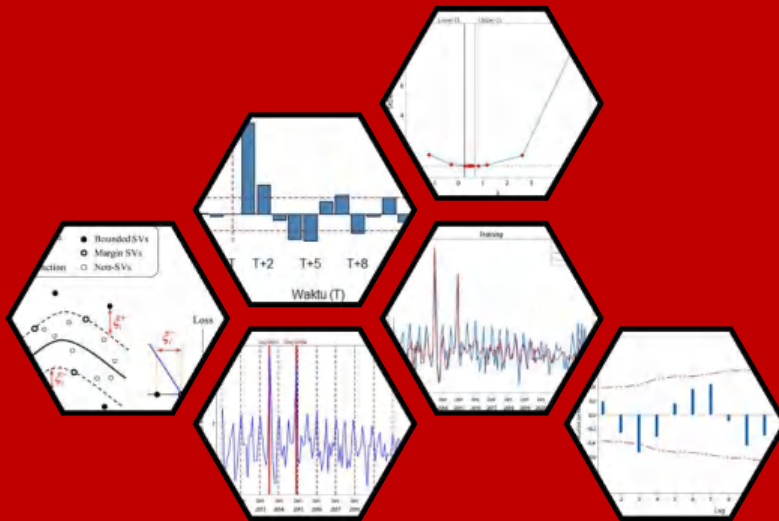


**PEMODELAN HYBRID GENERALIZED SPACE TIME  
AUTOREGRESSIVE DAN SUPPORT VECTOR REGRESSION  
DENGAN PULSE INTERVENTION**  
(Studi Kasus: Data Inflasi Tiga Kota di Sulawesi Selatan Tahun 2011-  
2023)



**DIVIA RATRI  
H051201041**



**Optimization Software:**  
[www.balesio.com](http://www.balesio.com)

**PROGRAM STUDI STATISTIKA  
MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS HASANUDDIN  
MAKASSAR  
2024**

**PEMODELAN *HYBRID GENERALIZED SPACE TIME*  
*AUTOREGRESSIVE* DAN *SUPPORT VECTOR REGRESSION*  
DENGAN *PULSE INTERVENTION***  
(Studi Kasus: Data Inflasi Tiga Kota di Sulawesi Selatan Tahun 2011-2023)

**DIVIA RATRI  
H051201041**



Optimization Software:  
[www.balesio.com](http://www.balesio.com)

**STUDI STATISTIKA DEPARTEMEN STATISTIKA  
MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS HASANUDDIN**

**2024**

**PEMODELAN *HYBRID GENERALIZED SPACE TIME*  
*AUTOREGRESSIVE* DAN *SUPPORT VECTOR REGRESSION* DENGAN  
*PULSE INTERVENTION***

**(Studi Kasus: Data Inflasi Tiga Kota di Sulawesi Selatan Tahun 2011-2023)**

DIVIA RATRI  
H051201041

Skripsi

Diajukan sebagai salah satu syarat memperoleh gelar Sarjana Statistika

Program Studi Statistika

pada



Optimization Software:  
[www.balesio.com](http://www.balesio.com)

**PROGRAM STUDI STATISTIKA  
DEPARTEMEN STATISTIKA  
MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS HASANUDDIN  
MAKASSAR  
2024**

## SKRIPSI

PEMODELAN *HYBRID GENERALIZED SPACE TIME*  
*AUTOREGRESSIVE* DAN *SUPPORT VECTOR REGRESSION* DENGAN  
*PULSE INTERVENTION*

(Studi Kasus: Data Inflasi Tiga Kota di Sulawesi Selatan Tahun 2011-2023)

yang disusun dan diajukan oleh

**DIVIA RATRI**  
**H051201041**

Skripsi,

Telah dipertahankan di depan Panitia Ujian Sarjana Statistika pada 24 Juni 2024  
dan dinyatakan telah memenuhi syarat kelulusan

pada

Program Studi Statistika  
Departemen Statistika  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Hasanuddin  
Makassar

Mengesahkan:  
Pembimbing tugas akhir,

Mengetahui:  
Ketua Program Studi,



Si  
2002



Dr. Anna Islamiyati, S.Si., M.Si.  
NIP. 197708082005012002

Optimization Software:  
[www.balesio.com](http://www.balesio.com)

## PERNYATAAN KEASLIAN SKRIPSI DAN PELIMPAHAN HAK CIPTA

Dengan ini saya menyatakan bahwa, skripsi berjudul "Pemodelan *Hybrid Generalized Space Time Autoregressive* dan *Support Vector Regression* dengan *Pulse Intervention* (Studi Kasus: Data Inflasi Tiga Kota di Sulawesi Selatan Tahun 2011-2023)" adalah benar karya saya dengan arahan dari pembimbing Sitti Sahriman, S.Si., M.Si. Karya ilmiah ini belum diajukan dan tidak sedang diajukan dalam bentuk apa pun kepada perguruan tinggi mana pun. Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka skripsi ini. Apabila di kemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan skripsi ini adalah karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut berdasarkan aturan yang berlaku.

Dengan ini saya melimpahkan hak cipta (hak ekonomis) dari karya tulis saya berupa skripsi ini kepada Universitas Hasanuddin.

Makassar, 24 Juni 2024



**Divia Ratri**

**NIM H051201041**



Optimization Software:  
[www.balesio.com](http://www.balesio.com)

## UCAPAN TERIMA KASIH

Puji syukur penulis panjatkan kepada Allah *Subhanahu Wa Ta'ala* atas segala limpahan rahmat, hidayah, dan karunia-Nya sehingga penulis dapat menyelesaikan penyusunan skripsi ini. Shalawat serta salam senantiasa tercurahkan kepada baginda Rasulullah *Shallallahu 'Alaihi Wa Sallam* beserta keluarga dan para sahabatnya. *Alhamdulillahirobbil'amin*, berkat umur yang panjang beserta kesehatan yang diberikan oleh Allah *Subhanahu Wa Ta'ala*, penulis dapat menyelesaikan skripsi yang berjudul "**Pemodelan *Hybrid Generalized Space Time Autoregressive* dan *Support Vector Regression* dengan *Pulse Intervention* (Studi Kasus: Data Inflasi Tiga Kota di Sulawesi Selatan Tahun 2011-2023)**" atas bimbingan dan arahan Ibu **Sitti Sahriman, S.Si., M.Si.** Saya mengucapkan terima kasih kepada Ibu **Dr. Anna Islamiyati** selaku Ketua Departemen Statistika Unhas dan sekaligus dosen penguji yang telah meluangkan waktu dalam memberikan saran dan kritikan yang membangun dalam penyempurnaan tugas akhir ini.

Penulis menyadari bahwa dalam penyelesaian skripsi ini tidak lepas dari bantuan dan dorongan dari berbagai pihak yang senantiasa turut membantu dalam bentuk moril maupun materil sehingga dengan segala keterbatasan kemampuan dan pengetahuan, penulis dapat menyelesaikan skripsi ini. Oleh karena itu, penulis menyampaikan ucapan terima kasih yang setulus-tulusnya serta penghargaan yang setinggi-tingginya kepada Ayahanda **Samaruddin Marsik** dan Ibunda **Nursia** yang telah memberikan dukungan penuh, pengorbanan luar biasa, limpahan cinta dan kasih sayang, kesabaran hati, serta dengan ikhlas telah menemani setiap langkah penulis dengan doa dan restu mulianya.

Akhirnya, Saya juga mengucapkan terima kasih kepada **Fadhil Al-Anshory** yang tak kalah penting kehadirannya, memberikan dukungan, semangat, maupun waktu kepada penulis. Teman-teman yang memberikan kenyamanan dalam saat penulisan skripsi (**Ayuni Sihombing** dan **Salsabila Ramadhani**), rekan-rekan yang menjadi tempat bertanya penulis (**Muh. Fahmi Alkaf**, **Andi Muhammad Hakam** dan **Eunike Laurine Randa**). Teman-teman POISS20N yang telah memberikan begitu banyak cerita suka dan duka, kenangan, dan kebersamaan selama menjadi bagian dari anggota Himpunan Mahasiswa Statistika Unhas, terkhusus teman-teman Bidang Akademik Himastat (**Muh. Fahmi Alkaf**, **Isra Leyla Bangsawang**, **Ayu Afrinah**, **Dania Nafila**, dan **Nurul Kurunubahriah**) dan teman-teman Dewan Himastat (**Fadlan Amin**, **M. Razy Qarar**, **Izzul Haq**, **Nurannisa Azzahra**, **Reza Hardiansyah** dan **Ryan Al-Aqsa**).

Makassar, 24 Juni 2024



Optimization Software:  
[www.balesio.com](http://www.balesio.com)

A handwritten signature in black ink, appearing to read 'Divia Ratri', with the name 'Divia Ratri' printed below it.



## ABSTRAK

Divia Ratri. **Pemodelan *Hybrid Generalized Space Time Autoregressive* dan *Support Vector Regression* dengan *Pulse Intervention* (Studi Kasus: Data Inflasi Tiga Kota di Sulawesi Selatan Tahun 2011-2023)** (dibimbing oleh Sitti Sahriman).

**Latar Belakang.** Inflasi merupakan data *time series* yang tidak hanya dipengaruhi oleh kejadian diwaktu sebelumnya, tetapi juga lokasi lain disekitarnya, termasuk kejadian eksternal yang memberikan *shock* pada inflasi yang disebut sebagai intervensi. Masalah ini dapat di atasi dengan melakukan pemodelan *Generalized Space Time Autoregressive* dengan varabel eksogen berupa *pulse Intervention* (GSTARX). Namun, model GSTARX tidak dapat mengakomodir adanya komponen non linier pada data. Komponen non linier dapat didekati dengan *Support Vector Regression* (SVR). Oleh karena itu, dilakukan pemodelan *hybrid* GSTARX-SVR untuk mendapatkan hasil ramalan yang akurat pada data inflasi di Sulawesi Selatan.

**Tujuan.** Penelitian ini bertujuan untuk mendapatkan estimasi parameter model *hybrid Generalized Space Time Autoregressive* dan *Support Vector Regression* dengan *Pulse Intervention* pada data inflasi tiga kota di Sulawesi Selatan. **Metode.** Penelitian ini dilakukan dengan pemodelan dua *level*, yaitu 1) *level* satu memodelkan data Inflasi dengan analisis intervensi berupa *pulse intervention*; 2) *level* dua memodelkan residual *level* satu dengan GSTAR-SVR. **Hasil.** Model *Hybrid Generalized Space Time Autoregressive* dan *Support Vector Regression* dengan *Pulse Intervention* bobot seragam mampu menurunkan kesalahan model ARIMA Intervensi sebesar 33.10%, menurunkan kesalahan model GSTARX bobot seragam sebesar 16.37%, model GSTARX bobot invers jarak sebesar 15.93% dan model GSTARX bobot normalisasi korelasi silang sebesar 16.34%. **Kesimpulan.** Model terbaik untuk meramalkan data inflasi tiga kota di Provinsi Sulawesi Selatan adalah model *Hybrid Generalized Space Time Autoregressive* dan *Support Vector Regression* dengan *Pulse Intervention* bobot seragam karena mampu meramalkan data inflasi tiga kota di Provinsi Sulawesi Selatan dengan akurat.

**Kata Kunci:** Analisis Intervensi, *Generalized Space Time Autoregressive*, *Support Vector Regression*, Inflasi.



## ABSTRACT

Divia Ratri. **Hybrid Generalized Space Time Autoregressive and Support Vector Regression Modeling with Pulse Intervention (Case Study: Inflation Data of Three Cities in South Sulawesi in 2011-2023)** (supervised by Sitti Sahriman).

