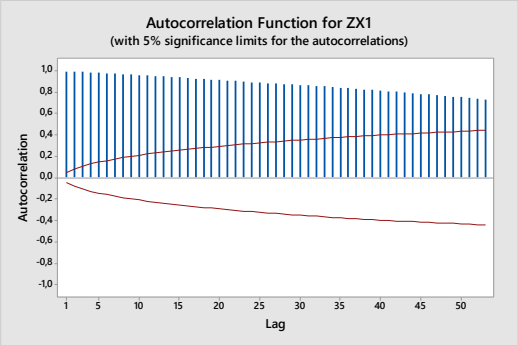

Harga minyak dunia Brent (USD/Barel)

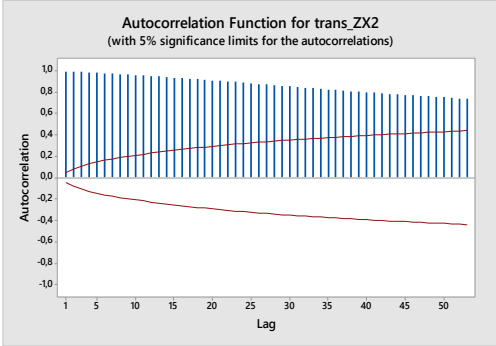

JISDOR (USD/IDR)

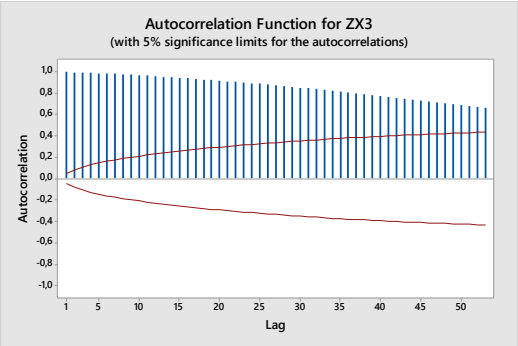

Harga Beras IR 64

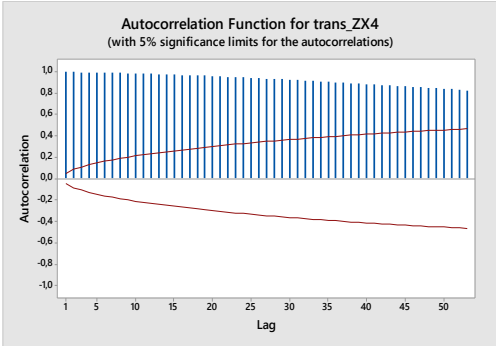

Harga Gula Pasir Dalam Negeri

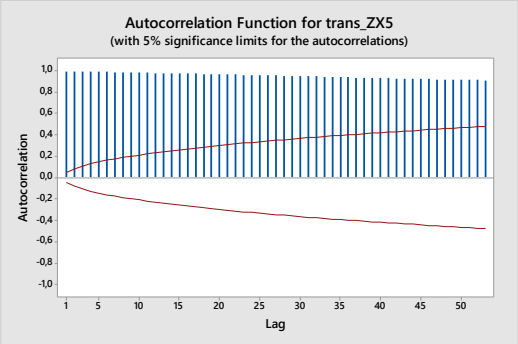

Harga Minyak Goreng Bimoli Botol/Kemasan 2L

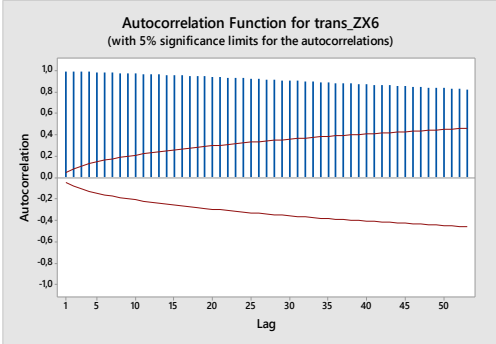

Harga Minyak Goreng Curah

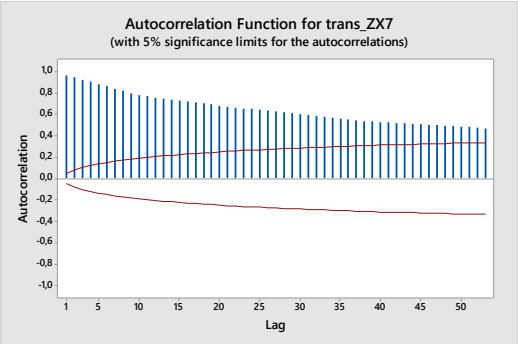

Harga Daging Sapi Murni

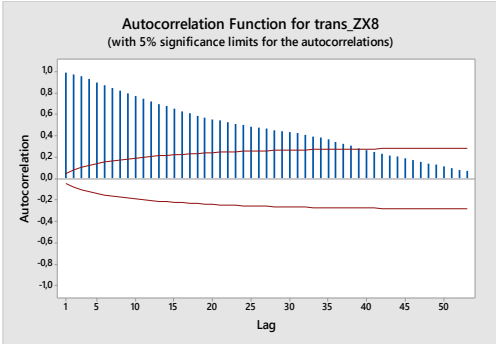

Harga Daging Ayam Broiler

Lampiran 8 Plot ACF Data Z_X^d Sebelum *Differencing* (Lanjutan)

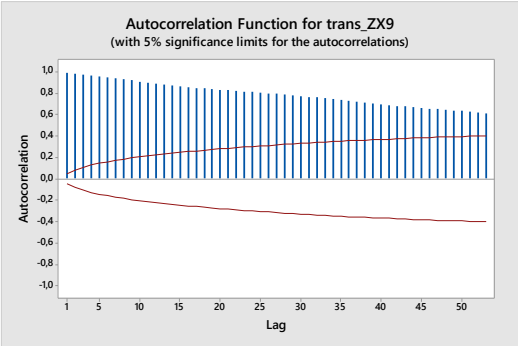

Harga Daging Ayam Kampung

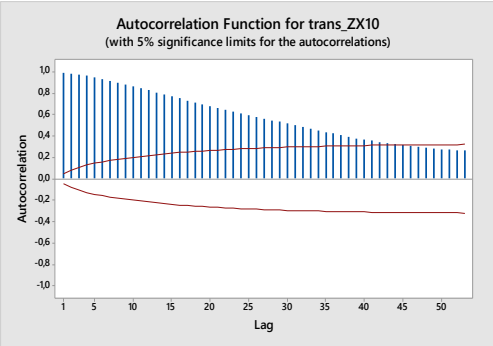

Harga Telur Ayam Ras

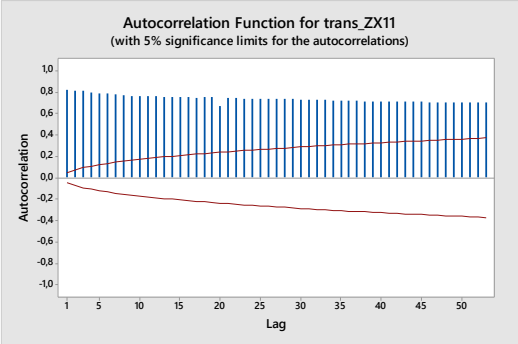

Harga Susu Kental Manis Merk Bendera (397 gr/kl)

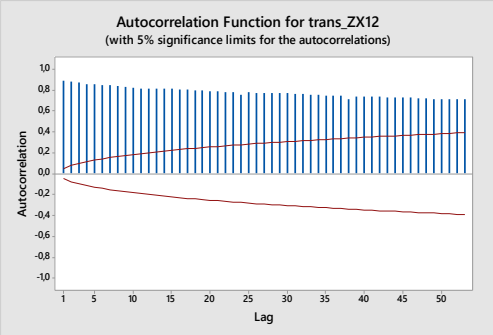

Harga Susu Kental Manis Merk Indomilk (390 gr/kl)