**Background.** Inflation is a time series data that is not only influenced by events in the previous time, but also other locations around it, including external events that give a shock to inflation called intervention. This problem can be overcome by doing Generalized Space Time Autoregressive modeling with exogenous variables in the form of pulse Intervention (GSTARX). However, the GSTARX model cannot accommodate the presence of non-linear components in the data. Non-linear components can be approached with Support Vector Regression (SVR). Therefore, hybrid GSTARX-SVR modeling is carried out to obtain accurate forecast results on inflation data in South Sulawesi. **Aim.** This study aims to obtain parameter estimates of the hybrid Generalized Space Time Autoregressive and Support Vector Regression model with Pulse Intervention on inflation data for three cities in South Sulawesi. **Method.** This study was conducted with two-level modeling, namely 1) level one modeling Inflation data with intervention analysis in the form of pulse intervention; 2) level two modeling level one residuals with GSTAR-SVR. **Results.** The Hybrid Generalized Space Time Autoregressive and Support Vector Regression model with Pulse Intervention uniform weight is able to reduce the error of the ARIMA Intervention model by 33.10%, reduce the error of the uniform weight GSTARX model by 16.37%, the inverse distance weight GSTARX model by 15.93% and the cross-correlation normalization weight GSTARX model by 16.34%. **Conclusion.** The best model for forecasting inflation data for three cities in South Sulawesi Province is the Hybrid Generalized Space Time Autoregressive and Support Vector Regression model with Pulse Intervention uniform weight because it is able to accurately forecast inflation data for three cities in South Sulawesi Province.

**Keywords:** Intervention Analysis, Generalized Space Time Autoregressive, Support Vector Regression, Inflation.





## DAFTAR ISTILAH

Istilah	Arti dan Penjelasan
Eksogen	Variabel yang mempengaruhi atau yang menjadi sebab perubahan dan timbulnya variabel terikat (endogen), baik secara positif maupun secara negatif
<i>Autocorrelation Function</i>	Fungsi yang menunjukkan besarnya korelasi antara pengamatan pada waktu ke- $t$ dengan pengamatan waktu sebelumnya
<i>Diagnostic Check</i>	Proses evaluasi model untuk memastikan bahwa model sesuai dengan data dan memenuhi asumsi yang diperlukan
<i>Differencing</i>	Teknik dalam analisis deret waktu yang digunakan untuk membuat data menjadi stasioner dilakukan dengan menghitung selisih antara nilai observasi pada waktu $t$ dengan nilai observasi pada waktu $t-1$
Fungsi Kernel	Fungsi matematis yang memungkinkan data yang tidak linier dalam strukturnya untuk diolah dalam ruang dimensi yang lebih tinggi
<i>Generalized Space Time Autoregressive</i>	Model statistik yang menggabungkan konsep <i>autoregresi</i> dalam domain waktu dan mempertimbangkan struktur spasial dari data tersebut.
<i>Grid Search</i>	Metode yang digunakan untuk menguji berbagai kombinasi parameter model dan menentukan kombinasi yang memberikan performa terbaik
<i>Hyperplane</i>	Fungsi regresi dengan solusi optimal yang dibangun untuk memprediksi nilai target ( <i>output</i> ) berdasarkan fitur-fitur dari data <i>input</i>
Intervensi	Kejadian yang memberikan dampak pada suatu variabel, dapat berupa kebijakan, program, atau tindakan yang diterapkan untuk mengubah atau mempengaruhi variabel tertentu
<i>Lag</i>	Pergeseran waktu antara observasi dalam dataset yang digunakan untuk mengukur hubungan antara nilai-nilai dalam deret waktu dengan nilai-nilai sebelumnya
<i>Lagrange Multiplier</i>	Konsep yang digunakan untuk menemukan titik optimum dari sebuah fungsi objektif yang terikat oleh satu atau lebih persamaan pembatas Tingkat atau derajat komponen yang digunakan dalam model



Istilah	Arti dan Penjelasan
<i>Partial Autocorelation Function</i>	Fungsi yang mengukur korelasi antara nilai dalam deret waktu dengan nilai pada <i>lag</i> tertentu, setelah mengontrol efek dari <i>lag-lag</i> yang ada di antaranya
Prediktor	Variabel dalam penelitian yang mempengaruhi variabel lain dan dapat dikendalikan oleh peneliti yang digunakan untuk memprediksi atau menjelaskan variasi dalam variabel lain yang diamati
Pre-Intervensi	Kondisi sebelum intervensi terjadi
<i>Pulse</i>	Jenis intervensi yang menunjukkan perubahan yang bersifat satu kali atau terjadi pada waktu tertentu dalam suatu <i>time series</i>
Respon	Variabel dalam penelitian yang dipengaruhi oleh variabel prediktor dan tidak dapat dikendalikan oleh peneliti yang digunakan untuk mengukur efek atau hasil dari perubahan variabel prediktor
<i>Response Function</i>	Fungsi yang digunakan untuk mengukur atau memperkirakan dampak atau respons dari suatu intervensi terhadap variabel tertentu
<i>Slack</i>	Toleransi terhadap kesalahan yang memperbolehkan beberapa titik data berada di luar batas margin atau memiliki error yang lebih besar dari nilai yang diizinkan
Stasioner	Sifat deret waktu di mana karakteristik statistik seperti rata-rata, variansi, dan autokorelasi tidak berubah seiring waktu.
<i>Step</i>	Jenis intervensi yang menunjukkan perubahan yang bersifat konstan dan terjadi pada waktu tertentu dalam suatu <i>time series</i> , intervensi ini juga dapat disebut sebagai intervensi berkelanjutan
<i>Support Vector Regression</i>	Metode dalam <i>machine learning</i> yang dapat mengatasi masalah regresi non-linier dengan memanfaatkan fungsi kernel, yang memungkinkan data untuk diproyeksikan ke ruang dimensi yang lebih tinggi di mana dapat ditemukan <i>hyperplane</i> terbaik.
	Uji linieritas yang dikembangkan dari model <i>neural networks</i> , dimana uji tersebut merupakan tipe <i>Langrange Multiplier</i> (LM) dengan ekspansi <i>Taylor</i>
	Data yang digunakan untuk menguji kinerja model yang telah dilatih dengan data <i>training</i> .



<b>Istilah</b>	<b>Arti dan Penjelasan</b>
<i>Training</i>	Kumpulan data yang digunakan untuk membangun atau melatih model.
Transformasi	Proses mengubah data ke dalam bentuk yang berbeda untuk membuatnya lebih cocok untuk analisis atau pemodelan
<i>White Noise</i>	Sinyal acak yang memiliki rata-rata konstan (biasanya nol), variansi konstan, dan tidak ada autokorelasi



## DAFTAR SINGKATAN DAN LAMBANG

LAMBANG/SINGKATAN	Arti dan Penjelasan
$\phi_p$	Koefisien AR berordo $p$
$\theta_q$	Koefisien MA berordo $q$
$\lambda$	Parameter dalam transformasi <i>box-cox</i>
$\hat{\rho}_{ij}(k)$	Korelasi silang sampel antara komponen <i>series</i> ke- $i$ dan ke- $j$
$\gamma_{ij}(k)$	Kovarians silang antara lokasi ke- $i$ dan ke- $j$
$\omega_s(B)$	Parameter model intervensi berordo $s$
$\delta_r(B)$	Parameter model intervensi berordo $r$
$\Phi_{k0}$	Matriks koefisien parameter waktu
$\Phi_{kl}$	Matriks koefisien parameter spasial
$W^{(l)}$	Matriks pembobot berukuran $(N \times N)$ pada <i>lag</i> spasial ke- $l$
$v$	Vektor pembobot pada SVR
$\phi(x)$	Titik didalam <i>feature space</i> $F$ , hasil dari pemetaan $x$ di dalam <i>input space</i>
$\varepsilon$	Margin
$\xi_i$	<i>Slack</i>
$\alpha_i$	Koefisien <i>lagrange</i>
$k(x_i, x_j)$	Fungsi kernel
$a_t$	Residual ARIMA yang memenuhi asumsi <i>white noise</i>
$F_0(a_t)$	Fungsi peluang kumulatif distribusi normal
$S(a_t)$	Fungsi distribusi kumulatif dari data asal
ACF	<i>Autocorrelation Function</i>
ADF	<i>Augmented Dickey Fuller</i>
AIC	<i>Akaike Information Criterion</i>
ARIMA	Autoregressive Integrated Moving Average
DF	Degree of freedom
	<i>Generalized Space Time Autoregressive Lagrange Multiplier</i>
	<i>Matrix Cross Correlation Function</i>



<b>LAMBANG/SINGKATAN</b>	<b>Arti dan Penjelasan</b>
MPCCF	<i>Matrix Partial Cross Correlation Function</i>
PACF	<i>Partial Autocorrelation Function</i>
RMSE	<i>Root Mean Square Error</i>
sMAPE	<i>Symmetric Mean Absolute Percentage Error</i>
SVR	<i>Support Vector Regression</i>



## DAFTAR ISI

<b>HALAMAN JUDUL .....</b>	<b>ii</b>
<b>HALAMAN PENGANTAR .....</b>	<b>ii</b>
<b>HALAMAN PENGESAHAN .....</b>	<b>iii</b>
<b>HALAMAN PERNYATAAN KEASLIAN SKRIPSI .....</b>	<b>iv</b>
<b>UCAPAN TERIMA KASIH .....</b>	<b>v</b>
<b>ABSTRAK .....</b>	<b>vi</b>
<b>ABSTRACT .....</b>	<b>vii</b>
<b>DAFTAR ISTILAH.....</b>	<b>viii</b>
<b>DAFTAR SINGKATAN DAN LAMBANG .....</b>	<b>xi</b>
<b>DAFTAR ISI.....</b>	<b>xiii</b>
<b>DAFTAR TABEL.....</b>	<b>xv</b>
<b>DAFTAR GAMBAR.....</b>	<b>xvii</b>
<b>DAFTAR LAMPIRAN .....</b>	<b>xix</b>
<b>BAB I PENDAHULUAN .....</b>	<b>1</b>
1.1 Latar Belakang.....	1
1.2 Batasan Masalah .....	3
1.3 Tujuan Penelitian .....	3
1.4 Manfaat Penelitian .....	3
1.5 Teori .....	4
1.5.1. Model <i>Univariate Time Series</i> .....	4
1.5.2. Analisis Intervensi.....	7
1.5.3. Model <i>Multivariate Time Series</i> .....	8
1.5.4. Model <i>Generalized Space Time Autoregressive</i> .....	10
1.5.5. Uji Terasvirta .....	15
1.5.6. <i>Support Vector Regression</i> .....	15
1.5.7. Model <i>Hybrid</i> .....	18
1.5.8. Pemilihan Model Terbaik .....	19
.....	19
<b>REVISI PENELITIAN.....</b>	<b>21</b>
.....	21
an .....	21
spon .....	21





2.2.2 Variabel Prediktor .....	21
2.3. Prosedur Penelitian.....	21
<b>BAB III HASIL DAN PEMBAHASAN .....</b>	<b>25</b>
3.1 Karakteristik Data.....	25
3.2 Stasioneritas Data.....	27
3.2.1 Stasioneritas dalam Varians .....	27
3.2.2 Stasioneritas dalam Mean .....	28
3.3 Pemodelan <i>Level</i> / Satu dengan Analisis Intervensi pada Inflasi Umum.....	29
3.3.1 Analisis Model Intervensi pada Inflasi Kota Makassar .....	29
3.3.2 Analisis Model Intervensi pada Inflasi Kota Pare-Pare.....	34
3.3.3 Analisis Model Intervensi pada Inflasi Kota Palopo.....	38
3.4 Pemodelan <i>Level</i> / Dua pada Data Inflasi Tiga Kota di Sulawesi Selatan.....	42
3.4.1 Pemodelan <i>Level</i> Dua dengan <i>Generalized Space Time Autoregressive</i>	42
3.4.2 Pemodelan <i>Level</i> Dua <i>Hybrid Generalized Space Time Autoregressive</i> dan <i>Support Vector Regression</i> dengan <i>Pulse Intervention</i> .....	61
3.5 Pemilihan Model Terbaik Data Inflasi Tiga Kota di Sulawesi Selatan .....	66
<b>BAB IV KESIMPULAN.....</b>	<b>70</b>
4.1 Kesimpulan.....	70
4.2 Saran.....	70
<b>DAFTAR PUSTAKA .....</b>	<b>71</b>
<b>LAMPIRAN .....</b>	<b>74</b>