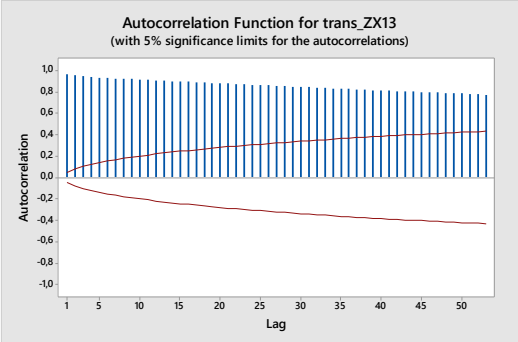

Harga Jagung Pipilan Kering

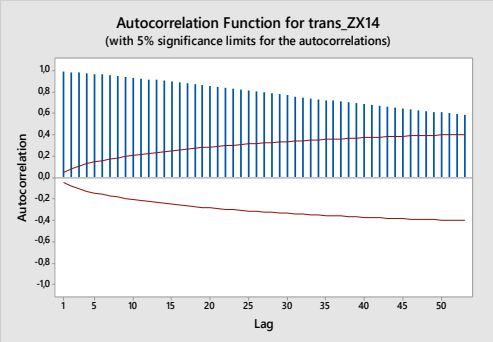

Harga Garam Beryodiun Halus

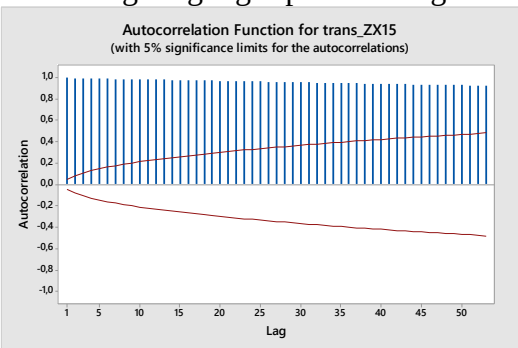

Harga Tepung Terigu Segitiga Biru Kw Medium

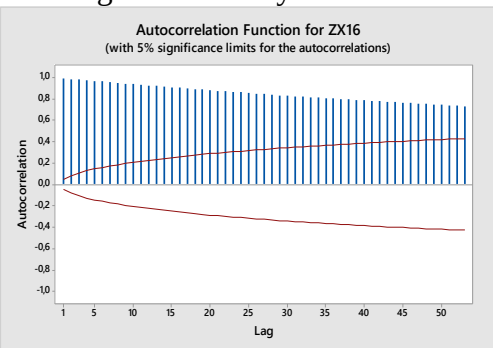

Harga Kacang Kedelai Eks Impor

Lampiran 8 Plot ACF Data Z_X^d Sebelum *Differencing* (Lanjutan)