## DAFTAR TABEL

Tabel	Halaman
1. Transformasi <i>Box-Cox</i> .....	5
2. Karakteristik ACF dan PACF untuk Model ARMA.....	6
3. Jarak antar Tiga Kota di Sulawesi Selatan .....	12
4. Fungsi Kernel .....	18
5. Variabel Respon .....	21
6. Statistik Deskriptif Inflasi Tiga Kota di Sulawesi Selatan .....	25
7. Nilai Korelasi Inflasi Tiga Kota di Provinsi Sulawesi Selatan .....	26
8. Nilai Indeks Gini.....	27
9. Bentuk Transformasi <i>Box-Cox</i> .....	28
10. Hasil Uji ADF Data Inflasi Tiga Kota di Sulawesi Selatan.....	29
11. Hasil AIC dan Estimasi Parameter Model ARIMA Pre-Intervensi Kota Makassar .....	30
12. Hasil Uji <i>White Noise</i> Residual Model ARIMA Pre-Intervensi Kota Makassar .....	30
13. Uji Signifikansi Parameter Model Intervensi Kenaikan BBM Juni 2013 Kota Makassar .....	32
14. Uji Signifikansi Parameter Model Intervensi Kota Makassar .....	32
15. Hasil Uji <i>White Noise</i> Residual Model ARIMA Intervensi Kota Makassar .....	33
16. Hasil AIC dan Estimasi Parameter Model ARIMA Pre-Intervensi Kota Pare-Pare.....	35
17. Hasil Uji <i>White Noise</i> Residual Model ARIMA Pre-Intervensi Kota Pare-Pare.....	35
18. Uji Signifikansi Parameter Model Intervensi Kenaikan BBM Juni 2013 Kota Pare-Pare.....	36
19. Uji Signifikansi Parameter Model Intervensi Kota Pare-Pare.....	36
20. Hasil Uji <i>White Noise</i> Residual Model ARIMA Intervensi Kota Pare-Pare.....	37
21. Hasil AIC dan Estimasi Parameter Model ARIMA Pre-Intervensi Kota Pare-Pare.....	39
22. Hasil Uji <i>White Noise</i> Residual Model ARIMA Pre-Intervensi Kota Palopo.....	39



23. Uji Signifikansi Parameter Model Intervensi Kenaikan BBM Juni 2013 Kota Palopo.....	40
24. Uji Signifikansi Parameter Model Intervensi Kota Palopo.....	40
25. Hasil Uji <i>White Noise</i> Residual Model ARIMA Intervensi Kota Palopo .....	41
26. Nilai AIC Residual Inflasi.....	44
27. Hasil Estimasi Parameter Model GSTAR dengan Bobot Seragam.....	46
28. Hasil Estimasi Parameter Model GSTAR dengan Bobot Invers Jarak.....	49
29. Hasil Estimasi Parameter Model GSTAR dengan Bobot Normalisasi Korelasi Silang .....	52
30. Nilai AIC Residual Model GSTARX.....	57
31. Hasil Uji Normal Multivariat Model GSTARX .....	59
32. Nilai Keباikan Model GSTARX.....	59
33. Hasil Uji <i>Terasvirta</i> pada Residual Model <i>Level Satu</i> .....	61
34. Rentang Nilai Parameter Metode <i>Grid Search</i> Tahapan <i>Loose Grid</i> .....	62
35. Hasil Evaluasi Model Optimal <i>Hybrid</i> GSTARX-SVR .....	62
36. Nilai Akurasi Hasil Pemodelan Data Inflasi.....	67
37. Persentase Penurunan Nilai RMSE Terhadap Model .....	68



## DAFTAR GAMBAR

Gambar	Halaman
1. Tahapan <i>Box-Jenkins</i> dalam Pemodelan ARIMA .....	4
2. Ilustrasi Penambahan <i>Slack</i> .....	16
3. Plot <i>Time Series</i> Inflasi Tiga Kota di Provinsi Sulawesi Selatan.....	26
4. Plot <i>Box-Cox</i> Data Inflasi Tiga Kota di Provinsi Sulawesi Selatan.....	28
5. Plot (a) ACF dan (b) PACF Kota Makassar sebelum Intervensi Kenaikan BBM Juni 2013.....	29
6. Plot <i>Response Function</i> Kota Makassar pada Intervensi Kenaikan BBM Juni 2013.....	31
7. Plot <i>Response Function</i> Kota Makassar pada Intervensi Kenaikan BBM November 2014 .....	32
8. Hasil Ramalan Model ARIMA Intervensi Kota Makassar.....	34
9. Plot (a) ACF dan (b) PACF Kota Pare-Pare sebelum Intervensi Kenaikan BBM Juni 2013.....	34
10. Plot <i>Response Function</i> Kota Pare-Pare pada Intervensi Kenaikan BBM Juni 2013 .....	35
11. Plot <i>Response Function</i> Kota Pare-Pare pada Intervensi Kenaikan BBM November 2014 .....	36
12. Hasil Ramalan Model ARIMA Intervensi Kota Pare-Pare.....	38
13. Plot (a) ACF dan (b) PACF Kota Palopo sebelum Intervensi Kenaikan BBM Juni 2013.....	38
14. Plot <i>Response Function</i> Kota Palopo pada Intervensi Kenaikan BBM Juni 2013.....	39
15. Plot <i>Response Function</i> Kota Palopo pada Intervensi Kenaikan BBM November 2014 .....	40
16. Hasil Ramalan Model ARIMA Intervensi Kota Palopo.....	41
17. Plot <i>Time Series</i> Residual Inflasi..... <b>Error! Bookmark not defined.</b>	
ematik MCCF Residual <i>Level</i> Satu .....	43
ematik MCCF Residual <i>Level</i> Satu Hasil .....	43
ematik MPCCF Residual <i>Level</i> Satu.....	44



21. Skema MCCF Residual Model GSTARX dengan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang .....	56
22. Plot Hasil Uji Normal Multivariat Model GSTARX dengan Bobot Seragam .....	57
23. Plot Hasil Uji Normal Multivariat Model GSTARX dengan Bobot Invers Jarak.....	58
24. Plot Hasil Uji Normal Multivariate Model GSTARX dengan Bobot Normalisasi Korelasi Silang .....	58
25. Plot <i>Time Series</i> Data Aktual Inflasi dengan Hasil Ramalan Model GSTARX di (a) Makassar, (b) Pare-Pare, dan (c) Palopo .....	60
26. Plot Residual Model <i>Level</i> Satu Tiga Kota di Sulawesi Selatan .....	61
27. Plot <i>Time Series</i> Data Aktual Inflasi dengan Hasil Ramalan Model <i>Hybrid</i> GSTARX-SVR di (a) Makassar, (b) Pare-Pare, dan (c) Palopo.....	66
28. Plot <i>Time Series</i> Hasil Ramalan Data <i>Testing</i> Model <i>Level</i> Dua.....	67
29. Nilai RMSE <i>Testing k-step</i> Data Inflasi.....	69



## DAFTAR LAMPIRAN

Lampiran	Halaman
1. Data Inflasi Tiga Kota di Sulawesi Selatan .....	75
2. Hasil Uji Stasioneritas Data Inflasi Sebelum Intervensi Pertama.....	76
3. <i>Output</i> Estimasi Parameter Model Arima Intervensi .....	78
4. Hasil Ramalan Data <i>Training</i> ARIMA Intervensi .....	79
5. Hasil Ramalan Data <i>Testing</i> ARIMA Intervensi .....	80
6. <i>Output</i> Estimasi Parameter Model GSTARX Bobot Seragam .....	81
7. <i>Output</i> Estimasi Parameter Model GSTARX Bobot Invers Jarak .....	82
8. <i>Output</i> Estimasi Parameter Model GSTARX Bobot Normalisasi .....	83
9. Hasil Ramalan Data Training Model GSTARX dengan Tiga Bobot .....	84
10. Pemelihan Parameter Model <i>Hybrid</i> GSTARX-SVR dengan Metode <i>Grid Search</i> .....	85
11. Matrix Kernel RBF <i>Hybrid</i> GSTARX-SVR dengan Bobot Seragam .....	87
12. Nilai $\alpha$ Model <i>Hybrid</i> GSTARX-SVR dengan Bobot Seragam .....	90
13. Hasil Ramalan Data <i>Training</i> Model Hybrid GSTARX-SVR .....	91
14. Hasil Ramalan Data <i>Testing</i> Model <i>Level</i> Dua .....	92
15. RMSE <i>k-step</i> Data <i>Testing</i> Model Hybrid GSTARX-SVR.....	95





# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Inflasi merupakan peningkatan harga sejumlah besar barang dan jasa yang dikonsumsi dalam suatu perekonomian dan terjadi terus-menerus (Suseno & Astiyah, 2009). Inflasi menjadi salah satu indikator penting dalam menganalisis perekonomian sebuah negara karena berhubungan langsung dengan masyarakat dan dunia usaha. Laju inflasi yang rendah dan stabil diperlukan dalam upaya menjaga pertumbuhan ekonomi sehingga dapat memberikan manfaat dalam meningkatkan kesejahteraan dan kondisi sosial ekonomi masyarakat. Inflasi dapat disebabkan oleh dua faktor utama, yaitu *demand pull inflation* yang muncul akibat peningkatan permintaan masyarakat terhadap berbagai barang dan jasa di pasar dan *cost push inflation* yang terjadi karena kenaikan harga faktor produksi. Hal ini seringkali disebabkan oleh kejadian tak terduga (*shock*), seperti bencana alam dan faktor kebijakan pemerintah (Bank Indonesia, 2023).

Inflasi yang tidak stabil dan tinggi masih menjadi permasalahan utama perekonomian di Indonesia. Dari tahun 2013-2017 tercatat Indonesia selalu menempati peringkat pertama inflasi paling tinggi di antara negara anggota ASEAN. Untuk mengatasi masalah tersebut, Bank Indonesia dan pemerintah membuat kebijakan moneter dan penetapan target inflasi tahunan untuk menurunkan tingkat inflasi. Namun, upaya tersebut belum sepenuhnya berhasil karena target inflasi yang telah ditetapkan oleh pemerintah belum tercapai. Pada tahun 2013 dan 2014, target tingkat inflasi Indonesia ditetapkan sebesar 4,5%, namun kenyataannya, tingkat inflasi pada tahun 2013 dan 2014 masing-masing mencapai 8,38% dan 8,36% (Bank Indonesia, 2018). Oleh karena itu, perlu dilakukan peramalan inflasi sebagai dasar pemerintah dalam mengambil kebijakan.

Penelitian tentang inflasi banyak difokuskan pada skala nasional dibanding skala regional. Penelitian tentang inflasi daerah perlu dilakukan karena inflasi nasional terbentuk dari inflasi daerah dan masing-masing daerah memiliki karakteristik yang berbeda, sehingga membutuhkan kebijakan pengendalian inflasi yang berbeda pula. Salah satu provinsi yang mengalami masalah inflasi adalah Sulawesi Selatan sebagai provinsi yang berperan penting di kawasan Indonesia bagian Timur. Sama halnya dengan inflasi nasional, inflasi tertinggi di Sulawesi Selatan juga terjadi pada tahun 2013 dan 2014 sebesar 6,22% dan 8.61%. Terdapat tiga kota penghitung inflasi yang bisa memberikan gambaran mengenai perubahan Sulawesi Selatan, yaitu Makassar, Pare-Pare, dan Palopo. Pada tahun tersebut dianggap mewakili inflasi di Sulawesi Selatan karena ketiga kota tersebut memiliki komoditas yang paling dominan untuk menghitung harga



akan data yang bersifat *time series*, sehingga banyak penelitian menggunakan pendekatan atau analisis *time series*. Salah satu model umum digunakan dalam analisis *time series* adalah model

ARIMA yang dikembangkan oleh George Box & Gwilym Jenkins (1970). Model ARIMA hanya memodelkan dan memprediksi perilaku data berdasarkan pola-pola historisnya. Pada kenyataannya kejadian data *time series* juga dipengaruhi oleh faktor lain, sehingga seringkali digunakan variabel prediktor (eksogen) untuk memperoleh informasi tambahan dan meningkatkan akurasi pemodelan atau peramalan. Variabel eksogen yang digunakan dapat berskala metrik atau non-metrik. Penambahan variabel eksogen dalam bentuk skala metrik dikenal sebagai Fungsi Transfer (Box dkk., 2008), sedangkan variabel eksogen dalam bentuk skala non-metrik dikenal sebagai Intervensi (Bowerman & O'Connell, 1993).