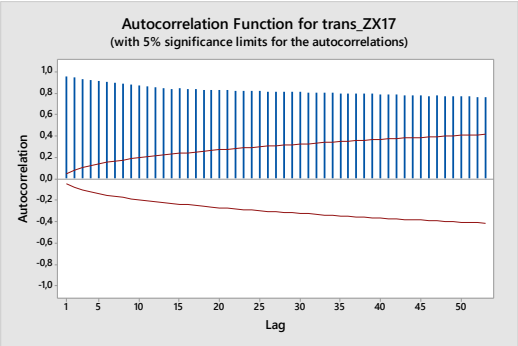

Rata-rata Bulanan Harga Indomie Rasa Kari Ayam

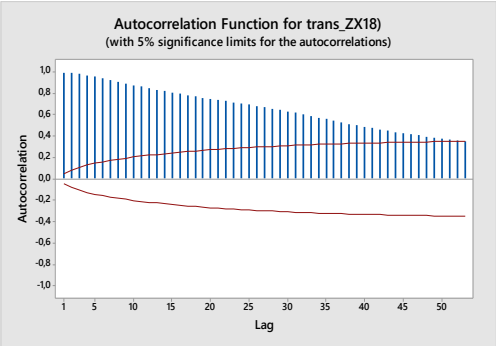

Harga Cabai Biasa

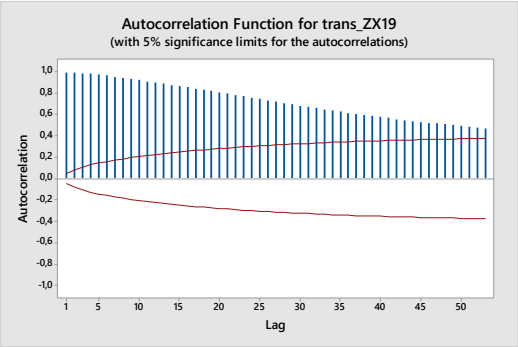

Harga Cabai Rawit

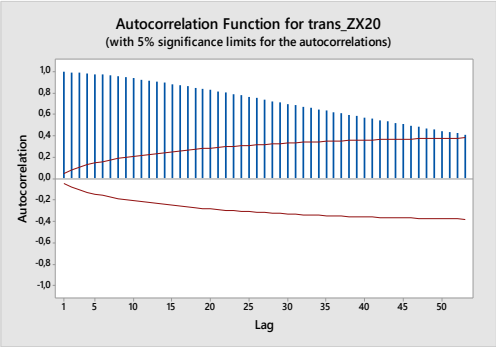

Harga Bawang Merah

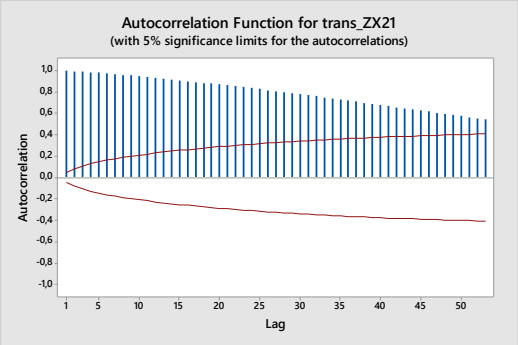

Harga Bawang Putih

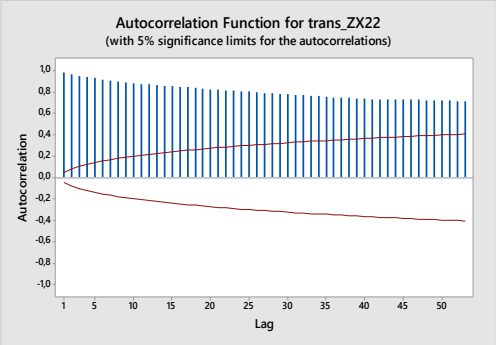

Harga Ikan Asin Teri

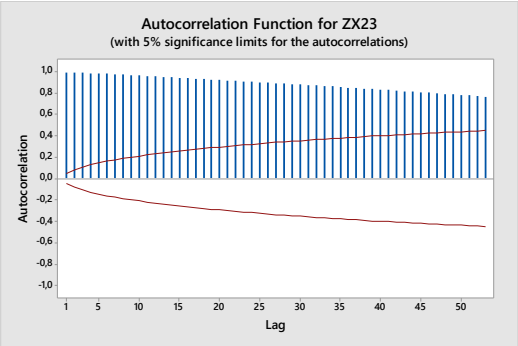

Harga Kacang Hijau

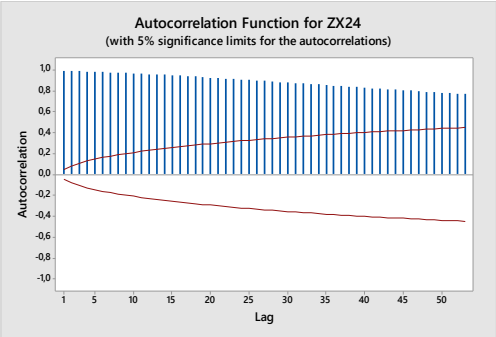

Harga Kacang Tanah

Lampiran 8 Plot ACF Data Z_X^d Sebelum *Differencing* (Lanjutan)

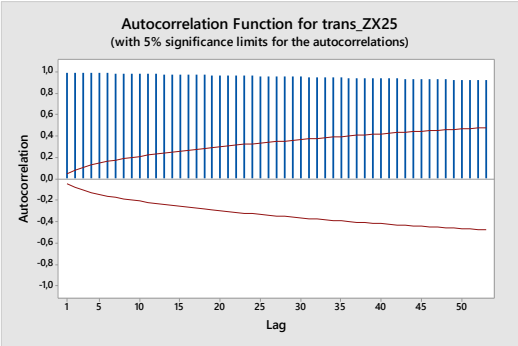

Harga Ketela Pohon

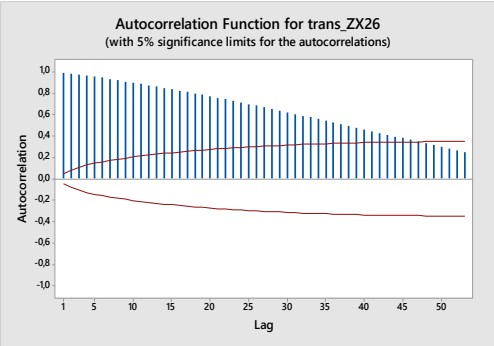

Harga Kol/ Kubis

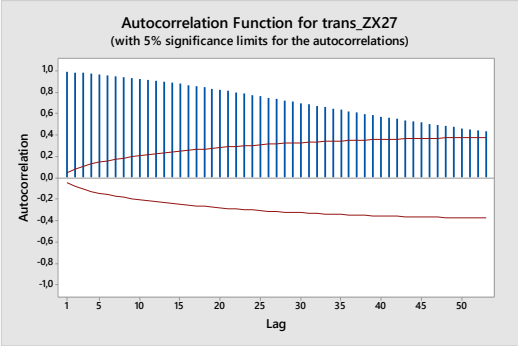

Harga Kentang

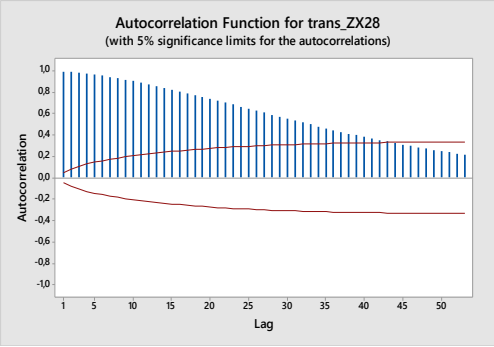

Harga Tomat

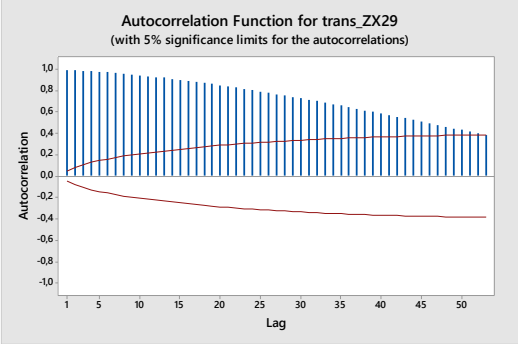

Harga Wortel

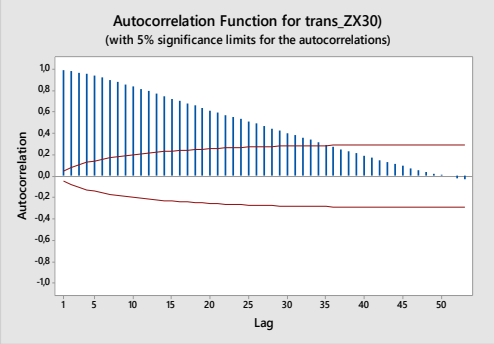

Harga Buncis

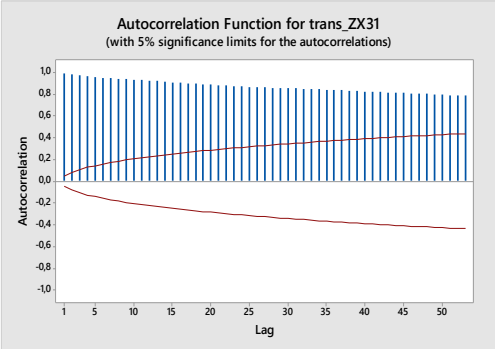

Harga Ikan Bandeng

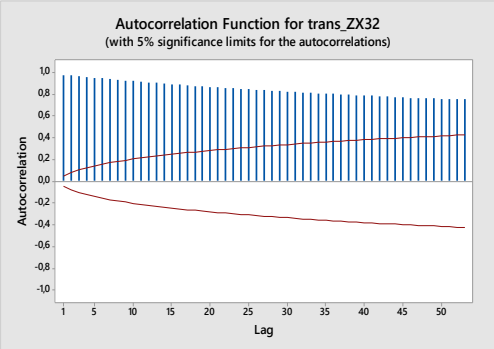

Harga Ikan Tongkol

Lampiran 8 Plot ACF Data Z_X^d Sebelum *Differencing* (Lanjutan)

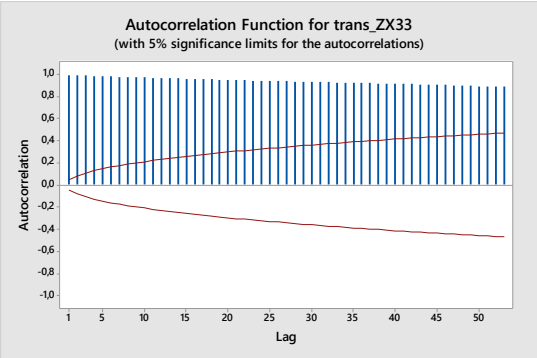

Harga Gas Elpiji 3 Kg

Lampiran 9 Hasil Estimasi Parameter pada *Time Series Regression* Model IHK Bulanan dan Hasil Uji Asumsi Residual

Estimasi Parameter Model 1

Prediktor	Koefisien	SE Koef	*t*	*p*	VIF
W_1^m	0,333	0,011	30,810	$< 2*10^{-16}$	1
W_2^m	-0,028	0,014	-2,009	0,051	1
W_3^m	-0,004	0,018	-2,111	0,834	1
W_4^m	0,012	0,022	0,560	0,578	1
W_5^m	-0,077	0,024	-3,271	0,002	1
W_6^m	-0,142	0,028	-5,066	$9,06*10^{-6}$	1
W_7^m	0,052	0,028	1,909	0,063	1

Hasil Uji Asumsi Residual Model 1