Data *time series* tidak hanya dipengaruhi oleh kejadian di waktu sebelumnya, tetapi juga memiliki keterkaitan dengan lokasi atau tempat lain disekitarnya, sehingga data *time series* juga dapat memiliki dimensi ruang dan waktu yang disebut *space time* (Ruchjana, 2002). Model *space time* pertama kali diperkenalkan oleh Cliff & Ord (1975). Kemudian ditahun 1980, Pfeifer & Deutsh mengembangkan model *space-time* yang dikenal dengan model STAR (*Space Time Autoregressive*). Namun, model STAR memiliki kelemahan yaitu mengandung parameter yang sama dalam menjelaskan dependensi pada lokasi dan waktu yang berbeda. Untuk mengatasi kelemahan tersebut, Ruchjana (2002) mengembangkan model GSTAR yang memungkinkan parameter model berubah untuk setiap lokasi dan waktu. Namun model GSTAR terbatas pada data yang memiliki model linear.

Sama halnya dengan model univariat, model *multivariate time series* juga memerlukan variabel eksogen untuk meningkatkan akurasi dalam pemodelan dan hasil ramalannya. Model GSTAR sebagai model *multivariate time series* dapat dikembangkan dengan melibatkan variabel eksogen yang disebut dengan model GSTARX. Model ini dinilai mampu menjelaskan adanya keterkaitan antara lokasi satu dan lokasi lain dengan kejadian eksternal yang mempengaruhi variabel *time series*. Kejadian eksternal yang memberikan *shock* pada data *time series* disebut sebagai intervensi yang dapat berupa fungsi *pulse dan step*. Intervensi termasuk variabel eksogen yang berskala non-metrik. Pada penelitian ini, intervensi *pulse* akan menjadi variabel eksogen pada model GSTARX.

Menurut Zhang (2003), jarang ditemukan data *time series* di dunia nyata yang murni hanya berbentuk linear atau nonlinear saja, melainkan memiliki bentuk linear dan nonlinear sekaligus. Oleh karena itu, Zhang (2003) mengembangkan suatu model *hybrid* yang menggabungkan ARIMA sebagai pendekatan untuk komponen linear dan ANN sebagai pendekatan untuk komponen nonlinear. Selain ANN, pendekatan yang bisa digunakan untuk komponen nonlinear adalah *Support Vector*

*Regression (SVR)* yang merupakan modifikasi dari *Support Vector Machine (SVM)* oleh Vapnik (1995) sebagai metode yang efektif untuk dalam masalah regresi. SVR memiliki keunggulan dalam yaitu ketika terdapat penyimpangan dari keadaan aktual yang antara faktor sulit dijelaskan (Yasin dkk., 2014).

Uji validasi parameter model GSTARX pernah dilakukan oleh Ditago (2015) dengan optimasi parameter GSTARX-GLS dua level pada data simulasi.



Pemodelan dengan GSTARX pernah dilakukan oleh Suhartono (2018) dengan membandingkan model VARX dan GSTARX untuk peramalan pada data *inflow* dan *outflow* dengan efek variasi kalender di Bali, NTT, dan NTB. Pada penelitian tersebut, diperoleh bahwa model VARX lebih baik untuk data *inflow*, sedangkan GSTARX lebih baik untuk meramalkan data *outflow*. Penelitian model *hybrid* pernah dilakukan oleh Dana (2019) dengan melakukan pemodelan *hybrid* GSTARX-ANN untuk peramalan data *space-time* dengan efek variasi kalender pada data *inflow* dan *outflow* uang kartal di Bank Indonesia Wilayah Jawa Timur dan didapatkan pemodelan data *inflow* menggunakan model GSTARX-FFNN (8,2,1) bobot invers jarak merupakan model terbaik, sedangkan pada pemodelan *outflow* model GSTARX-FFNN (8,15,1) merupakan model terbaik. Maghfiroh (2019) juga melakukan pemodelan *hybrid* VARX-SVR dan GSTARX-SVR untuk meramalkan arus uang di KPW II BI dan didapatkan model *hybrid* bekerja sangat baik pada data *training inflow* dan *outflow*.

Sampai saat ini, belum ada pemodelan data inflasi dengan menggunakan model *space time* yang melibatkan analisis intervensi sebagai variabel prediktor dengan menggabungkan komponen linier dan nonlinier. Oleh karena itu, dikembangkan model *Hybrid* GSTARX-SVR pada data inflasi tiga kota di Provinsi Sulawesi Selatan yaitu Makassar, Pare-Pare, dan Palopo.

## 1.2 Batasan Masalah

1. Data yang digunakan pada penelitian ini adalah data bulanan inflasi tiga kota di Provinsi Sulawesi Selatan yaitu Makassar, Pare-Pare, dan Palopo periode Januari 2011 – Desember 2023.
2. Variabel prediktor yang digunakan pada model *Hybrid* GSTARX-SVR berskala nonmetrik yaitu *pulse intervention* berupa kebijakan kenaikan harga BBM.
3. Ordo spasial yang digunakan pada penelitian skripsi ini adalah ordo satu, karena wilayah yang menjadi objek penelitian berada dalam satu wilayah yang sama yaitu Provinsi Sulawesi Selatan.
4. Bobot yang digunakan pada penelitian ini adalah bobot seragam, invers jarak, dan normalisasi korelasi silang.

## 1.3 Tujuan Penelitian

1. Memperoleh hasil estimasi parameter model *Hybrid* GSTARX-SVR data inflasi tiga kota di Provinsi Sulawesi Selatan.
2. Mendapatkan hasil ramalan model *Hybrid* GSTARX-SVR data inflasi tiga kota di Provinsi Sulawesi Selatan.

## 1.4 Manfaat Penelitian

Secara teoritis, penelitian ini menambah pengetahuan dan kemampuan penulis analisis data *time series* serta menambah wawasan mengenai *Hybrid* GSTARX-SVR dan penerapannya dalam kehidupan praktis, penelitian ini dapat menjadi bahan pertimbangan dan perintah untuk menentukan langkah terbaik dalam mengambil keputusan yang dapat mempengaruhi inflasi dari tahun ke tahun yang dapat diantisipasi.



## 1.5 Teori

### 1.5.1. Model Univariate Time Series

Model *univariate time series* yang paling sering digunakan adalah *Autoregressive Integrated Moving Average* (ARIMA) karena dapat mewakili beberapa jenis deret waktu yang berbeda, yaitu *Autoregressive* (AR), *Moving Average* (MA) serta kombinasi AR dan MA dengan proses *differencing* apabila data yang dimiliki tidak stasioner dalam rata-rata. Model ARIMA ( $p, d, q$ ) dinyatakan sebagai berikut (Wei, 2006):

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

Keterangan:

$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$  sebagai koefisien AR berordo  $p$

$\theta_q(B) = 1 - \theta_1 B - \theta_1 B^1 - \dots - \theta_q B^q$  sebagai koefisien MA berordo  $q$

$(1-B)^d =$  operator *differencing* berordo  $d$

$a_t =$  nilai residual yang memenuhi asumsi *white noise* atau  $a_t \sim WN(0, \sigma_a^2)$

$\theta_0 =$  konstanta

Jika data memiliki pola musiman, maka digunakan model ARIMA ( $p, d, q$ )( $P, D, Q$ )<sup>s</sup> dengan model umum sebagai berikut (Wei, 2006):

$$\Phi_P(B^s)\phi_p(B)(1-B)^d(1-B^s)^D Y_t = \theta_q(B)\theta_Q(B^s)a_t \quad (2)$$

Keterangan:

$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$  sebagai koefisien AR berordo  $p$

$\Phi_P(B^s) = 1 - \Phi_1 B - \Phi_2 B^2 - \dots - \Phi_P B^{Ps}$  sebagai koefisien AR musiman  $s$

$\theta_q(B) = 1 - \theta_1 B - \theta_1 B^1 - \dots - \theta_q B^q$  sebagai koefisien MA berordo  $q$

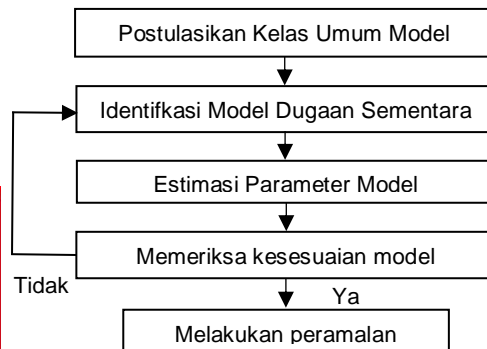
$\theta_Q(B^s) = 1 - \theta_1 B - \theta_1 B^1 - \dots - \theta_Q B^{Qs}$  sebagai koefisien MA musiman  $s$

$(1-B)^d =$  operator *differencing* berordo  $d$

$(1-B^s)^D =$  operator *differencing* musiman  $s$  berordo  $D$

$a_t =$  nilai residual yang memenuhi asumsi *white noise*

Ada beberapa langkah yang diperlukan dalam pemodelan ARIMA menggunakan metode *Box-Jenkins*, seperti yang ditunjukkan pada Gambar 1 di bawah ini (Box dkk., 2008):



Box-Jenkins dalam Pemodelan ARIMA



### a. Identifikasi Model

Menurut Wei (2006), dalam mengidentifikasi model ARIMA dapat dilakukan dengan tiga tahapan, yaitu:

Tahap 1. Melakukan plot data *time series*

Data yang akan digunakan untuk membuat model ARIMA harus stasioner baik dalam varians maupun rata-rata yang bisa dilihat dari hasil plot data *time series*. Jika data tidak stasioner dalam rata-rata, maka dapat dilakukan *differencing* dan data yang tidak stasioner dalam varians diatasi dengan melakukan transformasi.

Proses *differencing* data *time series* adalah proses pengurangan nilai-nilai data *time series* pada periode waktu yang berbeda untuk mendapatkan data yang stasioner. Apabila terdapat *differencing* ordo  $d$  untuk mencapai kestasioneran pada data, secara umum dapat dituliskan dalam persamaan (Box dkk., 2008):

$$\Delta^d Y_t = (1 - B)^d Y_t \quad (3)$$

Jika data yang tidak stasioner dalam varians maka salah satu transformasi yang bisa digunakan adalah transformasi *Box-Cox*. Transformasi untuk suatu parameter  $\lambda$  (*lambda*) menggunakan persamaan berikut:

$$T(Y_t) = \begin{cases} \frac{Y_t^\lambda - 1}{\lambda} & , \lambda \neq 0 \\ \lim_{\lambda \rightarrow 0} \frac{Y_t^\lambda - 1}{\lambda} = \ln(Y_t) & , \lambda = 0 \end{cases} \quad (4)$$

Variansi data dikatakan stasioner jika nilai *lambda* untuk batas bawah dan atas dari data deret waktu mengandung nilai satu. Bentuk transformasi *Box-Cox* untuk beberapa nilai estimasi  $\lambda$  dapat dilihat pada Tabel 1 (Wei, 2006)

**Tabel 1.** Transformasi *Box-Cox*

Nilai $\lambda$	Transformasi
-1.0	$\frac{1}{Y_t}$
-0.5	$\frac{1}{\sqrt{Y_t}}$
0.0	$\ln(Y_t)$
0.5	$\sqrt{Y_t}$

Tahap 2. Memeriksa *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF)



Optimization Software:  
[www.balesio.com](http://www.balesio.com)

tes yang dimiliki dapat dipastikan apakah benar-benar stasioner melihat ACF dan PACF data atau dapat menggunakan *unit root* Fuller (1979) dalam Wei (2006).

ACF dan PACF data yang sudah stasioner dari model AR( $p$ ), MA( $q$ ), ARMA ( $p, q$ ) berdasarkan model ACF stasioner dapat ditentukan dengan cara berikut (Wei, 2006):

**Tabel 2.** Karakteristik ACF dan PACF untuk Model ARMA

Proses	ACF	PACF
AR( $p$ )	<i>Dies down</i>	<i>Cut off</i> pada lag $p$
MA( $q$ )	<i>Cut off</i> pada lag $q$	<i>Dies down</i>
MA( $p, q$ )	<i>Dies down</i> setelah lag ( $q-p$ )	<i>Dies down</i> setelah lag ( $p-q$ )

### b. Estimasi Parameter Model

Untuk mengestimasi nilai parameter dalam model ARIMA, terdapat berbagai macam metode yang bisa digunakan salah satunya adalah metode *least square (LS)*. Metode ini bertujuan untuk meminimalkan *sum square error* (SSE) antara nilai-nilai yang diamati dan nilai-nilai yang diperkirakan oleh model yang digunakan. Setelah diperoleh hasil estimasi parameter model, selanjutnya akan diuji kelayakan dari model yang dimiliki dengan melihat signifikansi dari parameter. Hipotesis dalam pengujian ini adalah:

$$H_0: \phi = 0$$

$$H_1: \phi \neq 0$$

dengan statistik uji yang digunakan adalah uji  $t$

$$t_{hit} = \frac{\hat{\phi}}{s.e(\hat{\phi})} \quad (5)$$

Daerah penolakan  $H_0$  adalah  $|t_{hit}| > t_{\frac{\alpha}{2}; n-n_p}$  dengan  $s.e(\hat{\phi})$  adalah nilai estimasi standar *error* dari  $\phi$ ,  $n_p$  adalah banyaknya parameter dalam model dan  $n$  adalah banyaknya pengamatan.

### c. Diagnostic Check Model Univariat

Setelah melakukan estimasi parameter yang signifikan selanjutnya dilakukan *diagnostic checking* untuk memperoleh model yang paling sesuai dengan melihat apakah asumsi model sudah terpenuhi. Asumsi dasarnya adalah nilai residual  $\{a_t\}$  yang *white noise* dengan  $E(a_t) = 0$  dan  $Var(a_t) = \sigma_a^2$ . Asumsi *white noise* dapat diperiksa menggunakan uji *Ljung-box-pierce* dengan hipotesis berikut (Wei, 2006):

$$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0 \text{ (tidak ada korelasi antar residual)}$$

$$H_1: \text{ada } \rho_k \neq 0 \text{ untuk } k = 1, 2, \dots, K \text{ (ada korelasi antar residual)}$$

dengan statistik uji

$$Q^* = n(n+2) \sum_{k=1}^K \hat{\rho}_k^2 (n-k)^{-1} \quad (6)$$

dengan  $n$  adalah jumlah pengamatan,  $\hat{\rho}_k$  adalah estimasi residual ACF pada lag ke-

$$k \text{ dan } H_0 \text{ adalah } Q^* > \chi_{\frac{\alpha}{2}, (K-p-q)}^2$$

Untuk memenuhi asumsi *white noise*, residual  $\{a_t\}$  juga harus berdistribusi normal. Uji yang digunakan *Kolmogorov-Smirnov* dengan hipotesis:

$$H_0: a_t \text{ (residual berdistribusi normal)}$$

$$H_1: a_t \text{ (residual tidak berdistribusi normal)}$$

Uji yang digunakan yaitu:





$$D = \text{Sup}_x |S(a_t) - F_0(a_t)| \quad (7)$$

dan menolak  $H_0$  jika  $D \geq D_{(1-\alpha, n)}$ , dengan

$S(a_t)$  = fungsi distribusi kumulatif dari data asal

$F_0(a_t)$  = fungsi peluang kumulatif distribusi normal

$\text{Sup}_x$  = nilai supremum (maksimum) semua  $x$  dari  $|S(a_t) - F_0(a_t)|$

### 1.5.2. Analisis Intervensi

Data *time series* bisa saja dipengaruhi oleh suatu kejadian khusus yang dapat mengakibatkan perubahan pola dat. *Time series* dengan kasus seperti ini dapat dianalisis dengan analisis intervensi. Dalam analisis intervensi, selain mengidentifikasi keberadaan intervensi pada waktu tertentu, kita juga dapat mengevaluasi besar dan lamanya efek intervensi pada *time series* yang diamati (Wei, 1990).

#### a. Model Intervensi

Model intervensi adalah model statistik yang digunakan untuk mengidentifikasi dan memperhitungkan efek dari intervensi suatu *time series*. Intervensi bisa berupa perubahan dalam kebijakan, kondisi pasar, atau faktor lain yang mempengaruhi perilaku dari suatu *time series*. Model intervensi memperhitungkan variabel intervensi sebagai variabel penjelas yang mempengaruhi variabel dependent, serta mempertimbangkan perubahan level atau *trend* pada *time series* setelah intervensi terjadi. Model intervensi secara umum dapat ditulis dengan persamaan (Box dkk., 2008):

$$Y_t = \frac{\omega_s(B)B^b}{\delta_r(B)} I_t + n_t \quad (8)$$

Keterangan:

$Y_t$  = variabel respon pada waktu  $t$  (*output series*)

$I_t$  = variabel intervensi pada waktu  $t$  (*input series*)

$b, r, s$  = ordo model intervensi

$n_t$  = error (model ARIMA tanpa pengaruh intervensi)

$\omega_s(B)$  dan  $\delta_r(B)$  merupakan bentuk polinomial dari parameter model intervensi, dengan  $\omega_s(B) = \omega_0 - \omega_1 B - \dots - \omega_s B^s$  dan  $\delta_r(B) = 1 - \delta_1 B - \dots - \delta_r B^r$

Terdapat dua tipe intervensi dalam analisis intervensi *time series*, yaitu *pulse intervention* dan *step intervention*. *Pulse intervention* adalah perubahan yang bersifat satu kali atau terjadi pada waktu tertentu dalam suatu *time series*. Intervensi ini juga dapat disebut sebagai intervensi impulsif atau intervensi sesaat yang dapat ditingkatkan dengan (Wei, 2006):

$$I_t = S_t^T = \begin{cases} 0, & t < T \\ 1, & t \geq T \end{cases} \quad (9)$$



*step intervention* adalah perubahan yang bersifat konstan dan terjadi pada waktu tertentu dalam suatu *time series*, intervensi ini juga dapat disebut sebagai intervensi berkelanjutan yang dapat dinotasikan dengan:

$$I_t = P_t^T = \begin{cases} 0, & t \neq T \\ 1, & t = T \end{cases} \quad (10)$$

Jika jenis intervensi lebih dari satu, maka digunakan model intervensi multiplikatif dengan persamaan:

$$Y_t = \theta_0 + \sum_{j=1}^k \frac{\omega_{sj}(B)B^{bj}}{\delta_{rj}(B)} I_{jt} + n_t \quad (11)$$

dengan  $j = 1, 2, \dots, k$  merupakan jumlah variabel intervensi dan  $\theta_0$  sebagai konstanta serta  $n_t = \frac{\theta(B)}{\phi(B)} a_t$  adalah *error* atau model arima tanpa intervensi.

### b. Model Noise

Model *noise* pada model intervensi merupakan model ARIMA dari deret respon tanpa intervensi, yaitu deret respon sebelum terjadinya intervensi yang dapat dinyatakan sebagai berikut:

$$n_t = \frac{\theta(B)}{\phi(B)} a_t \quad (12)$$

Keterangan:

$\theta(B)$  = parameter moving average (MA)

$\phi(B)$  = parameter autoregressive (AR)

$a_t$  = nilai residual

### c. Identifikasi Ordo

Ordo untuk persamaan umum intervensi yaitu  $b$ ,  $s$ , dan  $r$  dapat diidentifikasi dengan memperhatikan plot residual selisih antara data yang diamati dengan hasil peramalan dengan model *noise* yaitu model ARIMA sebelum intervensi. Nilai  $b$  ditentukan dengan melihat kapan efek intervensi terjadi (nilai residual keluar dari batas  $\pm 3\sigma$ ), nilai  $s$  menunjukkan lamanya intervensi berpengaruh, dan  $r$  menyatakan pola dari efek intervensi (Nuvitasari dkk., 2008). Ordo  $r$  dapat di rumuskan sebagai bentuk *autoregressive*, sedangkan ordo  $s$  sebagai proses *moving average* untuk variable intervensi (Montgomery, 2008).

#### 1.5.3. Model Multivariate Time Series

Model *multivariate time series* dirancang untuk memodelkan dan menjelaskan interaksi serta pergerakan antar beberapa variabel *time series*. Proses pemodelan *multivariate time series* pada dasarnya mirip dengan pemodelan *univariate time series*. Salah satu langkah penting adalah memperhatikan stasioneritas data dalam varians dan rata-rata. Jika data multivariat tidak stasioner dalam varians akan terjadi heteroskedastisitas, sementara jika data tidak stasioner dalam mean akan terjadi drift. Stasioneritas data dapat dievaluasi melalui plot *Matrix Cross Correlation Function* (MCCF) dan *Matrix Partial Cross Correlation Function* (MPCCF) melalui metode *Box-Cox* (Wei, 2006).



### a. Matrix Cross Correlation Function

Jika kita memiliki sebuah vektor *time series* dengan  $n$  pengamatan, yaitu  $Y_1, Y_2, \dots, Y_n$ , maka persamaan untuk MCCF dapat dinyatakan sebagai berikut (Wei, 2006):

$$\hat{\rho}(k) = \hat{\rho}_{ij}(k) \quad (13)$$

dengan  $\hat{\rho}_{ij}(k)$  mewakili korelasi silang sampel antara komponen *series* ke- $i$  dan ke- $j$  dengan persamaan sebagai berikut:

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Y_{i,t} - \bar{Y}_i)(Y_{j,t+k} - \bar{Y}_j)}{\sqrt{\sum_{t=1}^n (Y_{i,t} - \bar{Y}_i)^2 \sum_{t=1}^n (Y_{j,t} - \bar{Y}_j)^2}} \quad (14)$$

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

MCCF digunakan menentukan ordo dalam model *Moving Average* (MA). Namun, seiring dengan peningkatan dimensi vektor, bentuk matriks dan grafik menjadi semakin kompleks. Tiao & Box (1981) kemudian mengenalkan sebuah metode yang tepat untuk menyederhanakan penjelasan korelasi sampel tersebut. Metode ini melibatkan penggunaan simbol (+), (-), dan (.) pada posisi baris ke- $i$  dan kolom ke- $j$  dalam matriks korelasi sampel. Simbol (+) digunakan untuk menunjukkan bahwa nilai sampel korelasi lebih besar dari 2 kali estimasi standar *error*, menandakan adanya hubungan korelasi positif. Simbol (-) digunakan untuk menunjukkan bahwa nilai sampel korelasi kurang dari -2 kali estimasi standar *error*, menandakan adanya hubungan korelasi negatif. Sedangkan simbol (.) digunakan untuk menunjukkan bahwa nilai sampel korelasi berada di antara -2 hingga 2 kali estimasi standar *error*, yang menandakan tidak adanya hubungan korelasi. Suatu data dikatakan stasioner jika plot MCCF menunjukkan hampir semua tanda dengan simbol (.).