Uji Normalitas		Uji *White Noise*							
KS	*p*	*Lag*	*Chisquare*	df	*p*	*Lag*	*Chisquare*	df	*p*
0,082	0,872	6	20,592	6	0,002	12	25,324	12	0,013

Estimasi Parameter Model 2

Prediktor	Koefisien	SE Koef	*t*	*p*	VIF
W_1^m	0,054	0,020	2,673	0,011	19,483
W_2^m	-0,0004	0,006	-0,067	0,947	1,138
W_3^m	-0,018	0,008	-2,424	0,020	1,022
W_4^m	0,019	0,009	2,045	0,048	1,010
W_5^m	0,003	0,011	0,283	0,779	1,371
W_6^m	-0,026	0,014	-1,826	0,076	1,407
W_7^m	0,004	0,012	0,302	0,764	1,119
$Z_{y_{t-1}}^m$	0,824	0,059	13,963	$< 2*10^{-16}$	20,547

Hasil Uji Asumsi Residual Model 2

Uji Normalitas		Uji *White Noise*							
KS	*p*	*Lag*	*Chisquare*	df	*p*	*Lag*	*Chisquare*	df	*p*
0,166	0,135	6	6,560	6	0,364	12	15,541	12	0,13

Lampiran 9 Hasil Estimasi Parameter pada *Time Series Regression* Model IHK Bulanan dan Hasil Uji Asumsi Residual (Lanjutan)

Estimasi Parameter Model 3

Prediktor	Koefisien	SE Koef	*t*	*p*	VIF
W_3^m	-0,021	0,008	-2,672	0,010	1,002
W_4^m	0,020	0,010	1,995	0,052	1,002
$Z_{y_{t-1}}^m$	0,972	0,014	69,503	$< 2*10^{-16}$	1,003

Hasil Uji Asumsi Residual Model 3

Uji Normalitas		Uji *White Noise*							
KS	*p*	*Lag*	*Chisquare*	df	*p*	*Lag*	*Chisquare*	df	*p*
0,092	0,783	6	10,778	6	0,096	12	16,415	12	0,173

Lampiran 10 Hasil Estimasi Parameter pada *Time Series Regression* Model IHK Harian dan Hasil Uji Asumsi Residual

Estimasi Parameter Model 1

Prediktor	Koefisien	SE Koef	*t*	*p*	VIF
W_1^d	0,369	0,002	180,324	$< 2*10^{-16}$	1
W_2^d	-0,040	0,002	-15,868	$< 2*10^{-16}$	1
W_3^d	-0,004	0,003	-1,399	0,162	1
W_4^d	-0,003	0,004	-0,680	0,497	1
W_5^d	-0,101	0,004	-24,182	$< 2*10^{-16}$	1
W_6^d	0,148	0,005	30,600	$< 2*10^{-16}$	1
W_7^d	-0,055	0,005	-11,224	$< 2*10^{-16}$	1

Hasil Uji Asumsi Residual Berdistribusi Normal pada Model 1

Uji Normalitas	
KS	*p*
0,031	0,118

Hasil Uji Asumsi Residual White Noise pada Model 1

Uji *White Noise*							
Lag	*Chi-square*	df	*p*	*Lag*	*Chi-square*	df	*p*
6	5656,2	6	$< 2,2*10^{-16}$	12	9407,3	12	$< 2,2*10^{-16}$

Estimasi Parameter Model 2

Prediktor	Koefisien	SE Koef	*t*	*p*	VIF
W_1^d	0,184	0,005	34,05	$< 2*10^{-16}$	13,052
W_2^d	-0,021	0,002	-10,908	$< 2*10^{-16}$	1,084
W_3^d	-0,003	0,002	-1,137	0,256	1,000
W_4^d	-0,002	0,003	-0,551	0,581	1,000
W_5^d	-0,062	0,003	-18,780	$< 2*10^{-16}$	1,135
W_6^d	0,082	0,004	20,316	$< 2*10^{-16}$	1,280
W_7^d	-0,016	0,004	-4,400	$1,16*10^{-5}$	1,092
$Z_{y_{t-1}}^d$	0,506	0,014	35,429	$< 2*10^{-16}$	13,737

Lampiran 10 Hasil Estimasi Parameter pada *Time Series Regression* Model IHK Harian dan Hasil Uji Asumsi Residual (Lanjutan)

Hasil Uji Asumsi Residual Berdistribusi Normal pada Model 2

Uji Normalitas	
KS	*p*
0.084	$2.232*10^{-9}$

Hasil Uji Asumsi Residual White Noise pada Model 2

Uji *White Noise*							
Lag	*Chi-square*	df	*p*	*Lag*	*Chi-square*	df	*p*
6	1106.1	6	$< 2,2*10^{-16}$	12	1921.2	12	$< 2,2*10^{-16}$

Estimasi Parameter Model 3

Prediktor	Koefisien	SE Koef	*t*	*p*	VIF
W_2^d	-0,004	0,002	-1,426	0,154	1,008
W_5^d	-0,025	0,004	-5,970	$2,98*10^{-9}$	1,011
W_6^d	0,020	0,005	4,202	$2,81*10^{-5}$	1,002
W_7^d	0,018	0,005	3,741	0,0002	1,012
$Z_{y_{t-1}}^d$	0,974	0,005	183,710	$< 2*10^{-16}$	1,053

Hasil Uji Asumsi Residual Berdistribusi Normal pada Model 3

Uji Normalitas	
KS	*p*
0,205	$2,2*10^{-16}$

Hasil Uji Asumsi Residual White Noise pada Model 3

Uji *White Noise*							
Lag	*Chi-square*	df	*p*	*Lag*	*Chi-square*	df	*p*
6	197,9	6	$< 2,2*10^{-16}$	12	214,69	12	$< 2,2*10^{-16}$