### b. Matrix Partial Cross Correlation Function

Dalam analisis *univariate time series*, fungsi autokorelasi parsial digunakan untuk menentukan ordo  $p$  dalam model *autoregressive*. Tiao & Box (1981) kemudian menggeneralisasi konsep PACF ke dalam bentuk *vector time series* sebagai sebuah matriks autoregresi parsial pada lag  $k$  yang dinotasikan sebagai  $\mathcal{P}$ . Dalam regresi linier *multivariate*,  $\mathcal{P}(k)$  sama dengan  $\Phi_{k,k}$  dengan persamaan sebagai berikut (Wei, 2006):

$$\mathcal{P}(k)_t^T = \begin{cases} \Gamma'(1)(\Gamma'(1))^{-1}, & s = 1 \\ [\Gamma'(k) - \mathbf{c}'(k)(\mathbf{A}(k))^{-1}\mathbf{b}(k)][\Gamma'(0) - \mathbf{b}'(k)(\mathbf{A}(k))^{-1}\mathbf{b}(k)], & s > 1 \end{cases} \quad (15)$$

dengan  $\Gamma(k) = \text{cov}(Y_t, Y_{t+k})$

dari  $\mathbf{A}(k), \mathbf{b}(k)$ , dan  $\mathbf{c}(k)$  adalah:

$$\begin{bmatrix} \Gamma(0) & \Gamma'(1) & \cdots & \Gamma'(k-2) \\ \Gamma'(1) & \Gamma(0) & \cdots & \Gamma'(k-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma'(k-2) & \Gamma(k-3) & \cdots & \Gamma(0) \end{bmatrix}, \mathbf{b}(s) = \begin{bmatrix} \Gamma'(k-1) \\ \Gamma'(k-2) \\ \vdots \\ \Gamma'(1) \end{bmatrix}$$



$$c(k) = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(k-1) \end{bmatrix}$$

untuk data dengan model vector AR( $p$ ), maka

$$\mathcal{P}(k)_t^T = \begin{cases} \Phi_p, & k = p \\ 0, & k > p \end{cases} \quad (16)$$

Persamaan matriks parsial autoregresi dalam kasus data multivariat juga memiliki sifat cut-off yang serupa dengan persamaan autokorelasi parsial pada kasus data univariat.

Seperti dalam MCCF, Tiao & Box (1981) juga menggunakan nilai Matrix Partial Cross Correlation Function (MPCCF) untuk mengidentifikasi data dengan menggunakan simbol (+), (-), dan (.). Simbol (+) digunakan untuk menunjukkan nilai MPCCF yang lebih besar dari 2 kali estimasi standar error ( $\hat{\Phi}_p(k)$ ), simbol (-) digunakan untuk nilai yang kurang dari -2 kali estimasi standar error ( $\hat{\Phi}_p(k)$ ), dan simbol (.) digunakan untuk nilai yang berada antara  $\pm 2$  kali estimasi standar error ( $\hat{\Phi}_p(k)$ ).

#### 1.5.4. Model *Generalized Space Time Autoregressive*

Model GSTAR merupakan salah satu model yang sering digunakan dalam memodelkan dan meramalkan data *time series* dan spasial. Model ini merupakan generalisasi dari model *Space-Time Autoregressive* (STAR) yang juga merupakan spesifikasi dari model *Vector Autoregressive* (VAR). Perbedaan utama antara model GSTAR dan model STAR terletak pada asumsi yang digunakan terkait dengan parameter-parameter. Model STAR mengasumsikan bahwa lokasi yang digunakan dalam penelitian adalah sama, sehingga model ini hanya berlaku untuk lokasi yang seragam. Di sisi lain, model GSTAR mengasumsikan bahwa lokasi-lokasi penelitian bersifat heterogen, dan perbedaan antar lokasi ini diwakili oleh matriks pembobot (Borovkova dkk., 2008).

Jika kita memiliki data *time series*  $\{Y(t): t = 0, 1, 2, \dots; i = 1, 2, \dots, N\}$  yang merupakan sebuah *multivariate time series* dengan N pengamatan, maka model GSTAR dengan ordo waktu AR( $p$ ) dan ordo spasial ( $\lambda_1, \lambda_2, \dots, \lambda_p$ ) dapat dinyatakan sebagai GSTAR ( $p, \lambda_1, \lambda_2, \dots, \lambda_p$ ) seperti yang dijelaskan oleh Ruchjana (2002):

$$Y_t = \sum_{k=1}^p \left( \Phi_{k0} Y_{t-k} + \sum_{l=1}^{\lambda_p} \Phi_{kl} W^{(l)} Y_{t-k} \right) + \varepsilon_t \quad (17)$$



ukuran ( $N \times 1$ ) pada waktu  $t$

en parameter waktu ( $diag(\phi_{k0}^{(1)}, \dots, \phi_{k0}^{(N)})$ )

en parameter spasial ( $diag(\phi_{kl}^{(1)}, \dots, \phi_{kl}^{(N)})$ )

embobot berukuran ( $N \times N$ ) pada lag spasial ke- $l$  dengan

syarat  $w_{ii}^{(l)} = 0$  dan  $\sum_{i \neq j} w_{ij}^{(l)} = 1$

$\varepsilon^{(l)}$  = vector galat yang memenuhi *iid* dan berdistribusi normal multivariat

Sebagai contoh, model GSTAR dengan ordo waktu 1 dan ordo spasial 1 pada lokasi yang berbeda, atau GSTAR (1<sub>1</sub>) dapat dinyatakan sebagai berikut sesuai dengan Persamaan (18):

$$Y_t = \Phi_{10} Y_{t-1} + \Phi_{11} W^{(1)} Y_{t-1} + \varepsilon_t \quad (18)$$

Berdasarkan Persamaan (18), model untuk tiga lokasi yang berbeda dapat ditulis sebagai berikut:

$$\begin{aligned} Y_{1,t} &= \phi_{10}^1 Y_{1,t-1} + \phi_{11}^1 w_{12} Y_{2,t-1} + \phi_{11}^1 w_{13} Y_{3,t-1} + \varepsilon_{1,t} \\ Y_{2,t} &= \phi_{10}^2 Y_{2,t-1} + \phi_{11}^2 w_{21} Y_{1,t-1} + \phi_{11}^2 w_{23} Y_{3,t-1} + \varepsilon_{2,t} \\ Y_{3,t} &= \phi_{10}^3 Y_{3,t-1} + \phi_{11}^3 w_{31} Y_{1,t-1} + \phi_{11}^3 w_{32} Y_{2,t-1} + \varepsilon_{3,t} \end{aligned}$$

atau dapat dinyatakan dalam notasi matriks seperti yang ditunjukkan pada persamaan berikut:

$$\begin{aligned} \begin{bmatrix} Y_{1,t} \\ Y_{2,t} \\ Y_{3,t} \end{bmatrix} &= \begin{bmatrix} \phi_{10}^1 & 0 & 0 \\ 0 & \phi_{10}^2 & 0 \\ 0 & 0 & \phi_{10}^3 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix} + \begin{bmatrix} \phi_{11}^1 & 0 & 0 \\ 0 & \phi_{11}^2 & 0 \\ 0 & 0 & \phi_{11}^3 \end{bmatrix} \\ &\quad \begin{bmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31} & w_{32} & 0 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix} \end{aligned} \quad (19)$$

Dalam menentukan ordo model GSTAR, ordo waktu dapat dipilih menggunakan AIC (Wei, 2006), sementara ordo spasial umumnya dibatasi hingga ordo satu karena ordo yang lebih tinggi sulit untuk diinterpretasikan (Wutsqa dkk., 2010). Penentuan ordo model juga dapat dilakukan dengan melihat plot MCCF dan MPCCF yang terbentuk (Wutsqa & Suhartono, 2010). Jika data yang digunakan memiliki pola musiman, maka digunakan model GSTAR musiman. Secara matematis, model GSTAR ( $p; \lambda_1, \lambda_2, \dots, \lambda_p$ )<sup>s</sup> dapat ditulis dalam bentuk sebagai berikut:

$$Y_t = \sum_{k=1}^p \left( \Phi_{k0}^s Y_{t-k} + \sum_{l=1}^{\lambda_p} \Phi_{kl}^{\lambda_p} W^{(l)} Y_{t-k} \right) + \varepsilon_t \quad (20)$$

Untuk model GSTAR dengan ordo musiman 12 dan ordo spasial 1 ditulis dengan persamaan sebagai berikut:

$$Y_t = \Phi_{10}^{12} Y_{t-12} + \Phi_{11}^{12} W^{(1)} Y_{t-12} + \varepsilon_t \quad (21)$$

### Bobot Lokasi

Bobot lokasi merupakan salah satu hal penting dalam pemodelan GSTAR. Pemilihan bobot yang tepat untuk diterapkan pada data deret dianalisis. Suhartono & Atok (2006) menyajikan beberapa bobot lokasi dalam pemodelan GSTAR. Pada penelitian ini bobot lokasi yaitu bobot seragam, invers jarak, dan normalisasi



Bobot lokasi seragam memberikan nilai yang sama untuk setiap lokasi. Penentuan nilai bobot dalam pendekatan bobot lokasi seragam adalah sebagai berikut:

$$w_{ij} = \frac{1}{n_i} \quad (22)$$

dengan  $n_i$  adalah jumlah lokasi yang dekat dengan lokasi ke- $i$ . Sehingga untuk kasus empat lokasi maka matriks pembobotnya adalah:

$$W = \begin{bmatrix} 0 & 1/2 & 1/2 \\ 1/2 & 0 & 1/2 \\ 1/2 & 1/2 & 0 \end{bmatrix}$$

Pada pembobotan yang dilakukan dengan metode invers jarak, bobot dihitung berdasarkan jarak sebenarnya antara lokasi-lokasi di lapangan. Perhitungan bobot dilakukan dengan menggunakan hasil invers dari jarak sebenarnya yang kemudian dinormalisasi:

$$w_{ij} = \frac{\frac{1}{d_{ij}}}{\sum_{j=1}^n \frac{1}{d_{ij}}}, \quad j \neq i \quad (23)$$

Berikut ini adalah jarak lokasi masing-masing 3 kota di Sulawesi Selatan

**Tabel 3.** Jarak antar Tiga Kota di Sulawesi Selatan

Lokasi	Jarak		
	Makassar	Pare-Pare	Palopo
Makassar	0	154.6	372
Pare-Pare	154.6	0	218.8
Palopo	372	218.8	0

Sehingga matriks pembobot yang diperoleh berdasarkan Persamaan (23) adalah

$$W = \begin{bmatrix} 0 & 0.5860 & 0.3703 \\ 0.7064 & 0 & 0.6297 \\ 0.2936 & 0.4140 & 0 \end{bmatrix}$$

Untuk menentukan nilai bobot normalisasi korelasi silang, digunakan hasil normalisasi korelasi silang antara lokasi pada  $lag$  yang sesuai. Penggunaan bobot ini diperkenalkan oleh Suhartono & Atok (2006). Secara umum, korelasi silang antara lokasi ke- $i$  dan ke- $j$  pada  $lag$  waktu ke- $k$  dinyatakan dengan persamaan berikut (Box dkk. 2008):

$$\rho_{ij}(k) = \frac{\gamma_{ij}(k)}{\sigma_i \sigma_j}, \quad k = 0, \pm 1, \pm 2, \dots \quad (24)$$

kovarians silang antara lokasi ke- $i$  dan ke- $j$ . Nilai korelasi silang dalam persamaan:



$$r_{ij}(k) = \frac{\sum_{t=k+1}^T (Y_{i,t} - \bar{Y}_i)(Y_{j,t-k} - \bar{Y}_j)}{\sqrt{\sum_{t=k+1}^T (Y_{i,t} - \bar{Y}_i)^2 \sum_{t=k+1}^T (Y_{j,t} - \bar{Y}_j)^2}} \quad (25)$$

Proses untuk menentukan bobot lokasi dalam model GSTAR(1<sub>1</sub>) dapat dilakukan dengan melakukan normalisasi terhadap hasil korelasi silang antar lokasi pada waktu yang sesuai. Hasil dari proses ini secara umum menghasilkan bobot lokasi sebagai berikut:

$$w_{ij} = \frac{r_{ij}(1)}{\sum_{k \neq 1} |r_{ij}(k)|}, \quad j \neq i \text{ dan } \sum_{k \neq 1} |w_{ij}| = 1 \quad (26)$$

### b. Estimasi Parameter *Generalized Space Time Autoregressive*

Estimasi parameter model GSTAR dengan OLS dapat dilakukan dengan meminimumkan jumlah kuadrat simpangannya (Ruchjana dkk., 2012). Dengan ordo *autoregressive*  $p = 1$  dan ordo spasial  $\lambda_p = 1$ , maka persamaan GSTAR (1<sub>1</sub>) dapat ditulis sebagai berikut:

$$\mathbf{Y}_t = \Phi_{10} \mathbf{Y}_{t-1} + \Phi_{11} W^{(1)} \mathbf{Y}_{t-1} + \boldsymbol{\varepsilon}_t \quad (27)$$

Metode *least square* sering digunakan untuk melakukan estimasi parameter model linier, sehingga metode ini dapat diterapkan pada model GSTAR (1<sub>1</sub>) untuk beberapa lokasi sebagai berikut:

$$\mathbf{Y}_{i,t} = X_i \boldsymbol{\beta}_i + \boldsymbol{\varepsilon}_i \quad (28)$$

dengan  $Y_{i,t}$  adalah banyaknya pengamatan ke- $t$  ( $t = 1, 2, \dots, T$ ) untuk lokasi ke- $i$  ( $i = 1, 2, \dots, N$ ) dan  $\boldsymbol{\beta}_i = (\phi_{i0}^1, \phi_{i1}^1)'$  yang dapat dijabarkan dalam bentuk matriks sebagai berikut:

$$\mathbf{Y} = \begin{bmatrix} Y_{i,t} \\ Y_{i,t} \\ \vdots \\ Y_{i,t} \end{bmatrix}, \quad X = \begin{bmatrix} Y_{i,0} & V_{i,0} \\ Y_{i,1} & V_{i,1} \\ \vdots & \vdots \\ Y_{i,T-1} & V_{i,T-1} \end{bmatrix}, \quad \boldsymbol{\beta} = \begin{bmatrix} \phi_{i0}^1 \\ \phi_{i1}^1 \end{bmatrix}, \quad \boldsymbol{\varepsilon} = \begin{bmatrix} \varepsilon_{i,1} \\ \varepsilon_{i,2} \\ \vdots \\ \varepsilon_{i,T} \end{bmatrix}$$

dimana  $V_i(t) = \sum_{j \neq i} w_{ij} Y_{j,t}$  yang mengindikasikan bahwa  $\beta_i$  dapat dihitung pada masing-masing lokasi tetapi tetap bergantung pada nilai  $Y_t$  di lokasi yang lain. Jika  $\boldsymbol{\beta}_i = (\phi_{i0}^1, \phi_{i1}^1, \phi_{i20}^1, \phi_{i21}^1, \dots, \phi_{iN0}^1, \phi_{iN1}^1)$ , maka Persamaan (28) dapat dijabarkan dalam bentuk matriks yang lebih rinci seperti pada persamaan berikut:

$$\begin{bmatrix} Y_{i,1} \\ Y_{i,2} \\ \vdots \\ Y_{i,T} \end{bmatrix} = \begin{bmatrix} Y_{i,0} & V_{i,0} & \dots & 0 & 0 \\ Y_{i,1} & V_{i,1} & \dots & 0 & 0 \\ \vdots & \vdots & \dots & \vdots & \vdots \\ Y_{i,T-1} & V_{i,T-1} & \dots & 0 & 0 \\ \vdots & \vdots & \dots & \vdots & \vdots \end{bmatrix} \begin{bmatrix} \phi_{i0}^1 \\ \phi_{i1}^1 \\ \vdots \\ \phi_{iN0}^1 \\ \phi_{iN1}^1 \end{bmatrix} + \begin{bmatrix} \varepsilon_{i,1} \\ \varepsilon_{i,2} \\ \vdots \\ \varepsilon_{i,T} \end{bmatrix} \quad (29)$$



nyanya metode OLS mengestimasi parameter  $\beta_i$  dengan kuadrat error dengan cara sebagai berikut:

$$\begin{aligned}
Y &= X\beta + \varepsilon \\
\varepsilon &= Y - X\beta \\
\varepsilon'\varepsilon &= (Y - X\beta)'(Y - X\beta) \\
&= (Y' - \beta'X')(Y - X\beta) \\
&= Y'Y - Y'X\beta - \beta'X'Y + \beta'X'X\beta \\
&= Y'Y - 2\beta'X'Y + \beta'X'X\beta
\end{aligned} \tag{30}$$

Persamaan (30) diturunkan terhadap  $\beta$  menjadi:

$$\frac{\partial(\varepsilon'\varepsilon)}{\partial(\beta)} = -2X'Y + 2X'X\beta \tag{31}$$

Kemudian Persamaan (31) diminimumkan dengan:

$$\begin{aligned}
-2X'Y + 2X'X\beta &= 0 \\
2X'X\beta &= 2X'Y \\
\beta &= (X'X)^{-1}X'Y
\end{aligned}$$

Sehingga diperoleh estimator  $\hat{\beta}$  sebagai berikut:

$$\hat{\beta} = (X'X)^{-1}X'Y \tag{32}$$

### c. Diagnostic Checking Model Multivariat

Uji diagnostik model dilakukan untuk membuktikan bahwa model yang diperoleh layak digunakan peramalan. Sama halnya dengan model univariat, model multivariat memiliki dua asumsi yang harus terpenuhi yaitu sisaan bersifat *white noise* dan berdistribusi normal multivariat. Menurut Wutsqa dkk. (2010), uji asumsi *white noise* dapat dilakukan dengan melihat plot MCCF dari sisaan. Jika tidak terdapat *lag* yang signifikan pada plot MCCF, maka sisaan bersifat *white noise* begitupun sebaliknya.

Pengujian normal multivariat dilakukan dengan mengukur *d-square* pada setiap nilai pengamatan yang dapat dilihat dari plot antara *d-square* dengan nilai *chi-square*. Berikut rumus untuk perhitungan *d-square*:

$$d_t^2 = (e_t - \bar{e})'S^{-1}(e_t - e) \tag{33}$$

dengan

$$e = \frac{1}{T-1} \sum_{t=1}^T (e_t - e)(e_t - \bar{e})' \tag{34}$$

Setelah didapatkan nilai  $d_t^2$  untuk  $t = 1, 2, \dots, T$ , selanjutnya diurutkan dari yang terkecil hingga terbesar. Sisaan dikatakan memenuhi asumsi normal multivariat jika minimal 50% pengamatan mempunyai nilai jarak mahalalanobis  $> \chi_{tabel}^2$ . Pengujian normal multivariat juga dapat dilakukan menggunakan uji Henze Zirkler dengan hipotesis dan statistik uji sebagai berikut (Henze & B. Zirkler, 1990).

$H_0$ :  $e$  berdistribusi  $N_p(\mu, \Sigma)$

distribusi  $N_p(\mu, \Sigma)$

merupakan distribusi normal berdimensi  $p$  dengan mean  $\mu$  dan  $\Sigma$ . Statistik uji yang digunakan dalam uji Henze-Zirkler adalah

$$T^{-1} \sum_{t=1}^T e^{-\frac{\beta}{2} d_t^2} - 2(1 + \beta^2)^{-\frac{p}{2}} \frac{1}{T} \sum_{t=1}^T e^{-\frac{\beta^2}{2(1+\beta^2)} d_t^2} + 2(1 + \beta^2)^{-\frac{p}{2}} \tag{35}$$





dengan

$$\beta = \frac{1}{\sqrt{2}} \left( \frac{n(2p+1)}{4} \right)^{\frac{1}{p+4}} \quad (36)$$

### 1.5.5. Uji Terasvirta

Sebelum memodelkan *time series* secara nonlinier, langkah pertama yang dilakukan adalah melakukan uji linieritas pada data *time series*. Pada penelitian ini, uji nonlinieritas dilakukan menggunakan uji Terasvirta yang dikembangkan oleh Terasvirta (1993) berdasarkan model *neural networks* dan termasuk dalam kelompok uji tipe *Lagrange Multiplier* (LM) yang dikembangkan dengan menggunakan ekspansi *Taylor*. Uji Terasvirta dapat diimplementasikan secara praktis melalui dua statistik uji, yaitu uji  $\chi^2$  atau uji F. Berikut adalah prosedur untuk uji F:

1. Meregresikan  $y_t$  dan  $y_{t-1}, \dots, y_{t-p}$ , kemudian menghitung *sum square error* ( $SSE_0 = \sum \hat{u}_t^2$ ) dimana  $\hat{u}_t = y_t - \hat{y}_t$
2. Meregresikan  $\hat{u}_t$  dan  $y_{t-1}, \dots, y_{t-p}$  dengan  $m$  prediktor tambahan kemudian menghitung  $SSE_1 = \sum \hat{v}_t^2$  dimana  $\hat{u}_t = \hat{\hat{u}}_t - \hat{u}_t$
3. Menghitung  $F = \frac{(SSR_0 - SSR_1)/m}{SSR_1/(n-p-1-m)}$

Model linear dikatakan *neglected nonlinearity* ketika  $H_0$  ditolak dimana  $F_{hitung} > F_{\alpha, m, (n-p-1-m)}$  sehingga perlu dibuat model nonlinear untuk estimasi model yang tepat.

### 1.5.6. Support Vector Regression

*Support Vector Regression* (SVR) adalah sebuah model yang dikembangkan dari SVM untuk melakukan pemodelan regresi menggunakan  $\varepsilon$  - *insensitive loss function* (Gunn, 1998). SVR digunakan untuk menemukan sebuah fungsi  $f(x)$  dengan tingkat kesalahan sekecil mungkin sebagai *hyperplane* (garis pemisah) berupa fungsi regresi yang sesuai dengan semua input data. Misal terdapat set data *training*,  $\{(x_1, y_1), \dots, (x_n, y_n)\}$  dengan  $x_i \in \mathbb{R}^d$ ,  $y_i$  adalah nilai target dan  $d$  adalah dimensi, maka persamaan fungsi *hyperplane* adalah (Smola & Scholkopt, 2004):

$$f(x) = v\phi(x) + b \quad (37)$$

Keterangan:

$v$  = vektor pembobot

$\phi(x)$  = titik didalam *feature space* F, hasil dari pemetaan  $x$  di dalam *input space*

$x$  = vektor data *training*

$b$  = bias

Optimalisasi yang baik pada Persamaan (33), dilakukan pencarian dengan solusi masalah optimasi berikut:

$$\min \frac{1}{2} \|v\|^2 \quad (38)$$

$$f(x) \leq \varepsilon, i = 1, 2, \dots, n$$

$$-y_i \leq \varepsilon, i = 1, 2, \dots, n$$



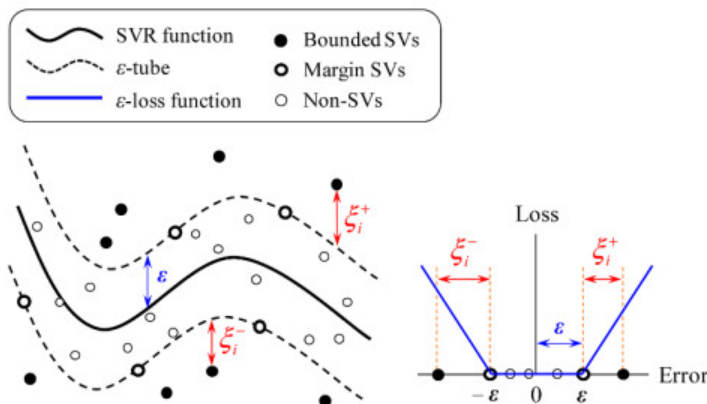
$y_i$  = nilai aktual periode ke  $-i$   
 $\varepsilon$  = margin

Persamaan (38) mengasumsikan semua titik berada dalam rentang  $f(x) \pm \varepsilon$ . Kondisi dimana nilai residual melebihi ambang nilai  $\varepsilon$  diperbolehkan karena ada kemungkinan titik-titik keluar dari rentang  $f(x) \pm \varepsilon$ . Pada kondisi ini dibutuhkan *slack* ( $\xi_i + \xi_i^*$ ), sehingga Persamaan (38) menjadi:

$$\min \frac{1}{2} \|v\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \tag{39}$$

yang memenuhi  $\begin{cases} y_i - f(x) \leq \varepsilon + \xi_i \\ y_i - f(x) \leq \varepsilon + \xi_i^* \\ \xi_i + \xi_i^* \geq 0 \end{cases}$

Konstanta  $C > 0$  adalah nilai penalti terhadap pelanggaran toleransi fungsi  $f(x)$  dan batas margin ( $\varepsilon$ ). Semuan nilai yang lebih besar dari  $\varepsilon$  akan dikenai penalty sebesar  $C$  yang disebut dengan  $\varepsilon - insensitive loss function |\xi_i|_\varepsilon$



**Gambar 2.** Ilustrasi Penambahan *Slack*

Gambar 2 menunjukkan situasi penambahan variabel *slack*. Variabel *slack* yang terletak dalam rentang  $\varepsilon$  akan bernilai nol, semakin jauh jarak variabel *slack* terhadap batas  $\varepsilon$  maka nilainya semakin besar. *Support vector* adalah titik-titik data training yang terletak tepat garis batas dan di luar batas  $\varepsilon$ . Semakin kecil nilai  $\varepsilon$  maka akurasi semakin tinggi, jumlah *support vector* semakin banyak dan nilai variabel *slack* juga semakin tinggi.

Penentuan parameter  $v$  dan  $b$  menjadi masalah pemrograman kuadratik karena meminimumkan fungsi kuadrat dengan syarat suatu pertidaksamaan linear. Masalah ini dapat diselesaikan dengan *Lagrange Multiplier* (LM), sehingga solusi persamaan (39) dapat diselesaikan dengan persamaan berikut (Smola

$$\|v\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \alpha_i (\varepsilon + \xi_i - y_i + f(x_i)) - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i^* - y_i + f(x_i)) - \sum_{i=1}^n (\eta_i \xi_i + \eta_i^* \xi_i^*) \tag{40}$$



**Optimization Software:**  
[www.balesio.com](http://www.balesio.com)

dengan  $\alpha_i, \alpha_i^*, \eta_i, \eta_i^* \geq 0$  merupakan koefisien *lagrange*. Nilai parameter persamaan *hyperplane* yang optimal ditentukan melalui turunan parsial fungsi *lagrange* terhadap  $v, b, \xi_i, \xi_i^*$ , sehingga diperoleh:

Turunan  $L$  terhadap  $v$

$$\begin{aligned}\frac{\partial L}{\partial v} &= v - \sum_{i=1}^n \alpha_i x_i + \sum_{i=1}^n \alpha_i^* x_i \\ 0 &= v - \sum_{i=1}^n (\alpha_i + \alpha_i^*) x_i \\ v &= \sum_{i=1}^n (\alpha_i + \alpha_i^*) x_i\end{aligned}\quad (41)$$

Turunan  $L$  terhadap  $b$

$$\begin{aligned}\frac{\partial L}{\partial b} &= -\sum_{i=1}^n \alpha_i + \sum_{i=1}^n \alpha_i^* \\ 0 &= -\sum_{i=1}^n \alpha_i + \sum_{i=1}^n \alpha_i^* \\ \sum_{i=1}^n \alpha_i &= \sum_{i=1}^n \alpha_i^*\end{aligned}\quad (42)$$

Turunan  $L$  terhadap  $\xi_i$

$$\begin{aligned}\frac{\partial L}{\partial b} &= C - \alpha_i - \eta_i \\ 0 &= C - \alpha_i - \eta_i \\ \eta_i &= C - \alpha_i\end{aligned}\quad (43)$$

Turunan  $L$  terhadap  $\xi_i^*$

$$\begin{aligned}\frac{\partial L}{\partial b} &= C - \alpha_i^* - \eta_i^* \\ 0 &= C - \alpha_i^* - \eta_i^* \\ \eta_i^* &= C - \alpha_i^*\end{aligned}\quad (44)$$

Hasil turunan parsial fungsi *lagrange* terhadap  $v, b, \xi_i, \xi_i^*$  disubstitusikan ke dalam persamaan *lagrange*, sehingga diperoleh persamaan dual untuk masalah optimasi SVR, sebagai berikut:

$$\begin{aligned}L(\alpha_i - \alpha_i^*) &= -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) k(x_i, x_j) - \\ &\quad \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n (\alpha_i - \alpha_i^*)\end{aligned}\quad (45)$$

yang memenuhi  $\sum_{i=1}^n (\alpha_i + \alpha_i^*) = 0$  dan  $\alpha_i + \alpha_i^* \in [0, C]$ . Berdasarkan penurunan rumus yang telah dilakukan, diperoleh persamaan untuk solusi optimal dari kendala estimasi parameter  $v$  dalam bentuk koefisien *lagrange* yaitu  $\alpha_i, \alpha_i^*$ . Solusi permasalahan ini diturunkan dari vektor  $v$  yang disubstitusikan ke dalam fungsi  $f(x)$ , maka dapat ditulis Kembali:

$$v = \sum_{i=1}^n (\alpha_i + \alpha_i^*) x_i \quad (46)$$

dan dari kondisi

$$\alpha_i (\varepsilon + \xi_i - y_i - (v \cdot x) + b) = 0 \quad (47)$$

$$\alpha_i^* (\varepsilon + \xi_i + y_i - (v \cdot x) - b) = 0 \quad (48)$$

$$(C - \alpha_i) \xi_i = 0 \quad (49)$$

$$(C - \alpha_i^*) \xi_i^* = 0 \quad (50)$$



Sehingga estimasi nilai  $b$  dapat diperoleh dari persamaan berikut

$$b = y_i - (v \cdot \phi(x_i)) \quad (51)$$

Selanjutnya substitusikan Persamaan (37) dan Persamaan (46), sehingga diperoleh persamaan baru sebagai berikut untuk persamaan non linier:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) k(x_i, x_j) + b \quad (52)$$

dengan:

$\alpha_i - \alpha_i^*$  = pengali *Lagrange*

$k(x_i, x_j)$  = fungsi kernel

$b$  = konstanta

Fungsi kernel yang sering digunakan pada metode SVR adalah sebagai berikut (Yu dkk., 2006).

**Tabel 4.** Fungsi Kernel

No	Tipe Kernel	Formula
1.	Linear	$k(x_i, x_j) = x_i \cdot x_j$
2.	Polinomial	$k(x_i, x_j) = ((x_i \cdot x_j) + 1)^d$
3.	Fungsi Radial Bebas	$k(x_i, x_j) = \exp(-\gamma  x_i - x_j ^2)$

### 1.5.7. Model Hybrid

Zhang (2003) pertama kali memperkenalkan model *hybrid* dengan tujuan meningkatkan akurasi peramalan. Model *hybrid* menggabungkan komponen linier dan komponen nonlinier yang dapat ditulis secara matematis melalui persamaan berikut:

$$Y_t = L_t + N_t \quad (53)$$

dengan  $L_t$  sebagai komponen linear dan  $N_t$  sebagai komponen nonlinear. Hal pertama yang dilakukan adalah memodelkan data pada *level* satu dengan model linier dan di peroleh residual  $e_t$  sebagai berikut

$$e_t = Y_t - \hat{L}_t \quad (54)$$

dimana  $\hat{y}_t$  merupakan nilai ramalan model linier pada *level* satu. Kemudian  $e_t$  dimodelkan menggunakan model nonlinier pada *level* dua dengan  $p$  input sebagai berikut:

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-p}) + \varepsilon_t \quad (55)$$

dengan  $f$  adalah fungsi nonlinier yang ditentukan oleh model nonlinier dan  $\varepsilon_t$  adalah kesalahan acak. Hasil ramalan Persamaan (55) dinotasikan dengan  $\hat{N}_t$ , sehingga dapat ditulis sebagai berikut

$$\hat{Y}_t = \hat{L}_t + \hat{N}_t \quad (56)$$

hasil ramalan Persamaan (50)



### 1.5.8. Pemilihan Model Terbaik

Evaluasi model dilakukan untuk mengukur kualitas model yang terbentuk berdasarkan residual yang dihasilkan. Kriteria yang digunakan untuk memilih model terbaik adalah AIC untuk evaluasi *training* dan RMSE untuk evaluasi *testing*. RMSE suatu sampel dapat dihitung melalui persamaan:

$$RMSE = \sqrt{\frac{1}{m} \sum_{l=1}^m (Y_{n+l} - \hat{Y}_n(l))^2} \quad (57)$$

dengan  $m$  merupakan banyaknya ramalan,  $n$  merupakan banyaknya data *training*,  $y_l$  menyatakan data *testing* ke- $l$  dan  $\hat{y}_l$  menyatakan data hasil ramalan ke- $l$ . Selain itu, digunakan juga kriteria *Symmetric Mean Absolute Percentage Error* (sMAPE) untuk mengukur persentase kesalahan peramalan. sMAPE dihitung menggunakan rumus berikut ini:

$$sMAPE = \frac{100}{m} \sum_{l=1}^m \frac{|Y_{n+l} - \hat{Y}_n(l)|}{|Y_{n+l}| + |\hat{Y}_n(l)|} \quad (58)$$

dimana  $n$  adalah jumlah data *in sample*

### 1.5.9. Inflasi

Inflasi adalah kenaikan harga barang dan jasa secara umum dan terus menerus dalam jangka waktu tertentu. Kenaikan harga dari satu atau dua barang saja tidak dapat disebut inflasi kecuali bila kenaikan itu meluas atau mengakibatkan kenaikan harga pada barang lainnya (Bank Indonesia, 2023). Berdasarkan penyebabnya, Sukirno (2013) membedakan inflasi menjadi:

1. Tekanan dari sisi permintaan (*Demand Pull Inflation*) terjadi ketika meningkatnya permintaan barang dan jasa terhadap ketersediaannya. Dalam konteks makroekonomi, kondisi ini digambarkan oleh permintaan total (*aggregate demand*) lebih besar dari pada kapasitas perekonomian.
2. Tekanan dari sisi penawaran (*Cost Push Inflation*) terjadi karena peningkatan biaya produksi. Hal ini disebabkan oleh beberapa factor, seperti depresiasi nilai tukar, dampak dari inflasi luar negeri, peningkatan harga komoditas yang diatur pemerintah dan *negative supply shocks* akibat adanya bencana alam atau gangguan distribusi.

Inflasi dihitung menggunakan Indeks Harga Konsumen (IHK) dengan menggunakan *Laspeyres* yang termodifikasi sebagai berikut:

$$Inflasi_t = \frac{IHK_t - IHK_{t-1}}{IHK_t} \times 100\% \quad (59)$$

$$IHK_t = \frac{\sum_{i=1}^g \frac{P_{ti}}{P_{(t-1)i}} P_{(t-1)i} Q_{0i}}{\sum_{i=1}^g P_{0i} Q_{0i}} \quad (60)$$



Keterangan:

$IHK_t$  = Indeks harga konsumen periode ke- $t$

$P_{ti}$  = Harga jenis barang/jasa ke- $i$ , periode ke- $t$

$P_{(t-1)i}$  = Harga jenis barang/jasa ke- $i$ , periode ke- $(t-1)$

$P_{(t-1)i}Q_{0i}$  = Nilai konsumsi jenis barang/jasa ke- $i$ , periode ke- $(t-1)$

$P_{0i}Q_{0i}$  = Nilai konsumsi jenis barang/jasa ke- $i$ , pada tahun dasar

Salah satu upaya yang dilakukan pemerintah untuk menjaga kestabilan inflasi adalah dengan mengeluarkan kebijakan moneter yang dilaksanakan oleh Bank Indonesia. Dalam pelaksanaannya, Bank Indonesia memiliki wewenang melakukan penetapan sasaran moneter untuk menjaga sasaran laju inflasi yang ditetapkan pemerintah.

Kebijakan pemerintah seperti kenaikan harga BBM dan Tarif Dasar Listrik (TDL) dapat memberikan factor *shock* terhadap inflasi. Kenaikan harga BBM atau TDL dapat memicu peningkatan biaya produksi barang dan jasa yang berpotensi meningkatkan tekanan inflasi. Sehingga, kemampuan Bank Indonesia untuk mengendalikan inflasi relatif terbatas apabila terdapat kejutan yang sangat besar ketika terjadi kenaikan harga BBM atau TDL. Oleh karena itu, maka pencapaian sasaran inflasi memerlukan kerja sama dan koordinasi antara Pemerintah dan Bank Indonesia melalui kebijakan makroekonomi yang terintegrasi baik dari kebijakan fiskal, moneter maupun sectoral (Bank Indonesia, 2023).

